

**Exzellenzcluster**  
**Cognitive Interaction Technology**  
Kognitronik und Sensorik  
Prof. Dr.-Ing. U. Rückert

# **Detektion und Analyse physiologischer und biokinematischer Parameter mit Körpersensoren**

zur Erlangung des akademischen Grades eines

**DOKTOR-INGENIEUR (Dr.-Ing.)**

der Technischen Fakultät  
der Universität Bielefeld

genehmigte Dissertation

von

**Dipl.-Inform. Med. Peter Christ**

Referent: Prof. Dr.-Ing. Ulrich Rückert

Korreferent: Prof. Dr.-Ing. Ulf Witkowski

Tag der mündlichen Prüfung: 18.12.2015

Bielefeld / Dezember 2015

DISS KS / 07



## Zusammenfassung

Das Ziel der vorliegenden Arbeit ist die Erfassung von Parametern, die den Gesundheitszustand und die körperliche Leistungsfähigkeit eines Menschen charakterisieren. Typischerweise erfolgt dies im Klinik- oder Laborumfeld mit stationären Messsystemen. Fortschreitende technologische Entwicklungen ermöglichen jedoch die Realisierung von energieeffizienten mikroelektronischen Systemen, die, angebracht am Körper eines Menschen (Körpersensor), eine ergänzende Aufzeichnung über lange Zeiträume, in der natürlichen Umgebung und mit einer Vielzahl von Menschen erlauben. Anwendungsmöglichkeiten bestehen unter anderem in der Sport-, Arbeits- und Präventivmedizin sowie der Rehabilitation.

Die Arbeit liefert Beiträge hinsichtlich der Entwicklung eines Körpersensors. Gegenstand ist die Erweiterung, Aktualisierung und Evaluation der Hardwareplattform sowie die Realisierung von Computerprogrammen zur Analyse und Visualisierung der Daten. Ein Anlegen des Körpersensors ist mit Hilfe eines Brustgurtes ohne Expertenwissen möglich. Dazu wird dieser Vorgang durch einen die Signalqualität überwachenden, computerbasierten Assistenten begleitet.

Darauf aufbauend liegt der Schwerpunkt der Beiträge in der Algorithmenentwicklung zur Bestimmung von Parametern, die die körperliche Aktivität und die physiologischen Reaktionen aus den Sensormesswerten bestimmen. Etablierte physiologische Parameter sind die Herzfrequenz und deren Variabilität. Die dazu nötige Detektion der einzelnen Herzschläge ist mit der entwickelten Hardwareplattform, auch während hoher körperlicher Belastung, mit einer Genauigkeit von 97,9 % möglich. Die hinzugefügte Sensorik zur Messung der Thoraxerweiterung und -verengung ermöglicht eine Atemfrequenzbestimmung, deren mittlere Differenz zu einem Ergospirometriesystem nur  $-0,32 \text{ min}^{-1}$  beträgt. Darüber hinaus erfolgte die Entwicklung einer Gang- und Laufgeschwindigkeitsbestimmung, die fünf Geschwindigkeitsstufen zwischen  $3 \text{ km}^{-\text{h}}$  und  $11 \text{ km}^{-\text{h}}$  aus Beschleunigungsmesswerten mit einer Genauigkeit von bis zu 97,8 % detektiert. Die weiteren biokinematischen Parameter umfassen die Bestimmung des Oberkörperneigungswinkels, die Detektion einzelner Schritte aus den Beschleunigungsmesswerten, die Erstellung von Aktivitätsprofilen sowie die Erkennung unterschiedlicher Sport- und Alltagsaktivitäten. Ferner wird gezeigt, wie sich personenspezifische Charakteristika aus den erfassten Biosignalen extrahieren lassen und in Kombination eine Identifizierung des Trägers des Körpersensors mit einer Genauigkeit von 91,4 % bis 98,1 % ermöglichen. Anwendungen sind die Individualisierung einer Algorithmuskonfiguration sowie Dateninterpretation durch Verwendung von personenspezifischen Zusatzinformationen. Ein Beispiel ist die realisierte Energieumsatzschätzung, die sowohl die Identität der Person als auch die physiologischen und biokinematischen Parameter nutzt. Eine adaptive Parameterauswahl ermöglicht hierbei die Berücksichtigung von Sensorsignalstörungen.

Die Arbeit behandelt zudem die Optimierung des Energiebedarfs der Sensorsignalverarbeitung auf Mikroprozessoren von Körpersensoren. Dazu wurde eine Analyseumgebung geschaffen, die die Durchführung einer Entwurfsraumexploration der Konfigurationsparameter ermöglicht. Bestimmt werden die bezüglich Genauigkeit und Energiebedarf Pareto-optimalen Konfigurationen. Beispielsweise lässt sich auf diese Weise der Energiebedarf für die Geschwindigkeitsbestimmung um den Faktor 20 reduzieren, bei einer Genauigkeitsabnahme von nur 1,7 %.



## Abstract

The aim of this work is the acquisition of information about the health and physical performance of a human. Traditionally, clinical or laboratory environments with stationary measurement equipment are used for this purpose. However, technological advancements facilitate the development of compact, energy efficient microelectronic systems. Attached to the body of a human (body sensor), they allow information to be captured over long periods of time, in the common environment and of many people. Among others, possible applications are found within sport, occupational and preventive medicine as well as rehabilitation.

This work contributes to the development of a body sensor. Covered are the extension, update and evaluation of the hardware platform, along with the realisation of computer programs for the analysis and visualisation of data. The body sensor is attached using a chest strap and the set-up does not require professional expertise. Therefore, this process is supported by the developed computer-based assistant, which monitors the signal quality.

Subsequently, the focus lies on the development of algorithms to derive parameters from the sensor signals, which capture physical activities and the physiological responses. Established physiological parameters are the heart rate and its variability. With the developed hardware platform, the required detection of individual heart beats is possible with an accuracy of 97.9%, even during high physical activity. The added sensor for measuring the thorax expansion and contraction allows the respiration rate to be determined with an average deviation from an ergospirometry system of  $-0.32 \text{ min}^{-1}$ . Furthermore, based on measurements of the acceleration sensor, a detection of walking and running velocities was developed. For the distinction of five velocities between  $3 \text{ km}^{-\text{h}}$  and  $11 \text{ km}^{-\text{h}}$  an accuracy of 97.8% is achieved. Additional derived biokinematic parameters include the determination of the upper body tilt angles, the detection of steps in the acceleration measurements, the creation of activity profiles and the distinction of sport and daily activities. Moreover, it is shown how person-specific characteristics from the acquired biosignals can be extracted and combined to enable an identification of the person wearing the body sensor. The achieved accuracy ranges from 91.4% to 98.1%. Applications include the individualisation of an algorithm's configuration as well as the interpretation of data by providing additional person-specific information. An example is the developed estimation of energy consumption, which requires the identity in addition to the derived physiological and biokinematic parameters. The parameters are therefore selected adaptively with regards to occurring signal disturbances.

This work is further concerned with the optimisation of the energy requirement of the signal processing on microprocessors of body sensors. For this purpose, a software framework was created, which allows a design space exploration of the configuration parameters to be conducted. Determined are the Pareto-optimal configurations in terms of accuracy and energy requirement. Thereby, the energy consumption of, for example, the velocity detection can be reduced by the factor of 20, whilst the accuracy drops by only 1.7%.



# Inhaltsverzeichnis

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>Einleitung</b>   | <b>1</b>  |
| 1.1      | Parameterbestimmung mit Körpersensoren                    | 1         |
| 1.1.1    | Die Begriffe physiologische und biokinematische Parameter | 1         |
| 1.1.2    | Der Begriff Körpersensor                                  | 1         |
| 1.1.3    | Anwendungsszenarien von Körpersensoren                    | 2         |
| 1.1.4    | Verfügbare Körpersensoren im Überblick                    | 5         |
| 1.2      | Motivation und Zielstellung                               | 11        |
| 1.3      | Aufbau der Arbeit   | 14        |
| <b>2</b> | <b>Komponenten eines Körpersensors</b>                    | <b>17</b> |
| 2.1      | Prototyp der AG K&S                                       | 17        |
| 2.1.1    | Körpersensor BG-V4.2                                      | 18        |
| 2.1.2    | Empfänger   | 20        |
| 2.1.3    | Datenvisualisierung                                       | 21        |
| 2.1.4    | Datenakquise  | 23        |
| 2.2      | Sensoren  | 25        |
| 2.2.1    | EKG-Sensor  | 25        |
| 2.2.2    | Atemsensor  | 32        |
| 2.2.3    | Temperatursensor  | 36        |
| 2.2.4    | Inertialsensoren  | 37        |
| 2.3      | Mikrocontroller   | 40        |
| 2.4      | Flash-Speicher  | 42        |
| 2.5      | Drahtlose Kommunikationsschnittstellen                    | 42        |
| 2.5.1    | Stand der Technik   | 43        |
| 2.5.2    | Evaluation des nRF24L01-Transceivers                      | 44        |
| 2.6      | Energieversorgung   | 56        |
| 2.6.1    | Leistungsaufnahme   | 56        |
| 2.6.2    | Energiespeicher   | 58        |
| 2.6.3    | Energy Harvesting   | 60        |
| <b>3</b> | <b>Physiologische Parameter</b>                           | <b>63</b> |
| 3.1      | Herzfrequenz (HF) und Herzfrequenzvariabilität (HFV)      | 63        |
| 3.1.1    | QRS-Detektionsalgorithmus                                 | 63        |
| 3.1.2    | Bestimmung der HF und HFV                                 | 65        |
| 3.2      | Atemfrequenz  | 66        |
| 3.2.1    | Atemzug-Detektionsalgorithmus                             | 66        |
| 3.2.2    | Evaluation Atemfrequenzbestimmung                         | 67        |
| 3.3      | Hauttemperatur  | 70        |
| 3.4      | Zusammenfassung und Ausblick                              | 72        |
| <b>4</b> | <b>Biokinematische Parameter</b>                          | <b>73</b> |
| 4.1      | Exkurs: Klassifikationsverfahren                          | 73        |

|          |  |            |
|----------|--|------------|
| 4.1.1    | Künstliche neuronale Netze . . . . .                           | 73         |
| 4.1.2    | Entscheidungsbäume und Random Forest . . . . .                 | 77         |
| 4.1.3    | Merkmale von MLP, EB und RF . . . . .                          | 79         |
| 4.1.4    | Datenpartitionierung für Evaluation . . . . .                  | 81         |
| 4.1.5    | Gütemaße Sensitivität und Spezifität . . . . .                 | 82         |
| 4.2      | Gang- und Laufgeschwindigkeit . . . . .                        | 83         |
| 4.2.1    | Motivation und Ziele . . . . .                                 | 83         |
| 4.2.2    | Stand der Technik und Forschung . . . . .                      | 84         |
| 4.2.3    | Geschwindigkeitsinformationen in Schrittmustern . . . . .      | 89         |
| 4.2.4    | Verfahrensbeschreibung . . . . .                               | 91         |
| 4.2.5    | Evaluation (Offline-Bestimmung) . . . . .                      | 98         |
| 4.2.6    | Portierung auf das BG-V4.2 . . . . .                           | 105        |
| 4.2.7    | Evaluation (Online-Bestimmung) . . . . .                       | 112        |
| 4.2.8    | Diskussion . . . . .   | 115        |
| 4.2.9    | Zusammenfassung und Ausblick . . . . .                         | 117        |
| 4.3      | Oberkörperhaltung . . . . .                                    | 118        |
| 4.4      | Aktivitätserfassung . . . . .                                  | 119        |
| <b>5</b> | <b>Biosignalbasierte Personenidentifikation</b>                | <b>125</b> |
| 5.1      | Ziele und Anwendungen . . . . .                                | 125        |
| 5.2      | Stand der Forschung . . . . .                                  | 127        |
| 5.2.1    | Gangbasierte Verfahren . . . . .                               | 127        |
| 5.2.2    | EKG-basierte Verfahren . . . . .                               | 129        |
| 5.2.3    | Abgrenzung vom Stand der Forschung . . . . .                   | 130        |
| 5.3      | Personenspezifische Charakteristika . . . . .                  | 130        |
| 5.3.1    | Charakteristika im Gang . . . . .                              | 131        |
| 5.3.2    | Charakteristika im EKG . . . . .                               | 134        |
| 5.4      | Verfahrensbeschreibung Personenidentifikation . . . . .        | 135        |
| 5.4.1    | Vorverarbeitung EKG- und Beschleunigungssignale . . . . .      | 135        |
| 5.4.2    | Merkmalsextraktion . . . . .                                   | 139        |
| 5.4.3    | Konfiguration des Klassifikators . . . . .                     | 146        |
| 5.5      | Evaluation Personenidentifikation . . . . .                    | 146        |
| 5.5.1    | Datenmaterial . . . . .  | 146        |
| 5.5.2    | Ergebnisse Laufbandversuche . . . . .                          | 148        |
| 5.5.3    | Ergebnisse Mannschaftssport . . . . .                          | 153        |
| 5.6      | Zusammenfassung und Ausblick . . . . .                         | 155        |
| <b>6</b> | <b>Anwendungen der Parameter</b>                               | <b>159</b> |
| 6.1      | Energieumsatzschätzung . . . . .                               | 159        |
| 6.2      | Unterstützung externer Trackingverfahren . . . . .             | 163        |
| <b>7</b> | <b>Sensorsignalverarbeitung auf Mikroprozessoren</b>           | <b>165</b> |
| 7.1      | Motivation und Ziele . . . . .                                 | 165        |
| 7.2      | Stand der Forschung eingebetteter Signalverarbeitung . . . . . | 167        |

|          |  |            |
|----------|--|------------|
| 7.3      | CoreVA Mikroprozessor . . . . .  | 170        |
| 7.4      | Analyseumgebung zur Entwurfsraumexploration . . . . .                    | 173        |
| 7.4.1    | Pareto-Optimalität und Entwurfsraumexploration . . . . .                 | 173        |
| 7.4.2    | Parametrisierung der Entwurfsraumexploration . . . . .                   | 174        |
| 7.4.3    | Analyseumgebung . . . . .  | 175        |
| 7.5      | Evaluation der Gang- und Laufgeschwindigkeitsbestimmung . . . . .        | 178        |
| 7.5.1    | Parametrisierung . . . . .   | 178        |
| 7.5.2    | Datenmaterial . . . . .  | 180        |
| 7.5.3    | Ergebnisse . . . . .   | 180        |
| 7.6      | Zusammenfassung und Ausblick . . . . .                                   | 188        |
| <b>8</b> | <b>Zusammenfassung und Ausblick</b>                                      | <b>191</b> |
|          | <b>Abkürzungsverzeichnis</b>   | <b>201</b> |
|          | <b>Symbolverzeichnis</b>   | <b>203</b> |
|          | <b>Literaturverzeichnis</b>  | <b>205</b> |
|          | <b>Eigene Veröffentlichungen</b>   | <b>219</b> |
|          | <b>Betreute Arbeiten</b>   | <b>221</b> |
| <b>A</b> | <b>Datenmaterial</b>   | <b>223</b> |
| A.1      | Verschiedene Geschwindigkeiten Laufband V1 . . . . .                     | 223        |
| A.1.1    | Hauptversuch Laufband V1.1 mit 22 Probanden . . . . .                    | 223        |
| A.1.2    | Versuch Laufband V1.2 mit 9 Probanden . . . . .                          | 225        |
| A.1.3    | Versuch Ergospirometrie V1.3 mit 5 Probanden . . . . .                   | 226        |
| A.2      | Verschiedene Geschwindigkeiten Laufbahn V2 . . . . .                     | 228        |
| A.3      | Handballtrainingsspiel V3 des Soester TV . . . . .                       | 230        |
| <b>B</b> | <b>Erweiterte Ergebnisdarstellung</b>                                    | <b>233</b> |
| B.1      | Gang- und Laufgeschwindigkeitsbestimmung . . . . .                       | 233        |
| B.1.1    | Ergebnisse Laufband V1.1 . . . . .                                       | 233        |
| B.1.2    | Ergebnisse Laufbahn V2 . . . . .   | 234        |
| B.1.3    | Ergebnisse Laufband V1.2 . . . . .                                       | 235        |
| B.2      | Personenidentifikation . . . . .   | 238        |
| B.2.1    | Ergebnisse Laufband V1.2 . . . . .                                       | 238        |
| B.2.2    | Ergebnisse Handballtrainingsspiel V3 . . . . .                           | 239        |
| B.3      | Pareto-optimale Konfigurationen Gang- und Laufgeschwindigkeitsbestimmung | 240        |
| <b>C</b> | <b>Algorithmen</b>   | <b>243</b> |
| C.1      | Entscheidungsbaum Gang- Laufgeschwindigkeitsbestimmung . . . . .         | 243        |



# 1 Einleitung

Dieses Kapitel führt in die Thematik tragbarer körpernaher Sensoren (im Folgenden als Körpersensoren bezeichnet) ein und beschreibt wie sich mit diesen Informationen (Parameter) über den Träger während Alltagsbedingungen erfassen lassen. Die im Folgenden betrachteten Anwendungsmöglichkeiten liegen im Breiten- und Leistungssport, dem Gesundheits- und Lifestylebereich sowie der Medizin und Rehabilitation. Weiterhin sind die Motivation und die Zielsetzung der vorliegenden Arbeit dargestellt und es wird ein inhaltlicher Überblick zu den einzelnen Dissertationskapitel gegeben.

## 1.1 Parameterbestimmung mit Körpersensoren

Technologische Fortschritte und die Fertigung von Bauteilen als mikroelektromechanische Systeme (MEMS) ermöglichen es, miniaturisierte Sensoren am Körper eines Menschen anzubringen, die Parameter erfassen können, ohne dabei den Bewegungsablauf oder die Handlungsfähigkeit einzuschränken. Parameter, die zuvor nur unter Laborbedingungen aufgezeichnet werden konnten, lassen sich auf diese Weise in der natürlichen Umgebung erheben [35; 79].

### 1.1.1 Die Begriffe physiologische und biokinematische Parameter

Als *Parameter*<sup>1</sup> werden im Rahmen der Dissertation Informationen bezeichnet, die sich aus den Signalen von am Körper eines Menschen angebrachten Sensoren ableiten lassen. Ein Beispiel ist die Herzfrequenz, die aus dem Elektrokardiogramm, welches die elektrische Aktivität des Herzmuskels erfasst, bestimmt werden kann. Differenziert wird dabei zwischen physiologischen und biokinematischen Parametern. *Physiologische Parameter* erfassen Informationen zu im menschlichen Körper ablaufenden physiologischen Prozessen. Beispiele sind die Herzfrequenz, der Blutdruck, die Sauerstoffsättigung im Blut, die Atemfrequenz oder die Hauttemperatur. Im allgemeinen Sprachgebrauch ist auch eine Bezeichnung als Vitalparameter geläufig. *Biokinematische Parameter* enthalten hingegen Informationen basierend auf einer Analyse von Körperbewegungen (*Biokinematik*) wie die Orientierung und Bewegung von Gliedmaßen, Körperrumpf und Kopf, die Bestimmung der Fortbewegungsgeschwindigkeit oder Anomalien des menschlichen Gangs.

### 1.1.2 Der Begriff Körpersensor

Als *Körpersensoren* lassen sich Sensorsysteme definieren, die am Körper angebracht, getragen oder im Körper implantiert werden und über eine integrierte Verarbeitungseinheit verfügen. Ein Körpersensor kann dabei über mehrere Sensoren und Aktoren verfügen, die eine benutzerzentrierte Überwachung (Monitoring) und eine Verabreichung von Medikamenten [31] oder Stimulation mit elektrischen, akustischen oder visuellen Reizen ermöglichen [107].

Mehrere Körpersensoren können über (drahtlose) Kommunikationsschnittstellen verbunden zu einem *Körpersensornetzwerk* zusammengeschlossen werden. Das Netz kann dabei aus verschiedenen trag- und implantierbaren Sensoren bestehen, die unterschiedliche Parameter erfassen. Informationen werden dabei entweder direkt ausgegeben oder in Abhängigkeit von

---

<sup>1</sup>Alternative Bezeichnungen sind Kenn- und Messgrößen, die jedoch eher im technischen Umfeld üblich sind.

der verfügbaren Rechenleistung verteilt oder zentral im Körpersensornetz verarbeitet. Weiterhin kann ein Datenaustausch über eine Kommunikationsschnittstelle mit einem externen Computersystem erfolgen [107].

Im Rahmen der Dissertation wurde die Bezeichnung Körpersensor gewählt. Im Deutschen sind weiterhin Begriffe wie körpernahe Sensorsysteme, tragbare Sensoren oder tragbare Gesundheitstechnik geläufig. Im Englischen sind unter anderem die Bezeichnungen *Body Sensors*, *Miniaturized Body Sensor Unit*, *Single Body Central Unit* (für ein zentrales Modul) oder *Wearables (Wearable Computers)* verbreitet. Körpersensornetzwerke werden im Englischen als *(Wireless) Body Sensor Network* oder *(Wireless) Body Area Network* bezeichnet [31; 35; 79; 92].

### 1.1.3 Anwendungsszenarien von Körpersensoren

Während die ersten Schrittzähler den Gang des Trägers durch die Bewegung einer Quecksilberblase oder Metallkugel erfassten, ermöglichen dies heute als mikroelektromechanische Systeme (MEMS) gefertigte Beschleunigungssensoren mit Abmessungen von nur wenigen Mikrometern [35], die in hohen Stückzahlen zu niedrigen Kosten gefertigt werden können [42]. Aufgrund von Fortschritten in den Entwurfs- und Fertigungsverfahren von Sensoren, Mikroprozessoren sowie Speicherbausteinen lassen sich auf diese Weise miniaturisierte, nicht-invasive Körpersensoren realisieren, die mit *low-power* Funktransceivern ausgestattet sind [79]. Die Anbringung solcher Körpersensoren ist dabei komfortabel mittels Bändern, Brustgurten oder integriert in ein Textil möglich. Auf diese Weise ist eine Erfassung von physiologischen und biokinematischen Parametern unter Alltagsbedingungen und in dynamischen Anwendungsszenarien möglich, ohne den Träger des Sensorsystems in seiner Bewegungsfreiheit einzuschränken.

Im Folgenden werden Anwendungsmöglichkeiten von Körpersensoren für die Bereiche Breiten- und Leistungssport, Gesundheit und Lifestyle sowie Medizin und Rehabilitation aufgezeigt.

**Breiten- und Leistungssport** Die Leistungsfähigkeit von Spitzensportlern wird heutzutage, außer von intensivem Training, von Erkenntnissen der Wissenschaft beeinflusst [77]. Mit der Zunahme der Popularität des Leistungssports hat sich auch die unterstützende Industrie vergrößert. Angetrieben, ihre Leistungsfähigkeit weiter zu steigern, sind die Grenzen für Athleten zwischen Gewinnen und Verlieren dabei schmaler geworden [107]. Die Durchführung von leistungsdiagnostischen Untersuchungen erfolgt üblicherweise stationär unter Laborbedingungen, wodurch eine präzise Erfassung von physiologischen und biokinematischen Parametern möglich ist. Laborbedingungen schränken jedoch die Vielfalt der Bewegungsausführungen ein und ermöglichen keine Analyse der Leistungsfähigkeit unter natürlichen Trainings- und Wettkampfbedingungen [77]. Körpersensoren hingegen erlauben die Erhebung einer Vielzahl von Parametern unter natürlichen Umgebungsbedingungen, ohne den Athleten in der Bewegungsausführung einzuschränken.

Sportinstrumente zur Herzfrequenzkontrolle sind bereits seit vielen Jahren im Breiten- und Leistungssport etabliert. Zusätzliche Sensoren zur Geschwindigkeits- und Distanzerfassung ermöglichen es, Trainingseinheiten zu dokumentieren und den Fortschritt zu bewerten.

Darüber hinaus ist der Einsatz von Inertialsensoren zur Überprüfung der Körperhaltung und Bewegungsausführung Gegenstand von Forschungsarbeiten. Beispiele sind die Analyse von Ruderbewegungen, der Schlagausführung im Tennis oder dem Golf sowie der Bewegungstechniken beim Skifahren, Schwimmen, Klettern oder der Kampfkunst *Material Arts* [4; 35; 107]. Eine quantitative Analyse mittels Körpersensoren bietet den Vorteil, dem Athleten Technikverbesserung anschaulich verständlich machen zu können und eine Technikkontrolle auch in Abwesenheit des Trainers durchzuführen [107]. Weiterhin bieten Inertialsensoren die Möglichkeit, sowohl unterschiedliche Alltagsaktivitäten als auch sportliche Betätigungen zu erkennen. Neben der Nutzung zur Abschätzung des Energieumsatzes besteht dabei die Möglichkeit einer automatischen Annotation von Videoaufzeichnungen und Zusammenstellung von Videoszenen mit Highlights [14].

Weitere Anwendungsmöglichkeiten bestehen in der Erfassung von hohen körperlichen Belastungen bei Einsätzen von Streitkräften des Militärs oder von Rettungsmannschaften der Feuerwehr. Körpersensoren bieten die Möglichkeit, auch während des Einsatzes den Gesundheitszustand zu überwachen, um beispielsweise einer Dehydrierung oder Gesundheitsschädigung aufgrund von rauen Umweltbedingungen vorzubeugen oder die Qualität der medizinischen Versorgung im Verletzungsfall (Militäreinsatz) verbessern zu können [35].

**Gesundheit und Lifestyle** Der Gesundheitsbericht (2005) des Robert Koch Instituts betont, wie wichtig regelmäßige Bewegung und körperliche Aktivität für die Lebensqualität und die Aufrechterhaltung von Gesundheit und Wohlbefinden sind. „Durch gezielte Förderung der körperlichen Aktivität lässt sich in jedem Alter der Entwicklung von Krankheiten und Beschwerden entgegenwirken“ [136, S.7]. Die Statistik des Berichts zeigt jedoch eine Lebensweise auf, die zunehmend durch einen Mangel an Bewegung sowie monotonen Bewegungsabläufen geprägt ist.

Miniaturisierte Körpersensoren ermöglichen in diesem Zusammenhang, Parameter im Alltag zu erfassen, die die körperliche Aktivität und die Herz-/Kreislaufbelastung des Trägers im zeitlichen Verlauf quantifizieren. Auf diese Weise bieten sie Einsatzmöglichkeiten im Rahmen von Präventionsmaßnahmen und zur „Selbstbeobachtung“ der eigenen Gewohnheiten. Insbesondere Letzteres wird auch als *Quantified Self-Tracking* (Selbstvermessung) bezeichnet. Dabei erfolgt ein gemeinschaftlicher Informationsaustausch zwischen Menschen bezüglich der erfassten Parameter der eigenen Gesundheit, des Verhaltens und der Umwelt mit dem Ziel, bessere Entscheidungen bezüglich der eigenen Lebensgewohnheiten ableiten zu können<sup>2</sup>. Der Ursprung der Bewegung lässt sich auf G. Wolf und K. Kelly zurückführen, die 2007 die Webseite [quantifiedself.com](http://quantifiedself.com) veröffentlichten und 2008 ein erstes Treffen in der San Francisco Bay Area organisierten. Weltweit sind es inzwischen mehr als 100 Gruppen, die sich bezüglich eines Austauschs von Erfahrungen, Methoden und Technologien zur Erfassung und Auswertung persönlicher Daten (öffentlich) treffen. In Deutschland wurde *Quantified Self* 2012 von F. Schumacher gegründet. Neben dem Einsatz von klassischen Hilfsmitteln zur Datenerfassung wie Zettel, Stift oder Stoppuhr bieten *Smartphones* oder Körpersensoren die Möglichkeit einer automatisierten Erfassung.

---

<sup>2</sup>Informationsquelle ist die deutsche Internetpräsenz von *Quantified Self*: [www.quantified-self.de](http://www.quantified-self.de), letzter Zugriff 01.10.2014.

Insbesondere bei der aktuellen Generation von Körpersensoren zur Analyse der körperlichen Aktivität und des Schlafverhaltens tritt die Elektronik zunehmend in den Hintergrund. Sie lassen sich am Hosenbund oder T-Shirt anstecken, am Handgelenk tragen oder sind in Uhren mit klassischem Design integriert (eine Vorstellung von Produktbeispielen erfolgt im nächsten Abschnitt 1.1.4). Insbesondere Letztere verfügen über ein edles Gehäuse, das sich mittels Wahl eines Uhrenarmbands teils individualisieren lässt. Auf diese Weise wird die Sensorik neben dem Ausdruck einer aktiven Lebensweise (Selbstreflektion und *Work-Life-Balance*) zum Modeaccessoire.

Darüber hinaus bieten Körpersensoren Einsatzmöglichkeiten im Rahmen von *Biofeedback*-Anwendungen, beispielsweise durch eine Analyse von Hautleitwert-, Herz- und Atemfrequenzänderungen [35]. Ein weiterer Bereich ist die Erweiterung des Spielerlebnisses interaktiver Computerspiele mittels Steuerung des Geschehens durch erfasste Körperbewegungen [80]. Körpersensoren bieten in diesem Zusammenhang das Potential, physiologische Informationen, wie beispielsweise die Herzfrequenz, zusätzlich in das Spielgeschehen rückzukoppeln [37].

**Medizin und Rehabilitation** Die Anzahl adipöser Menschen hat sich weltweit seit 1980 verdoppelt. Statistiken der Weltgesundheitsorganisation (WHO) zeigen, dass mehr als 1,4 Milliarden Erwachsene (20 Jahre und älter) übergewichtig sind, wobei 500 Millionen von diesen als adipös (Körpermasseindex  $\geq 30 \text{ kg/m}^2$ ) einzustufen sind <sup>3</sup>. Adipositas steht dabei in direktem Zusammenhang mit einer Vielzahl an Erkrankungen wie beispielsweise Blutdruck, Diabetes Mellitus und Fettstoffwechselstörungen. Darüber hinaus leiden weltweit mehr als 600 Millionen Menschen an chronischen Erkrankungen und es wird erwartet, dass sich die Anzahl an Menschen, die älter als 65 Jahre sind, 2020 verdoppelt und 2050 verdreifacht hat [35]. Körpersensoren ermöglichen in diesem Zusammenhang eine kontinuierliche, ambulante Langzeiterfassung des Zustands eines Patienten im Alltagsleben und grenzen sich dadurch von den traditionellen, episodenhaften Messungen beim Arzt ab, die nur eine Momentaufnahme des Patientenzustands darstellen [107]. Körpersensoren können somit die Versorgungslücke zwischen Arztbesuchen füllen [14] und die Behandlung (das Management) von chronischen Erkrankungen verbessern [79]. Zusätzlich lassen sich auf diese Weise longitudinale Daten vieler Menschen im Zeitverlauf erheben, die für eine Verbesserung von Diagnose und Behandlung eingesetzt werden können [31].

Anwendungsmöglichkeiten bestehen weiterhin in der Überwachung der Rehabilitation von Patienten nach einem Schlaganfall, einem Myokardinfarkt, einem Schädel-Hirn-Trauma und einer Hüft- oder Knieoperation, da derzeit über den Rehabilitationsverlauf im Alltag noch relativ wenig bekannt ist [79]. Darüber hinaus lassen sich Körpersensoren im Zusammenhang mit kardiovaskulären Erkrankungen zur Herz-/Kreislaufüberwachung [107], der Analyse von Bewegungsausführungen mit Prothesen, der Unterstützung von blinden oder tauben Menschen durch Nervenstimulationen oder zur Sicherstellung einer unabhängigen Lebensgestaltung im hohen Alter einsetzen [31].

Im Gegensatz zu stationären Messmethoden mittels beispielsweise Kraftmessplatten oder einer (markerbasierten) optischen Analyse ermöglichen Beschleunigungssensoren eine konti-

---

<sup>3</sup>Internetpräsenz der WHO, Statistiken zu Übergewicht und Adipositas: <http://www.who.int/mediacentre/factsheets/fs311/en/>, letzter Zugriff 21.01.2014.

nierliche Bewegungsanalyse auch außerhalb von Laborumgebungen [42]. Die Erkennung von Gang- und Gleichgewichtsstörungen bei älteren Menschen ist im Hinblick auf eine frühzeitige Therapie zur Sturzprävention wichtig. Klinische Beobachtungen können dabei subjektiv und inkonsistent sein, eine Analyse mit Beschleunigungssensoren ermöglicht es, unterstützend objektive Informationen zu liefern. Weiterhin können sie für die Durchführung von standardisierten Tests eingesetzt werden; Beispiele sind die Überprüfung des Gleichgewichtsinns mittels des Romberg-Tests, das Ablaufen einer geraden Linie oder die Fähigkeit, sicher aufzustehen und sich hinzusetzen [42].

Erkrankungen in höherem Alter stehen häufig in Zusammenhang mit einer verringerten Mobilität im Alltagsleben [42]. In diesem Zusammenhang lassen sich Körpersensoren mit Beschleunigungssensoren für ein ambulantes Aktivitätsmonitoring zur kontinuierlichen, unbeaufsichtigten und objektiven Mobilitätsfassung nutzen [42].

Wichtige internationale Konferenzen und Fachzeitschriften für Körpersensoren sowie die Bestimmung biokinematischer und physiologischer Parameter sind unter anderem IEEE Sensors, IEEE Engineering in Medicine and Biology Society, BIOSTEC BioSignals, IEEE Body Sensor Networks, IEEE Wearable and Implantable Body Sensor Networks, Journal of Applied Physiology und ACSM Medicine & Science in Sports & Exercise.

### 1.1.4 Verfügbare Körpersensoren im Überblick

Der Branchenverband Bitkom prognostiziert für den europäischen Markt ein jährliches Umsatzwachstum von 24 % für Körpersensoren (*Wearables*) und auch die Erwartungen der PricewaterhouseCoopers AG belaufen sich für die Jahre 2014 bis 2018 auf hohe 25,2 % [15, S.20]. Allein für den europäischen Raum bedeutet diese Prognose einen Umsatz von etwa 9 Milliarden Euro im Jahr 2018 (siehe Abbildung 1.1). Im Folgenden wird eine Auswahl an Körpersensoren für die verschiedenen Anwendungsbereiche vorgestellt.

**Breiten- und Leistungssport** Verbreitete Körpersensoren für den Breiten- und Leistungssport sind Herzfrequenzmessgeräte der Firmen Polar, Suunto und Garmin<sup>4</sup>. Diese Sportinstrumente bestehen in der Regel aus einem Brustgurt zur Erfassung der Herzfrequenz und einer Armbanduhr für die Ausgabe von Statistiken der Trainingseinheit (siehe Abbildung 1.2a). Erweitern lassen sich diese Systeme durch einen Fußsensor (engl. *Foot-Pod*) zur Schritterfassung, GPS-Empfänger oder Kraftmesser an der Fahrradkurbel. Mit der *miCoach*-Produktserie bietet Adidas<sup>5</sup> außerdem den *X\_Cell*, der, auf einem Brustgurt angebracht, zusätzlich zu der Herzfrequenz Informationen der Körperbewegung (Sprunghöhe, Wendigkeit und Schnelligkeit) erfassen kann. Für die Erfassung der Herzfrequenz im Mannschaftssport sind von Polar das System *TEAM*<sup>2</sup> und von Suunto der *Team POD* erhältlich. Die Firma Zephyr<sup>6</sup> bietet zusätzlich zu dem vorgestellten *BioPatch* den *BioHarness 3*, der, auf einem Brustgurt oder Funktionsshirt angebracht, für den Einsatz im Sport und Militär geeignet ist. Das System

---

<sup>4</sup>Internetpräsenzen: [www.polar.com/de](http://www.polar.com/de), [www.suunto.com/de-DE](http://www.suunto.com/de-DE) und [www.garmin.com/de-DE/explore/intosports](http://www.garmin.com/de-DE/explore/intosports), letzter Zugriff 09.04.2015.

<sup>5</sup>Internetpräsenz: [http://micoach.adidas.com/de/x\\_cell](http://micoach.adidas.com/de/x_cell), letzter Zugriff 09.04.2015.

<sup>6</sup>Internetpräsenz: [www.zephyranywhere.com/products/bioharness-3](http://www.zephyranywhere.com/products/bioharness-3), letzter Zugriff 09.04.2015.

## 1. Einleitung

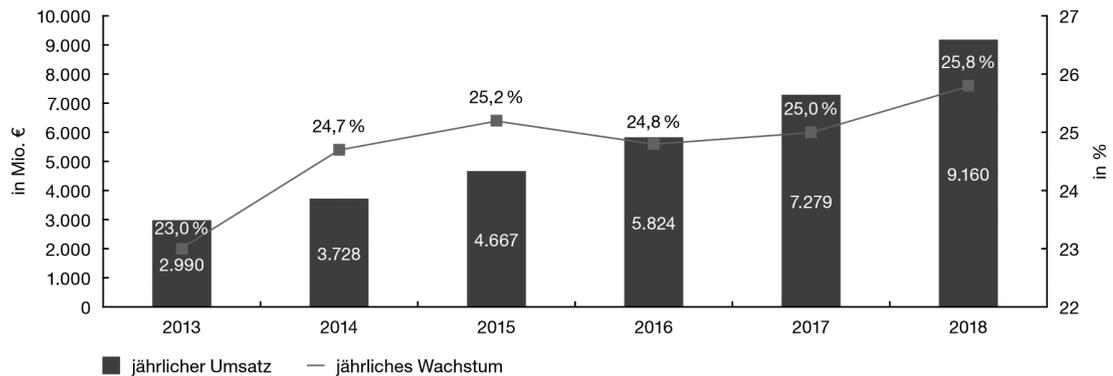


Abbildung 1.1.: Umsatzentwicklung für den Verkauf von *Wearables* in Europa (Quelle: IHS Technology, PwC Analysis, Abbildung aus [15, S.20]).

ermöglicht eine Aufzeichnung und Übertragung der Herzfrequenz, der Atemfrequenz, der Oberkörperhaltung, des Aktivitätslevels und der Spitzenbeschleunigung.

Seit 2013 sind Sportinstrumente (*Mio Alpha*, *miCoach Smart Run* oder *Basis*)<sup>7</sup> verfügbar, die die Herzfrequenz ohne Brustgurt mittels einer Licht emittierenden LED und einem optischen Sensor am Handgelenk ermitteln können. Das eingesetzte Messverfahren (Photoplethysmographie) wird auch von Pulsoxymetern genutzt, die den Pulsschlag und die Sauerstoffsättigung am Finger oder Ohrläppchen erfassen.

Die Firma Reebok bietet den *CHECKLIGHT* an, eine Kopfbedeckung mit integrierter Sensorik der Firma MC10 zur Erkennung von Kopfverletzungen im Sport<sup>8</sup>. Das System kann auch unter einem Helm getragen werden und erfasst die während des Sports auf den Kopf einwirkenden Kräfte. Alarmiert wird visuell mittels eines rot leuchtenden Warnindikators nach beispielsweise einem schweren Aufprall, da ein hierdurch potentiell verursachtes Schädel-Hirn-Trauma dem Sportler während der körperlichen Belastung nicht unmittelbar selbst bewusst sein muss.

Am Imperial College in London wurde der *Sensixa e-AR*<sup>9</sup> entwickelt, der mittels Beschleunigungssensoren biomechanische Signale erfasst [95]. Hierzu wird das System am Außenohr angebracht (siehe Abbildung 1.2d). Es verfügt über Funktionen zur Segmentierung der Beschleunigungssignale in Schritte, zur Detektion von unsicherem Gang und der Erfassung von Spitzenbeschleunigungen. Der e-Ar kann um einen Pulsoxymeter zur Messung der Herzfrequenz und der arteriellen Sauerstoffsättigung erweitert werden.

Das *Functional Assessment of Biomechanics System (F.A.B.)*<sup>10</sup> ist ein ortsunabhängiges Ganzkörper-Kinematik-System, das mit bis zu dreizehn am Körper verteilten angebrachten Sensoren Lageänderungen und den Fußdruck erfasst (siehe Abbildung 1.2e). Die einzelnen Körpersensoren verfügen über Inertial- und Drucksensoren (Füße) und übertragen die

<sup>7</sup>Internetpräsenzen: [www.mioglobal.com](http://www.mioglobal.com) (*Mio Alpha* von Mio), [micoach.adidas.com/de/smartrun](http://micoach.adidas.com/de/smartrun) (*miCoach Smart Run* von Adidas) und [www.mybasis.com](http://www.mybasis.com) (*Basis* von Basis Science), letzter Zugriff 09.04.2015.

<sup>8</sup>Internetpräsenz: [www.mc10inc.com/consumer-products/sports/checklight](http://www.mc10inc.com/consumer-products/sports/checklight), letzter Zugriff 09.04.2015.

<sup>9</sup>Der e-Ar wird inzwischen von der Firma Sensixa geführt (siehe [www.sensixa.com](http://www.sensixa.com), letzter Zugriff 09.04.2015).

<sup>10</sup>Internetpräsenz des Herstellers Biosyn Systems: [www.biosynsystems.net/f-a-b-system](http://www.biosynsystems.net/f-a-b-system), letzter Zugriff 09.04.2015.



Abbildung 1.2.: Beispiele für Körpersensoren mit unterschiedlichen Anwendungsszenarien. Produkte aus dem Breitensport (a), der Sportdiagnostik (b, e), den Bereichen Gesundheit- und Lifestyle (c) und der Forschung (d). Die Produktabbildungen wurden den jeweiligen Internetpräsenzen entnommen (siehe Fußnoten).

Messwerte drahtlos an einen Empfänger. Das System kann zusätzlich um Elektromyogramm (EMG)-Sensoren des Herstellers Noraxon ergänzt werden (siehe Abbildung 1.2b). Ein Anwendungsbeispiel des Systems sind Bewegungsanalysen für körperliche Funktionstests in der Rehabilitation.

**Gesundheit und Lifestyle** Während in der Vergangenheit vornehmlich Körpersensoren zur Herzfrequenz- oder Geschwindigkeitserfassung den Markt bestimmten, werden inzwischen zusätzlich Produkte zur individuellen Überwachung der Gesundheit und körperlichen Aktivität für den Alltagseinsatz vorgestellt. Der Bericht für das Jahr 2014 der jährlichen *Consumer Electronics Show (CES)* in Las Vegas prognostiziert für 2018 einen Absatzanstieg von Produkten in den Bereichen Gesundheit (*Connected Health*) und Lifestyle auf mehr als 70 Mio. Stück für die Vereinigten Staaten von Amerika <sup>11</sup>. Demnach sind 29% der Nutzer von Mobiltelefonen mit Gesundheitsproblemen bereit, einfach anwendbare Geräte einzusetzen,

<sup>11</sup>Consumer Electronics Association (CEA), Comprehensive Report, „The Connected Health and Wellness Market“, Feb. 2014.

um ihren Gesundheitszustand und -fortschritt zu überwachen. Darüber hinaus sind 27 % an einem individualisierten Plan interessiert, um ihre Gesundheit zu verbessern. Der folgende Überblick konzentriert sich auf Körpersensoren zur Überprüfung der eigenen Gesundheit, der körperlichen Aktivität und des Schlafs.

Der *Scanadu Scout*<sup>12</sup> misst, analysiert und speichert den EKG-Signalverlauf, die Herzfrequenz und deren Variabilität, die Sauerstoffsättigung im Blut (Oxymetrie), den Blutdruck, die Hauttemperatur und aus den Parametern abgeleitet den Stresslevel. Das Gerät wird für die Messung zwischen Zeigefinger und Daumen gehalten und an der Schläfe angesetzt<sup>13</sup>. Mit dem *Scanadu Scout* wird angestrebt, es Menschen zu ermöglichen, selbst mehr über ihren eigenen Gesundheitszustand zu erfahren. Unnötige Arztbesuche sollen reduziert werden und Informationen für einen Arztbesuch bereits vorab zur Verfügung stehen. Im Januar 2015 wurden die ersten mittels der Plattform Indiegogo finanzierten Prototypen als *Investigational Devices* ausgeliefert. Das Interesse an portablen, drahtlosen Sensorsystemen zur eigenen Gesundheitsüberwachung spiegelt das hohe erreichte Finanzierungsvolumen von mehr als 1,6 Mio. Dollar und die Ausschreibung des mit 10 Mio. Dollar dotierten Wettbewerbs um den *Tricoder X Prize*<sup>14</sup> wider.

Der *Cosinuss*<sup>15</sup> ist ein Körpersensor, der das Außenohr als Messposition hat und ähnlich wie ein Hörgerät getragen wird. Das System ermöglicht es, kontinuierlich die Herzfrequenz, die arterielle Sauerstoffsättigung und die Körperkerntemperatur zu erfassen und diese über die Funktechniken Bluetooth SMART oder ANT+ beispielsweise an ein Smartphone weiterzugeben. Mögliche Anwendungen des Systems liegen in der Medizin zur Fruchtbarkeitsbestimmung des weiblichen Menstruationszyklus mittels Temperaturmethode (Bestimmung der Basaltemperatur<sup>16</sup>), dem Arbeitsschutz (z.B. Hochofenarbeiter oder Einsatzkräfte der Feuerwehr) und im Sport.

Der *BodyMedia FIT*<sup>17</sup> (siehe Abbildung 1.2c) wird als Armband um den Oberarm getragen und erfasst Körperbewegungen und die Schrittzahl, die elektrodermale Aktivität (EDA), die Hauttemperatur und den Wärmefluss. Der Wärmefluss gibt die Abgabe der vom Oberarmmuskel durch Bewegung produzierten Wärme an die Umgebung an. Die Zielanwendung des Systems liegt im Gewichtsmanagement; dazu ist es möglich, den Energieumsatz im Alltag mit einem Fehler von <10 % zu ermitteln. Weitere Anwendungsmöglichkeiten bestehen im Sport und in der Schlafanalyse.

Zunehmend werden Produkte vorgestellt, die kombiniert Parameter zur körperlichen Aktivität, der Gesundheit und des Schlafverhaltens im Alltag erfassen und analysieren können. Ein Beispiel ist die Armbanduhr *BASIS Peak*<sup>18</sup>, die vom Hersteller als *Health-Tracking Watch* (Uhr zur Verfolgung des Gesundheitszustands) bezeichnet wird. Ausgestattet ist die *BASIS Peak* mit

---

<sup>12</sup>Internetpräsenz: [www.scanadu.com](http://www.scanadu.com), letzter Zugriff 09.04.2015.

<sup>13</sup>Entsprechend der eingangs gewählten Definition eines Körpersensors erfüllt der *Scanadu Scout* jedoch nicht das Kriterium der kontinuierlichen Anbringung.

<sup>14</sup>*Tricoder X Prize* der Firma Qualcomm (siehe [www.qualcommtricorderxprize.org](http://www.qualcommtricorderxprize.org), letzter Zugriff 09.04.2015).

<sup>15</sup>Internetpräsenz des deutschen Start-ups *Cosinuss*: [www.sinuss.com](http://www.sinuss.com), letzter Zugriff 09.04.2015.

<sup>16</sup>Nächtliches Minimum der Körpertemperatur im täglichen Rhythmus (etwa zwischen 3 Uhr und 4 Uhr).

<sup>17</sup>Internetpräsenz: [www.bodymedia.com](http://www.bodymedia.com), letzter Zugriff 09.04.2015.

<sup>18</sup>Internetpräsenz: [www.mybasis.com](http://www.mybasis.com), Verkauf beschränkt auf die Vereinigten Staaten von Amerika, letzter Zugriff 09.04.2015.

einem optischen Sensor zur Messung des Blutflusses, einem Beschleunigungssensor, einem Perspirationssensor (Hautfeuchtigkeitssensor) und einem Temperatursensor. Erfasst werden die Herzfrequenz, die Schweißrate, die Hauttemperatur und Statistiken der körperlichen Aktivität sowie des Schlafverhaltens. Auf Grundlage dieser Parameter wird der Energieumsatz geschätzt und der Nutzer motiviert, die gesteckten Ziele zu erreichen (vom Hersteller als *Body IQ* bezeichnet).

Der *Withings Pulse (Activity Tracker)*<sup>19</sup> wird mittels Clip an der Hosentasche angesteckt und verfolgt die Schrittzahl, die Distanz, das Höhenprofil, die Kalorien und nach dem Auflegen eines Fingers zusätzlich die Pulsfrequenz und die Sauerstoffsättigung im Blut. Die Darstellung der eigenen Aktivität soll den Probanden motivieren, Ziele, wie beispielsweise die Empfehlung der Weltgesundheitsorganisation 10000 Schritte pro Tag zu absolvieren, zu erreichen. Eingeschoben in ein Armband erfolgt nachts eine Schlafanalyse und es werden Hinweise zur Verbesserung der Schlafqualität gegeben. Die erfassten Daten werden drahtlos mittels Bluetooth an ein Smartphone oder Tablet übertragen. Für eine weiterführende Datenanalyse und Kombination mit zusätzlichen Gesundheitsprodukten der Firma Withings ist, wie auch bei anderen Firmen, ein Abgleich mittels eines Internetkontos nötig.

Die Firma Fitbit bietet mit dem *One*<sup>20</sup> ebenfalls einen Aktivitäts- und Schlaftracker, der am Handgelenk oder angesteckt an der Hosentasche oder dem Kleidungsoberteil getragen wird. Die Tagesaktivität wird in Form von Schrittzahl, Wegstrecke, Stockwerkanzahl und aktiven Minuten erfasst und der Energieumsatz (Kalorien) geschätzt. Die Analyse der Schlafqualität umfasst die Schlafdauer und die Häufigkeit des nächtlichen Aufwachens. Morgens wird durch einen stummen Vibrationsalarm geweckt. Die Firma Jawbone bietet den *UP*<sup>21</sup> an, der, am Handgelenk getragen, die körperliche Aktivität (Schrittzahl, Distanz, Dauer und Energieumsatz in Kalorien) im Tagesverlauf und das Schlafverhalten erfasst. Die Schlafanalyse ermöglicht dabei ein sanftes Wecken (*Smart Alarm*) am Morgen oder sie weckt bei einem Mittagsschlaf nach 26,5 erkannten Schlafminuten. Die Daten werden zwecks Darstellung drahtlos (Bluetooth) an ein Smartphone übertragen, da das UP selbst über keine Anzeige verfügt. Mittels Smartphone können zusätzlich das Ess- und Trinkverhalten erfasst werden. Das System warnt bei Inaktivität. Primär soll es jedoch dabei unterstützen, sich selbst zu beobachten, um verborgene Zusammenhänge zu entdecken. Ähnliche weitere Produkte sind das *Fuelband* der Firma Nike oder der *Loop* von Polar<sup>22</sup>.

**Medizin und Rehabilitation** Körpersensoren bieten für diese Bereiche die Möglichkeit, Parameter des Trägers über einen langen Zeitraum von Tagen bis hin zu Wochen aufzuzeichnen, um die Diagnose und Therapie zu unterstützen.

Der *ZioPatch* der US-amerikanischen Firma iRhythm<sup>23</sup> wird dazu, ähnlich wie ein Pflaster, im Brustbereich aufgeklebt. Über integrierte Elektroden ist eine EKG-Aufzeichnung für eine Dauer von bis zu 14 Tagen möglich mit dem Ziel, Arrhythmien im Herzrhythmus durch den

---

<sup>19</sup>Internetpräsenz: [www.withings.com/de/pulse](http://www.withings.com/de/pulse), letzter Zugriff 09.04.2015.

<sup>20</sup>Internetpräsenz: [www.fitbit.com/de/one](http://www.fitbit.com/de/one), letzter Zugriff 09.04.2015.

<sup>21</sup>Internetpräsenz: <https://jawbone.com/up>, letzter Zugriff 09.04.2015.

<sup>22</sup>Internetpräsenzen: [www.nike.com/de/de\\_de/c/nikeplus-fuelband](http://www.nike.com/de/de_de/c/nikeplus-fuelband) und [www.polarloop.com/de](http://www.polarloop.com/de), letzter Zugriff 09.04.2015.

<sup>23</sup>Internetpräsenz: [www.irhythmtech.com](http://www.irhythmtech.com), letzter Zugriff 09.04.2015.

verlängerten Beobachtungszeitraum erkennen zu können. Die Zielgruppe sind Patienten mit Symptomen wie Palpitation, Kurzatmigkeit, Schwindel, Synkope (Kreislaufkollaps), Fatigue-Syndrom (Erschöpfung) oder Angststörungen. Das EKG wird nach der Aufzeichnung in den *iRhythms' Clinical Centers* oder *Independent Diagnostic Testing Facilities* von kardiologischem Fachpersonal ausgewertet und es erfolgt eine Berichtserstellung. Der ZioPatch muss in den USA durch einen Arzt verordnet werden.

Seit 2013 bietet die ebenfalls US-amerikanische Firma Zephyr<sup>24</sup> den *BioPatch (BH3-M1)* an, der mit zwei handelsüblichen selbstklebenden EKG-Elektroden im Brustbereich angebracht wird. Bis zu 24 Stunden lang können ein EKG, die Herzfrequenz, der zeitliche Abstand zwischen Herzschlägen (RR-Abstand), die Atemfrequenz, die körperliche Aktivität und die Körperhaltung aufgezeichnet werden. Eine Anbindung an ein Patientenüberwachungssystem, bestehend aus *ZephyrLIFE Home* und *Hospital*, ermöglicht eine Übertragung der Parameter an eine klinische Einrichtung. Ziel ist es, frühzeitig kritische Veränderungen der Atmung, der Herzfrequenz sowie des -rhythmus zu erkennen, Informationen im Rahmen der Sturz- und Dekubitusprävention zu liefern oder die Behandlung von chronischen Erkrankungen zu unterstützen.

Die Firma BioSensics<sup>25</sup> bietet mit *LEGSys* die Möglichkeit, eine Ganganalyse mit zwei bis vier Körpersensoren, angebracht an Unter- und Oberschenkeln, durchzuführen. Ein weiterer Körpersensor der Firma ist *PAMSys*, der an einer Halskette getragen wird. Möglich ist eine Erfassung der Körperhaltung und von Statistiken des Gangs in Form von Schrittzahl, Ganggeschwindigkeit oder Variabilität der Schrittdauer. Das System kann um eine zusätzliche EKG-Erfassung erweitert werden, die Körperbewegungen während und nach einem abnormalen EKG für Analysezwecke aufzeichnet. Die Firma Philips bietet mit *Lifeline* ein System<sup>26</sup>, das, ebenfalls an einer Halskette getragen, einen Sturz erkennt und automatisch einen Hilferuf absetzt.

Die Firma Shimmer<sup>27</sup> stellt drahtlose Körpersensoren her, die aus einer Hauptplatine mit Energieversorgung bestehen, die um eine Sensorplatine erweitert werden kann. Es sind Sensorplatinen zur Erfassung von Körperbewegungen (Inertialsensor mit 9 Freiheitsgraden), Kräften (Dehnungsmessstreifen), EKG, EMG, EDA oder der Ortsposition (GPS-basiert) verfügbar. Eingesetzt wird das System insbesondere in der Forschung und Lehre für Anwendungen wie der Erkennung von Aktivitäten, Gesten oder Emotionen, der Leistungsdiagnostik im Sport, der Ganganalyse, der Erforschung und Therapie von Parkinson, Epilepsie oder Schlaganfällen.

Die deutsche Movisens GmbH<sup>28</sup>, eine Ausgründung des Karlsruher Instituts für Technologie, bietet ein psychophysiologisches Messsystem zum persönlichen Gesundheitsmanagement an. Der insbesondere für den Forschungseinsatz konzipierte Körpersensor wird auf einem Brustgurt angebracht getragen und ermöglicht eine Langzeitüberwachung von EKG, physiologischen Belastungen, Energieumsatz, körperlichen Aktivitäten, Verhalten und Schlaf.

Die Firma Noraxon vertreibt unter anderem ein mobiles EMG-Telemetriesystem<sup>29</sup>, welches

---

<sup>24</sup>Internetpräsenz: [www.zephyranywhere.com](http://www.zephyranywhere.com), letzter Zugriff 09.04.2015.

<sup>25</sup>Internetpräsenz: [www.biosensics.com](http://www.biosensics.com), letzter Zugriff 09.04.2015.

<sup>26</sup>Internetpräsenz: [www.lifelinesys.com](http://www.lifelinesys.com), letzter Zugriff 09.04.2015.

<sup>27</sup>Internetpräsenz: [www.shimmersensing.com](http://www.shimmersensing.com), letzter Zugriff 09.04.2015.

<sup>28</sup>Internetpräsenz: [www.movisens.com](http://www.movisens.com), letzter Zugriff 09.04.2015.

<sup>29</sup>Internetpräsenz: [www.noraxon.com/emg](http://www.noraxon.com/emg), letzter Zugriff 09.04.2015.

mit mehreren, verteilt am Körper angebrachten EMG-Sensoren die elektrischen Aktivitäten von Skelettmuskeln aufzeichnen und drahtlos übertragen kann (siehe Abbildung 1.2b). Anwendungen umfassen Analysen von Muskelaktivierungen, Symmetrie- und Koordinationstests sowie Biofeedback-Training von dysfunktionalen Muskelgruppen.

## 1.2 Motivation und Zielstellung

Im Folgenden werden die Problemstellung und die Motivation der vorliegenden Arbeit beschrieben, gegliedert für die drei betrachteten Bereiche Entwicklung des Körpersensors, Bestimmung physiologischer und biokinematischer Parameter sowie Sensorsignalverarbeitung auf Mikroprozessoren.

**Körpersensor** Im Vergleich zu Messsystemen für den Einsatz im Klinik- oder Laborumfeld stellen sich für einen Körpersensor abweichende Anforderungen. Hinsichtlich Nutzerakzeptanz und Verwendung während Alltagsbedingungen sind eine kompakte Größe, niedriges Gewicht und lange Betriebsdauer des Körpersensors entscheidende Faktoren [79]. Dabei ist eine Auswahl von Komponenten mit besonders niedrigem Energiebedarf von hoher Bedeutung, um möglichst kleine Energiespeicher einsetzen zu können. Weiterhin sind die Art und Anzahl aktiver Sensoren entsprechend den Anforderungen des Anwendungsszenarios auszuwählen. In diesem Zusammenhang kann es nötig sein, den Sensorinformationsgehalt zu reduzieren, um die jeweils nötige Aufzeichnungsdauer bei dennoch hohem Tragekomfort zu erreichen [36]. Hinsichtlich Nutzerakzeptanz und Praxistauglichkeit sind eine einfache Anbringung und Handhabung des Körpersensors von Bedeutung, dabei sollte keine Präparation oder Positionierung des Körpersensors durch einen Experten nötig sein.

Der Körpersensor der AG K&S erfüllt mittels seines kompakten, stoßsicheren und wasserdichten Gehäuses diese wesentlichen Voraussetzungen. Für eine einfache Handhabung erfolgt die Anbringung aufgesteckt auf einen Brustgurt oder ein Funktions-T-Shirt, wie sich dies bereits für die Erfassung der Herzfrequenz im Breiten- und Leistungssport etabliert hat. Die Energieversorgung ist mit einer handelsüblichen und vom Benutzer austauschbaren Knopfzelle realisiert. Die Komponenten des Körpersensors und dessen Funktionalität (z.B. Einstellungen zur Aufzeichnung und Parameterbestimmung) lassen sich über Konfigurationsparameter an unterschiedliche Einsatzszenarien anpassen. Die Eigenentwicklung der AG K&S ermöglicht dabei einen freien Zugriff auf die Hardware- und Softwarekomponenten des Körpersensors. Im Rahmen der Dissertation bestand das Ziel, aufbauend auf der Version 4.0 (siehe Abschnitt 2.1.1), Hard- und Softwarekomponenten des Körpersensors zu erweitern, zu aktualisieren und zu evaluieren:

1. Erweiterung der physiologischen Sensoren zwecks Erfassung der Atemfrequenz für die Messposition Brustbereich.
2. Auswahl und Integration eines Beschleunigungssensors mit einem erweiterten Messbereich für die Erfassung von Spitzenbeschleunigungen, beispielsweise von Schrittmustern.
3. Erweiterung um einen Flash-Speicher für eine lückenlose Aufzeichnung von Sensor-

messwerten und Parametern unabhängig vom Empfangsbereich der drahtlosen Kommunikationsschnittstelle.

4. Evaluation des nRF24L01-Transceivers zur drahtlosen Kommunikation von Sensormesswerten und Parametern. Bestimmung der möglichen Datenrate und der Anzahl parallel einsetzbarer Sender.
5. Spezifikation und Implementierung geeigneter Übertragungs- und Speicherformate für unterschiedliche Anwendungs- und Laufzeitanforderungen.
6. Realisierung von Softwarekomponenten zur Darstellung und Analyse der Sensormesswerte und Parameter.

**Parametererkennung** Die Komplexität des menschlichen Körpers, hochdynamische Körperbewegungen im Alltag oder beim Sport und der Einfluss von (stark wechselnden) Umgebungsbedingungen stellen hohe Anforderungen an die Verarbeitung der Sensormesswerte eines Körpersensors [31; 77; 107]. Für die Biosignalerfassung mit einem Körpersensor bestehen dabei im Gegensatz zu Messsystemen des Klinik- oder Laborumfelds Einschränkungen, beispielsweise bezüglich der Anbringung und der Übertragungseigenschaften der Sensorik (Leitfähigkeit von EKG-Elektroden, Anpressdruck eines Atemsensors oder Ausrichtung eines Beschleunigungssensors). Weiterhin enthalten die Signalverläufe Störungen elektromagnetischer Einstreuungen oder Bewegungsartefakte mit variabler Intensität. Darüber hinaus führen unterschiedliche anatomische Gegebenheiten zwischen Menschen zu interindividuellen Variabilitäten und es treten Veränderungen in den Signalverläufen in Abhängigkeit von der „Tagesform“ auf.

Zunächst erfolgte im Rahmen der vorliegenden Arbeit eine Überprüfung, welche physiologischen und biokinematischen Parameter sich im Brustbereich zusätzlich zu der mit dem Körpersensor in der Version 4.0 erfassbaren Herzfrequenz und Hauttemperatur bestimmen lassen. Als geeignete Parameter wurden die Atemfrequenz, die Gang- / Laufgeschwindigkeit, die Oberkörperhaltung und die körperliche Aktivität ausgewählt. Für die Entwicklung der entsprechenden Verfahren bedurfte es zunächst einer Betrachtung der jeweils relevanten Störgrößen und Variabilitäten der Sensormesswerte, um eine diesbezüglich robuste Parameterbestimmung realisieren zu können. Weiterhin bestand die Motivation, zu prüfen, ob interindividuelle Charakteristika in den Signalverläufen für eine Identifikation des Trägers des Körpersensors geeignet sind. Die Ziele liegen in einer Nutzung für eine automatisierte Annotation von Sensormesswerten mit der Identität des Trägers und der Optimierung der Sensorsignalverarbeitung durch individuelle Einstellungen. Auf Grundlage der physiologischen und biokinematischen Parameter sowie der Identität erfolgte weiterhin eine Betrachtung, wie diese Informationen in Kombination die Bestimmung einer übergeordneten Größe wie des Energieumsatzes verbessern können. Für die Evaluation der realisierten Erkennungsalgorithmen konnte nicht auf Benchmark-Datensätze zurückgegriffen werden, sodass es notwendig war, entsprechende Versuche mit Probandenkollektiven durchzuführen. Im Rahmen der vorliegenden Arbeit stellten sich zusammenfassend die folgenden Ziele:

1. Evaluation und Optimierung der Herzfrequenz- und Hauttemperaturbestimmung für verschiedene körperliche Belastungsstufen.
2. Realisierung einer Atemfrequenzbestimmung auf Grundlage von Kraftmessungen der Thoraxerweiterung und -verengung.
3. Realisierung einer Gang- / Laufgeschwindigkeitsbestimmung mittels eines Beschleunigungssensors im Brustbereich.
4. Portierung der Geschwindigkeitsbestimmung auf den Mikrocontroller des Körpersensors und Analyse des Ressourcenbedarfs.
5. Realisierung einer Oberkörperneigungswinkelbestimmung auf Grundlage eines dreiaxialen Beschleunigungssensors.
6. Realisierung einer Aktivitätserfassung basierend auf einem Beschleunigungssensor.
7. Realisierung einer Personenidentifikation anhand von personenspezifischen Charakteristika in EKG- und Beschleunigungssignalen.
8. Evaluation der Parameterbestimmungen während leichter bis hoher körperlicher Belastung mit Probandenkollektiven.
9. Nutzung der Parameter als Grundlage für übergeordnete Größen wie der Bestimmung des Energieumsatzes.

**Sensorsignalverarbeitung auf Mikroprozessoren** Kompakte Abmessungen und ein geringes Gewicht eines Körpersensors stellen wichtige Voraussetzungen bezüglich dessen Tragekomforts und Praxistauglichkeit dar. Erreichen lassen sich diese durch den Einsatz von Komponenten mit einem besonders niedrigen Energiebedarf und einer Verkürzung der Aktivzeit von Komponenten mit einem hohen Energiebedarf, wie dem Mikrocontroller oder dem Transceiver eines Körpersensors [35; 79]. Die Realisierung einer ressourceneffizienten Sensorsignalverarbeitung entsprechend der Anwendungsanforderungen stellt dabei die Grundlage dar und ermöglicht eine lokale Datenverarbeitung sowie eine Reduktion der drahtlos zu kommunizierenden Informationen. Klassifikationsalgorithmen, wie sie in der vorliegenden Arbeit für die Parameterbestimmungen eingesetzt werden, verfügen über eine Vielzahl an Konfigurationsparametern, die deren Klassifikationsgenauigkeit und Ressourcenbedarf (Taktzyklen- und Speicheraufwand) beeinflussen. Darüber hinaus ist zu prüfen, wie die jeweils vorliegende Mikroprozessorarchitektur und die vorhandenen Funktionseinheiten im Rahmen der Implementierung effizient genutzt werden können. Für die Realisierung einer Parameterbestimmung auf einem Körpersensor mit einem stark begrenzten Energiebudget sind daher eine Vielzahl an Konfigurationsmöglichkeiten hinsichtlich ihrer Eignung zu prüfen (Entwurfsraumexploration).

Im Rahmen der vorliegenden Arbeit wurde dazu eine Analyseumgebung realisiert, die es erlaubt, automatisiert den Einfluss einer Konstellation unterschiedlicher Konfigurationsparameter bezüglich der Zielgrößen Klassifikationsgenauigkeit und Taktzyklenaufwand (Energiebedarf) zu untersuchen. Die Analyseumgebung soll auf diese Weise die Realisierung einer

Sensorsignalverarbeitung auf Mikroprozessoren unterstützen, der Schwerpunkt liegt auf Klassifikationsalgorithmen zur Parameterbestimmung. Es stellten sich dazu die folgenden Ziele:

1. Realisierung einer Analyseumgebung zur Entwurfsraumexploration von Anwendungen zur Sensorsignalverarbeitung auf Mikroprozessoren.
2. Durchführung einer Entwurfsraumexploration der Gang- / Laufgeschwindigkeitsbestimmung für den CoreVA-Mikroprozessor der AG K&S als exemplarische Zielplattform. Exploration der Konfigurationsparameter Sensoranzahl, Aufzeichnungsfrequenz, Merkmalsraum, Klassifikatortyp und dessen Konfiguration sowie von Eigenschaften der Hardwarearchitektur des CoreVA-Mikroprozessors. Bestimmung der Pareto-optimalen Konfigurationen bezüglich erzielter Genauigkeit und Taktzyklenaufwand (Energiebedarf).
3. Ermittlung einer geeigneten Konfiguration für die Portierung der Geschwindigkeitsbestimmung auf den CoreVA-Mikroprozessor.

### 1.3 Aufbau der Arbeit

Die vorliegende Arbeit ist wie folgt aufgebaut.

**Kapitel 2** führt zunächst den Begriff Körpersensor ein und stellt deren verschiedene Komponenten vor. Einleitend wird zunächst ein Überblick über den Körpersensor der AG K&S gegeben, der, in der sich anschließenden Vorstellung von typischen Komponenten, vertieft wird. Betrachtet werden dabei Sensoren für die Erfassung von physiologischen und biokinematischen Parametern, Mikrocontroller, Flash-Speicher, drahtlose Kommunikationsschnittstellen und Energieversorgungsmöglichkeiten. Bezüglich drahtloser Kommunikationsschnittstellen werden die Ergebnisse der Evaluation des nRF24L01-Transceivers von Nordic Semiconductor in statischen und dynamischen Funkszenarien vorgestellt.

**Kapitel 3** beschreibt Verfahren zur Bestimmung von physiologischen Parametern mit dem Körpersensor der AG K&S. Zunächst wird der eingesetzte QRS-Detektionsalgorithmus vorgestellt, der für die Ermittlung der Herzfrequenz und deren Variabilität auf Grundlage des Einkanal-EKGs genutzt wird. Weiterführend wird die entwickelte Atemfrequenzerkennung und deren Evaluation im Rahmen eines Stufenbelastungstests erläutert, für die ein Ergospirometrysystem als Referenz eingesetzt wurde. Abschließend erfolgt ein Ausblick auf potentielle Anwendungsmöglichkeiten des Parameters Hauttemperatur.

**Kapitel 4** beschreibt die Bestimmung von biokinematischen Parametern aus Beschleunigungsmessungen im Brustbereich. Eingesetzt werden dazu unter anderem Klassifikationsalgorithmen, sodass zunächst die nötigen Grundlagen bezüglich der Klassifikatoren mehrschichtiges Perzeptron, Entscheidungsbaum und Random Forest gegeben werden. Darüber hinaus erfolgt eine Gegenüberstellung der drei Klassifikatoren und eine Vorstellung der für

die Evaluation genutzten Methoden zur Datenpartitionierung sowie der verwendeten Gütemaße zur Bewertung der Klassifikationsergebnisse. Der Schwerpunkt liegt anschließend auf der Beschreibung der entwickelten Bestimmung der Gang- / Laufgeschwindigkeit aus Schrittmusterinformationen in Beschleunigungssignalen. An die Verfahrensbeschreibung schließen sich die Ergebnisse der Evaluationen an, die auf Laufbändern und einer Laufbahn im Außenbereich durchgeführt wurden. Weiterhin wird die Portierung der Geschwindigkeitsbestimmung auf den Körpersensor der AG K&S erläutert. Als weitere biokinematische Parameter werden die Bestimmung der Oberkörperhaltung und die Aktivitätserfassung mittels Beschleunigungssensoren beschrieben.

**Kapitel 5** stellt die entwickelte biosignalbasierte Personenidentifikation anhand von personenspezifischen Charakteristika des Gangstils und des EKG-Signalverlaufs vor. Im Anschluss an die Erläuterung der dazu nötigen Grundlagen und des Stands der Forschung folgt die Verfahrensbeschreibung. Die Ergebnisdarstellung umfasst die Evaluation der Identifikation im Rahmen verschiedener Laufbandversuche und des Mannschaftssports Handball.

**Kapitel 6** beschreibt die Nutzung der physiologischen und biokinematischen Parameter sowie der Identitätsinformation zur Bestimmung des Energieumsatzes. Zunächst erfolgt dazu eine Vorstellung von Modellen der Energieumsatzschätzung anhand der unterschiedlichen Parameter. Im Anschluss wird die in der AG K&S entwickelte Energieumsatzschätzung, die unterschiedliche Informationsquellen kombiniert und die Signalqualität berücksichtigt, vorgestellt. Darüber hinaus wird die Anwendung der Parameter für ein ganzheitliches Aktivitätsmonitoring und für eine Unterstützung externer Trackingverfahren beschrieben.

**Kapitel 7** behandelt die Sensorsignalverarbeitung auf Mikroprozessoren. Zunächst erfolgt ein Überblick zum Stand der Forschung eingebetteter Signalverarbeitung. Im Anschluss wird der CoreVA-Mikroprozessor der AG K&S vorgestellt, der exemplarisch als Zielplattform für die Sensorsignalverarbeitung gewählt wurde. Anschließend wird die entwickelte Analyseumgebung beschrieben, die eine Entwurfsraumexploration der Implementierung der Sensorsignalverarbeitung hinsichtlich erzielter Genauigkeit und benötigtem Taktzylenaufwand unter Berücksichtigung der Mikroprozessorarchitektur ermöglicht. Im Anschluss erfolgt die Ergebnisdarstellung der exemplarisch durchgeführten Entwurfsraumexploration für die Gang- / Laufgeschwindigkeitsbestimmung und es wird eine Konfiguration für eine zukünftige Portierung auf den CoreVA-Mikroprozessor vorgestellt.

**Kapitel 8** fasst die einzelnen Beiträge zusammen und gibt einen Ausblick.



## 2 Komponenten eines Körpersensors

Das folgende Kapitel beschreibt Komponenten, die für die Realisierung eines Körpersensors nötig sind. Zunächst wird in dem Abschnitt 2.1 der Körpersensor der AG K&S vorgestellt. Die folgenden Abschnitte 2.2 bis 2.6 geben einen Überblick bezüglich des Stands der Technik von Sensoren, Mikrocontrollern, Speichern und drahtlosen Kommunikationsschnittstellen sowie der Leistungsaufnahme und möglicher Energiespeicher. In dem Kapitel wird dabei stets Bezug auf den Körpersensor der AG K&S genommen.

### 2.1 Prototyp der AG K&S

M. Chen u.a. benennen als wichtige Eigenschaften eines Körpersensors, dass dieser komfortabel getragen werden kann, keine besonderen Erfahrungen in der Vorbereitung benötigt und keine akkurate Positionierung bei der Anbringung erfordert [35]. Diese Eigenschaften stellen eine grundlegende Motivation im Rahmen der vorliegenden Arbeit dar.

**Anforderungen Körpersensor** Bei der Entwicklung des Körpersensorprototyps wurde das Ziel verfolgt, mit nur einem Körpersensormodul physiologische und biokinematische Parameter erfassen zu können. Als Messposition bietet insbesondere der Brustbereich die Möglichkeit, die elektrische Aktivität des Herzmuskels und die Atemtätigkeit in Form von Thoraxerweiterungen und -verengungen messen zu können. Zusätzlich zu diesen wichtigen physiologischen Parametern lassen sich mittels eines Beschleunigungssensors die körperliche Aktivität des Trägers und die Oberkörperhaltung erfassen. Eine praxistaugliche Anbringung des Körpersensors ist dabei durch einen Brustgurt gewährleistet. Für den Einsatz im Sport und im Alltag ist die Verwendung eines kompakten, robusten und ergonomischen Gehäuses von Bedeutung. Diese Anforderungen begrenzen jedoch das Volumen und das Gewicht des einsetzbaren Energiespeichers. Eine wichtige Funktionalität stellt weiterhin eine drahtlose Kommunikationsschnittstelle dar, um Messsignale und Parameter online auf einem externen Gerät ausgeben zu können. Die Möglichkeit der parallelen Datenerfassung von mehreren Körpersensoren ist beispielsweise im Mannschaftssport von Bedeutung.

**Motivation Prototypentwicklung** Die erste Version des Körpersensorprototyps wurde in der Fachgruppe Schaltungstechnik des Heinz Nixdorf Instituts der Universität Paderborn entwickelt [163, S.80]. Seit 2010 wird die Entwicklung in der AG K&S der Universität Bielefeld fortgeführt. Gründe für die Eigenentwicklung eines Körpersensors liegen in der freien Auswahl von Sensoren, Mikrocontrollern, Speichern, Transceivern und Bauteilen der Energieversorgung. Dabei lassen sich einzelne Komponenten modular gestalten, etwa in Form eines austauschbaren Erweiterungsmoduls (engl. *Daughterboard*). Ein Beispiel ist das Modul für die drahtlose Kommunikationsschnittstelle zur Evaluation verschiedener Transceiver. Weiterhin ist eine freie Auswahl der Sensoren hinsichtlich Messbereich, Qualität und Energiebedarf möglich. Der Zugriff auf die Hardware ermöglicht außerdem eine Anbindung zusätzlicher Sensoren an freie Schnittstellen zu einem späteren Zeitpunkt. Im Rahmen der vorliegenden Arbeit war insbesondere die Möglichkeit der freien Programmierung des Mikrocontrollers von Bedeutung, um eine Sensorsignalverarbeitung implementieren und evaluieren zu können. Der Zugriff auf die Betriebssoftware ermöglicht weiterhin, geeignete Frequenzen für die

Abtastung der Sensoren, die Datenaufzeichnung und -kommunikation entsprechend den Anforderungen einer Anwendung auszuwählen. Zusätzlich ist auf diese Weise eine Anpassung des Messbereichs oder des Verstärkungsverhaltens der Sensoren sowie des Paketformats für die Speicherung oder Kommunikation möglich.

### 2.1.1 Körpersensor BG-V4.2

Dieser Abschnitt stellt den Körpersensor der AG K&S vor. Zusätzliche Informationen zu den einzelnen Komponenten werden in den folgenden Abschnitten 2.2 bis 2.6 gegeben. Bezeichnet wird der Körpersensor als Brustgurtmodul (BG)-*V<sub>i</sub>*, wobei *i* die Versionsnummer angibt [163, S.80].

Im Rahmen der vorliegenden Arbeit kamen die Versionen V4.1 und V4.2 in den durchgeführten Versuchen zum Einsatz. Die Version 4.1 wurde im ersten Quartal 2010 realisiert. Die Ergebnisse der weiterführenden Evaluation, Aktualisierung und Erweiterung von Komponenten flossen in die Version 4.2 ein, deren Fertigung erfolgte im zweiten Quartal 2011. Das BG-V4.1 verfügt über Sensoren zur Messung eines Einkanal-EKGs und der Hauttemperatur. Das BG-V4.2 (siehe Abbildung 2.1) ermöglicht darüber hinaus, die Atemtätigkeit als Ausdehnung und Verengung des Thoraxes zu erfassen. Auf dem BG-V4.1 ist der dreiaxiale Beschleunigungssensor LIS3LV02DL [138] der Firma STMicroelectronics integriert, der eine Messung entlang der drei Körperebenen (siehe Abbildung 2.7) mit einem maximalen Messbereich von  $\pm 6$  g ermöglicht<sup>1</sup>. Für die Erfassung von Spitzenbeschleunigungen beim Einsatz im Sport und der Messung an den Extremitäten wurde für das BG-V4.2 der Beschleunigungssensor LIS331HH [137] (STMicroelectronics) mit einem erweiterten konfigurierbaren Messbereich von  $\pm 6$  g bis  $\pm 24$  g gewählt. Die Sensorsignale werden mit einer Wortbreite<sup>2</sup> von 12 b abgespeichert. Die Abtast- und Aufzeichnungsfrequenz der Sensoren ist anpassbar.

Die Ausführung der Betriebssoftware sowie die Erfassung und die Verarbeitung der Sensorsignale erfolgen auf einem 16 b Mikrocontroller, dem MSP430FG4618 [76] der Firma Texas Instruments. Zusätzlich ist ein 8 b ATmega88 [38] der Firma Atmel für die Steuerung der drahtlosen Kommunikationsschnittstelle integriert. Der zweite Mikrocontroller ermöglicht weiterhin eine Aktualisierung des Programmspeichers des MSP430FG4618 über Funk [186, Kap.4].

Die drahtlose Kommunikationsschnittstelle selbst ist als ein austauschbares Erweiterungsmodul mit einem nRF24L01-Transceiver [118] der Firma Nordic Semiconductors realisiert. Betrieben wird der Transceiver in dem 2,4 GHz Frequenzband mit einer Sendeleistung von 0 dBm. Die Kommunikation erfolgt über eine Chip-Antenne mit einer maximalen Verstärkung von +0.5 dBi. Für die Übertragung wurde als Trägerfrequenz 2,482 GHz eingestellt, eine Frequenz im Außenbereich des 2,4 GHz bis 2,5 GHz *Industrial Scientific Medical (ISM)* Bands (siehe auch Evaluation des nRF24L01-Transceivers in Abschnitt 2.5.2). Auf dem Erweiterungsmodul befindet sich zusätzlich ein ATmega88-Mikrocontroller, der die drahtlose Kommunikation steuert und diese dem MSP430FG4618 über eine vom Transceiver unabhängige Schnittstelle verfügbar macht. Die Paketsendefrequenz und das Paketformat können

---

<sup>1</sup>Angabe der Beschleunigung als Lastvielfaches der Erdbeschleunigung  $g$  mit  $1 g = 9,80665 \text{ m} \cdot \text{s}^{-2}$  (Normfallbeschleunigung).

<sup>2</sup>In der vorliegenden Arbeit steht das Einheitskürzel „b“ für Bit und „B“ für Byte.

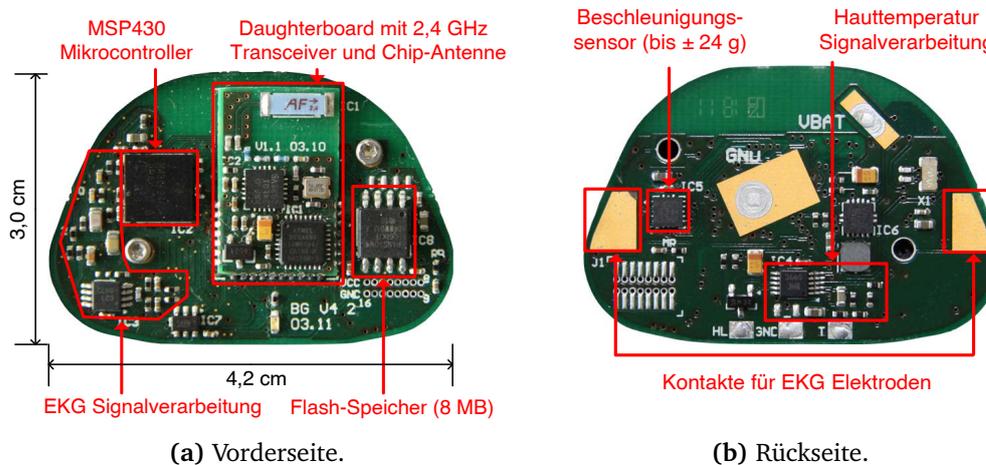


Abbildung 2.1.: Fotoaufnahme der bestückten Platine des BG-V4.2.

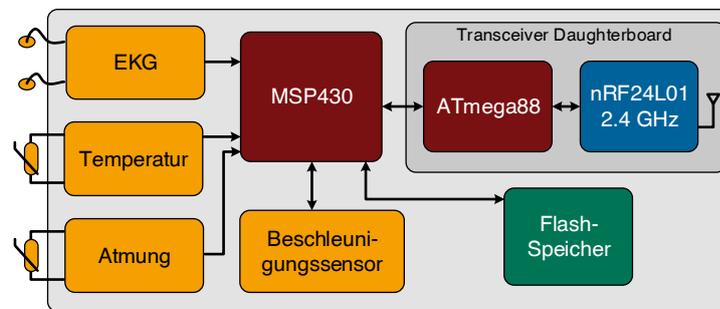


Abbildung 2.2.: Technisches Blockschaltbild des BG-V4.2.

abhängig vom Anwendungsszenario angepasst werden.

Das BG-V4.2 verfügt zusätzlich über einen 8 MB großen Flash-Speicher (Spansion S25FL0-64K), der eine Aufzeichnung auch außerhalb des Empfangsbereichs (z.B. im Außenbereich) oder bei einem gestörten Funkkanal<sup>3</sup> ermöglicht. Dadurch können in diesen Szenarien die Sensorsignale auch bei einer hohen Aufzeichnungsfrequenz lückenlos gespeichert werden. Die Abbildung 2.2 zeigt das BG-V4.2 mit den beschriebenen Komponenten als technisches Blockschaltbild.

Die Energieversorgung erfolgt über eine CR2025-Knopfzelle (Primärzelle, nicht wiederaufladbar) mit einer Kapazität von etwa 140 mAh bis 170 mAh bei 3 V. Möglich ist die Programmierung der beiden Mikrocontroller und das Auslesen des Flash-Speichers drahtgebunden über einen Adapter, der auf die Platine aufgesteckt wird. Weiterhin kann dies auch über die drahtlose Kommunikationsschnittstelle erfolgen [186, Kap.4].

<sup>3</sup>Ein Beispiel ist die Aufzeichnung (V3) im Mannschaftssport mit 42 BG-V4.2 in einer Sporthalle, siehe Anhang A.3.



(a) Empfänger.



(b) Entwicklungsboard und Konfigurationsmenü des Empfängers.

Abbildung 2.3.: Empfänger mit integriertem nRF24L01-Transceiver und einer +9 dBi-Antenne. Das prototypische Gehäuse hat die Maße: L120 x B70 x H35 mm<sup>3</sup>. Die Konfiguration erfolgt über das Steuerkreuz mit einem integrierten Taster.

### 2.1.2 Empfänger

Für den Empfang von Daten mehrerer Körpersensoren wurde ein Empfänger (siehe Abbildung 2.3a) mit einer USB-Schnittstelle für die Anbindung an einen Computer realisiert. Der Empfänger basiert auf dem Entwicklungsboard MSP430-4619-LCD [98] der Firma Olimex LTD (siehe Abbildung 2.3b), an welches der nRF24L01-Transceiver angeschlossen ist. Eingesetzt wird eine Rundstrahlantenne für den 2,4 GHz Frequenzbereich mit einer Verstärkung von +9 dBi. Die Kommunikation mit dem Computer erfolgt mittels eines seriellen USB-zu-UART<sup>4</sup>-Wandlers (FT232R von FTDI<sup>5</sup>).

Die Konfiguration des Empfängers erfolgt über ein Steuerkreuz mit vier Richtungen und einem integrierten Taster. Unter anderem können die Anzahl an Adress- und Paketbytes, die zu nutzende Trägerfrequenz im 2,4 GHz bis 2,5 GHz ISM-Band sowie die Überprüfung der Werte der Paketbytes durch einen zweiten *Cyclic Redundancy Check* (CRC) eingestellt werden. Die integrierte Anzeige gibt die Konfiguration und Statistiken zu den empfangenen Paketen aus.

Ein Paket besteht aus den vom Körpersensor versendeten 20 Datenbytes und einem Zeitstempel (vier Bytes), der auf Seiten des Empfängers nach Erhalt hinzugefügt wird. Eine Echtzeituhr (engl. *Real-Time Clock*, RTC) mit einer Frequenz von 32768 Hz misst die seit dem Start des Empfängers verstrichene Zeit. Die Datenbytes umfassen eine eindeutige Identifikationsnummer des Körpersensors (KS-ID), Konfigurationsinformationen (z.B. Abtast- und Paketsendefrequenz), einen Paketzähler, Sensormesswerte sowie Parameter und eine

<sup>4</sup>UART: *Universal Asynchronous Receiver Transmitter*.

<sup>5</sup>Technische Produktinformationen siehe [www.ftdichip.com/Products/ICs/FT232R.htm](http://www.ftdichip.com/Products/ICs/FT232R.htm), letzter Zugriff 22.06.2014.

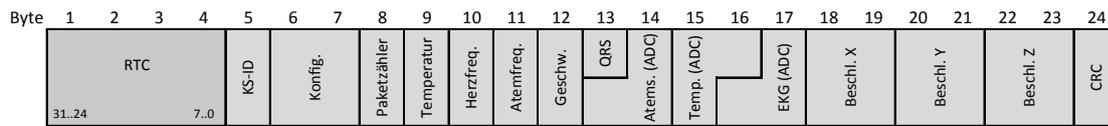


Abbildung 2.4.: Paketaufbau für die drahtlose Kommunikation zwischen BG-V4.2 und dem Empfänger. Die ersten vier Bytes (RTC) enthalten einen Zeitstempel, der auf der Empfängerseite hinzugefügt wird.



Abbildung 2.5.: Signalmonitor zur Online-Darstellung von Sensormesswerten und Parametern.

CRC-Prüfsumme (Paketaufbau siehe Abbildung 2.4, Stand 18.02.2014).

### 2.1.3 Datenvisualisierung

Eine visuelle Darstellung der Sensormesswerte und der Parameter ist online mit dem im Rahmen dieser Arbeit realisierten Visualisierungsprogramm *Signalmonitor* möglich (siehe Abbildung 2.5). Die Funktionalität umfasst unter anderem:

- Anzeige des Einkanal-EKGs, der Beschleunigungssignale (dreiaxial) sowie des Kraftverlaufs der Thoraxausdehnung und -verengung.
- Anzeige der abgeleiteten physiologischen und biokinematischen Parameter: Herz- und Atemfrequenz, Hauttemperatur und Oberkörperneigung (Neigungswinkelangaben für *Pitch* und *Roll* in Grad sowie visualisiert als Avatar).
- Gleichzeitige Darstellung der Daten von zwei Körpersensoren.
- Speicherung der Daten von mehreren Körpersensoren (entsprechend der Kapazität des Funkkanals) in Dateien.

- Bereitstellung der Daten über den *Robotics Service Bus* (RSB) <sup>6</sup>.

Für die Darstellung und Analyse von aufgezeichneten Datenreihen wurde der *Aktivitätsmonitor* (siehe Abbildung 2.6) mit folgender Funktionalität realisiert:

- Darstellung von Sensormesswerten, physiologischen und biokinematischen Parametern sowie dem abgeleiteten Energieumsatz (Angabe in Kilojoule pro Minute und als relativer Leistungsumsatz, siehe Abschnitt 6.1) im zeitlichen Verlauf. Markierung von Sensormesswerten mit signifikanten Störungen, die keine zuverlässige Parameterbestimmung sicherstellen.
- Ausgabe von Statistiken zu Sensormesswerten und Parametern (vollständige Datenreihe oder Bereichsauswahl).
- Verwaltung von verschiedenen Personen und Datenreihen.
- Laden von Aufzeichnungen aus einer Datei oder dem Flash-Speicher des Körpersensors.
- Schnittstelle zur Einbindung von Funktionen für die Bestimmung zusätzlicher Parameter.
- Datenexport von Sensormesswerten, Parametern, Konfigurations- und Personeninformationen.

Realisiert wurden der Signal- und der Aktivitätsmonitor in der Programmiersprache C++ mit der plattformübergreifenden Softwarebibliothek QT <sup>7</sup>.

---

<sup>6</sup>Datenaustausch mittels RSB, siehe <https://code.cor-lab.de/projects/rsb> (letzter Zugriff 21.04.2014). Die RSB-Anbindung wurde im Rahmen der Projektarbeit [183] realisiert.

<sup>7</sup>QT Version 5, Internetpräsenz <http://qt-project.org>, letzter Zugriff 22.06.2015.

Informationen zur Person und Datenreihen      Sensorwerte und Parameter im zeitlichen Verlauf      Statistiken zu Sensorwerten und Parameter

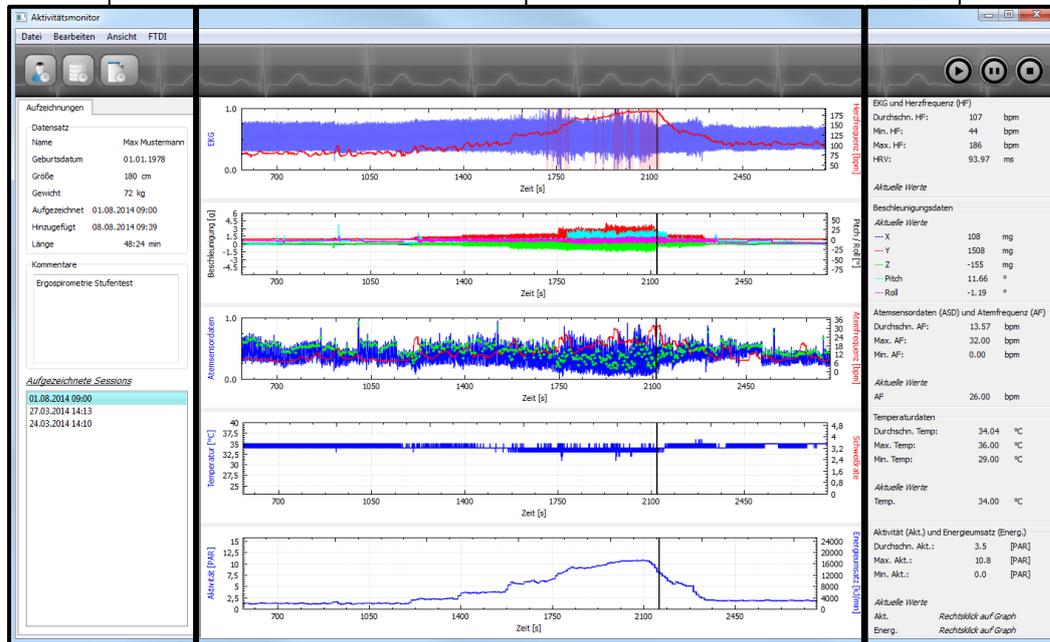


Abbildung 2.6.: Aktivitätsmonitor zur Offline-Analyse von Sensormesswerten und Parameter.

## 2.1.4 Datenakquise

Der Körpersensor ist primär für die Anbringung im Brustbereich vorgesehen, um ein Einkanal-EKG, die Thoraxausdehnung und -verengung bedingt durch die Atemtätigkeit, die Hauttemperatur und die Beschleunigungen resultierend aus körperlicher Aktivität erfassen zu können. Die Anbringung erfolgt mit Druckknopfverbindungen auf einem elastischen Brustgurt mit integrierten EKG-Elektroden. Die Bezeichnung der im Brustbereich (Sternum) erfassten Beschleunigungen erfolgt entlang von drei zueinander orthogonal angeordneten Achsen. Diese werden durch jeweils zwei Schnittpunkte der drei definierten Körperebenen des Menschen gebildet: der Sagittal-, der Transversal- und der Frontalebene (siehe Abbildung 2.7). Im Rahmen dieser Arbeit werden die Achsen mit den folgenden Abkürzungen bezeichnet: AP (anteroposterior, Sagittalachse), ML (mediolateral, Transversalachse) und V (vertikal, Längsachse der Frontalebene). Darüber hinaus sind weitere Anbringungsstellen des Körpersensors möglich. Für die Messung an den Extremitäten (oberhalb von Sprung- und Handgelenk) wurden dazu „Taschen“ in die Innenseiten von Schweißbändern eingenäht, in die die BG-V4.2 eingeschoben werden können (siehe Abbildung A.3).

Die Speicherung der Daten erfolgt über den Signalmonitor (drahtlose Kommunikation) oder den internen Flash-Speicher des BG-V4.2. Für die Aufzeichnung in den Flash-Speicher wurden zwei Paketformate mit unterschiedlichen Aufzeichnungsfrequenzen definiert, die

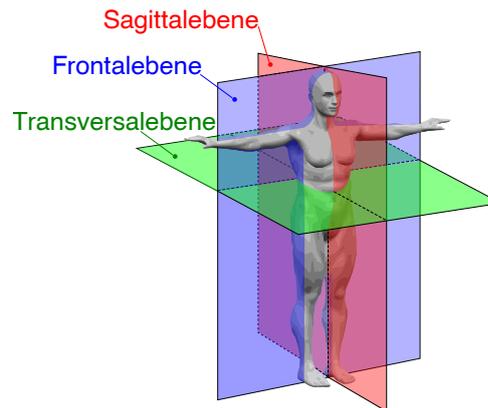


Abbildung 2.7.: Körperebenen des Menschen (Bildquelle [112]).

eine Langzeit- und eine Kurzeiterfassung ermöglichen. Die Langzeiterfassung eignet sich dabei unter anderem für ein Aktivitätsmonitoring im (Arbeits-) Alltag. Gewählt wurde dazu eine Aufzeichnungsfrequenz von 25 Hz, um die QRS-Komplexe im EKG identifizieren und körperliche Aktivitäten in den Beschleunigungssignalen voneinander abgrenzen zu können. Die dazu nötigen Wortbreiten betragen:

- EKG ADC-Wert (10 b) und Herzfrequenz (8 b)
- Hauttemperatur (6 b)
- Atemkurve ADC-Wert (10 b) und Atemfrequenz (6 b)
- Drei Beschleunigungswerte (3 x 8 b)

Pro Datenpaket fallen 64 b an, die mit 25 Hz gespeichert werden (1600 b/s). Dies entspricht einer Aufzeichnungsdauer von 11 h 39 min. Mit einer deaktivierten Funkkommunikation ist eine entsprechende Betriebsdauer des BG-V4.2 möglich; geprüft wurde dies für Modul 62 unter Verwendung einer CR2025-Knopfzelle mit einer Kapazität 170 mAh der Firma Renata Batteries.

Der Modus für die Kurzeitaufzeichnung erfolgt mit einer höheren Frequenz von 100 Hz sowie einer vergrößerten Wortbreite und erlaubt dadurch die Erfassung von Details der Sensorsignale. Ein Anwendungsszenario ist die Personenidentifikation oder die Durchführung einer EKG- oder Ganganalyse. Aufgrund der erhöhten Anzahl an zu schreibenden Bits pro Sekunde wurde zunächst der maximale Entladungsstrom für CR2025-Knopfzellen phasenweise überschritten und es traten Paketverluste auf. Dies wurde durch einen Kondensator mit höherer Kapazität ausgeglichen, der Paketzähler wird zur Kontrolle weiterhin im Paketformat behalten. Das Datenpaket umfasst 104 b und hat folgenden Aufbau:

- Paketzähler (7 b)
- EKG ADC-Wert (12 b), Erkennung QRS-Komplex (1 b) und Herzfrequenz (8 b)

- Hauttemperatur (8 b)
- Atemkurve ADC-Wert (12 b) und Atemfrequenz (8 b)
- Drei Beschleunigungswerte (3 x 16 b)

Es ergibt sich eine Datenrate von 10400 b/s, sodass eine Aufzeichnung über einen Zeitraum von 1 h 48 min möglich ist. Für die Unterstützung des Nutzers beim Anlegen des Messsystems wurde ein Assistent realisiert, der die Signalqualität des EKGs, der Atemkurve und die Ausrichtung des Beschleunigungssensors analysiert und dem Nutzer entsprechende Korrekturhinweise ausgibt [185, S.39f]. Die Übertragung der Daten des Flash-Speichers kann mittels eines Programmieradapters oder drahtlos über den nRF24L01-Transceiver erfolgen [186, Kap.4].

Für die weiterführende Datenaufbereitung nach der Aufzeichnung sind im Rahmen der vorliegenden Arbeit Funktionen zur Datenpartitionierung, Annotation, Signalfilterung, Merkmalsberechnung, Training und Evaluation von Klassifikatoren realisiert worden.

## 2.2 Sensoren

Im folgenden Abschnitt werden Grundlagen der Sensoren zur Messung von EKG, Atmung (Thoraxausdehnung und -verengung), Hauttemperatur und körperlicher Aktivität vorgestellt; es wird jeweils Bezug auf den Körpersensor BG-V4.2 genommen. Die Signale der vorgestellten Sensoren bilden die Grundlage für die Bestimmung der in den Kapiteln 3 und 4 vorgestellten physiologischen und biokinematischen Parameter. Ausgewählt wurden Sensoren, die Messungen im Brustbereich ermöglichen und in einen Körpersensor, wie dem BG-V4.2, integriert werden können. Darüber hinaus wären Anbindungen von Sensoren für beispielsweise die Erfassung der Sauerstoffsättigung im Blut, des Blutdrucks, eines Elektromyogramms (EMGs) oder Elektroenzephalogramms (EEGs) realisierbar; geeignete Messpositionen befinden sich dazu an den Extremitäten und am Kopf.

### 2.2.1 EKG-Sensor

Das Elektrokardiogramm (EKG) ist ein nichtinvasives Verfahren zur Aufzeichnung der elektrischen Erregungsvorgänge des Herzmuskels im zeitlichen und örtlichen Verlauf [89, S.113].

#### 2.2.1.1 Grundlagen

Erste Potentialschwankungen des menschlichen Herzens erfasste 1887 A. D. Waller mit einem Lippman-Kapillar-Elektrometer. W. Einthoven verbesserte Anfang des 20. Jahrhunderts das Messverfahren für die Nutzung in der klinischen Diagnose. Die periodischen Potentialschwankungen bezeichnete er mit den Buchstaben P, Q, R, S und T [19]. Weitere wichtige Ableitungskonfigurationen entwickelten F. N. Wilson (1934) und E. Goldberger (1942).

**Das Erregungssystem** Der Herzmuskel benötigt wie die Skelettmuskeln einen elektrischen Impuls, der die Kontraktion auslöst. Im Unterschied zu den Skelettmuskeln verfügt das Herz über ein autonomes Erregungssystem. Das zentrale Nervensystem hat nur einen

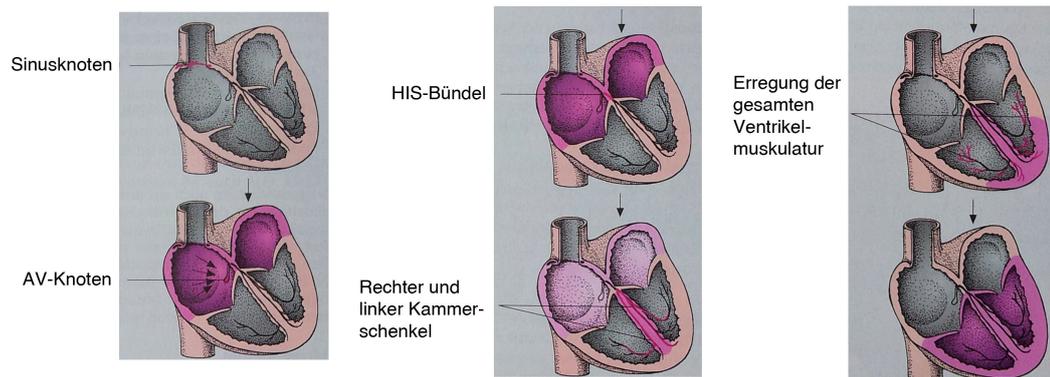


Abbildung 2.8.: Die Erregungsausbreitung im Herzen. Mit Violett sind die jeweils erregten Myokardanteile gekennzeichnet (Abbildung aus [73, S.278]).

regulierenden (Herzfrequenz und Herzschlagstärke) jedoch keinen taktgebenden Einfluss [73, S.278].

Der Ursprung der Erregungsbildung liegt im Sinusknoten, der sich in der Wand des rechten Vorhofs befindet (siehe Abbildung 2.8). Der Sinusknoten bestimmt mit seinen Erregungen die Häufigkeit der rhythmischen Kontraktionen (primärer Schrittmacher). Die Erregungsweiterleitung erfolgt über die Vorhofmuskulatur (Vorhofmyokard) zu dem Atrio-Ventrikular-Knoten am Boden des rechten Vorhofs (sekundärer Schrittmacher<sup>8</sup>). Die Erregungen der Vorhofmuskulatur werden über das His-Bündel in den linken und rechten Kammer-schenkel (Tawara-Schenkel) geleitet. Die Endabzweigungen der Kammer-schenkel werden als Purkinje-Fasern bezeichnet und übertragen die Erregung auf die Kammermuskulatur (Ventrikelmyokard) [73, S.278f]. Der Herzmuskel ist durch eine Refraktärzeit von 150 ms bis 350 ms [53, S.149f], in denen die Muskelzellen nicht erneut auf einen Reiz reagieren, vor einer zu schnellen Kontraktionsfolge geschützt.

**Das EKG** Die Erregungsausbreitung im Herzen erzeugt Spannungsdifferenzen [89, S.114], die an der Körperoberfläche mit EKG-Messgeräten abgeleitet werden können; die messbaren Potentialdifferenzen liegen dabei in einer Größenordnung von etwa 1 mV [53, S.155]. Die Erregung (Depolarisation) der Vorhöfe wird im EKG (siehe Abbildung 2.9) als P-Welle und die Erregung der Kammern als QRS-Komplex bezeichnet. Die T-Welle spiegelt die Erregungsrückbildung (Repolarisation) der Kammern wider. Die Ableitung des EKGs erfolgt mit Elektroden auf der Körperoberfläche, deren Platzierung standardisiert ist. Folgende Ableitungen werden üblicherweise für die Anbringung der Elektroden an der Brustwand und den Extremitäten unterschieden [53, S.158-161]:

- Bipolare Ableitungen (I, II, III) an den Extremitäten nach W. Einthoven (siehe Abbildung 2.10a)

<sup>8</sup>Bei Ausfall der Erregung durch den Sinusknoten dient der AV-Knoten als sekundärer Schrittmacher für die Kammer. Als tertiäre Schrittmacher fungieren das His-Bündel oder die Kammer-schenkel (jeweils mit niedrigerer autonomer Erregungsfrequenz) [53, S.148f].

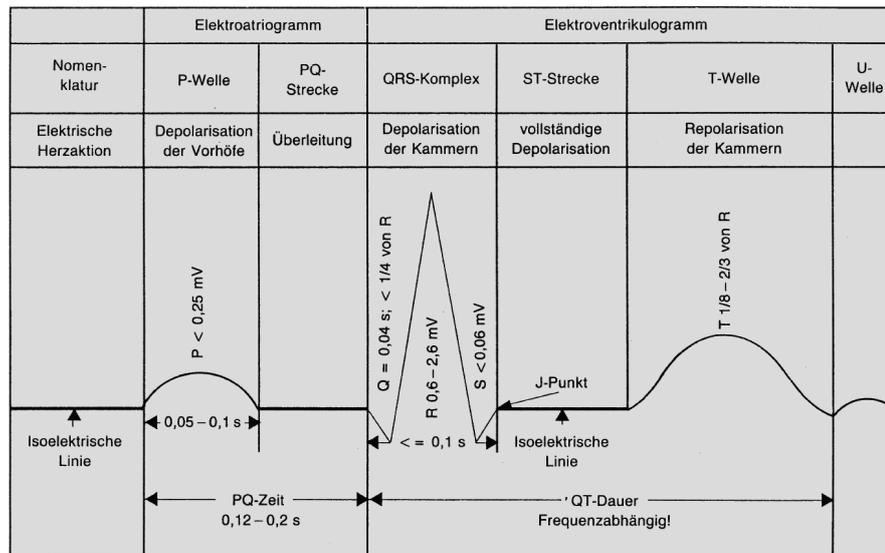


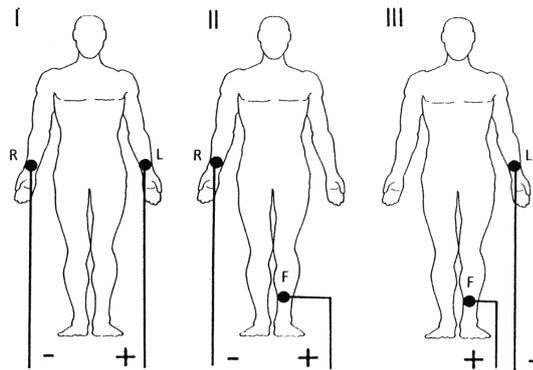
Abbildung 2.9.: Nomenklatur des Elektrokardiogramms (Abbildung aus [89, S.114]).

- Unipolare Ableitungen (aVR, aVL, aVF) an den Extremitäten nach E. Goldberger (siehe Abbildung 2.10b)
- Unipolare Ableitungen ( $V_1$  bis  $V_6$ ) an der Brustwand nach F. N. Wilson (siehe Abbildung 2.10c)

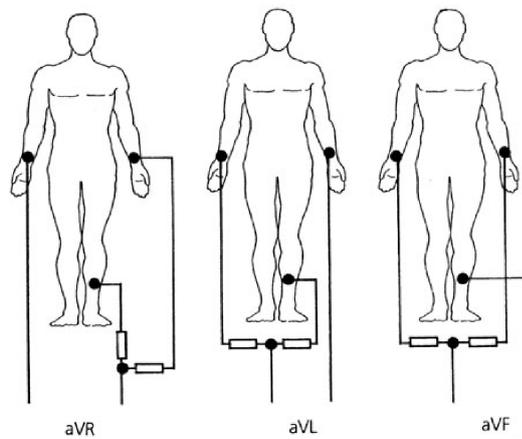
Darüber hinaus existieren weitere Ableitungskonfigurationen, beispielsweise die bipolare Brustwandableitung nach W. Nehb. Bei einer bipolaren Ableitung wird die Spannungsdifferenz zwischen zwei gleichartigen Elektroden gemessen. Für unipolare Ableitungen wird eine gemeinsame indifferente Referenzelektrode genutzt [89, S.159]. Für die unipolare Brustwandableitung nach F. N. Wilson wird diese beispielsweise durch eine Zusammenschaltung der Extremitätenelektroden realisiert.

**EKG-Messgeräte** Die Erfassung der Potentialdifferenzen erfolgt im Allgemeinen mit Einmal-Klebelektroden, Saugelektroden oder Extremitäten-Klammerelektroden; zur Reduzierung der Übergangsimpedanz dient ein EKG-Elektrodengel. Gegenüber Störeinflüssen geschirmte Kabel werden eingesetzt, um die Elektroden mit dem Vorverstärkereingang eines EKG-Messgeräts zu verbinden.

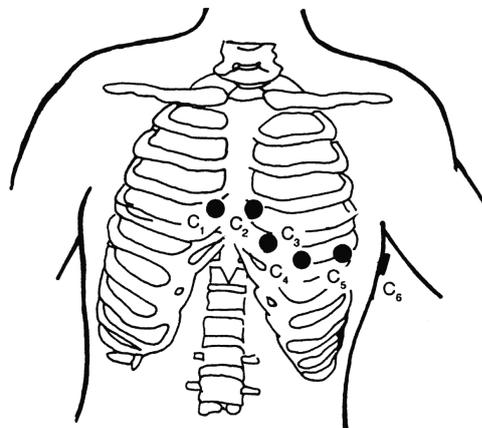
Das EKG-Nutzsignal ist mit einem Gleichspannungsanteil von bis zu 300 mV der Kontaktspannung an der Grenzschicht zwischen Haut und Elektrode [89, S.116], überlagert. Weitere Störungen entstehen durch Körperbewegungen (z.B. Nulllinienschwankungen), Aktivitäten der Skelettmuskulatur (Elektromyogramm-Rauschen) sowie kapazitiven und induktiven Einstreuungen aus dem Stromnetz (50 Hz / 60 Hz Brummspannung) [25, S.413]. In der Abbildung 2.11 sind die Leistungsspektren des EKG-Nutzsignals und von Störeinflüssen in Form von Bewegungsartefakten (engl. *Motion Artifacts*) und Elektromyogramm-Rauschen (engl. *Muscle Noise*) dargestellt.



(a) Bipolare Extremitätenableitungen nach W. Einthoven.



(b) Unipolare Extremitätenableitungen nach E. Goldberger.



(c) Unipolare Brustwandableitungen nach F. N. Wilson (Elektrodenpositionen C).

Abbildung 2.10.: Positionierung von EKG-Elektroden für Extremitäten- und Brustwandableitungen (Abbildung aus [89, S.118-119]).

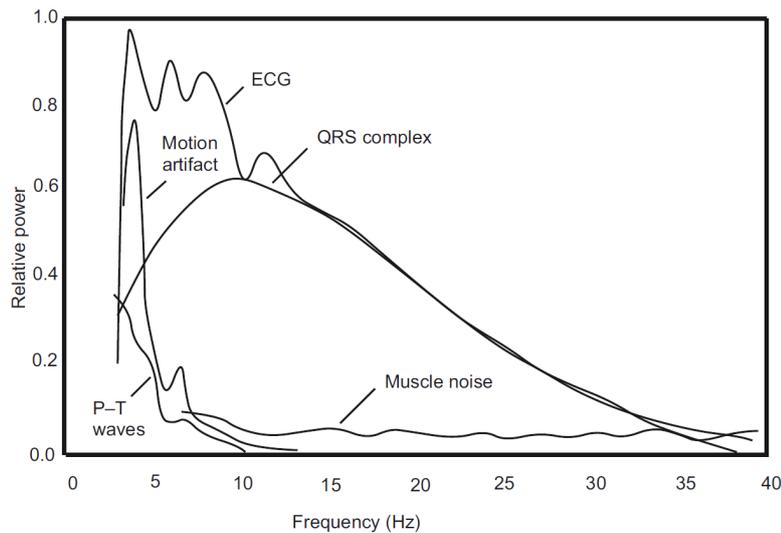


Abbildung 2.11.: Leistungsspektren (normalisiert) von QRS-Komplex, P- und T-Welle, Elektromyogramm-Rauschen und Bewegungsartefakten gemittelt über 150 Herzschläge (Abbildung aus [152, S.237]).

Ein EKG-Messgerät ist ein rauscharmer Differenzverstärker [89, S.114f]. Hochfrequente Störgrößen werden mittels eines Tiefpassfilters am Vorverstärkereingang gedämpft (erste Bandbegrenzung) und extreme Störspannungen (z.B. während Defibrillation) über Entladestrecken und antiparallele Dioden abgeblockt. Eingesetzt werden Instrumentenverstärker mit einem hohen Eingangswiderstand (in der Regel  $>10\text{ M}\Omega$ ) und einer hohen Gleichtaktunterdrückung (engl. *Common-Mode Rejection Ratio*). Nach einer 20- bis 30-fachen Vorverstärkung wird mittels eines Hochpassfilters der Gleichanteil entfernt; die standardisierte Grenzfrequenz beträgt dabei 0,05 Hz. Für den Tiefpassfilter wird eine Grenzfrequenz von 100 Hz und höher verwendet.

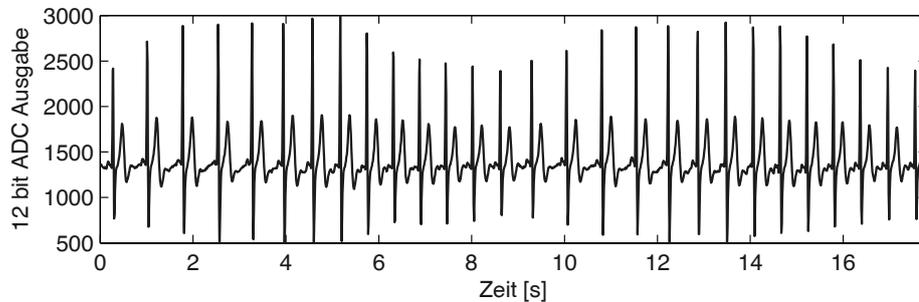
Bei der Ausgabe mit einem analogen EKG-Messgerät mittels mechanischem Registriersystem wird eine weitere Verstärkung auf 1 V bis 2 V durchgeführt (Leistungsverstärkerstufe). Bei einem digitalen EKG-Messgerät erfolgt eine Umwandlung der analogen Signale der einzelnen Ableitungen in zeit- und wertdiskrete Signale (Abtastfrequenzen zwischen 400 Hz und 1000 Hz), die digital weiterverarbeitet werden. Für den Einsatz in nichtklinischen Anwendungsszenarien können Abtastfrequenzen ab bereits 100 Hz ausreichend sein, da ein Großteil der relevanten Informationen des EKG-Nutzsignals bereits erfasst werden (siehe Abbildung 2.11).

Die Darstellung des EKG erfolgt standardisiert auf EKG-Papier, wobei die EKG-Amplitude als 2,5, 5, 10 und 20 mm/mV und die Zeit als 10, 25, 50 und 100 mm/s aufgetragen werden, gekennzeichnet mit einer Eichzacke von 1 mV Amplitude und 1 s Dauer [89, S.114f]. Nach dem Medizinproduktgesetz ist eine galvanische Trennung des Patienten von der Netzspannung vorgeschrieben. Dazu werden die Spannungsversorgung und das Ausgangssignal galvanisch entkoppelt [25, S.130f].

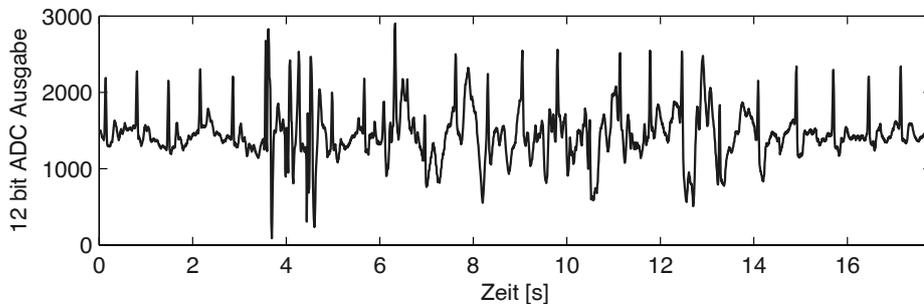
**EKG-Sensor des BG-V4.x** Angebracht auf einem Brustgurt mit zwei EKG-Elektroden, die links und rechts des Sternums platziert sind, ist mit dem EKG-Sensor eines BG-V4.x eine bipolare Brustwandableitung möglich. Für eine ausführliche Beschreibung der technischen Realisierung des EKG-Sensors, der in BG-V4.1 und V4.2 zum Einsatz kommt, wird auf die Arbeit von P. Wilhelm verwiesen [163, S.166ff].

Die Qualität der EKG-Aufzeichnung ist unter anderem von der Platzierung und der Leitfähigkeit der EKG-Elektroden abhängig sowie der Intensität der körperlichen Belastung. Die Abbildungen 2.12 a-c zeigen dazu eine ungestörte Aufzeichnung, eine Überlagerung des EKGs mit Bewegungsartefakten und eine Zunahme der Leitfähigkeit aufgrund von Schweißbildung. Realisiert wurde für den BG-V4.x ein Assistent, der den Nutzer durch den Prozess des korrekten Anlegens führt und die Signalqualität des EKGs bewertet [185, S.39f].

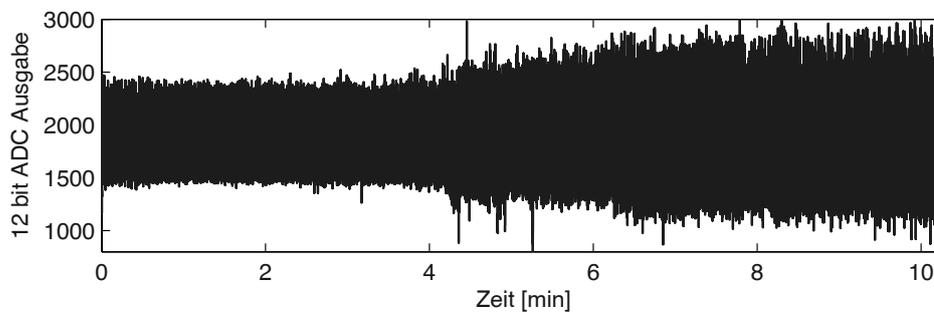
Die Aussagemöglichkeiten der bipolaren Brustwand-EKG-Messung belaufen sich auf die Bestimmung des Herzrhythmus. So lassen sich die Herzfrequenz und deren Variabilität ermitteln (siehe Abschnitt 3.1) und beispielsweise Extrasystolen erkennen. Die im Rahmen der Dissertation durchgeführten Aufzeichnungen zeigen weiterhin, dass teils auch Störungen der Erregungsausbreitung und -rückbildung sichtbar werden; für eine weiterführende Abklärung ist jedoch ein klinisches Mehrkanal-EKG-Messsystem nötig.



- (a) EKG von  $P1_{V1.3}$  mit korrekter Elektrodenposition, sehr guter Leitfähigkeit und ohne Bewegungsartefakte. Die Änderungen der Spitze-Tal-Werte der R-Zacken sind auf die Erweiterung und Verengung des Thoraxes aufgrund der Atmung zurückzuführen.



- (b) EKG von  $P4_{V1.3}$  überlagert mit Bewegungsartefakten.



- (c) Zunahme der Spitze-Tal-Werte des EKGs von  $P4_{V1.1}$  im zeitlichen Verlauf bedingt durch die Schweißbildung aufgrund der körperlichen Belastung.

Abbildung 2.12.: EKGs von drei Probanden (P) aufgezeichnet mit dem EKG-Sensor von BG-V4.x während des Gehens und Laufens auf Laufbändern.

### 2.2.2 Atemsensor

Im Folgenden werden zunächst biologische Grundlagen der Atmung beschrieben. Anschließend wird ein Überblick zu Messprinzipien von Atemsensoren gegeben und der für das BG-V4.2 realisierte Atemsensor vorgestellt.

#### 2.2.2.1 Die Atmung (Respiration)

Das Atmungssystem dient dem Gasaustausch zwischen Blut und Umgebung (äußere Atmung<sup>9</sup>). Das Organ Lunge besteht aus Luftwegen (Bronchialsystem) für den Gastransport und den Alveolen für den Gasaustausch. Während der Einatmung (Inspiration) erweitert sich der Thorax (Brustkorb) und verengt sich anschließend durch die Ausatmung (Expiration). Zuständig dafür sind die Zwischenrippenmuskulatur (*Mm. intercostales interni* und *externi*) sowie das Zwerchfell. Unter körperlicher Belastung (vertiefte Atmung) unterstützt die Atemhilfsmuskulatur. Unterschieden wird zwischen Brustatmung und Bauchatmung (Abdominalatmung) abhängig davon, ob bei der Inspiration die Hebung der Rippen oder die Senkung des Zwerchfells (Hervorwölbung des Bauchs) überwiegen. Das Atemzugvolumen ist abhängig von der Körpergröße und dem Körperbau und beträgt bei einem erwachsenen Mann etwa 500 ml. Bei 15 Atemzügen in Ruhe ergibt dies ein Atemminutenvolumen von 7,5 l. Bei Frauen ist es meist um 15 % bis 20 % niedriger. Während verstärkter Inspiration können weitere 2 l bis 3 l eingeatmet werden (inspiratorisches Reservevolumen). Das expiratorische Reservevolumen beträgt etwa 1 l, das zusätzlich zur normalen Expiration ausgeatmet werden kann. Als Vitalkapazität wird das Atemzugvolumen zuzüglich der inspiratorischen und expiratorischen Reservevolumen bezeichnet. Es verbleibt stets ein Restvolumen von etwa 1 l, das nicht ausgeatmet werden kann (Residualvolumen) [73, Kap.17]. Während einer körperlichen Belastung kann die Atemfrequenz auf 40 bis 50 Atemzüge/min und bei Spitzenausdauertrainierten sogar auf 60 Atemzüge/min ansteigen [159, S.207].

#### 2.2.2.2 Atemsensoren

Sensoren zur Messung der Atmung erfassen üblicherweise den Atemstrom selbst oder die Erweiterung und Verengung von Thorax und Abdomen. Gemessen wird der Atemstrom mit einem Atemfühler an der Nase oder mit einem in einer Gesichtsmaske integrierten Strömungssensor. Dabei kommen unterschiedliche Messprinzipien zum Einsatz: Pneumotachographie, Turbine, thermischer Massenfluss mittels Thermistor, Ultraschallsensor, u. a. [89, Kap.11]. Die Erweiterung und Verengung des Thoraxes und des Abdomens sind hingegen mittels induktiver Atmungsbänder (respiratorische induktive Plethysmografie, RIP) sowie piezoresistiver und piezoelektrischer Sensoren messbar<sup>10</sup>. RIP basiert auf in Atmungsbändern eingearbeiteten Induktionsschleifen, die Volumenänderungen (Plethysmografie), bedingt durch Inspiration und Expiration, als induktive Änderungen messbar machen. Bei piezoresistiven Sensoren variiert deren elektrischer Widerstand unter Einwirkung von Kraft [49, S.362f]. Das Messprinzip bei piezoelektrischen Sensoren beruht hingegen auf Spannungsänderungen hervorgerufen durch die Verformung einer beispielsweise piezoelektrischen Folie [49, S.359f].

---

<sup>9</sup>Als innere Atmung wird der Prozess der Adenosintriphosphat-Herstellung in den Zellen, unter Nutzung des Sauerstoffs der äußeren Atmung, bezeichnet.

<sup>10</sup>GVB-geliMED bietet kommerzielle Atemsensoren der verschiedenen Messprinzipien an: [www.gvb-gelimed.de/polysomnographie/atemsensoren](http://www.gvb-gelimed.de/polysomnographie/atemsensoren), letzter Zugriff 22.06.2015.

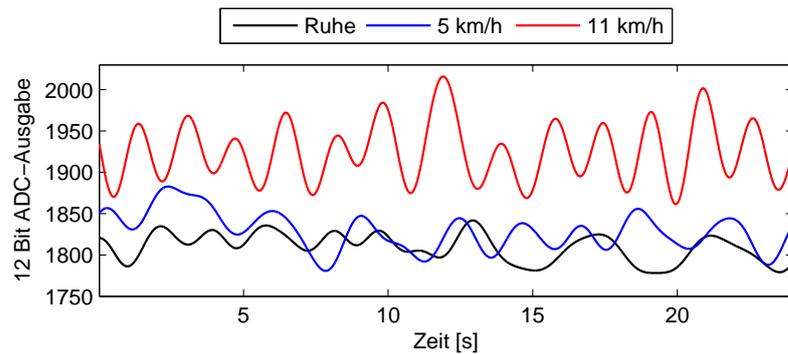
Ein weiteres Verfahren ist die Impedanzpneumographie, welche die Volumenzunahme während der Inspiration als Erhöhung der Thoraximpedanz erfasst. Während der Expiration hingegen nimmt die Impedanz ab. Das Messprinzip beruht auf zwei Thoraxelektroden, durch die ein hochfrequenter Konstantstrom fließt ( $<10\ \mu\text{A}$  bei etwa 40 kHz); die Impedanzänderung bewirkt dabei eine synchrone Spannungsänderung. Das Messprinzip ist anfällig für Bewegungsartefakte [89, S.709f]. Darüber hinaus existieren Verfahren, die die Atmung unter anderem mittels Photoplethysmographie (PPG) [93], EKG (engl. *ECG-Derived Respiration*, EDR) [111] und Mikrofon [101] erfassen.

### 2.2.2.3 Atemsensor des BG-V4.2

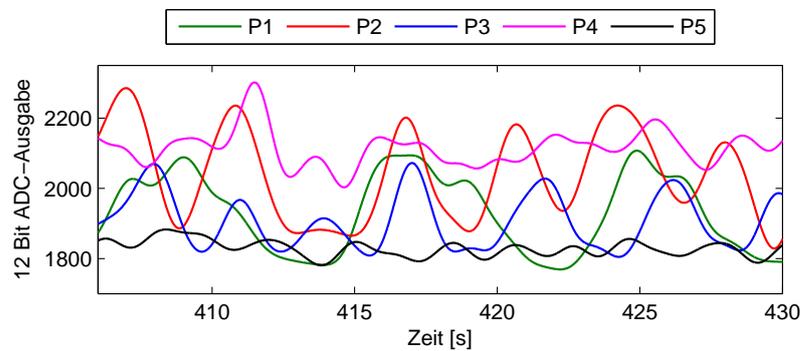
Für die Entwicklung eines Atemsensors stellt sich für das BG-V4.2 die Anforderung einer Integration in den Brustgurt. Das Messsystem soll außerdem weiterhin ohne Experten anlegbar sein und eine Aufzeichnung der Atemkurve und -frequenz beispielsweise im Alltag, in der Arbeitsmedizin und im Sport ermöglichen. Als Messprinzip wird RIP aufgrund der schwer in das bestehende System zu integrierenden mäanderförmigen Induktionsschleifen ausgeschlossen. Weiterhin sind derartige kommerzielle Atmungsbänder für den einmaligen Gebrauch spezifiziert, sodass die Bandabschnitte mit den Induktionsschleifen nach einer Aufzeichnung ausgetauscht werden müssen. Die Impedanzpneumographie hingegen eignet sich aufgrund ihrer Anfälligkeit gegenüber Bewegungsartefakten nur bedingt für den Einsatz unter körperlicher Belastung.

Eingesetzt wird der piezoresistive Kraftsensor (engl. *Force-Sensing Resistor*) FlexiForce A201 der Firma Tekscan [151]. Aus der auf die Sensorfläche einwirkenden messbaren Kraft kann der Anpressdruck abgeleitet werden. Aufgrund der Integration in den weichen Brustgurt und um ein Eindringen der Sensorfläche während der Inspiration in den Zwischenrippenraum zu vermeiden, wurde der Sensor für die Kraftübertragung zwischen zwei quadratischen Plättchen aus Kunststoff mit einer Kantenlänge von 1,5 cm positioniert. Die Anbringung des Atemsensors am Brustgurt erfolgt seitlich am Thorax zwischen den senkrechten Orientierungslinien *linea medioclavicularis* und *linea axillaris anterior* (Positionierung siehe Abbildung 2.14e). Die Zuleitung (Folienkabel) des FlexiForce A201 wird zwischen Gurt und Körper verschiebbar zum BG-V4.2 geführt und über Steckverbindungen kontaktiert. Die Signalerfassung erfolgt mit einem Operationsverstärker mit nachgeschaltetem Tiefpassfilter an einem ADC-Eingang des MSP430FG4618.

Nach der Prüfung des Atemsensors in vorbereitenden Tests wurde ein Laufbandversuch mit fünf Probanden und unterschiedlichen körperlichen Belastungsstufen durchgeführt (V1.3). Als Referenzsystem zur Erfassung der Atmung kam dabei ein Ergospirometer zum Einsatz (Versuchsbeschreibung siehe Anhang A.1.3). Die Erweiterungen und Verengungen des Thoraxes ergaben für die Probanden P1 bis P3 eine Änderung des Spitze-Tal-(ST)-Werts im 12 Bit ADC-Ausgabewert um etwa 50 Quantisierungsstufen während der Ruhephase und bis zu 350 Quantisierungsstufen während des schnellen Laufens bedingt durch eine vertiefte Atmung (siehe Abbildung 2.13a). Bei P4 und P5 fielen die Änderungen des ST-Werts niedriger aus, sodass die einzelnen Atemzüge phasenweise schwer zu erkennen waren (siehe Abbildung 2.13b). Diese Problematik erklärt sich jedoch nicht mit einem zu straff oder zu locker angelegten Brustgurt. Der Gurt war bei P4, ähnlich wie bei P2, straff angelegt (hoher mittlerer ADC-Ausgabewert von 2196 Quantisierungsstufen) und dazu im Vergleich bei P5 lockerer



(a) Gegenüberstellung der Atemkurven eines Probanden in Ruhe und bei vertiefter Atmung während des Gehens mit 5 km/h und des Laufens mit 11 km/h auf einem Laufband (V1.3).



(b) Gegenüberstellung der Atemkurven von 5 Probanden während des Gehens mit 5 km/h (V1.3).

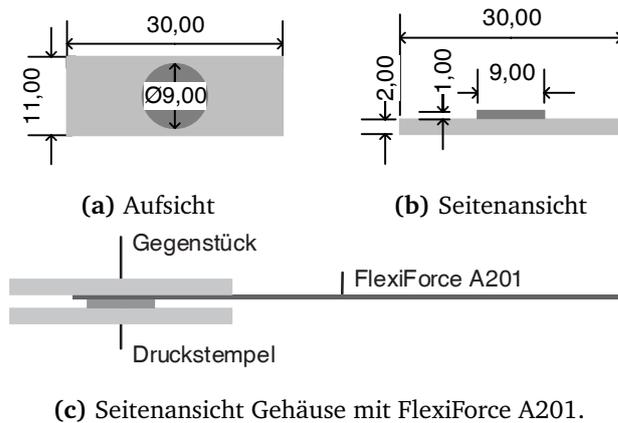
Abbildung 2.13.: Atemkurven aufgezeichnet mit dem piezoresistiven Kraftsensor nach Verstärkung und Tiefpassfilterung (Butterworth 5. Ordnung,  $f_c = 0,6$  Hz).

angebracht (niedrigster mittlerer ADC-Ausgabewert im Versuch von 1861 Quantisierungsstufen)<sup>11</sup>. Eine mögliche Erklärung ist, dass mit den quadratischen Kunststoffplättchen noch keine definierte Kraftübertragung sichergestellt war. Probleme, die auftreten konnten, umfassten eine nicht korrekte Auflage auf zwei Rippen und eine Verformung der Plättchen aufgrund der Atembewegung, sodass die sensitive Sensorfläche nicht vollständig planar auflag.

Um diesem Problem zu begegnen, wurde ein 3 cm langes Gehäuse entwickelt, das, vertikal angebracht, eine Auflage auf zwei Rippen gewährleistet. Auf der Oberseite befindet sich mittig eine 1 mm hohe kreisrunde Erhöhung mit einem Durchmesser von 9 mm (Druckstempel), die eine mechanische Kraftübertragung der Atembewegung ausschließlich auf die kreisrunde sensitive Fläche des FlexiForce A201 sicherstellt. Auf der Rückseite wird der Kraftsensor durch ein flaches Gegenstück eingeschlossen (siehe Abbildungen 2.14a-c). Zwei Prototypen des Gehäuses wurden zunächst aus starrem Kunststoff mittels einer CNC-Fräse<sup>12</sup> erstellt und in

<sup>11</sup>Siehe auch Differenz aus Brustumfang und eingestellter Gurtlänge, Tabelle A.3.

<sup>12</sup>CNC: *Computerized Numerical Control*. Mein Dank gilt Sebastian Zehe für das CNC-Fräsen.



(d) Prototyp gefertigt mit einer CNC-Fräse.



(e) Integration und Platzierung des Atemsensors.

Abbildung 2.14.: Konstruktion und Integration des Atemsensors in den Brustgurt von BG-V4.2 (Größenangaben in Millimetern). Innenseite des Brustgurts nach außen gedreht für Sichtbarkeit des Atemsensors (e).

den Brustgurt integriert (siehe Abbildungen 2.14d-e).

Nach Prüfung von deren Funktionalität wurde eine Herstellung mittels eines 3D-Druckverfahrens<sup>13</sup> erprobt; es wurden dazu leichte Anpassungen vorgenommen. Das auf diese Weise hergestellte Gehäuse ist flacher, umschließt den Kraftsensor vollständig und der Mechanismus zur Kraftübertragung ist gegen ein Verrutschen des Kraftsensors geschützt; die Konstruktion ist in [178] veröffentlicht.

Die Erfassung der Thoraxerweiterung und -verengung wurde für dieses optimierte Gehäuse anschließend mit einem kommerziellen RIP-basierten Atemsensor der Firma Brain Products<sup>14</sup> verglichen. Betrachtet wurden Stehen, Sitzen, leichte Körperbewegungen (auf der Stelle) sowie normale und tiefe Atemzüge. Die Atemzüge in den Signalverläufen der beiden Atem-

<sup>13</sup>Mein Dank gilt dem Zentrallabor, insbesondere Simon Schulz, für die Unterstützung beim 3D-Druck.

<sup>14</sup>Siehe [www.brainproducts.com/productdetails.php?id=25](http://www.brainproducts.com/productdetails.php?id=25), letzter Zugriff 25.06.2014.

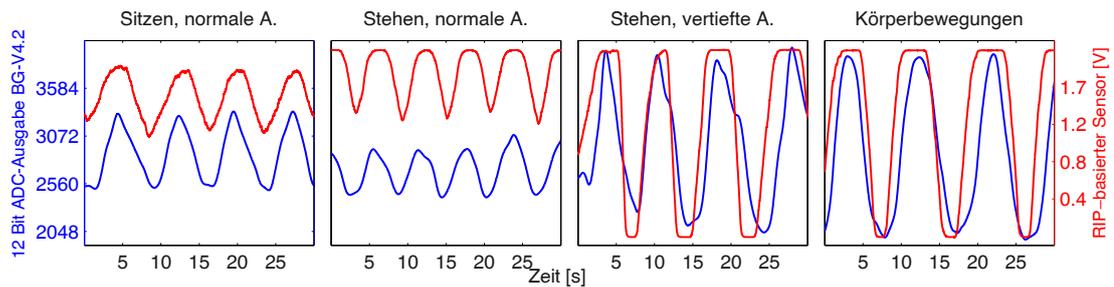


Abbildung 2.15.: Gegenüberstellung der Atemkurven aufgezeichnet mit dem BG-V4.2 und einem kommerziellen RIP-basierten Atemsensor der Firma Brain Products.

sensoren zeigen eine hohe Übereinstimmung; eine Veränderung der Atemzugtiefe bewirkt mindestens eine Verdopplung des ST-Werts (siehe Abbildung 2.15). Im Gegensatz zu dem RIP-basierten Atemsensor wird der Messbereich des FlexiForce A201 nicht überschritten [178].

### 2.2.3 Temperatursensor

Eine Temperaturmessung beim Menschen kann innerhalb des Körpers (intrakorporal), in Körperöffnungen oder an der Körperoberfläche erfolgen. Zu den intrakorporalen Messpositionen gehört die Speiseröhre (Ösophagus), die Pulmonalarterie oder die Harnblase. Die Messung in Körperöffnungen erfolgt im äußeren Gehörgang, im Nasenrachen (Nasopharynx), unter der Zunge (sublingual) oder im Rektum (einfachste Annäherung der Körperkerntemperatur). An der Körperoberfläche wird in den Achselhöhlen (Axilla) gemessen, der Temperaturwert liegt dabei etwa  $1^{\circ}\text{C}$  unterhalb der rektalen Messung. Die Messung der Hauttemperatur an weiteren Messpositionen hängt von deren Durchblutungsqualität ab [89, S.726].

Der typische Messbereich liegt zwischen  $24^{\circ}\text{C}$  und  $42^{\circ}\text{C}$  [89, S.725]. Gemessen wird unter anderem mit Flüssigkeiten (thermische Ausdehnung von Quecksilber, heute Galinstan), Infrarotsensoren oder Thermistoren. Im BG-V4.x wird ein Thermistor eingesetzt, der, auf die Haut aufgeklebt oder zwischen Brustgurt und Haut angebracht, eine Erfassung der Hauttemperatur (Körperoberflächentemperatur) ermöglicht.

Ein Thermistor (Kunstwort aus *Thermal* und *Resistor*) beschreibt einen Widerstand, der stromdurchflossen eine temperaturabhängige Widerstandsänderung aufweist. In Bezug auf eine Temperaturskala ist die Änderung absolut. Unterschieden werden die zwei Gruppen *Negative Temperature Coefficient (NTC)*- und *Positive Temperature Coefficient (PTC)*-Thermistoren; es eignen sich jedoch nur NTC-Thermistoren für eine Temperaturmessung mit hoher Genauigkeit [49, S.532]. Bei einem NTC-Thermistor reduziert sich der Widerstand mit zunehmender Temperatur (Heißleiter), der Zusammenhang zwischen Widerstand und Temperatur ist dabei nicht linear. Weiterhin wirken auf die Temperaturmessung Fertigungsschwankungen und die Selbsterwärmung des Widerstands aufgrund des Stromdurchflusses ein, sodass für eine hohe Genauigkeit der Messung eine individuelle Kalibrierung sinnvoll ist. Durchgeführt wird diese beispielsweise durch Eintauchen in eine erwärmte Flüssigkeit (Mineralöl / *Fluorinert Electronic Fluid* von 3M) [49, S.532]. Darüber hinaus müssen für die Kalibrierung Toleranzen der Bauteile der Messschaltung und des Analog-Digital-Wandlers berücksichtigt werden.

Im BG-V4.x ist die Hauttemperaturmessung als Wheatstonesche Brücke mit einem NTC-Thermistor realisiert; für eine technische Beschreibung wird an dieser Stelle auf [163, Kap.C1.3] verwiesen. Nach der Kalibrierung von fünf BG-V4.2 betrug die mittlere Abweichung  $\pm 0,1^\circ\text{C}$  für das Modul Nummer 63 und  $\pm 0,2^\circ\text{C}$  für die übrigen vier Module; die maximale Abweichung lag bei  $\pm 0,5^\circ\text{C}$ . Als Referenzthermometer diente ein Fluke 289 mit dem Temperaturmessfühler 80BK-A.

## 2.2.4 Inertialsensoren

Sensoren, die die Beschleunigung (Beschleunigungssensoren oder engl. *Accelerometer*) sowie die Drehrate (Gyroskope) eines Körpers erfassen können, werden als Inertialsensoren (lat. *Inertia* für Trägheit) bezeichnet. Eine Kombination der beiden Sensortypen bildet eine inertielle Messeinheit (engl. *Inertial Measurement Unit, IMU*); zusätzlich können Magnetometer integriert sein. Im Folgenden werden diese drei Sensortypen vorgestellt, wobei der Schwerpunkt auf den für die vorliegende Arbeit relevanten Beschleunigungssensoren liegt.

### 2.2.4.1 Beschleunigungssensoren

Der Einsatz von Beschleunigungssensoren zur Erkennung von menschlichen Körperbewegungen ist Gegenstand intensiver Forschung. Beschleunigungssensoren bieten eine kosteneffektive Lösung und stellen bezüglich des Eingriffs in die Privatsphäre des Nutzers eine Alternative zu videobasierten Sensoren dar [14; 107].

Beschleunigungssensoren sind elektromechanische Geräte, die Beschleunigungen, resultierend aus statischen Kräften wie der Gravitationskraft (Schwerkraft, lat. *Gravitas* für Schwere) oder dynamischen Kräften verursacht durch Bewegungen, messen [42]. Die Ausgabe eines Beschleunigungssensors besteht somit aus einer Überlagerung der Erdbeschleunigung (Schwerebeschleunigung) mit inertialen dynamischen Beschleunigungsanteilen. Die Messung erfolgt dabei im Koordinatensystem des Körpersensors (Beschleunigungssensors), dessen Orientierung gegenüber dem Referenzkoordinatensystem Erde im Allgemeinen abweicht (z.B. Anbringung im Brustbereich). Die Angabe von Beschleunigungen erfolgt in Metern pro Sekunde zum Quadrat (SI-Einheit  $\text{m} \cdot \text{s}^{-2}$ ). Für Beschleunigungssensoren ist eine Bezeichnung als Lastvielfaches der Erdbeschleunigung  $g$  mit  $1g = 9,80665 \text{ m} \cdot \text{s}^{-2}$  (Normfallbeschleunigung) üblich<sup>15</sup>; im Rahmen der vorliegenden Arbeit wird die Ausgabe der Beschleunigungssensoren in  $g$  angegeben.

Ein Beschleunigungssensor besteht aus einer Prüfmasse, die beispielsweise mittels einer Feder an einem Befestigungsrahmen angebracht ist. Wird der gesamte Sensor beschleunigt, folgt die Prüfmasse der Bewegung verzögert. Die Messung einer Änderung der Auslenkung zwischen Masse und Rahmenstruktur ermöglicht es, die Beschleunigung zu bestimmen. Technisch lässt sich dies beispielsweise durch die Erfassung von Kapazitätsänderungen realisieren. Benötigt wird dazu eine stationäre Platte, die am Rahmen befestigt ist, und eine zweite Platte an der beweglichen Prüfmasse. Die beiden Platten bilden einen Kondensator, dessen Kapazität sich mit der Änderung des Plattenabstands aufgrund der Auslenkung verändert. Eine weitere Möglichkeit ist, die Auslenkung über piezoresistive Dehnungsmessstreifen (engl. *Strain Gauge*) zu erfassen, deren elektrischer Widerstand sich unter Einwirken einer Zugkraft

<sup>15</sup>Auch als  $g$ -Kraft bezeichnet, wobei  $g$  für Gravitation steht. Zu beachten ist, dass es sich dennoch stets um die Angabe einer Beschleunigung handelt.

Tabelle 2.1.: Überblick Stand der Technik von Beschleunigungssensoren. Angabe des Messbereichs der Beschleunigungssensoren als  $g$ -Kraft und des Gewichts in Milligramm  $mg$ . † Bezüglich der Leistungsaufnahme optimierte Variante mit reduzierter Abtastfrequenz (50 Hz). ‡ Leistungsaufnahme ohne Gyroskope, Magnetometer und Coprozessor.

| Bezeichnung<br>Hersteller  | ADXL05<br>Analog Devices | ADXL202 | LIS3LV02DL<br>STMicroelectronics | LIS331HH<br>STMicroelectronics | LIS2DM               | MPU-9250<br>InvenSense |
|----------------------------|--------------------------|---------|----------------------------------|--------------------------------|----------------------|------------------------|
| Ersch.jahr                 | 1996                     | 1999    | 2008                             | 2009                           | 2013                 | 2014                   |
| Achsenanzahl               | 1                        | 2       | 3                                | 3                              | 3                    | 3 (9)                  |
| Messbereich [g]            | $\pm 1-5$                | 2       | $\pm 2/6$                        | $\pm 6/12/24$                  | $\pm 2/4/8/16$       | $\pm 2/4/8/16$         |
| Volumen [mm <sup>3</sup> ] | 326                      | 50      | 33                               | 9                              | 4                    | 9                      |
| Gewicht [mg]               | 5000                     | 5000    | 72                               | 20                             | -                    | -                      |
| Leistung [ $\mu$ W]        | 38000                    | 1800    | 1500                             | 625                            | 15†                  | 1125‡                  |
| Schnittstelle              | Analog                   | Analog  | I <sup>2</sup> C/SPI             | I <sup>2</sup> C/SPI           | I <sup>2</sup> C/SPI | I <sup>2</sup> C/SPI   |

verändert. Eingesetzt werden außerdem piezoelektrische Sensoren, die eine Wandlung von mechanischer Energie in elektrische Energie in einem kristallinen Material, bestehend aus zwei elektrischen Dipolen, ermöglichen [49, S.305-309].

**Stand der Technik** Der Einsatz von Beschleunigungssensoren zur Erfassung von Bewegungsabläufen des menschlichen Körpers wurde erstmals 1950 vorgeschlagen. Die Sensoren waren zu diesem Zeitpunkt jedoch noch groß, unzuverlässig und teuer [42]. Die heutigen Realisierungen als Mikroelektromechanische Systeme (MEMS) ermöglichen eine kosteneffektive Fertigung von miniaturisierten Beschleunigungssensoren in hoher Stückzahl mit Gehäuseabmessungen im Millimeterbereich und einer Leistungsaufnahme von nur wenigen Mikrowatt. Diese Eigenschaften machen sie besonders interessant für den Einsatz mit Körpersensoren.

Während anfangs Beschleunigungssensoren nur eine sensitive Achse aufwiesen (einen Freiheitsgrad, engl. *Single Degree-Of-Freedom, DOF*), folgten später Sensoren mit zwei und inzwischen drei orthogonal zueinander angeordneten Beschleunigungsachsen. Zunächst erfolgte eine Anbindung der Beschleunigungssensoren über analoge Schnittstellen, inzwischen finden jedoch überwiegend digitale I<sup>2</sup>C- oder SPI-Schnittstellen Anwendung.

Analog Devices stellte 1996 den auf einer kapazitiven Messmethode basierenden ADXL05 mit einem einstellbaren Messbereich zwischen  $\pm 1$  g und  $\pm 5$  g vor. Der Beschleunigungssensor wiegt noch 5 Gramm bei einem Volumen von 326 mm<sup>3</sup> und die Leistungsaufnahme beträgt während des Betriebs 38 mW (siehe Übersicht ausgewählter Beschleunigungssensoren, Tabelle 2.1). Drei Jahre später erschien der ADXL202 (Messbereich  $\pm 2$  g, ADXL210 Variante mit  $\pm 10$  g) mit bereits zwei Beschleunigungsachsen, einem auf  $1/6$  verkleinerten Volumen und einer etwa halbierten Leistungsaufnahme.

STMicroelectronics stellte 2008 den dreiaxialen Beschleunigungssensor LIS3LV02DL vor (eingesetzt auf BG-V4.0/1), der bei einem Volumen von 33 mm<sup>3</sup> nur 72 Milligramm wiegt und eine Leistungsaufnahme von 1500  $\mu$ W aufweist. Ein Jahr später folgte der LIS331HH (eingesetzt auf BG-V4.0/1), der bei einem Volumen von 33 mm<sup>3</sup> nur 20 Milligramm wiegt und eine Leistungsaufnahme von 625  $\mu$ W aufweist.

setzt auf BG-V4.2), der einen wählbaren Messbereich von  $\pm 6$  bis  $\pm 24$  g bietet und dessen Volumen nur etwa  $\frac{1}{3}$  und die Leistungsaufnahme die Hälfte beträgt. Im Jahr 2013 erschienen ein bezüglich der Leistungsaufnahme optimierter Beschleunigungssensor (LIS3DH), der nur  $15 \mu\text{W}$  benötigt<sup>16</sup>. Darüber hinaus werden Versionen angeboten, die für eine hohe Genauigkeit (LIS2HH12) oder für sehr hohe Beschleunigungen (H3LIS331DL, Messbereich  $\pm 100 / \pm 200 / \pm 400$  g) ausgelegt sind.

#### 2.2.4.2 Gyroskope

Gyroskope (auch Gyrometer oder Drehratensensoren) messen Drehgeschwindigkeiten (Rotationsgeschwindigkeiten) als Winkeländerung pro Zeit (SI-Einheit  $\text{rad} \cdot \text{s}^{-1}$ ). Mit Gyroskopen lassen sich Winkeländerungen an Gelenken erfassen. Ist die Position und die Orientierung von Gliedmaßen zum Startzeitpunkt bekannt, lassen sich durch Integration der Drehgeschwindigkeiten Änderungen in der Orientierung approximieren und über ein biomechanisches Modell auf die Position abbilden [107]; zu beachten ist jedoch der dabei auftretende Drift im zeitlichen Verlauf.

Ein Gyroskop besteht aus einer Kreisscheibe, die frei um eine Drehachse rotiert (Kreiselinstrument), welche an einer Rahmenkonstruktion angebracht ist, die sich frei um eine oder zwei Achsen drehen kann. Wenn die Kreisscheibe frei rotiert, bleibt die axiale Ausrichtung bestehen, falls keine externen Kräfte einwirken. Rotiert die Rahmenkonstruktion um ihre sensitive Achse, entwickelt sich jedoch ein Drehmoment bezüglich einer sich im Lot (perpendikulär) befindlichen Achse und die Ausrichtung der Drehachse verändert sich entsprechend. Die Genauigkeit der Bestimmung der Drehgeschwindigkeit ist dabei in hohem Maße von zusätzlichen ungewollt einwirkenden Drehmomenten abhängig, die durch Reibung, einem nicht gleichmäßig ausbalancierten Motor oder magnetischen Einflüssen entstehen [49, S.313f].

Gyroskope mit einem Motor für den Antrieb der Kreisscheibe waren für viele Jahre die einzige praktische Wahl. Abnutzungen an Motoren und Lager ermöglichten jedoch nur eine gewisse Anzahl an Betriebsstunden mit der spezifizierten Genauigkeit. Weiterhin ließen sich keine kompakten Gyroskope zu niedrigen Kosten realisieren. Überwunden wurden diese Nachteile durch eine Fertigung als MEMS, wobei die Kreisscheibe durch ein vibrierendes Element ersetzt wurde (Ausnutzung der Corioliskraft) [49, S.315f]. Darüber hinaus existieren optische Gyroskope, die auf dem Sagnac-Effekt beruhen [49, S.317ff].

Für das initiale Design des BG-V4.1 (2009) wurde sich aufgrund der höheren Leistungsaufnahme gegen eine Integration von Gyroskopen entschieden<sup>17</sup>. Für die fünfte Version ist jedoch der Einsatz der MPU-9250 von InvenSense geplant. Der Messbereich des dreiaxialen Gyroskops ist zwischen  $\pm 250$ ,  $\pm 500$ ,  $\pm 1000$  und  $\pm 2000 \text{ rad} \cdot \text{s}^{-1}$  einstellbar. Bei einer Abtastfrequenz von 1 kHz beträgt die Leistungsaufnahme 8 mW.

<sup>16</sup>Die Angabe gilt bei einer auf 50 Hz reduzierten Abtastfrequenz. Für 400 Hz sind es  $90 \mu\text{W}$  und für 1620 Hz  $250 \mu\text{W}$ . Die Leistungsaufnahme des LIS3DH ist auch im Vergleich zu STMicroelectronics Produktportfolio sehr niedrig, Varianten mit höherer Genauigkeit weisen eine höhere Leistungsaufnahme auf.

<sup>17</sup>Der Einsatz von Knopfzellen als Energiequelle begrenzt den möglichen kontinuierlichen Entladungsstrom auf nur wenige Milliampere (siehe Abschnitt 2.6.2).

### 2.2.4.3 Magnetometer

Magnetometer ermöglichen die Messung der magnetischen Flussdichte (Stärke und Richtung eines Magnetfelds) in der SI-Einheit Tesla (T). Verfügbar sind Sensoren, die unter anderem auf dem anisotropen magnetoresistiven Effekt (AMR) und dem Hall-Effekt beruhen.

AMR tritt in ferromagnetischen Materialien auf und beschreibt eine Änderung des elektrischen Widerstandswerts in Abhängigkeit von einem Magnetfeld. Am niedrigsten ist der Widerstand, wenn das Magnetfeld senkrecht (perpendikular) zum stromdurchflossenen Leiter auftritt. Die Firma Honeywell nutzt für die magnetoresistiven Sensoren einen Dünnschichtfilm aus einer Nickel-Eisen-Legierung (engl. *Permalloy Thin-Film*), von denen vier Stück als Wheatstone-Messbrücke aufgebaut sind [69].

Der Hall-Effekt beschreibt die Ablenkung von Elektronen, wenn diese ein Magnetfeld passieren (Lorentzkraft). Als Folge tritt die Hall-Spannungsdifferenz senkrecht zur Stromrichtung und dem Magnetfeld auf [49, S.82ff]. Mit vier in einer Brückenschaltung kombinierten Hall-Sensoren lässt sich auf diese Weise die magnetische Flussdichte erfassen [49, S.267ff]. Ein Beispiel ist die MPU-9250, die mittels Hall-Sensoren dreiaxial die magnetische Flussdichte in einem Messbereich von bis zu  $\pm 4800 \mu\text{T}$  erfasst. Die Abtastfrequenz beträgt 8 Hz und es werden 700  $\mu\text{W}$  benötigt.

### 2.2.4.4 Inertiale Messeinheiten

Inertiale Messeinheiten (engl. *Inertial Measurement Units, IMU*) kombinieren Beschleunigungssensoren, Gyroskope und häufig zusätzlich Magnetometer auf einem Chip. Werden jeweils dreiaxiale Sensoren eingesetzt, weist die IMU neun Freiheitsgrade auf. Ein Beispiel ist die 2014 erschienene MPU-9250 von InvenSense mit einem Volumen von nur  $9 \text{ mm}^3$  (inklusive Coprozessor zur Signalverarbeitung). Sind alle Sensoren aktiv, beträgt die Leistungsaufnahme  $9,3 \text{ mW}$ <sup>18</sup>. Zusätzlich ist ein Coprozessor integriert, der Schrittzahl, Dauer des Gehens und Rotationswinkel (basierend auf Beschleunigungssensoren und Gyroskopen) ermittelt<sup>19</sup>. Die Firma STMicroelectronics bietet ebenfalls inertielle Messeinheiten mit zusätzlicher *iNEMO-Engine* zur Sensorfusion und weiteren Signalverarbeitung an. Angaben zu den verwendeten Methoden der Sensorfusion machen die Hersteller nicht. Einen Überblick zur Sensorfusion der Signale einer IMU mittels Kalman-Filterung gibt [56].

## 2.3 Mikrocontroller

Mikrocontroller in Körpersensoren werden für die Ausführung der Betriebssoftware, die Erfassung und Verarbeitung von Sensormesswerten sowie zum Datentransfer an externe Speicher oder Kommunikationsschnittstellen genutzt. Die Leistungsaufnahme des Mikrocontrollers stellt jedoch ein Schlüsselkriterium im Hinblick auf Betriebsdauer, Volumen und Gewicht des Körpersensors dar.

Vor allem in der Vergangenheit wurden dazu Mikrocontroller mit nur wenigen Megahertz Taktfrequenz eingesetzt. Aufgrund des geringen Berechnungsaufwands vieler Anwendungen sind geeignete Energiesparmodi mit kurzen Reaktivierungszeiten des Mikrocontrollers von

---

<sup>18</sup>Siehe MPU-9250 Product Specification, Revision 1.0, InvenSense Inc., San Jose, CA 95110 USA.

<sup>19</sup>Siehe Embedded Motion Driver v5.1.1 APIs Specification, Revision 1.0, InvenSense Inc., San Jose, CA 95110 USA.

Tabelle 2.2.: Gegenüberstellung des MSP430xG461x (eingesetzt auf BG-V4.x) und der Kinetis KL25 Sub-Family (geplant für BG-V5). †  $V_{CC} = 2,2 / 3V$ . ‡  $V_{CC} = 3V$ .

| Bezeichnung<br>Hersteller           | MSP430xG461x<br>Texas Instruments | Kinetis KL25 Sub-Family<br>Freescale |
|-------------------------------------|-----------------------------------|--------------------------------------|
| Erscheinungsjahr                    | 2006                              | 2013                                 |
| Wortbreite Architektur [b]          | 16                                | 32                                   |
| Max. Taktfrequenz [MHz]             | 1 - 8                             | 1 - 48                               |
| RAM / Flash [kB]                    | 4 / 120                           | 16 / 128                             |
| E (aktiv) [mW/MHz]                  | 0,88 / 1,8 †                      | 0,4 ‡                                |
| E (stop/low-power mode) [ $\mu W$ ] | 0,484 / 0,9 - 99 / 225 †          | 0,5 - 900 ‡                          |
| Volumen [mm <sup>3</sup> ]          | 50                                | 25                                   |

Bedeutung [125].

Mikrocontroller unterscheiden sich unter anderem in ihren Leistungsmerkmalen (z.B. Taktfrequenz und Wortbreite der Datenverarbeitung), Ein- und Ausgabeschnittstellen und funktionalen Einheiten (z.B. Multiplizierer). Beispiele für Mikrocontroller mit einer Wortbreite von 8 b sind die PIC18-Mikrocontrollerfamilie der Firma Microchip Technology oder Modellvarianten der AVR-Mikrocontroller von Atmel. Für das *Transceiver*-Erweiterungsmodul des BG-V4.x wird ein ATmega88 verwendet. Weiterhin setzen die Berkeley Mote (University of California, Berkeley), die Medusa MK-2 (University of California, Los Angeles) oder die BTnode (Eidgenössische Technische Hochschule, Zürich) auf 8 b AVR-Mikrocontroller [125]. Varianten des MSP430 der Firma Texas Instruments mit einer Wortbreite von 16 b finden vielfältig Anwendung in verschiedenen Sensorplattformen, einige Beispiele sind in [86; 87; 95; 132; 158] beschrieben. Ein kommerziell erhältliches System sind die tragbaren Sensoren von Shimmer<sup>20</sup>. Die Firma ARM bietet mit der Cortex-M Mikroprozessorfamilie die Grundlage für die Herstellung von Mikrocontrollern mit 32 b Wortbreite; insbesondere die Variante Cortex-M0+ ist dabei für Anwendungen mit niedriger Leistungsaufnahme geeignet.

**MSP430xG461x und Kinetis KL25 Sub-Family** Auf dem BG-V4.x kommt der im Jahr 2006 erschienene MSP430xG461x zum Einsatz. Der 16-Bit-Mikrocontroller kann mit Taktfrequenzen zwischen 1 MHz und 8 MHz betrieben werden und verfügt über einen RISC-ähnlichen (*Reduced Instruction Set Computer*) Befehlssatz. Betriebssoftware und Anwendungen stehen 8 kB RAM und 124 kB Flash-Speicher zur Verfügung. Weiterhin sind unter anderem drei konfigurierbare Operationsverstärker, ein Analog-Digital-Wandler (engl. *Analog Digital Converter*, ADC), ein 16 b Timer, ein DMA-Controller (*Direct Memory Access*) und eine funktionale Einheit für 16 b x 16 b - Multiplikationen integriert. Die Leistungsaufnahme beträgt im aktiven Modus etwa 1,8 mW / MHz und in den Energiespar- oder Stop-Modi zwischen 0,9  $\mu W$  und 225  $\mu W$  (Versorgungsspannung  $V_{CC} = 3V$ ). Auf dem BG-V4.x wird der MSP430xG461x, integriert in einem BGA-Gehäuse (*Ball Grid Array*), eingesetzt. Das Volumen beträgt etwa

<sup>20</sup>Internetpräsenz des Unternehmens: [www.shimmersensing.com](http://www.shimmersensing.com), letzter Zugriff 12.06.2014.

50 mm<sup>3</sup> [76].

Für die fünfte Version des Körpersensors ist der Einsatz eines Cortex-M0+ geplant. Besonders geeignet ist die sieben Jahre jüngere *Kinetis KL25 Sub-Family* der Firma Freescale, die über eine integrierte USB-Schnittstelle verfügt (Programmierung und Datenübertragung). Die Mikrocontroller bieten eine 32 b Architektur, einen Betrieb mit Taktfrequenzen von bis zu 48 MHz und 16 kB RAM. Gegenüber dem MSP430xG461x beträgt die Leistungsaufnahme im aktiven Modus nur 0,4 mW/MHz. Integriert in einem 32-Pin QFN-Gehäuse (*Quad Flat No-Lead*) beträgt das Volumen mit 25 mm<sup>3</sup> die Hälfte [50]. Eine Auswahl an technischen Eigenschaften der beiden Mikrocontroller ist in Tabelle 2.2 gegenübergestellt.

### 2.4 Flash-Speicher

Flash-Speicher werden in Körpersensoren als Programmspeicher von Mikrocontrollern (Software und Konfigurationseinstellungen) und als zusätzliche Speicherkomponenten zur Aufzeichnung von Sensormesswerten sowie Parametern benötigt. Die verfügbaren Flash-Speicher lassen sich in NOR- und NAND-Architekturen unterteilen. NOR-Flash-Speicher erlauben einen wahlfreien Lesezugriff auf die parallel geschalteten Speicherzellen. Während eines Schreibzugriffs werden die einzelnen Bits von eins auf null gesetzt. Dieser Vorgang kann während des Löschens nur blockweise rückgängig gemacht werden indem alle Bits des Blocks auf eins gesetzt werden. NAND-Flash-Speicher weisen hingegen in der Regel längere Zugriffszeiten auf, da die Speicherzellen in Reihe geschaltet werden. Weiterhin wird nur eine Datenleitung für Lese- und Schreibzugriffe genutzt, dies reduziert jedoch den Flächenbedarf um etwa 40 %. Der Speicher ist in Blöcken organisiert, die wiederum in Seiten (*Pages*) unterteilt sind. Schreib- und Lesezugriffe sind seitenweise möglich, Löschen jedoch nur blockweise. Während NOR-Flash-Speicher aufgrund des wahlfreien Zugriffs für eingebettete Anwendungen (z.B. Programmspeicher des Mikrocontrollers) geeignet sind, werden NAND-Flash-Speicher angesichts ihres niedrigeren Flächenbedarfs für das sequentielle Speichern und Lesen von größeren Datenmengen eingesetzt [123].

Auf dem BG-V4.2 wird für die Aufzeichnung von Sensormesswerten und Parametern dennoch ein NOR-Flash-Speicher (S25FL064K von Spansion) eingesetzt. Gewählt wurde diese Architektur, um nicht auf RAM und Flash-Speicher des MSP430xG461x zurückgreifen zu müssen. Bei der Verwendung von NAND-Flash-Speichern ist dies für die Zwischenpufferung der zu schreibenden Daten (Seiten) notwendig. Der eingesetzte NOR-Flash-Speicher umfasst 64 Mb und ist für 100000 Schreibzyklen spezifiziert. Abhängig von der gewählten Lesegeschwindigkeit beträgt die Leistungsaufnahme zwischen 12 mW und 36 mW, für das Schreiben und Löschen werden 50 mW benötigt und im Standby-Modus sind es 30  $\mu$ W (Angaben gelten für  $V_{CC} = 3$  V). Das Volumen des Flash-Speichers umfasst etwa 55 mm<sup>3</sup> [147].

### 2.5 Drahtlose Kommunikationsschnittstellen

Sensormesswerte und Parameter können entweder für eine spätere Offline-Analyse in einem Flash-Speicher eines Körpersensors zwischengespeichert werden oder drahtlos an einen Empfänger für eine Online-Ausgabe kommuniziert werden. Gegenüber einer kabelgebundenen Schnittstelle wird die Bewegungsfreiheit des Trägers nicht eingeschränkt. Der Energiebedarf einer drahtlosen Kommunikationsschnittstelle eines Körpersensors ist anteilig

betrachtet jedoch häufig hoch, sodass ein Transceiver mit besonders niedrigem Energiebedarf benötigt wird [156].

### 2.5.1 Stand der Technik

Bei dem Begriff *Transceiver* handelt es sich um ein Kunstwort, welches sich aus *Transmitter* (Sender) und *Receiver* (Empfänger) zusammensetzt. Für Körpersensoren und Körpersensornetzwerke werden häufig das 868 MHz und 2,4 GHz Frequenzband genutzt [31]. Eingesetzt werden dabei Transceiver mit unter anderem den Funktechnologien Bluetooth Classic, Bluetooth Low Energy, ZigBee und ANT [35].

Bluetooth IEEE 802.15.1 ist ein von der Bluetooth Special Interest Group (SIG) entwickelter Standard für eine drahtlose Kommunikation über kurze Distanzen in dem 2,4 GHz *Industrial Scientific Medical (Band)* (ISM)-Frequenzband. Für die Übertragung wird eine Frequenzmodulation mit Gaußfilter, das *Gaussian Frequency-Shift Keying (GFSK)*, angewandt<sup>21</sup>. Zur Reduktion des Einflusses von Interferenzen wird ein Frequenzsprungverfahren mit 79 Kanälen (1 MHz Abstand, bis zu 1600 Wechsel pro Sekunde) eingesetzt [35]. Bezüglich der Sendeleistung erfolgt eine Unterscheidung zwischen drei Sendeleistungsklassen mit 1 mW (0 dBm) bis 100 mW (20 dBm). Für die Klasse 1 mit der höchsten Sendeleistung sind Reichweiten bis zu etwa 100 m möglich. Höchstens acht aktive Bluetooth-Geräte können zusammen ein Netzwerk (*Piconet*) bilden. Für die Entwicklung von Gesundheits- und Fitnessgeräten mit Bluetooth-Kommunikation spezialisierte die SIG ein *Bluetooth Health Device Profile*. Anwendungsbeispiele sind die Datenkommunikation zwischen Blutdruckmessgeräten, Körperwaagen, Blutzuckermessgeräten, Fieberthermometern oder Pulsoximetern sowie Smartphones oder Computern [121].

*Bluetooth Low Energy* (BLE), auch als *Bluetooth Smart* bezeichnet, ist ein optionaler Bestandteil von Bluetooth 4.0 und wurde für kleine Geräte mit sehr niedrigem Energiebedarf entwickelt, dazu wurden entsprechende Optimierungen eingeführt. Ein Transceiver, der ausschließlich BLE unterstützt, ist nicht abwärtskompatibel zu Transceivern der älteren Bluetooth-Standards<sup>22</sup>. Die Datenrate beträgt bis zu 1 Mb/s und eine Kommunikation kann im Gegensatz zu klassischem Bluetooth in wenigen Millisekunden aufgebaut werden [35]. Die Spezifikation nutzt eine Service-basierte Architektur, die auf einem *Attribute Protocol* basiert. Die Kommunikation erfolgt stets strukturiert über ein *Generic Attribute Profile (GATT)*<sup>23</sup>. Die SIG spezialisierte dazu bereits Profile (*Profiles*) und entsprechende Dienste (*Services*) für unter anderem Fieberthermometer, Blutdruck-, Herzfrequenz- und Blutzuckermessgeräte. Weiterhin ist ein Austausch von etwa Zeit-, Batterie- und Ortsinformationen vorgesehen. Auf diese Weise lässt sich eine standardisierte Kommunikation zwischen BLE-kompatiblen Geräten, wie Sportinstrumenten und Smartphones, realisieren. Darüber hinaus ist es möglich, eigene Profile und Dienste zu spezifizieren und bei der SIG zu registrieren.

Für Körpersensornetzwerke ist ZigBee ein weit verbreiteter Kommunikationsstandard in dem 2,4 GHz ISM-Frequenzband (Stand 2011). Verwendet wird eine Phasenmodulation

---

<sup>21</sup>Später erfolgte eine Erweiterung um zwei Methoden zur Phasenmodulation.

<sup>22</sup>Hybride Transceiver, die den abwärtskompatiblen Bluetooth 4.0 Standard und BLE unterstützen, werden als *Smart Ready* bezeichnet.

<sup>23</sup>Für weiterführende Informationen siehe: <https://developer.bluetooth.org/TechnologyOverview/Pages/BLE.aspx>, letzter Zugriff 04.11.2014.

Tabelle 2.3.: Vier bei Körpersensoren in dem 2,4 GHz ISM-Frequenzband verbreitete Funktechnologien (Tabelle gekürzt aus [121]). † Angegeben ist der Energiebedarf für die Übertragung von einem Bit mit der jeweiligen Funktechnologie.

| Technologie           | Bluetooth | BLE       | ZigBee     | ANT       |
|-----------------------|-----------|-----------|------------|-----------|
| Modulation            | GFSK      | GFSK      | O-QPSK     | GFSK      |
| Datenrate             | 1-3 Mb/s  | 1 Mb/s    | 250 kb/s   | 1 Mb/s    |
| Reichweite            | 1-10 m    | 1-10 m    | 10-100 m   | 10-30 m   |
| Verbindungsaufbau     | ≈3 s      | <100 ms   | 30 ms      | -         |
| Stromaufnahme (max.)  | ≈45 mA    | ≈28 mA    | ≈16,5 mA   | ≈22 mA    |
|                       | @3,3 V    | @3,3 V    | @1,8 V     | @3,3 V    |
| Energiebedarf / Bit † | 50 [nJ/b] | 92 [nJ/b] | 119 [nJ/b] | 73 [nJ/b] |

und die erzielte Datenrate beträgt bis zu 250 kb/s bei einer Reichweite von 10 m bis 100 m. Der Protokollstapel (engl. *Stack*) von ZigBee definiert eine Anwendungs-, Sicherheits- und Vermittlungsschicht, die auf den Unterschichten MAC (Sicherheit) und PHY (Bitübertragung) des IEEE Standards 802.15.4 aufbauen. Unterschieden werden drei Arten der Datenkommunikation: von einem Koordinator zu einem Gerät, von einem Gerät zu einem Koordinator und zwischen den Geräten. Die Kommunikation wird dabei vollständig von den Geräten und nicht von dem Koordinator gesteuert (Anforderung und Versenden von Daten), um Energiesparfunktionen effektiv nutzen zu können [35]. Die ZigBee-Allianz hat ein *Personal Health and Hospital Care Profile* für den Datenaustausch zwischen Geräten in Gesundheits- und Fitnessanwendungen spezifiziert.

ANT ist eine proprietäre Funktechnologie, die sich durch einen sehr niedrigen Energiebedarf und kurze Latenzen auszeichnet. Die Kommunikation erfolgt ebenfalls im 2,4 GHz ISM-Frequenzband unter Verwendung von GFSK. Die Reichweite beträgt zwischen 10 bis 30 m. Das ANT-Bündnis besteht aus bis zu 200 Partnern. Anwendungen finden sich bereits in vielen Sport-, Gesundheits- und Fitnessprodukten. Beispiele sind Uhren, Herzfrequenzmesser, Fußsensoren (Laufstrecke), Körperwaagen oder Sensoren für Fahrradcomputer [35].

Zusätzlich zu den beschriebenen Eigenschaften sind die Spitzenstromaufnahme und der Energiebedarf (nJ) pro übertragenem Bit für die vier Funktechnologien in der Tabelle 2.3 gegenübergestellt. Weitere genutzte Funktechnologien sind unter anderem Sensium (Frequenzen 868 MHz und 915 MHz) für Gesundheitsanwendungen und Zarlink (Frequenzbereiche 402 MHz bis 405 MHz und 433 MHz bis 434 MHz) für implantierbare medizinische Geräte [121]. Im Forschungsbereich wurden bereits Transceiver mit signifikant niedrigerem Energiebedarf pro übertragenem Bit realisiert. Ein Beispiel ist ein Transceiver basierend auf der *Impulse Radio Ultra Wideband*-Technologie, der nur 1,64 nJ/b bis 2,18 nJ/b benötigt [41].

### 2.5.2 Evaluation des nRF24L01-Transceivers

Die Körpersensoren BG-V4.1 und BG-V4.2 nutzen den nRF24L01-Transceiver der Firma Nordic Semiconductors, der auf einem Erweiterungsmodul (siehe Abschnitt 2.1.1) mit einer

Chip-Antenne (Verstärkung +0,5 dBi) platziert ist. Auf Seiten des Empfängers ist für die Kommunikation eine Stabantenne mit +9 dBi angeschlossen. Die Stromaufnahme des Transceivers beträgt 11,3 mA bei 3 V und 0 dBm Sendeleistung.

Im Rahmen der vorliegenden Arbeit wurde der nRF24L01-Transceiver zwecks kontinuierlicher Übertragung von Sensormesswerten evaluiert; die notwendige Paketsendefrequenz ist für ein solches Anwendungsszenario signifikant höher als für die Kommunikation von ausgewerteten Sensormesswerten (Parameter)<sup>24</sup>. Ziel ist es, für Sport und Gesundheitsanwendungen das EKG-Signal, die Atemkurve und die Beschleunigungssignale des BG-V4.x, möglichst für mehrere Personen parallel, online visualisieren zu können. Um dies zu erreichen, wurden zunächst in statischen Funkszenarien (siehe Abschnitt 2.5.2.1), in denen Sender und Empfänger während der Messung fixiert waren, der Einfluss von Senderanzahl, Paketsendefrequenz und Paketlänge untersucht. Geprüft wurde dabei der Einsatz von einem und vier in einem Testraum verteilten Empfängern. Es folgte eine Ausweitung der Evaluation auf dynamische Funkszenarien (siehe Abschnitt 2.5.2.2), in denen Sender an Personen angebracht wurden, die auf Laufbändern liefen, Badminton spielten oder den Testraum in alternierender Richtung abschritten. Betrachtet wurde im Rahmen der Evaluation eine unidirektionale Funkkommunikation, bei der der Erhalt eines Datenpakets nicht bestätigt wird (engl. *Handshaking*). Gründe dafür sind ein höherer Datendurchsatz und ein niedrigerer Energiebedarf des Transceivers, da dieser ausschließlich als Sender agiert und Energiesparfunktionen in den Sendepausen genutzt werden können. Die Versuchsergebnisse sind teilweise in [171] veröffentlicht und geben einen Überblick über den zu erwartenden Paketverlust in Abhängigkeit von der gewählten Sendekonfiguration und des Anwendungsszenarios.

### 2.5.2.1 Statische Funkszenarien

Die statischen Tests dienten der Ermittlung des maximalen Datendurchsatzes in Abhängigkeit der im Folgenden vorgestellten Testkonfigurationen und Messanordnungen.

**Testkonfigurationen und Messanordnungen** Die Messungen erfolgten in einem leerstehenden Raum (Länge 11 m und Breite 8,5 m) der Universität Bielefeld. Zunächst wurden in der ersten Messanordnung (siehe Abbildung 2.16), bei der die BG-V4.1 Körpersensoren in einem Kreis um einen Empfänger angeordnet waren, 500 verschiedene Testkonfigurationen analysiert und ein Überblick zu dem Einfluss der Konfigurationsparameter erstellt. Dazu wurde die Paketlänge schrittweise um 5 B von 15 B auf 35 B vergrößert (5 Konfigurationen). Ein Paket bestand dabei aus einer Präambel (1 B), einer Adresse (3 B), einem Prüfwert (1 B CRC) und 10 B bis 30 B für Daten (*Payload*). Für jede der fünf Paketlängen wurde die Paketsendefrequenz schrittweise um 25 Hz von 25 Hz bis auf 250 Hz gesteigert (10 Konfigurationen). Anschließend erfolgte eine schrittweise Erhöhung der Senderanzahl von 5 auf 14 durch Aktivierung von jeweils einem weiteren BG-V4.1 (10 Konfigurationen). Zu jeder der sich daraus ergebenden 500 Konfigurationen wurden 50000 Datenpakete verschickt.

Die beschriebenen Obergrenzen wurden mit einem vorbereitenden Test abgeschätzt, um den maximalen Datendurchsatz bestimmen zu können. Während dieser Vorbetrachtung zeigte

---

<sup>24</sup>Für Parameter kann eine Paketsendefrequenz von 1 Hz ausreichend sein. Für die Übertragung von Sensormesswerten wurden hier Paketsendefrequenzen von 25 Hz bis 250 Hz betrachtet.

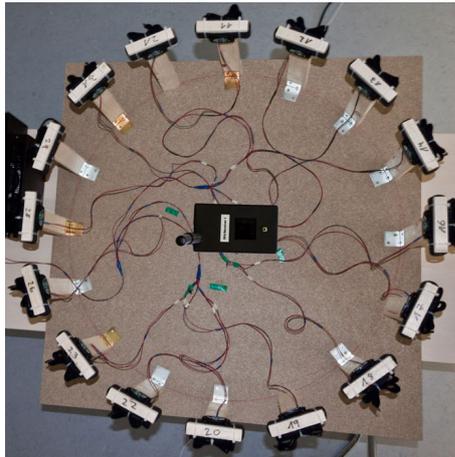


Abbildung 2.16.: Messanordnung 1: Statisches Funkszenario mit um den Empfänger in einem Kreis (Radius 0,5 m) angeordneten Sendern. Die Messung erfolgte mit bis zu 14 aktiven BG-V4.1, die dazu aufrecht an die Standfüße angebracht wurden. Die Platine mit der Chip-Antenne (siehe Abb. 2.1a) wurde dazu jeweils auf die Stabantenne des Empfängers ausgerichtet.

sich weiterhin eine erhöhte Paketverlustrate mit einzelnen Ausreißern von über 60 % für den Zeitraum, in dem die Universität in besonderem Maße von Studierenden und wissenschaftlichen Mitarbeitern besucht war. Dies lässt sich auf Störeinflüsse einer gesteigerten WiFi- und Bluetooth-Kommunikation zurückführen. Die hohe Paketverlustrate von etwa 20 % während des übrigen Zeitraums (siehe Abbildung 2.17) erklärt sich aus der voreingestellten Trägerfrequenz von 2,465 GHz, die zwischen den von WiFi-Routern genutzten Kanälen 11 und 12 liegt<sup>25</sup>. Weiterhin wurde das BG-V4.1 während der Messung, auf der Rückseite liegend, in der Nähe des Empfängers platziert, was zu einer ungünstigen Ausrichtung zwischen Chip- und Stabantenne führte. Die Trägerfrequenz wurde daher auf 2,482 GHz (oberer Außenbereich des Kanals 13) eingestellt und die BG-V4.1 aufrecht an einem Standfuß auf mittlerer Höhe der Stabantenne angebracht (Abstand 25 cm). Der vorbereitende Test zeigte weiterhin, dass sich die Sender teils aufgrund eines zu nahe beieinander liegenden Sendezeitpunkts fortlaufend gegenseitig störten. Bei der gewählten unidirektionalen Funkkommunikation erfolgt keine Aushandlung von Sendezeitpunkten mit festen Zeitschlitz für die verschiedenen Sender (*Broadcast*). Daher wurden dem Startzeitpunkt der einzelnen BG-V4.1 und den Sendezeitpunkten der einzelnen Pakete jeweils eine zufällig generierte Zeitdauer hinzugefügt. Weiterhin traten bei hohen Datenraten vereinzelt Bitfehler auf, die nicht von dem Transceiver durch die Bildung eines Prüfwerts abgewiesen wurden. Für die Tests wurde daher eine zusätzliche zyklische Redundanzprüfung durchgeführt (Polynomlänge 8 b), um diese fälschlicherweise akzeptierten Pakete auszuschließen.

Zusätzlich zu der Evaluation der 500 Konfigurationen in der ersten Messanordnung wurden

---

<sup>25</sup>Mittenträgerfrequenzen: 2,462 GHz und 2,467 GHz, IEEE 802.11b/g mit einer Bandbreite von 20 MHz pro Kanal.

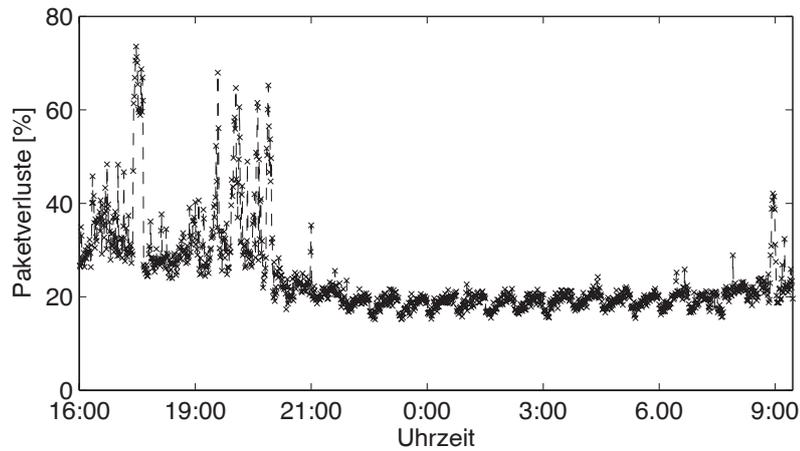


Abbildung 2.17.: Paketverlustrate im zeitlichen Verlauf von 16 Uhr nachmittags bis 9 Uhr morgens eines Senders im Einzeltest (nRF24L01-Transceiver, Trägerfrequenz 2,465 GHz). Das BG-V4.1 wurde neben einem Empfänger auf einem Tisch platziert.

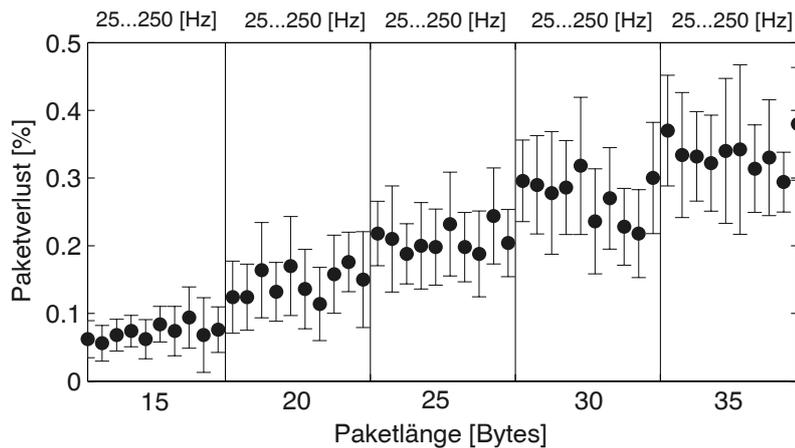


Abbildung 2.18.: Mittlere Paketverlustrate von 14 Sendern im Einzeltest in Abhängigkeit von der Paketlänge (15 B bis 35 B) und der Paketsendefrequenz (25 Hz bis 250 Hz). Die Trägerfrequenz der nRF24L01-Transceiver betrug 2,482 GHz und die Platzierung erfolgte nach Messanordnung 1 (siehe Abbildung 2.16).

in den Versuchen der räumliche Einfluss auf die Paketverlustrate sowie der Einsatz von vier Empfängern in den Ecken des Versuchsraumes untersucht. Sieben bis acht Sender wurden dazu verteilt platziert (siehe Messanordnungen 2 bis 4, Abbildung 2.20).

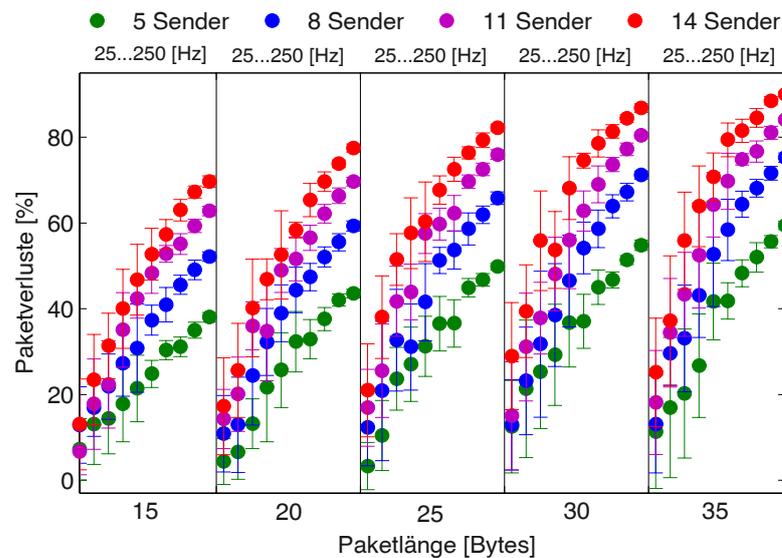


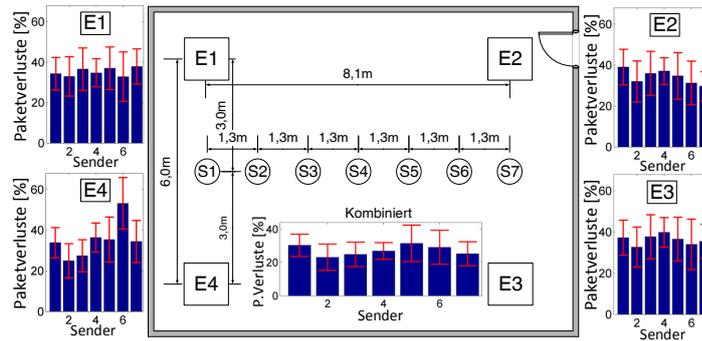
Abbildung 2.19.: Mittlere Paketverlustrate (mit der Standardabweichung als Fehlerbalken) für 5 bis 14 zeitgleich aktive Sender in Abhängigkeit von der Paketlänge (15 B bis 35 B) und der Paketsendefrequenz (25 Hz bis 250 Hz). Die Platzierung erfolgte entsprechend der Messanordnung 1.

**Ergebnisse mit einem Empfänger** Für die Auswertung wurde das Verhältnis aus verlorenen zu gesendeten Paketen auf der Empfängerseite ermittelt. Auf zusätzliche Informationen, wie die Bitfehlerhäufigkeit (engl. *Bit Error Rate*, BER) oder ein Maß für die Empfangsfeldstärke (engl. *Received Signal Strength Indication*, RSSI), konnte nicht zurückgegriffen werden.

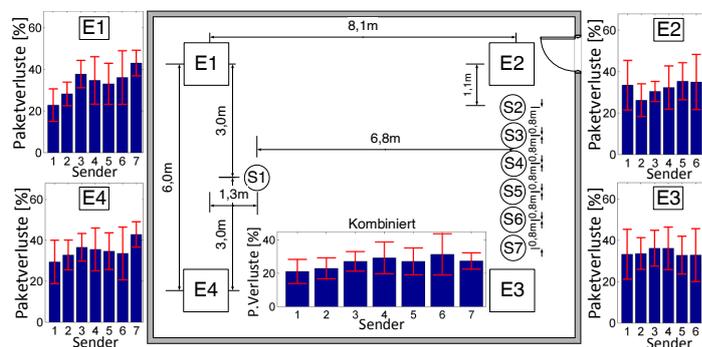
Zunächst wurde der Paketverlust für 14 BG-V4.1 einzeln für die 500 Konfigurationen (mit jeweils 50000 Paketen) in der ersten Messanordnung ermittelt, um die Verluste ohne Interferenz mit den übrigen Sendern abschätzen zu können. Der prozentuale mittlere Paketverlust für die 14 Sender lag bei einer Paketlänge von 15 B bei  $0,076 \pm 0,034\%$  und nahm leicht mit der Paketlänge auf  $0,38 \pm 0,083\%$  zu (siehe Abbildung 2.18).

Im Anschluss wurden die 500 Konfigurationen mit zeitgleich aktiven Gruppen von 5 bis 14 Sendern wiederholt geprüft. Der mittlere prozentuale Paketverlust nahm signifikant mit der höheren Datenrate bedingt durch zusätzliche Sender, der Vergrößerung der Paketlänge und der Steigerung der Paketsendefrequenz zu (siehe Abbildung 2.19). Die höchste in den Tests erreichte Datenrate betrug  $16,3 \pm 2,1$  kB/s, es wurde dabei keine begrenzende Abhängigkeit zu einem der drei Konfigurationsparameter beobachtet. Für die Auswahl einer Konfiguration ist daher sicherzustellen, dass dieses Maximum nicht überschritten wird. Für eine kontinuierliche Übertragung von Sensormesswerten lassen sich bei einem Empfänger somit beispielsweise maximal fünf Sender mit jeweils 100 Hz Paketsendefrequenz und 30 B Paketlänge nutzen.

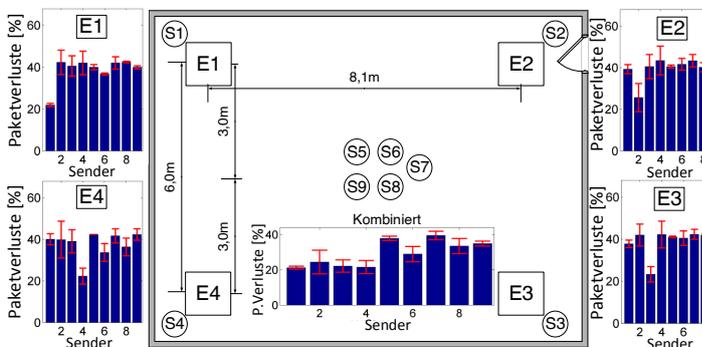
**Ergebnisse mit vier Empfängern** Weiterführend wurde der räumliche Einfluss auf die Paketverlustrate mit 7 bis 9 Sendern untersucht, deren Platzierung verteilt im Testraum



(a) Messanordnung 2: 7 Sender über 8 m in einer Reihe mittig im Raum angeordnet.



(b) Messanordnung 3: 6 Sender in einer Reihe zwischen E2 und E3 angeordnet und ein Sender isoliert auf der gegenüberliegenden Raumseite.



(c) Messanordnung 4: Jeweils 1 Sender direkt neben den 4 Empfängern sowie 5 Sender mittig im Raum gruppiert.

Abbildung 2.20.: Paketverlustraten für drei Messanordnungen mit Sendern (S) verteilt in einem Testraum (Länge 11 m, Breite 8,5 m) und vier Empfängern (E) in den Ecken.

erfolgte (Messanordnungen 2 bis 4, siehe Abbildung 2.20). Die BG-V4.1 wurden auf 100 Hz Paketsendefrequenz und 30 B Paketlänge eingestellt, einer für eine drahtlose Übertragung von Sensormesswerten geeignete Konfiguration<sup>26</sup>. Die Messungen erfolgten mit vier Empfängern (E1 bis E4) in den Ecken des Testraumes, um den Einfluss der räumlichen Distanz zwischen Sender und Empfänger sowie die Möglichkeit einer Kombination mehrerer Empfänger ermitteln zu können. Zur Bestimmung des kombinierten Paketverlusts wurden die empfangenen Pakete der vier Empfänger zusammengeführt.

Die zweite Messanordnung bestand aus sieben Sendern, angeordnet in einer Reihe entlang der Längsseite des Raumes mit einem gleichmäßigen Abstand von 1,3 m zueinander. Die Paketverlustraten variierten zwischen den Sendern, zeigten jedoch keine signifikanten Unterschiede bezüglich der räumlichen Distanz zu den Empfängern (siehe Abbildung 2.20a). Eine Erklärung dafür ist, dass mittels Mehrwegeausbreitung (engl. *Multipath Propagation*) Pakete aufgrund von Reflektionen an den Raumwänden die Empfänger erreichten. Dieser positive Einfluss reduziert sich oder entfällt bei der Nutzung in großen Räumen (z.B. Sporthalle) oder im Außenbereich<sup>27</sup>.

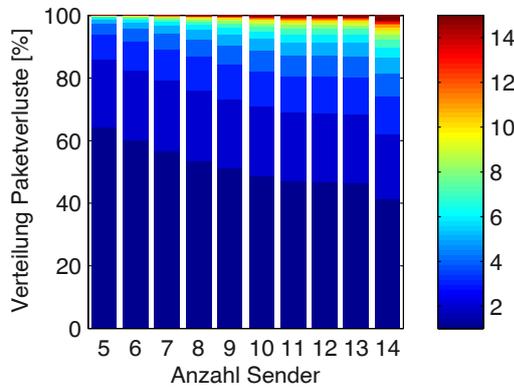
Für die dritte Messanordnung wurden sechs Sender (Abstand zueinander 0,8 m) auf einer der kürzeren Seiten des Testraumes zwischen den Empfängern E2 und E3 platziert und ein Sender (S1) auf der gegenüberliegenden Seite (siehe Abbildung 2.20b). S2 und S7, jeweils in der Nähe von E2 und E3, zeigten eine leicht reduzierte Paketverlustrate. Der Paketverlust des isolierten S1 war für die Empfänger E1 und E4 niedriger als der von den übrigen sechs Sendern. Unterschiede in den Paketverlusten zwischen den sechs Sendern konnten durch die Kombination der vier Empfänger verbessert werden. Die mittlere kombinierte Paketverlustrate betrug 26,6 %, dies waren 7,4 % weniger als die mittlere Paketverlustrate der einzelnen Empfänger.

Die vierte Messanordnung bestand aus vier Sendern S1 bis S4, die verteilt neben den vier Empfängern in einem Abstand von 0,4 m platziert wurden. Zusätzlich wurden weitere fünf Sender S5 bis S9 mittig im Raum gruppiert (siehe Abbildung 2.20c). Während sich die Paketverlustraten von S5 bis S9 untereinander nur geringfügig unterschieden, betrugen die Abweichungen zu S1 bis S4 an den vier Empfängern zwischen 11,2 % und 20,4 %. Die mittlere kombinierte Paketverlustrate von S1 bis S4 war ebenfalls 4,6 % bis 18,4 % niedriger als die Verlustraten von S5 bis S9. Für diese überspitzte Betrachtung des räumlichen Abstands zu einem Empfänger konnte folglich ein signifikanter Einfluss auf die Paketverlustrate beobachtet werden.

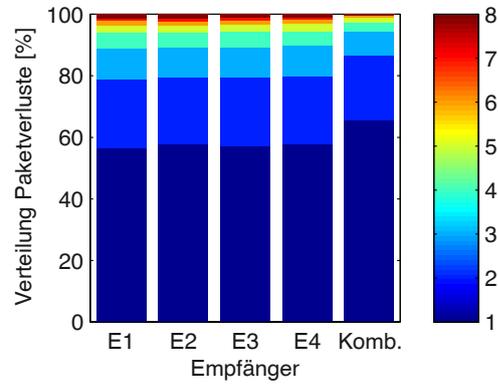
---

<sup>26</sup>Die Datenrate überschreitet zwar die in der ersten Messanordnung ermittelte Obergrenze, es wurden hier jedoch vier räumlich verteilte Empfänger eingesetzt.

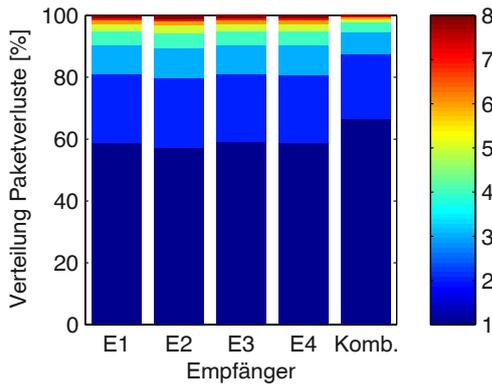
<sup>27</sup>Im Rahmen der Arbeit wurde dies in den Versuchen V2, V3 und in einer Messehalle beobachtet.



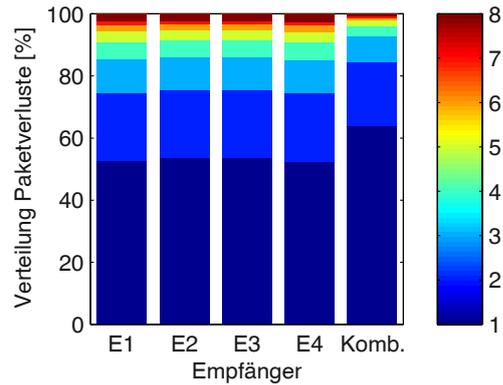
(a) Messanordnung 1: 5 bis 14 Sender und 1 Empfänger.



(b) Messanordnung 2: 7 Sender und 4 Empfänger.



(c) Messanordnung 3: 7 Sender und 4 Empfänger.



(d) Messanordnung 4: 8 Sender und 4 Empfänger.

Abbildung 2.21.: Balkendiagramme mit der prozentualen Verteilung der Anzahl aufeinanderfolgend verlorener Pakete für vier Messanordnungen. Das unterste Segment der Balken (dunkelblau) entspricht einem fehlenden Paket. Das Maximum der aufeinanderfolgenden Paketverluste repräsentiert jeweils das oberste Segment (rot). Die Paketverluste nach Zusammenführung der Daten der vier Empfänger sind mit *Komb.* bezeichnet (Abb. b - d).

**Verteilung der Paketverluste** Für die Übertragung und Darstellung von Sensorsignalen ist es wichtig, den Zeitpunkt und die Anzahl an aufeinanderfolgenden fehlenden Sensormesswerten zu kennen, um beispielsweise geeignete Interpolationsmethoden anwenden oder den Nutzer über Empfangsprobleme informieren zu können. In den Einzeltests der 14 Sender (Messanordnung 1) waren es in 99,7 % der Fälle Verluste von nur einem Paket; maximal fehlten zwei aufeinanderfolgende Pakete. Mit mehreren gleichzeitig aktiven Sendern (Messanordnung 1 bis 4) erhöhte sich die Anzahl der aufeinanderfolgenden fehlenden Pakete (siehe Abbildung 2.21). Eine Kombination der Pakete von vier Empfängern reduzierte dieses Problem.

### 2.5.2.2 Dynamische Funkszenarien

Im Folgenden sind die Ergebnisse aus den dynamischen Funkszenarien, in denen die Sender an einer sich im Testraum bewegenden Person angebracht waren, dargestellt. Bewegungen einer Person [13] sowie die Dämpfung von elektromagnetischen Wellen durch den menschlichen Körper [9; 140] beeinflussen eine drahtlose Kommunikation. Dazu wurden die folgenden dynamischen Szenarien gewählt und die Paketverluste ermittelt.

**Laufbandversuch V1.1** In der fünften Messanordnung wurde ein Empfänger mittig vor drei Laufbändern platziert. Die Messung erfolgte im Fitness- und Gesundheitszentrum der Universität Bielefeld mit drei Probanden, die nebeneinander auf den Laufbändern gingen und liefen (Versuch V1.1, siehe Anhang A.1.1). Die Transceiver der drei BG-V4.1 wurden auf eine Paketsendefrequenz von 75 Hz bei einer Paketlänge von 35 B eingestellt. Die Paketverlustrate betrug 5,3 % für Sender 1, 1,8 % für Sender 2 und 6,0 % für Sender 3. Der Vergleich der Paketverlustraten im zeitlichen Verlauf des Versuchs, ermittelt für Zeitfenster von 30 s Länge<sup>28</sup>, ergab folgende Standardabweichungen sowie minimale und maximale Verlustraten (siehe auch Abbildung 2.22a):

- Sender 1:  $\pm 1,8\%$  [1,7 % - 9,2 %]
- Sender 2:  $\pm 0,6\%$  [0,7 % - 4,3 %]
- Sender 3:  $\pm 1,8\%$  [2,1 % - 11,3 %]

Für diese niedrigen Paketverlustraten reichte bereits eine lineare Interpolation zwecks Visualisierung der Sensormesswerte im Signalmonitor aus.

**Badminton** Für die sechste Messanordnung wurde ein Empfänger seitlich unterhalb des Netzes eines Badminton-Spielfelds in einer Sporthalle mit sechs Spielfeldern<sup>29</sup> platziert und der Paketverlust während eines Doppels mit vier Spielern über eine Spieldauer von etwa 35 min ermittelt. Zwei gegnerische Spieler wurden dabei mit jeweils einem BG-V4.1, angebracht auf einem Brustgurt, ausgestattet. Die Übertragung der Sensormesswerte erfolgte mit einer Paketsendefrequenz von 100 Hz bei einer Paketlänge von 22 B.

---

<sup>28</sup>Die Paketverluste wurden gleitend mittels einer Fensterfunktion (Länge des Zeitfensters 30 s) und sich zu 50 % überlappenden Fenstern berechnet.

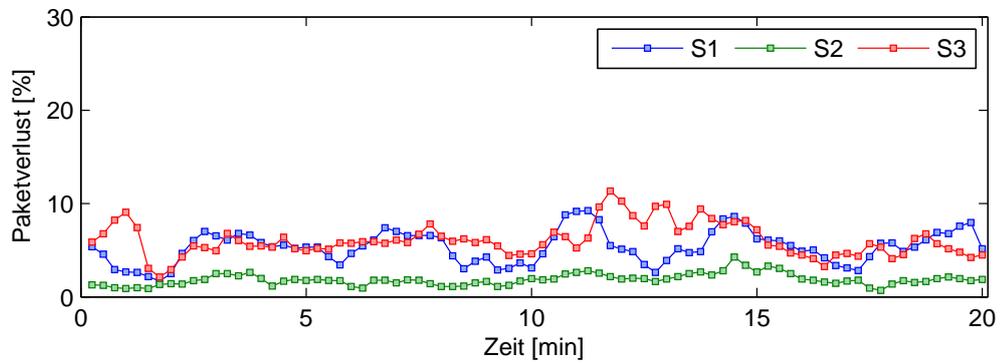
<sup>29</sup>Die Aufzeichnung erfolgte am 17.12.2010 im Sportland Dornberg in Bielefeld.

Die Paketverlustrate betrug 9,7 % für Sender 1 und 4,9 % für Sender 2. Die Betrachtung der Paketverluste im zeitlichen Verlauf über 30 s lange Zeitfenster (50 % Überlappung) ergab für beide Sender eine Standardabweichung von  $\pm 3,7\%$ . Für Sender 1 reichten die Verluste von 3,6 % bis 20,6 %, bei Sender 2 waren es 0,5 % bis 18,7 % (siehe auch Abbildung 2.22b).

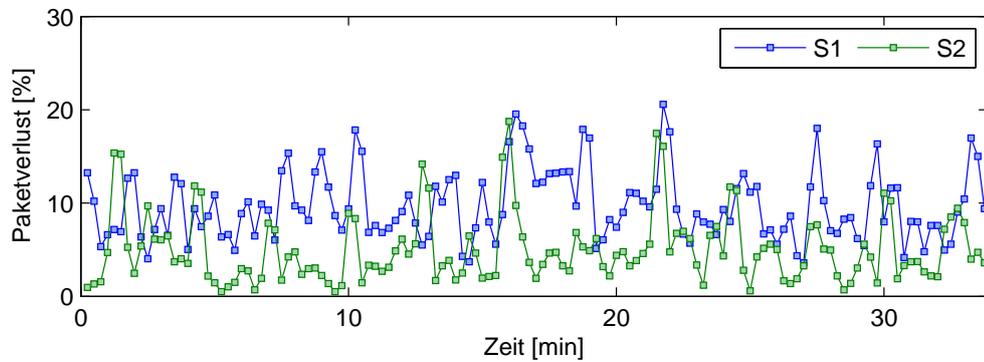
Im Vergleich zu dem Laufbandversuch sind die Paketverluste hier höher. Gründe dafür sind insbesondere die Hallengröße (fehlende Mehrwegausbreitung) sowie das hochdynamische Szenario mit kontinuierlichen Distanzänderungen zwischen den Sendern und dem Empfänger. Weiterhin waren die Spieler teils vom Empfänger abgewandt oder wurden durch den zweiten Mitspieler verdeckt (Dämpfung durch menschlichen Körper). Im Laufbandversuch hingegen liefen die Probanden nebeneinander dem Empfänger zugewandt; der Abstand zwischen Sendern und Empfänger betrug dabei nur bis zu 2 m.

**Abschreiten in alternierender Richtung** Die siebte Messanordnung befand sich im Testraum, in dem auch die Evaluation der statischen Funkszenarien stattfand. Dazu wurden die beiden Empfänger mittig zur Querseite des Raumes in der Nähe der Wände platziert. Der Abstand zwischen den Empfängern betrug 8,1 m. Ein Proband wurde mit einem Sender (BG-V4.1 angebracht auf einem Brustgurt) ausgestattet und schritt die Strecke zwischen den beiden Empfängern ab, die Richtungswechsel erfolgten jeweils vor den Empfängern. Ziel war es, den Einfluss der beobachteten Abschattung der Funkkommunikation durch den menschlichen Körper sowie den Vorteil eines zweiten Empfängers (ohne Verdeckung) abschätzen zu können.

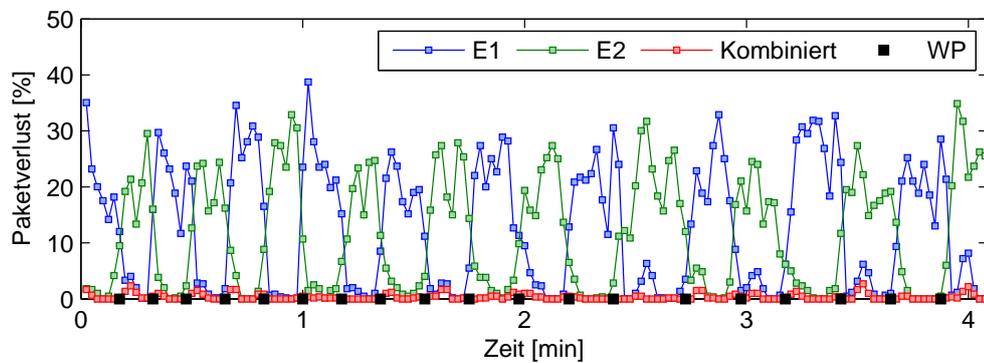
Bei einer Paketsendefrequenz von 200 Hz und einer Paketlänge von 22 B betrug der Paketverlust an den Empfängern im Mittel über die gesamte Messung 12,6 % (E1) und 11,6 % (E2). Betrachtet über 3 s lange Zeitfenster (50 % Überlappung) stieg der Verlust während des abgewandten Weggehens vom Empfänger auf etwa 15 % bis 35 % an. Zugewandt zum Empfänger traten hingegen nur sehr geringe Paketverluste auf (siehe auch Abbildung 2.22c). Die Standardabweichung der Paketverlustrate innerhalb der drei Sekunden Zeitfenster betrug daher hohe  $\pm 11,3\%$  (E1) und  $\pm 10,2\%$  (E2). Der höchste Paketverlust lag bei 38,7 % (E1) und 34,9 % (E2), der niedrigste war für beide Empfänger null. Eine Kombination von zwei Empfängern reduzierte die mittlerer Paketverlustrate auf 0,4 % bei einer Standardabweichung von  $\pm 0,5\%$  und einem maximalen Verlust von nur 2,7 %.



(a) Messanordnung 5: Laufbandversuch V1.1 mit einem Empfänger und drei Sendern.



(b) Messanordnung 6: Badminton (Doppel) mit einem Empfänger seitlich unterhalb des Netzes.



(c) Messanordnung 7: Abschreiten der Strecke zwischen zwei, mittig an beiden Enden des Testraums (Abstand 8,1 m) platzierten Empfängern. WP bezeichnet die Wendepunkte des Richtungswechsels.

Abbildung 2.22.: Paketverlustraten in drei dynamischen Funkszenarien.

### 2.5.2.3 Zusammenfassung und Ausblick

Bestimmt wurden die Paketverluste des nRF24L01-Transceivers, integriert auf dem BG-V4.x, in fünf statischen und drei dynamischen Messanordnungen. Mit der ersten Messanordnung wurden 500 Konfigurationen geprüft, die verschiedene Senderanzahlen, Paketsendefrequenzen und -längen umfassten. In den Einzeltests der Sender mit einem Empfänger betrug die höchste mittlere Paketverlustrate nur  $0,38 \pm 0,083$  %, sie stieg jedoch mit mehreren zeitgleich aktiven Sendern an. Es konnte keine Abhängigkeit zu einem der drei Konfigurationsparameter beobachtet werden; der höchste erreichte Datendurchsatz betrug  $16,3 \pm 2,1$  kB/s. Die statischen Messungen zeigten weiterhin, dass ein Wechsel der Trägerfrequenz von 2,465 GHz auf 2,482 GHz signifikant die beobachteten Störeinflüsse von WiFi- und Bluetoothkommunikation im Testraum reduzieren konnte. Weiterhin wurde eine zusätzliche Absicherung der Datenpakete mittels eines CRC eingeführt, um Bitfehler, die beim Einsatz mehrerer Sender und bei Datenraten im Bereich der ermittelten Obergrenze vereinzelt beobachtet wurden, erkennen zu können. Die Messungen mit vier Empfängern und im Testraum verteilten Sendern zeigten einen (leichten) räumlichen Einfluss der Platzierung auf die Paketverlustrate; teils war dieser jedoch durch den Einfluss der Mehrwegeausbreitung überlagert. Die Zusammenschaltung mehrerer Empfänger reduzierte die Paketverlustrate sowie die Anzahl an aufeinanderfolgenden verlorenen Paketen gegenüber dem Einsatz von nur einem Empfänger. Die Erweiterung der Messungen auf dynamische Funkszenarien ergab in einem Laufbandversuch mit drei aktiven Sendern eine niedrige mittlere Paketverlustrate von nur 1,8 % (S2) und höchstens 6 % (S3). Für die Aufzeichnung zweier Badmintonspieler betrugen die Paketverlustraten 4,9 % und 9,7 %. Die leicht höheren Verluste lassen sich mit der Hallengröße (fehlende Mehrwegeausbreitung), dem Abwenden vom Empfänger und der Abschirmung durch den zweiten Mitspieler erklären. Durch ein alternierendes Abschreiten der Strecke zwischen zwei Empfängern wurde der Einfluss der Abschirmung durch den menschlichen Körper gezielt betrachtet, wobei die Paketverlustraten auf 15 % bis 35 % an dem jeweils durch den Körper verdeckten Empfänger anstiegen. Für diese Messanordnung konnte die Zusammenschaltung der beiden Empfänger die Verluste signifikant auf 0,4 % reduzieren. Der nRF24L01-Transceiver ist für eine kontinuierliche Übertragung von Sensormesswerten im Innenbereich geeignet. Fehlende Pakete können in der Regel mittels Interpolation ausgeglichen werden. Alternativ ist in Abhängigkeit des Anwendungsszenarios zu prüfen, ob ein zweiter Empfänger eingesetzt werden kann.

Der Einsatz in großen Hallen (z.B. im Mannschaftssport) zur Übertragung von Sensormesswerten und Parametern muss weiterführend untersucht werden. Problematisch ist eine hohe Anzahl an Sendern (z.B. 14 im Handball) in Verbindung mit einer niedrigen maximalen Sendestärke von 0 dBm des Transceivers. Ein Lösungsansatz besteht in der Nutzung mehrerer, entlang des Spielfelds verteilter Empfänger. Weiterhin können Paketkollisionen der verschiedenen Sender durch die Nutzung zusätzlicher Trägerfrequenzen reduziert werden. Die Empfänger benötigen dazu zusätzliche auf unterschiedliche Trägerfrequenzen eingestellte Transceiver. Für die lückenlose Aufzeichnung von Sensormesswerten, beispielsweise zwecks Datenakquise zur Entwicklung von Algorithmen zur Parameterbestimmung, wurde auf dem BG-V4.2 zusätzlich ein Flash-Speicher integriert.

Für die fünfte Version des Körpersensors der AG K&S ist der Einsatz des Transceivers BLE112

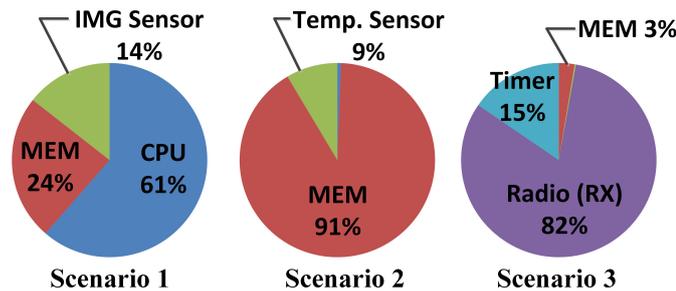


Abbildung 2.23.: Leistungsaufnahme (anteilig) der Komponenten von Sensorknoten für drei Anwendungsszenarien (Abbildung aus [94]).

der Firma Bluegiga Technologies geplant. BLE bietet den Vorteil, Parameter standardisiert mittels der GATT-Spezifikation austauschen zu können. Auf diese Weise lässt sich beispielsweise die mit dem Körpersensor ermittelte Herzfrequenz über das *Heart Rate Profile* und *Service* an ein Endgerät (z.B. Smartphone oder Tablet) senden und in Sport- oder Wellnessanwendungen, die die GATT-Spezifikation implementieren, integrieren.

## 2.6 Energieversorgung

Der folgende Abschnitt behandelt die Leistungsaufnahme von Körpersensoren. Es wird dessen Abhängigkeit von Anwendungsszenarien aufgezeigt und verfügbare Energiespeicher vorgestellt. Weiterhin erfolgt ein Ausblick auf Möglichkeiten des *Energy Harvesting* im Kontext von Körpersensoren.

### 2.6.1 Leistungsaufnahme

Die Leistungsaufnahme eines Körpersensors wird bestimmt durch die Aktiv-, Standby- oder Powerdown-Zeiten seiner einzelnen Komponenten (Sensoren, Mikrocontroller, Flash-Speicher, Transceiver, etc.). Das Anwendungsszenario definiert dabei Zeitpunkt und Dauer des Betriebs in den unterschiedlichen Betriebsmodi und nimmt somit direkten Einfluss auf die Leistungsaufnahme eines Körpersensors.

Y. Lee u.a. bestimmten anteilig die Leistungsaufnahme von typischen Komponenten eines Körpersensors für drei mögliche Anwendungsszenarien [94]. Das erste Szenario stellt eine Überwachung mittels eines Bildsensors (IMG-Sensor) dar, der alle fünf Sekunden eine Aufnahme macht, die von einem Mikroprozessor auf Unterschiede zur vorherigen Aufnahme hin untersucht wird. Das Ergebnis wird an eine Basisstation drahtlos kommuniziert. Aufgrund des hohen Rechenaufwands (100 k Instruktionen) dominiert der Mikroprozessor die Leistungsaufnahme (siehe Abbildung 2.23). Im zweiten Szenario wird alle 10 min die Temperatur gemessen, gespeichert (1 kB RAM) und einmal pro Stunde drahtlos kommuniziert (100 b). Die Anwendung umfasst nur 2 k Instruktionen und der Mikroprozessor verweilt im Vergleich zu Szenario 1 nur kurze Zeit im aktiven Modus. Die Leistungsaufnahme der Temperaturüberwachung wird von Leckströmen des Speichers dominiert. Das dritte Szenario erweitert die Temperaturüberwachung um eine symmetrische drahtlose Kommunikation zwischen

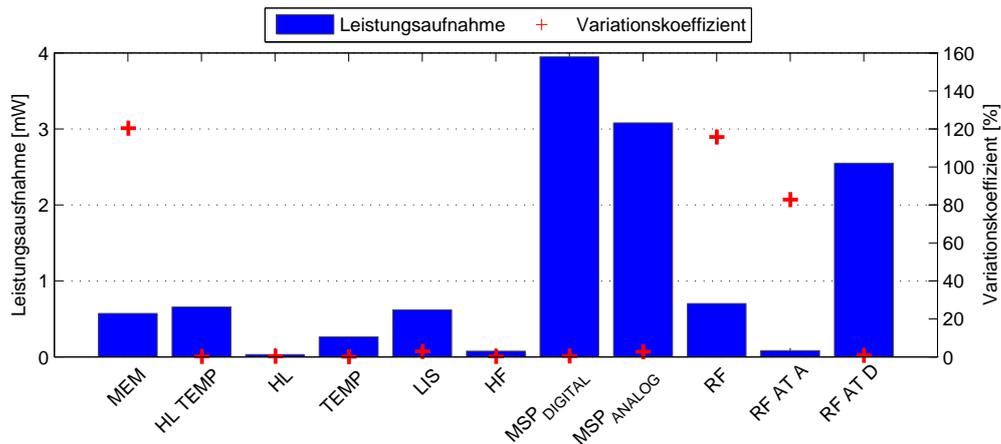


Abbildung 2.24.: Leistungsaufnahme der Komponenten des BG-V4.2 während der Speicherung und Übertragung von Sensormesswerten (Abbildung aus [70, S.46]). Dargestellte Komponenten: Flash-Speicher (MEM), Hautleitwert (HL), Temperatur (TEMP), Beschleunigungssensor (LIS), Herzfrequenzerkennung ohne Analoganteil des EKGs (HF), Mikrocontroller (MSP), Transceiver (RF) mit Analog- (A) und Digital- (D) Anteilen.

Sensorknoten anstelle einer zentralen Basisstation. Dazu muss der Transceiver in den Empfangsmodus versetzt werden; da dies aufgrund der verhältnismäßig hohen Leistungsaufnahme von 1,64 mW nicht kontinuierlich möglich ist, wurde ein *Timer* (8,6 nW) eingesetzt, der die Aktivierung steuert. Als Folge dominieren im dritten Szenario der Transceiver (Empfangsmodus) und der *Timer* die Leistungsaufnahme.

**Leistungsaufnahme des BG-V4.2** Die Leistungsaufnahme der Komponenten des BG-V4.2 wurde im Rahmen der Bachelorarbeit von T. Hörmann theoretisch abgeschätzt und experimentell anhand eines Messboards (BGM) ermittelt (siehe Ergebnisübersicht [70, S.49]). Gewählt wurde dabei ein Szenario mit Speicherung (interner Flashspeicher) und drahtloser Übertragung von Sensormesswerten. Die Paketgröße betrug 22 B und die Speicher- sowie Paketsendefrequenz 200 Hz. Für jeden Messpunkt des BGM wurden jeweils 4000 Messungen vorgenommen; deren Mittelwerte und Variationskoeffizienten sind in der Abbildung 2.24 dargestellt. Anteilig entfiel die höchste Leistungsaufnahme auf den MSP430xG461x Mikrocontroller gefolgt von dem Transceiver (RF).

Das BGM wurde im Anschluss an die Bachelorarbeit genutzt, um die Leistungsaufnahme exemplarisch für die folgenden drei Anwendungsszenarien zu ermitteln:

- Szenario 1: Hohe Aufzeichnungsfrequenz (100 Hz) für eine Offline-Analyse von Sensormesswerten (Schwerpunkt: hohe zeitliche Auflösung, z.B. Aufzeichnungen in der Sportdiagnostik unabhängig vom Empfangsbereich).
- Szenario 2: Reduzierte Aufzeichnungsfrequenz (25 Hz) für eine Offline-Analyse von

Tabelle 2.4.: Leistungsaufnahme und Betriebsdauer ermittelt mit dem Messboard BGM für drei Anwendungsszenarien. † Die Kapazität des Flash-Speichers war vor der Kapazität der Batterie erschöpft.

|                                 | Szenario 1  | Szenario 2  | Szenario 3  |
|---------------------------------|-------------|-------------|-------------|
| Abtastfreq. [Hz]                | 200         | 125         | 125         |
| Aufzeichnungsfreq. [Hz]         | 100         | 25          | 25          |
| Funkfreq. [Hz]                  | –           | –           | 100         |
| Leistungsaufnahme (USB) [mW]    | 28,7 ± 17,8 | 16,0 ± 14,0 | 21,9 ± 14,6 |
| Leistungsaufnahme (CR2025) [mW] | 24,2 ± 14,1 | 13,9 ± 8,9  | 20,1 ± 9,8  |
| Betriebsdauer (CR2025) [min]    | 108 †       | >699 †      | 314         |

Sensormesswerten (Schwerpunkt: lange Aufzeichnungsdauer, z.B. Aktivitätsmonitoring im Arbeitsalltag).

- Szenario 3: Hohe Paketsendefrequenz (100 Hz) für eine Online-Analyse von Sensormesswerten (Schwerpunkt: hohe zeitliche Auflösung, z.B. Sportdiagnostik). Zusätzliche Speicherung von Sensormesswerten (25 Hz), geeignet für eine Offline-Analyse.

Als Paketgröße wurden 22 B gewählt und der Mikrocontroller bei 8 MHz betrieben. Während der Leerlaufzeiten wurde der Mikrocontroller in den Energiesparmodus LPM1 (*Low-Power Mode 1*, [76, S.12]) versetzt. Die Ermittlung der Leistungsaufnahme erfolgte für alle drei Szenarien mit einer spannungsstabilisierten USB-Stromversorgung sowie einer CR2025-Knopfzelle der Firma Renata (Ausgangsspannung 3 V, Kapazität 165 mAh)<sup>30</sup>, die Ergebnisse sind in Tabelle 2.4 dargestellt. Die Leistungsaufnahme (USB-Stromversorgung) betrug für das erste Szenario 28,7 ± 17,8 mW und reduzierte sich in dem zweiten Szenario bei verringerter Abtast- und Aufzeichnungsfrequenz auf 16,0 ± 14,0 mW. Die zusätzliche Nutzung des Transceivers (nur Senden) erhöhte die Aufnahme um etwa 6 mW gegenüber dem zweiten Szenario. In den ersten beiden Szenarien war der Flash-Speicher vollgeschrieben bevor die Kapazität der Batterie erschöpft war, sodass die Angaben als Mindestbetriebsdauer zu interpretieren sind. Für Szenario 3 wurde mit einer Knopfzelle eine Betriebsdauer von 314 min erzielt.

Weiterführend wird im Abschnitt 4.2.6.3 diskutiert, ob es bezüglich des Körpersensors energetisch sinnvoller ist, die Herzfrequenz und Laufgeschwindigkeit auf dem MSP430FG4618-Mikrocontroller zu bestimmen (drahtlose Übertragung der Parameter) oder mittels einer externen Signalverarbeitung auf beispielsweise einem Desktop-Computer (Übertragung der Sensormesswerte).

### 2.6.2 Energiespeicher

Energiespeicher sichern die Versorgung von Körpersensoren mit elektrischer Energie. Verbreitet ist der Einsatz von entweder nicht-wiederaufladbaren (Primärelementen) oder wiederaufladbaren Batterien (Sekundärelementen, Akkumulatoren). Im Nachfolgenden werden

<sup>30</sup>Zu beachten ist, dass der kontinuierliche Entladestrom oberhalb der Spezifikation von 3,0 mA liegt. Dies kann dazu führen, dass nicht die vollständige Kapazität ausgeschöpft werden kann.

Tabelle 2.5.: Überblick über Eigenschaften von Primär- und Sekundärelementen. † Sekundärelemente (LP-402025-1S-3 und LP-443440-1S-3) der Firma BAK-Technology. ‡ Angaben gelten für den höheren Kapazitätswert.

|  | Primärelemente    |                          | Sekundärelemente |          |
|--|-------------------|--------------------------|------------------|----------|
|  | CR2032/CR2025     | Microzelle               | klein †          | mittel † |
| Zellchemie                             | Lithium-Mangan    | Alkali / Lithium-Eisens. | Lithium-Polymer  |          |
| Volumen [cm <sup>3</sup> ]             | 1,0 / 0,8         | 3,8                      | 2,0              | 5,9      |
| Typ. Spannung [V]                      | 3                 | 1,5                      | 3,7              |          |
| Max. Entladestrom [mA]                 | 3 (Spitze 15)     | >100                     | 310              | 1120     |
| Max. Ladestrom [mA]                    | –                 | –                        | 155              | 560      |
| Typ. Kapazität [mAh]                   | 200-240 / 140-170 | 400-1260                 | 165              | 600      |
| Gewicht [g]                            | 3 / 2,5           | 8-12                     | 4                | 13       |
| Energiedichte [MJ · m <sup>-3</sup> ]  | 2578 / 2336 ‡     | 1791                     | 1112             | 1365     |
| Energiedichte [MJ · kg <sup>-1</sup> ] | 0,86 / 0,73 ‡     | 0,85 ‡                   | 0,55             | 0,61     |

Primär- und Sekundärelemente vorgestellt mit Gewichten zwischen 2,5 g und 13 g und Volumina von 0,8 cm<sup>3</sup> bis 5,9 cm<sup>3</sup>.

**Primärelemente** Der Einsatz von Primärelementen in Form von nicht-wiederaufladbaren Mignon-, Micro- oder Rundzellen (auch Knopfzellen) ist bei Körpersensoren im kommerziellen Bereich und in der Forschung verbreitet. Gegenüber Sekundärelementen bieten sie eine höhere Energiedichte bei niedrigeren Anschaffungskosten [125].

Mignon- und Microzellen werden häufig als Alkali-Mangan- (umgangssprachlich Alkaline) oder Lithium-Eisensulfid-Zellen realisiert. Die Microzellen bieten Kapazitäten von bis zu etwa 1260 mAh bei einem Volumen von 3,8 cm<sup>3</sup> und 7,6 g Gewicht (z.B. Energizer L92). Das Äquivalent als Mignonzelle (Energizer L91) erreicht eine Kapazität von 3000 mAh bei einem Volumen von 8 cm<sup>3</sup> und 14,5 g Gewicht (siehe auch Tabelle 2.5).

Lithium-Rundzellen (CR) finden typischerweise Einsatz für den Betrieb von Körpersensoren mit einem geringen Volumen und Gewicht und deren Stromaufnahme nur wenige Milliampere beträgt. CR2032-Rundzellen mit etwa 1 cm<sup>3</sup> Volumen bieten dazu Kapazitäten zwischen 200 mAh und 240 mAh und wiegen nur 3 g. CR2025-Zellen sind 0,5 g leichter und das Volumen beträgt 0,8 cm<sup>3</sup>, dafür reduziert sich die Kapazität auf 140 mAh bis 170 mAh. Darüber hinaus sind andere Zelltypen verfügbar (z.B. Alkali-Mangan, Silberoxid-Zink und Zink-Luft). Gegenüber Mignon- oder Microzellen sind CR20xx-Knopfzellen für kontinuierlich niedrige Entladungsströme im Milliampere-Bereich konzipiert. CR2025-Knopfzellen der Firma Renata sind beispielsweise bis maximal 3 mA spezifiziert, einzelne Hersteller (z.B. Ansmann) geben 15 mA für kurzzeitige Spitzenströme (*Pulse Discharge*) an.

**Sekundärelemente** Sekundärelemente sind wiederaufladbare Batterien (Akkumulatoren). Sie stellen einem Körpersensor vorab aufgeladene Energie zur Verfügung und können durch Methoden des *Energy Harvesting* auch während des Betriebs nachgeladen werden. Ver-

füßbar sind Akkumulatortypen basierend auf unter anderem Lithium-Ionen, Nickel-Cadmium- oder Nickel-Metallhydrid-Zellchemie.

Für Körpersensoren werden häufig Lithium-Polymer-Akkumulatoren (Gruppe der Lithium-Ionen-Akkumulatoren) eingesetzt. Kleine Ausführungen mit 165 mAh Kapazität erreichen dabei ein Volumen von etwa  $2\text{ cm}^3$  und 4 g Gewicht. Für Kapazitäten von 600 mAh sind es knapp  $6\text{ cm}^3$  und 13 g. Im Smartphone-Bereich werden Akkumulatoren mit deutlich größeren Kapazitäten (2800 mAh, Galaxy S5 von Samsung) bei jedoch auch höherem Volumen und Gewicht eingesetzt. Ein Vorteil von Lithium-Polymer-Akkumulatoren sind hohe kontinuierliche Lade- und Entladeströme von mehreren hundert Milliampere.

### 2.6.3 Energy Harvesting

Unter *Energy Harvesting* wird die Umwandlung und Speicherung von Energie aus beispielsweise Bewegungen, Temperaturdifferenzen oder Licht in elektrische Energie verstanden. Körpersensoren nutzen derzeit vornehmlich Primär- oder Sekundärelemente für ihren Betrieb. Der Einsatz von Methoden des *Energy Harvesting* kann zukünftig die Möglichkeit bieten, kleinere Gehäuse einzusetzen, längere Betriebszeiten oder einen autonomen Betrieb zu erreichen; einen Überblick diesbezüglich gibt [155]. Problematisch ist, dass häufig nur geringe „Ertragsmengen“ an elektrischer Energie pro Zeit und Fläche anfallen. Daher erfolgt die Energieumwandlung zunächst über einen verhältnismäßig langen Zeitraum, um anschließend ein kurzzeitiges Auslesen, Verarbeiten und Kommunizieren von Sensorinformationen zu ermöglichen.

Während im industriellen Umfeld durch Vibrationen und Bewegungen etwa  $100\text{ }\mu\text{W}/\text{cm}^2$  an elektrischer Leistung möglich sind, sind es am menschlichen Körper nur etwa  $4\text{ }\mu\text{W}/\text{cm}^2$ . Unter Ausnutzung von Temperaturdifferenzen steigt die Leistung auf  $25\text{ }\mu\text{W}/\text{cm}^2$  (siehe Tabelle 2.6). Weitere vom menschlichen Körper unabhängige Quellen sind unter anderem das Umgebungslicht oder Energie aus öffentlichen Funknetzen [127; 155].

Derzeitig ist *Energy Harvesting* Gegenstand von Forschungsprojekten. Zwei Beispiele sind das europäische Projekt Piezotex (Entwicklung von Fasern mit piezoelektrischen Eigenschaften)<sup>31</sup> und das BMBF geförderte Projekt TePat (Erfassung von Bewegungsenergie mittels Piezoelementen und Entwicklung textiler Mikrosysteme)<sup>32</sup>. Das Projekt *Sole Power*, eine Ausgründung der *Carnegie Mellon University* (Pittsburgh), strebt an, mit Piezokristallen, integriert in Schuhsohlen, den Akkumulator eines Smartphones bereits nach 4 km bis 8 km Gehen aufgeladen zu haben. Im Juli 2013 wurde die dazu nötige finanzielle Fördermenge erfolgreich eingeworben<sup>33</sup>, inzwischen ist eine Vorbestellung möglich (Stand Juli 2015).

*Energy Harvesting* bietet weiterhin zukünftig die Möglichkeit, implantierte biomedizinische Geräte mit elektrischer Energie zu versorgen. Beispielsweise lässt sich die in Vibrationen des Herzschlags enthaltene Energie mittels piezoelektrischen Elementen in elektrische Energie umwandeln und kann auf diese Weise den autarken Betrieb eines Herzschrittmachers

---

<sup>31</sup>Piezotex, [www.mnt-era.net/mnt-era-net-success-stories/2010-45-Piezotex.pdf](http://www.mnt-era.net/mnt-era-net-success-stories/2010-45-Piezotex.pdf), letzter Zugriff 04.07.2014.

<sup>32</sup>TePat, Förderkennzeichen 16SV4054, <http://edok01.tib.uni-hannover.de/edoks/e01fb13/77239038X.pdf>, letzter Zugriff 04.07.2014.

<sup>33</sup>Siehe Kickstarter, [www.kickstarter.com/projects/764467377/solepower-power-by-walking-0](http://www.kickstarter.com/projects/764467377/solepower-power-by-walking-0), letzter Zugriff 04.07.2014.

Tabelle 2.6.: Abschätzung von Energy Harvesting-Möglichkeiten nach [127].

| Quelle               | Elektrische Leistung / Fläche [ $\mu\text{W}/\text{cm}^2$ ] |
|----------------------|---|
| Vibrationen/Bewegung | Mensch: 4 und Industrie: 100                                |
| Temperaturdifferenz  | Mensch: 25 und Industrie: 1000 - 10000                      |
| Licht                | Innen: 10 und Außen: 10000                                  |
| Funknetze            | GSM: 0,1 und WiFi: 1  |

ermöglichen. Zusätzlich zu Kosteneinsparungen im Gesundheitswesen würden somit die Belastungen des Eingriffs zwecks Batteriewechsel für den Patienten entfallen [10].



# 3 Physiologische Parameter

Im folgenden Kapitel wird die Bestimmung der physiologischen Parameter Herzfrequenz (HF), Herzfrequenzvariabilität (HFV), Atemfrequenz und Hauttemperatur aus den Sensormesswerten des Körpersensors BG-V4.2 beschrieben. Weiterhin werden Einsatzmöglichkeiten der Parameter aufgezeigt.

## 3.1 Herzfrequenz (HF) und Herzfrequenzvariabilität (HFV)

Eine Analyse der HF und HFV findet vielfältig Anwendung in der Sportwissenschaft sowie im Gesundheits- und Medizinbereich [1; 71; 107]. Eine Bestimmung der HF ist unter anderem auf Grundlage eines Einkanal-EKGs möglich. Dazu erfolgt zunächst eine Segmentierung des EKGs in einzelne Herzschläge mittels eines QRS-Detektionsalgorithmus. Im Anschluss werden die HF und HFV aus den zeitlichen Abständen zwischen den Herzschlägen berechnet.

### 3.1.1 QRS-Detektionsalgorithmus

Der QRS-Komplex unterscheidet sich signifikant von dem übrigen EKG-Signalverlauf (siehe Abschnitt 2.2.1.1) und wird daher für die automatische Detektion von Herzschlägen genutzt. Detektionsalgorithmen zur Erkennung des QRS-Komplexes sind seit mehr als 40 Jahren Gegenstand der Forschung. Die Verfahren basieren auf künstlichen neuronalen Netzen, genetischen Algorithmen, Wavelettransformationen, Filterbänken oder heuristischen Methoden; einen Überblick diesbezüglich gibt [88].

Auf dem Körpersensor BG-V4.2 kommt ein QRS-Detektionsalgorithmus von J. Pan und W. J. Tompkins [119] in der quelloffenen und für die Ausführung auf Mikroprozessoren optimierten Implementierung von P. Hamilton zum Einsatz [58; 59]. Die Vorverarbeitung des Algorithmus (siehe Abbildung 3.1) umfasst eine Bandpassfilterung des EKGs und eine zeitliche Ableitung (Differenzierer), deren Ausgabe als Betrag über ein Zeitfenster von 80 ms gleitend gemittelt wird (engl. *Moving Average Window*). Es folgt eine Spitzenerkennung, aus deren Ergebnis die QRS-Komplexe anhand der folgenden Regeln erkannt werden [58]:

1. Es werden alle Spitzen 200 ms vor und nach einer größeren Spitze ignoriert.
2. Wird eine Spitze erkannt, muss das EKG dazu eine positive und negative Flanke aufweisen (sonst Gleichanteiländerung).
3. Wurde in einem Zeitraum von 360 ms zuvor eine Spitze erkannt und beträgt der aktuelle Spitzenwert nur die Hälfte von dem vorhergehenden Spitzenwert, wird von einer T-Welle ausgegangen.

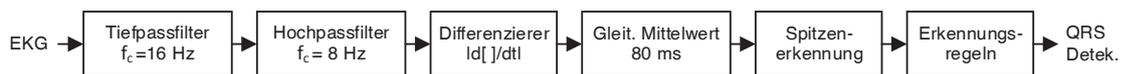


Abbildung 3.1.: Verarbeitungsschritte des QRS-Detektionsalgorithmus in der Implementierung von P. Hamilton.

4. Überschreitet der Spitzenwert einen vorgegebenen adaptiven Schwellenwert, wird dieser als QRS-Komplex markiert, andernfalls als Störung.
5. Ist ein Zeitintervall von mehr als dem 1,5-fachen des mittleren RR-Abstands<sup>1</sup> vergangen, wurde eine Spitze in diesem Intervall erkannt, die größer als der halbe Schwellenwert gewesen ist und beträgt der zeitliche Abstand zur vorhergehenden Spitze mindestens 360 ms, wird diese Spitze ebenfalls als QRS-Komplex markiert.

Der Schwellenwert wird auf Grundlage der Spitzenwerte der letzten acht QRS-Komplexe und der letzten acht EKG-Störungen gebildet.

**Ressourcenbedarf der QRS-Detektion** Die Dokumentation der Implementierung von P. Hamilton [58] stellt keine Angaben bezüglich der Berechnungskomplexität des QRS-Detektionsalgorithmus oder des dazu benötigten Energiebedarfs für die Ausführung auf dem von P. Hamilton gewählten PIC16F877-Mikrocontroller zur Verfügung. Im Rahmen der vorliegenden Arbeit erfolgte eine Bestimmung des Taktzyklenaufwands und Energiebedarfs für die einzelnen Verarbeitungsschritte des Algorithmus für den MSP430FG4618-Mikrocontroller des BG-V4.2. Die Ermittlung des Taktzyklenaufwands erfolgte mittels der *IAR Embedded Workbench*<sup>2</sup> und dem *IAR C/C++ Compiler for MSP430* (Version 5.40.2) unter Ausnutzung der Compileroption *O<sub>3</sub>* (siehe Abschnitt 4.2.6.3). Die Tief- und Hochpassfilterung benötigen mit 1124 Takten etwa 3,5-mal so viel Takte wie die übrigen Verarbeitungsschritte des QRS-Detektionsalgorithmus. Die analoge Schaltung des BG-V4.2 [163, Kap.4] zur Vorverarbeitung des EKGs bietet jedoch bereits eine ausreichende Bandpassfilterung, sodass die Softwarefilter deaktiviert wurden. Der Differenzierer und die gleitende Mittelwertbildung benötigen zusammen 172 Takte. Für die QRS-Detektion sowie die Aktualisierung des Schwellenwerts und des mittleren zeitlichen RR-Abstands sind weitere 108 Takte nötig. Der Takt Aufwand beträgt ohne Bandpassfilterung pro Aufruf insgesamt 323 Takte (siehe Tabelle 3.1). Der statische Speicherbedarf für die Implementierung der QRS-Detektion umfasst 1862 B.

Für den Betrieb des MSP430FG4618 bei einer Versorgungsspannung von 3 V und einer Taktfrequenz von 8 MHz, wie dies auf dem BG-V4.2 der Fall ist, ergibt sich ein Energiebedarf von 582 nJ für die reine Aktivzeit des Mikrocontrollers während der Ausführung der QRS-Detektion. Für eine weiterführende Modellierung der Energieaufnahme des EKG-Sensors sind zusätzliche Eigenschaften von unter anderem der EKG-Verstärkerschaltung, der Analog-Digital-Wandlung und der Betriebsmodi des Mikrocontrollers zu berücksichtigen.

**Evaluation der QRS-Detektion** Im Folgenden ist die Sensitivität und Spezifität (siehe Abschnitt 4.1.5) der QRS-Detektion angegeben. Grundlage bildet die Datenreihe V1.1 mit 22 Probanden, die bei unterschiedlichen Belastungsstufen (Geschwindigkeiten von 3 km/h bis 9 km/h) auf Laufbändern gingen und liefen (siehe Anhang A.1.1). Für die Evaluation wurden dazu in den EKGs der ersten zwölf Probanden 1836 Herzschläge manuell annotiert, verteilt über die Geschwindigkeiten 3 km/h, 7 km/h und 9 km/h, um Daten unterschiedlicher Belastungsstufen und mit Bewegungsartefakten verschiedener Intensität zu berücksichtigen. Die

---

<sup>1</sup>Mittlerer zeitlicher Abstand zwischen den letzten acht R-Zacken (Herzschlägen).

<sup>2</sup>Internetpräsenz: [www.iar.com/iar-embedded-workbench](http://www.iar.com/iar-embedded-workbench), letzter Zugriff 29.05.2015.

Tabelle 3.1.: Taktaufwand und Energiebedarf der Verarbeitungsschritte des QRS-Detektionsalgorithmus für die Ausführung auf dem MSP430FG4618. † Bei 3 V Versorgungsspannung und 8 MHz Taktfrequenz. ‡ Auf dem BG-V4.2 deaktiviert.

| Verarbeitungsschritte      | Takte        | Energiebedarf †    |
|----------------------------|--------------|--------------------|
| Tief- und Hochpassfilter ‡ | (1124)       | (2024 nJ)          |
| Differenzierer             | 68           | 122 nJ             |
| Gleit. Mittelwert          | 104          | 187 nJ             |
| QRS-Detektion              | 108          | 194 nJ             |
| Sonstiges                  | 43           | 77 nJ              |
| Gesamt                     | 323 / (1447) | 582 nJ / (2606 nJ) |

Annotationen wurden anschließend mit den Markierungen des QRS-Detektionsalgorithmus verglichen und die Gütemaße Sensitivität und Spezifität berechnet.

Die Sensitivität zeigt eine leichte Abnahme mit zunehmender Geschwindigkeit und beträgt  $99,9 \pm 0,4\%$  (3 km/h),  $98,9 \pm 2,2\%$  (7 km/h) und  $97,9 \pm 2,7\%$  (9 km/h). Die Spezifität liegt für die betrachtete Datenreihe bei 100 %. Die Sensitivität des QRS-Detektionsalgorithmus befindet sich trotz des nicht-klinischen EKGs insbesondere während des Gehens mit 3 km/h (geringfügige Bewegungsartefakte) auf einem ähnlichen Niveau wie die von J. Pan und W. J. Tompkins für EKGs der MIT-BIH Datenbank<sup>3</sup> ermittelte Sensitivität von 99,3 % [119].

#### 3.1.2 Bestimmung der HF und HFV

Berechnet wird die HF auf dem BG-V4.2 aus den zeitlichen Abständen zwischen den erkannten QRS-Komplexen. Um eine Robustheit der Bestimmung gegenüber Fehlern in der QRS-Detektion aufgrund von beispielsweise Bewegungsartefakten im EKG-Signalverlauf zu erzielen, werden die letzten neun HF-Werte zusätzlich im Speicher vorgehalten. Nach dem Hinzufügen des aktuellen Werts erfolgt eine aufsteigende Sortierung der zehn Werte. Anschließend wird das arithmetische Mittel über die mittleren vier Werte gebildet und ausgegeben. Anwendungsmöglichkeiten der HF-Analyse bestehen unter anderem in der Trainingssteuerung, der Erkennung und Prävention von Übertraining oder der Bestimmung der maximalen Sauerstoffaufnahme ( $VO_{2max}$ ) und des Energieumsatzes [1], siehe auch Kapitel 6.

Darüber hinaus kann aus der Variabilität der zeitlichen Abstände zwischen den detektierten QRS-Komplexen die Herzfrequenzvariabilität (HFV) bestimmt werden. Eingesetzt werden zur Variabilitätsbestimmung unterschiedliche Methoden, einen Überblick diesbezüglich gibt [71]. Eine HFV-Analyse bietet die Möglichkeit, das Zusammenspiel der Aktivität von Sympathikus und Parasympathikus des autonomen Nervensystems zu untersuchen. Eine bedeutende Anwendung stellt die Überwachung von Patienten nach einem Herzinfarkt und von Diabe-

<sup>3</sup>MIT-BIH ist eine Datenbank mit EKG-Aufzeichnungen für Forschungszwecke. Im Rahmen von Physionet werden weitere physiologische Signale und Algorithmen zur Verfügung gestellt ([www.physionet.org](http://www.physionet.org), letzter Zugriff 22.06.2015).

tikern dar, um einen plötzlichen Herztod zu vermeiden. Standardisierte Messbedingungen sind für eine gute Reproduzierbarkeit der Ergebnisse einer HFV-Analyse von Bedeutung. Einfluss nehmende Faktoren sind beispielsweise Änderungen der Atemfrequenz und Körperhaltung. Weiterhin wird die Alterszunahme in Verbindung mit einer niedrigeren HFV gebracht [128]. Ferner ermöglicht eine HFV-Analyse, mentalen Stress zu erfassen [150]. Eine 23-stündige Aufzeichnung der HFV von 50 Studenten in ihrem Alltag bestätigte eine Reduktion der HFV während mentaler Belastung aufgrund universitärer Aktivitäten [115]. Dieser Zusammenhang wird durch weitere Studien, wie beispielsweise einer HFV-Analyse während anspruchsvoller Computerarbeit [67], bestätigt. Dabei bietet eine Analyse der HFV im Vergleich zu anderen Stressparametern, wie etwa dem Blutdruckverlauf, eine höhere Sensitivität und Selektivität [67]. Im Rahmen des Leistungssports ist die HFV-Analyse Gegenstand von Untersuchungen, um eine Methodik zu entwickeln, sie als „leistungsdiagnostische Kenngröße, Kontrollparameter der Beanspruchung und als Steuerparameter der Belastungsintensität“ zukünftig einzusetzen [71]. Die derzeitigen Ergebnisse beruhen jedoch auf Studien mit zu kleinen Probandenkollektiven sowie unterschiedlichen HFV- und Studienmethodiken; HFV-Referenzwerte für verschiedene Sportartengruppen fehlen [71].

Eine erste Bewertung von Methoden zwecks Stresserkennung wurde im Rahmen der Masterarbeit von C. Menßen durchgeführt [188, S.27ff]. Eine weiterführende HFV-Analyse war nicht Gegenstand der vorliegenden Arbeit.

## 3.2 Atemfrequenz

Im Folgenden wird beschrieben, wie aus der mit dem realisierten Atemsensor (Konstruktion siehe Abschnitt 2.2.2.3) erfassten Thoraxerweiterung und -verengung die Atemfrequenz abgeleitet wird. Die Evaluation der Atemfrequenzbestimmung erfolgte im Rahmen einer Ergospirometrie auf einem Laufband. Die in diesem Abschnitt präsentierten Ergebnisse sind in [178] veröffentlicht.

### 3.2.1 Atemzug-Detektionsalgorithmus

Die erfassten Kraftänderungen am Thorax stellen idealisiert betrachtet eine Schwingung synchron zu den Atemzügen dar, deren Frequenz und ST-Wert mit der körperlichen Belastung variiert (siehe auch Abbildung 2.13a). Die Atemtätigkeit ist im Ausgangssignal des Analog-Digital-Wandlers jedoch zusätzlich teils mit Rauschen, Einflüssen der mechanischen Herzmuskelaktivität und Bewegungsartefakten behaftet, sodass ein Tiefpassfilter (Butterworth 5. Ordnung) zwecks Glättung angewandt wird. Als Grenzfrequenz zeigten sich  $f_c = 0,6$  Hz für die Erfassung der Atemtätigkeit während Ruhephasen, Alltagsaktivitäten und Sport mit leichter bis mittlerer Intensität als geeignet<sup>4</sup>.

Für die Bestimmung der Atemfrequenz (engl. *Respiration Rate*) ist eine Erkennung der einzelnen Atemzüge nötig. Dazu wurde eine Spitzenerkennung realisiert, die auf dem *peakDet*-Algorithmus von Billauer basiert<sup>5</sup>. Aufgrund der Variabilität der Signalfrequenz und des ST-

---

<sup>4</sup>Für den Einsatz während hoher körperlicher Belastung könnte zukünftig eine adaptive Anpassung der Grenzfrequenz sinnvoll sein.

<sup>5</sup>Eli Billauer, „Peakdet: Peak detection using MATLAB (v.3.4.05)“, <http://billauer.co.il/peakdet.html>, letzter Zugriff 08.04.2014.

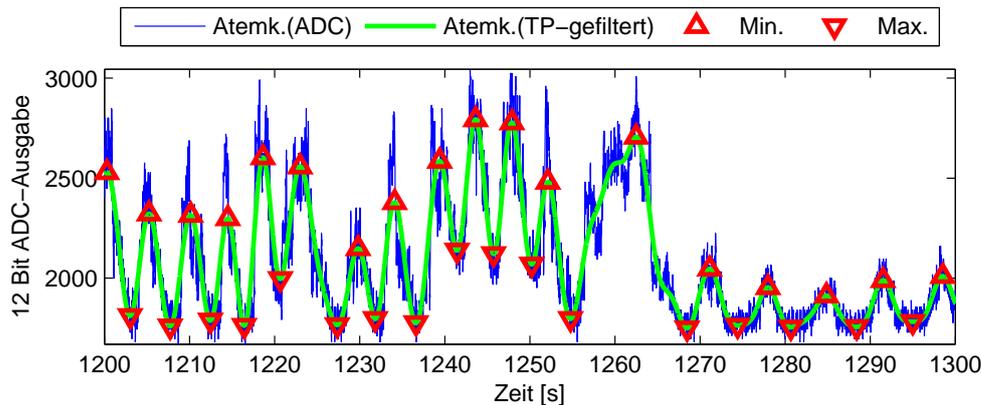


Abbildung 3.2.: Atemkurve nach Analog-Digital-Wandlung (ADC) und digitaler Tiefpassfilterung ( $f_c = 0,6$  Hz). Die Atemzugdetektion erfolgt mit einer Spitzenerkennung, die sich an Änderungen der Frequenz und des ST-Werts anpasst.

Werts (siehe auch Abbildung 3.2) wurde der Algorithmus um eine entsprechende Adaptivität erweitert. Die Ausführung der Spitzenerkennung erfolgt dazu in Zeitfenstern, deren Längen entsprechend den aktuellen zeitlichen Abständen zwischen den Atemzügen angepasst werden. Der Schwellenwert wird für jede neu erkannte Spitze oder falls das Zeitfenster verstrichen ist aktualisiert. Dabei ergibt sich der aktualisierte Schwellenwert aus der gewichteten Summe des vorherigen Werts (Gewichtsfaktor 0,9) und dem neuen Wert (Gewichtsfaktor 0,1). Die Untergrenze (75 Quantisierungsstufen) ist durch das Rauschen des Kraftsensors bestimmt. Die Atemfrequenz wird aus den letzten zehn Atemzügen als Median berechnet.

### 3.2.2 Evaluation Atemfrequenzbestimmung

Während in Abschnitt 2.2.2.3 bereits eine Evaluation auf der Ebene der Atemkurve (Kraftübertragung zwischen Thorax und Sensor) erfolgte, wird hier die Bestimmung der Atemfrequenz bewertet. Die Spirometrie stellt dabei ein geläufiges Verfahren dar, um neben dem Atemzugvolumen auch die Atemfrequenz zu messen [107]. Für die Evaluation des Atemsensors während Ruhe und körperlicher Belastung wurde das Ergospirometriesystem *Metalizer* der Firma Cortex Biophysik GmbH als Referenz eingesetzt. Es erfolgte ein Vergleich auf der Ebene der Atemfrequenz, da Angaben zu den einzelnen detektierten Atemzügen nicht zur Verfügung stehen.

Der Versuch V1.3 wurde mit fünf Probanden durchgeführt und bestand aus einer zunächst dreiminütigen Ruhephase am Versuchsanfang und -ende sowie den Laufbelastungsstufen 3, 5, 7, 9, 11 und 5 km/h für jeweils drei Minuten (24 min Gesamtdauer). Die Aufzeichnung der Atemkurve erfolgte mit dem BG-V4.2 mit einer Frequenz von 100 Hz. Die Atemfrequenz, ermittelt mit dem Ergospirometriesystem, wurde mit 0,1 Hz abgespeichert. Die Abbildung 3.3 zeigt einen Probanden während der Ergospirometrie. Die Atemfrequenzen variieren in den Ruhephasen zwischen 8 und 21 Atemzügen pro Minute und die Atemminutenvolumina zwischen 7 und 24 Liter pro Minute (l/min). Durch die körperliche Belastung kommt es zu einem Anstieg auf bis zu 41 Atemzügen pro Minute (P3) und einer Erhöhung der Atemzugvolumina



Abbildung 3.3.: Proband während der Ergospirometrie. Zusätzliche Erfassung der Thoraxerweiterung und -verengung mit dem Atemsensor des BG-V4.2; der gemessene Kraftverlauf ist im Signalmonitor blau visualisiert.

auf bis zu 122,71/min (P4). Die Atemfrequenzen und die Atemzugvolumina zeigen dabei eine hohe Variabilität zwischen den Probanden. Die Atemfrequenz von P1 ist im Vergleich zu den übrigen Probanden über den gesamten Versuchsablauf hinweg niedriger; das Maximum beträgt nur 25,8 Atemzüge pro Minute (weiterführende Informationen siehe Anhang A.1.3).

Die ermittelten Atemfrequenzen des BG-V4.2 und des Ergospirometriesystems sind für die fünf Probanden während des 24-minütigen Versuchsablaufs in der Abbildung 3.4 dargestellt. Der Fehler wurde berechnet, indem die Atemfrequenzwerte des BG-V4.2 von den Werten des Ergospirometriesystems subtrahiert wurden. Im Idealfall ist die Differenz null, ist sie positiv, wurde die Atemfrequenz mit dem BG-V4.2 überschätzt (zu viele erkannte Spitzen) und ist sie negativ, wurde sie unterschätzt. Für die Daten von fünf Probanden beträgt das arithmetische Mittel über die Differenzwerte  $-0,32 \pm 0,68$  Atemzüge pro Minute. Die niedrigste mittlere Abweichung liegt bei 0,09 Atemzüge pro Minute (P1) und die höchste bei 0,89 Atemzüge pro Minute (P4). Die Differenzwerte sind zusätzlich in der Abbildung 3.5 als *Box-Whisker-Plots* (Kastengrafik)<sup>6</sup> dargestellt. Das arithmetische Mittel über die fünf Medianwerte beträgt  $-0,08 \pm 0,42$  Atemzüge pro Minute. Die Ergebnisse von Proband P1 zeigen die wenigsten Ausreißer (13) und die von P4 die meisten (31). Abweichungen treten dabei insbesondere für P2 ab Minute 20 und für P3 zu Anfang und Ende des Versuchsablaufs auf und sind auf ein nicht

<sup>6</sup>Ein Box-Whisker-Plot bietet mit den Maßen Median, unteres und oberes Quartil sowie Ausreißern (Minimum und Maximum als *Whiskers*) eine kompakte Darstellung der Verteilung von Daten.

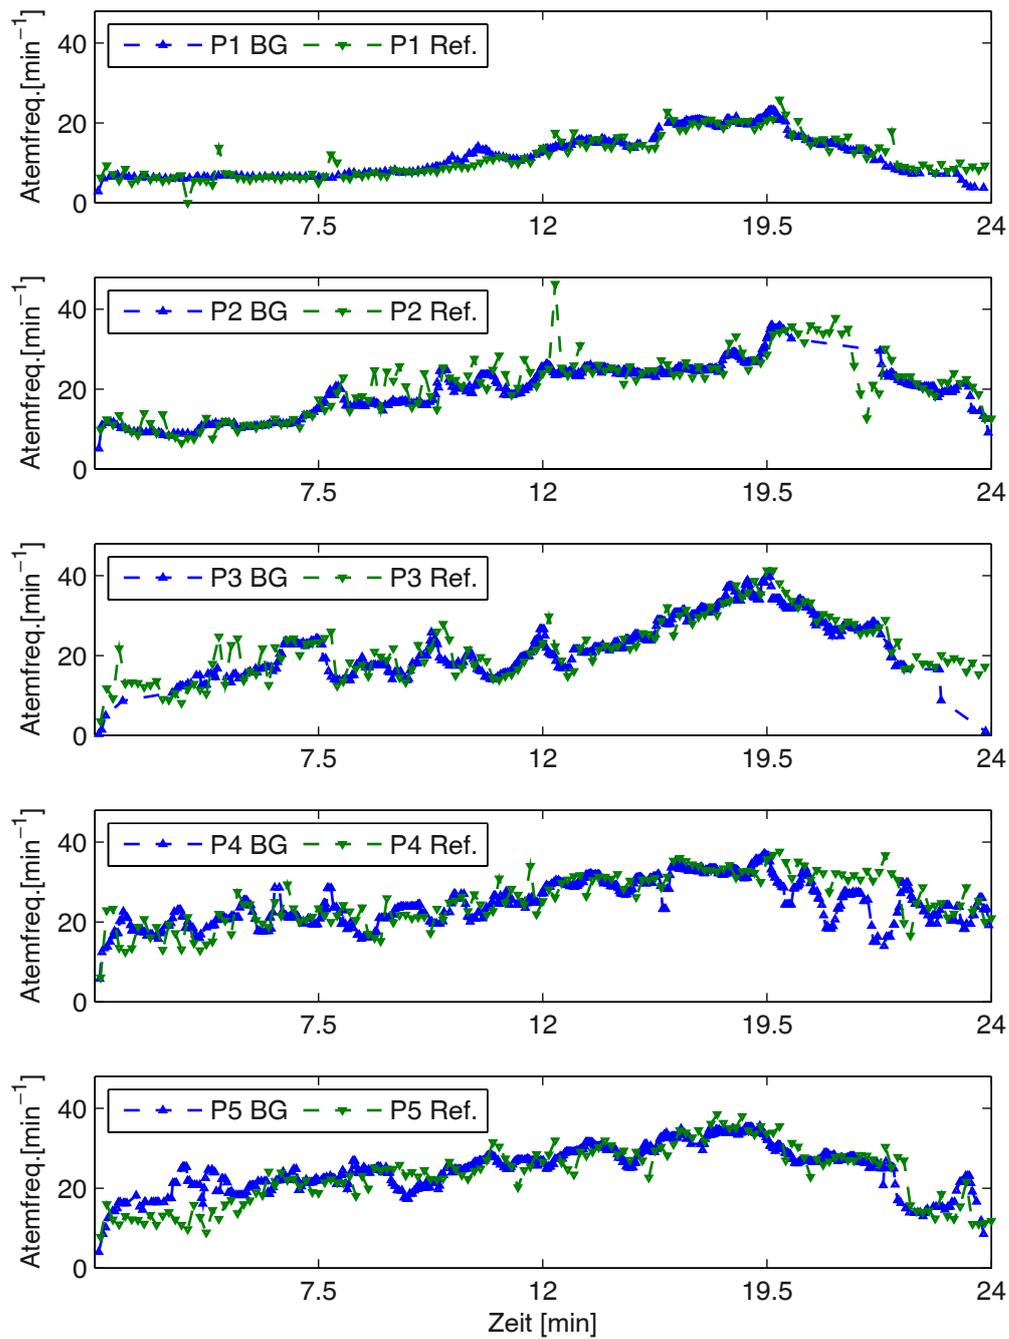


Abbildung 3.4.: Gegenüberstellung der Atemfrequenzbestimmung des BG-V4.2 mit den Referenzwerten des Ergospirometriesystems (5 Probanden, Datenreihe V1.3).

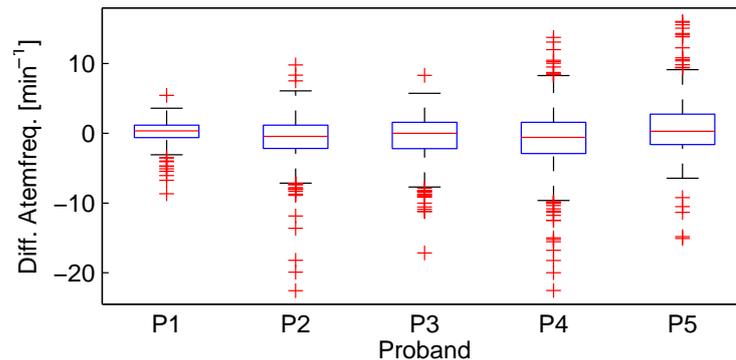


Abbildung 3.5.: Darstellung der Differenzwerte zwischen den Atemfrequenzen ermittelt mit dem Ergospirometriesystem und dem BG-V4.2 als *Box-Whisker-Plots*.

korrektes Aufliegen des Atemsensors zurückzuführen. Die dadurch phasenweise fehlenden Atemzüge im Signalverlauf motivierten, ein Gehäuse für eine definierte Kraftübertragung zu entwickeln (siehe Abschnitt 2.2.2.3).

### 3.3 Hauttemperatur

Die Hauttemperatur ist ein weiterer physiologischer Parameter, der mit dem BG-V4.2 im Brustbereich gemessen werden kann. Im Folgenden wird zunächst beschrieben, wie sich die Hauttemperatur während einer körperlichen Belastung verändert.

T. Reily und G. A. Brooks erfassten Temperaturen rektal (Annäherung der Körperkern-temperatur) und an der Hautoberfläche im Brustbereich sowie den Extremitäten während Ruhe, leichter (82 W), mittlerer (147 W) und maximaler körperlicher Belastung [131]. Die bezüglich des BG-V4.2 relevante Messung im Brustbereich zeigte während leichter und mittlerer Belastung zunächst eine Temperaturabnahme von  $0,5^{\circ}\text{C}$ , welche auf eine Reduktion des Blutflusses in der Haut zwecks Versorgung der aktiven Muskeln zurückzuführen ist; die rektalen Temperaturwerte blieben unverändert. Mit einem Anstieg der Körperkerntemperatur aufgrund einer lang andauernden oder sehr hohen körperlichen Belastung erhöht sich jedoch der Blutfluss in die Körperperipherie (Wärmetransport zwecks Kühlung zur Thermoregulation). T. Reily und G. A. Brooks beobachteten diesbezüglich einen Anstieg der Körperkern- und der Hauttemperatur. Im Anschluss an die Belastung dauert zunächst der Rückfluss des warmen venösen Bluts aus den aktiven Muskeln an, sodass der Abfall der Temperaturen zeitversetzt erfolgt.

Das BG-V4.2 verfügt über einen NTC-Thermistor, dessen Widerstand sich mit zunehmender Temperatur reduziert. Die Widerstandsänderungen werden mittels eines Analog-Digital-Wandlers erfasst und auf Temperaturwerte abgebildet (siehe Abschnitt 2.2.3). Erste Aufzeichnungen der Hauttemperatur mit dem BG-V4.2 zeigten während einer körperlichen Belastung durch Laufen<sup>7</sup> eine Abnahme der Hauttemperatur, vor allem bei höheren Geschwindigkeiten.

<sup>7</sup>Grundlage bilden zwei Datenreihen, die Hauttemperatur-, HF- und Beschleunigungswerte während eines Waldlaufs und im Innenbereich (Laufband) umfassen (BG-V4.2, Aufzeichnungsdaten 27.03.2012 und 22.07.2013).

Insbesondere im Außenbereich ist eine Wärmeabfuhr durch die kühlende Luftbewegung während des Laufens gewährleistet. Im Innenbereich auf dem Laufband (stationär) reichten jedoch ebenfalls die rhythmischen Oberkörperbewegungen bereits aus, um die Temperatur zu reduzieren. Zu einem Anstieg kam es in den Laufpausen. Beobachten ließ sich daher ein gegenläufiger (anti-korrelierter) zeitlicher Verlauf zwischen der Hauttemperatur und der HF sowie der beobachteten Aktivität in den Beschleunigungssignalen. Aufgrund der Luftkühlung konnte daher die in der Literatur beschriebene kurzfristige Abnahme um  $0,5^{\circ}\text{C}$  mit einer sich anschließenden Zunahme der Hauttemperatur nicht während der Ausübung der körperlichen Aktivität beobachtet werden. Weiterführend ist daher zu prüfen, ob Änderungen der Messposition (z.B. Rücken) sinnvoll sind.

Neben der Leistungsdiagnostik ist eine Temperaturüberwachung im Arbeitsschutz, beispielsweise bei Einsatzkräften der Feuerwehr, von hoher Bedeutung. Die Einsatzkleidung ist schwer und mehrschichtig aufgebaut, um Schutz vor Hitze und Flammen zu bieten. Eine geeignete Thermoregulierung und ein frühzeitiges Erkennen eines kritischen Anstiegs der Körperkerntemperatur sind für die Gesundheit der Einsatzkräfte wichtig. Neben der Erfassung der Körperkerntemperatur (rektal als Referenz) wird in der Literatur die Hauttemperatur überwacht, um geeignete Kühlungsmechanismen zu entwickeln [141]. Weitere Beispiele aus dem Arbeitsschutz sind Hochofenarbeiten oder zukünftig die Gasturbinenwartung (BMBF-Projekt ALUBAR, siehe Abschnitt 8). Weiterführend ist daher zu prüfen, ob die Hauttemperaturmessung des BG-V4.2 diesbezüglich genutzt werden kann, da der beobachtete Effekt durch die Luftkühlung in diesen Szenarien weitestgehend ausgeschlossen werden kann. Ein Brustgurt-basiertes Messsystem ist im Hinblick auf Anbringung, Tragekomfort und Bewegungsfreiheit für diese Einsatzzwecke besonders gut geeignet.

## 3.4 Zusammenfassung und Ausblick

In diesem Kapitel ist die Bestimmung der physiologischen Parameter Herzfrequenz, Atemfrequenz und Hauttemperatur aus den Sensorsignalen des BG-V4.2 beschrieben.

Die Ermittlung der Herzfrequenz und -variabilität erfolgt auf Grundlage der zeitlichen Abstände zwischen den einzelnen Herzschlägen im EKG (QRS-Komplexe). Eingesetzt wird hierzu ein quelloffener QRS-Detektionsalgorithmus. Der MSP430FG4618-Mikrocontroller des BG-V4.2 benötigt für die Ausführung des Algorithmus 323 Takte, dies entspricht einem Energiebedarf von 582 nJ; der Speicherbedarf beträgt 1862 B. Die Evaluation auf der Datenreihe V1.1 ergibt eine hohe mittlere Sensitivität der QRS-Detektion von mindestens 97,9% trotz auftretender Bewegungsartefakte während des Laufens mit 9 km/h. Zukünftig ist darüber hinaus eine Nutzung des Beschleunigungssensors zur adaptiven Reduktion von Bewegungsartefakten im EKG denkbar [129].

Der realisierte Atemsensor erfasst die Thoraxerweiterung und -verengung mittels eines Kraftsensors, der in ein Gehäuse zur mechanischen Kraftübertragung eingebettet ist. Für die Bestimmung der Atemfrequenz wurde ein Algorithmus zur Atemzugdetektion entwickelt. Im Rahmen der Evaluation wurden die Atemfrequenzwerte mit den Ausgaben eines Ergospirometrysystems (Datenreihe V1.3) verglichen; die Abweichungen betragen im arithmetischen Mittel sehr niedrige  $-0,32 \pm 0,68$  Atemzüge pro Minute. Zukünftig ist eine Bestätigung der Ergebnisse durch eine Evaluation mit einem größeren Probandenkollektiv sinnvoll. Weiterhin ist zu prüfen, ob für Ruhephasen mit vorwiegender Abdominalatmung ein zusätzlicher Gurt im Abdomenbereich für die Atemfrequenzbestimmung benötigt wird, oder ob eine Nutzung von Informationen eines EKG-basierten Verfahrens zur Atemfrequenzbestimmung [27] in Ruhe sinnvoll ist. Im Rahmen der Modellierung der Energieaufnahme des BG-V4.2 ist weiterhin die Atemfrequenzdetektion zu analysieren. Zu betrachten sind dazu Eigenschaften des Atemsensors (z.B. Verstärkerschaltung und Analog-Digital-Wandler), des Detektionsalgorithmus und die Zeiten in den unterschiedlichen Betriebsmodi des Mikrocontrollers.

Die ersten Aufzeichnungen zur Hauttemperaturerfassung zeigen für den Einsatz während des Laufens einen signifikanten Einfluss durch die auftretende Luftkühlung. Als Folge wird der Anstieg der Körperkerntemperatur derzeit während der körperlichen Belastung in den Messwerten nicht sichtbar. Für den Einsatz in der Leistungsdiagnostik sind daher alternative Messpositionen zu prüfen. Geeignete Einsatzmöglichkeiten werden im Bereich des Arbeitsschutzes gesehen, wo diese Problematik nicht besteht.

## 4 Biokinematische Parameter

In Kapitel 3 wurden mit dem Körpersensor BG-V4.2 bestimmbare physiologische Parameter vorgestellt. Das folgende Kapitel beschreibt die Erfassung von Parameter, die Körperbewegungen analysieren (*Biokinematik*) und aus den Beschleunigungssignalen, gemessen im Brustbereich (Sternum), abgeleitet werden. Der Schwerpunkt in der vorliegenden Arbeit liegt auf der Bestimmung der Laufgeschwindigkeit aus Schrittmustern, eine Beschreibung des Verfahrens und der Evaluationsergebnisse erfolgt in Abschnitt 4.2. Die dazu nötigen Grundlagen des maschinellen Lernens werden zunächst als Exkurs in Abschnitt 4.1 gegeben. In den folgenden Abschnitten 4.3 und 4.4 wird ein Überblick zur Bestimmung des Oberkörperneigungswinkels und der Aktivität mittels Beschleunigungssensoren gegeben.

### 4.1 Exkurs: Klassifikationsverfahren

Methoden des maschinellen Lernens lassen sich vielfältig einsetzen, um Parameter aus den Sensorsignalen eines Körpersensors zu bestimmen; ein Beispiel ist die körperliche Aktivität einer Person [102]. Im Rahmen der vorliegenden Arbeit sind die Zielgrößen der Klassifikation Geschwindigkeitsklassen (3, 5, 7, 9 und 11 km/h), die Identität des Trägers des Körpersensors (Probandennummer) oder die ausgeführte Alltagsaktivität (z.B. Stehen, Gehen, Treppensteigen). Im Gegensatz zu einer Regressionsanalyse, bei der eine kontinuierliche Schätzung der Zielgröße vorgenommen wird, handelt es sich somit um die Vorhersage diskreter Ausgabeklassen.

Das Training eines Klassifikators beschreibt den Prozess einer Modellfindung zur Unterscheidung von Datenklassen. Im Rahmen von überwachtem Lernen (*Supervised Learning*) wird mittels Trainingsdaten, zu denen Klassenannotationen vorliegen, ein Modell erstellt, welches anschließend Vorhersagen zur Klassenzugehörigkeit unbekannter Daten ermöglicht. Ein solches Vorhersagemodell kann dabei in verschiedenen Repräsentationsformen vorliegen [60, S.24f]. Die Klassifikation selbst erfolgt im Allgemeinen am Ende einer Verarbeitungskette bestehend aus: Abtastung der Sensoren, Filterung der Sensorwerte und Merkmalsextraktion (Bündelung von Informationen der betrachteten Domäne).

Im Bereich des maschinellen Lernens existieren eine Vielzahl von Verfahren<sup>1</sup>, die sich für eine Klassifikation einsetzen lassen, Beispiele sind der *k*-nächste-Nachbarn-Algorithmus (engl. *k-Nearest-Neighbor*), der Naïve-Bayes-Klassifikator, Entscheidungsbäume (EB), Random Forests (RF), Support Vektor Maschinen oder künstliche neuronale Netze (KNN). Im Rahmen der vorliegenden Arbeit wurden für die Parameterbestimmung die Klassifikatoren KNN, EB und RF ausgewählt, die im Folgenden vorgestellt werden.

#### 4.1.1 Künstliche neuronale Netze

Mit künstlichen neuronalen Netzen wird versucht, eine mathematische Repräsentation der Informationsverarbeitung zu finden, wie sie in biologischen Systemen anzutreffen ist. Entstanden sind dazu eine Vielzahl an unterschiedlichen Modellen, stets mit dem Anspruch, sich näher am biologischen Vorbild zu orientieren. Für den Einsatz in der Mustererkennung würde ein zu hoher biologischer Realismus jedoch unnötige Einschränkungen auferlegen.

---

<sup>1</sup>Eine umfassende Beschreibung von Verfahren des maschinellen Lernens wird in [24] gegeben.

Insbesondere die Leistung des mehrschichtige Perzeptrons ist in vielen praktischen Anwendungen der Mustererkennung bestätigt worden [24, S.226]. Im Rahmen der vorliegenden Arbeit wurde sich auf diese Klasse der künstlichen neuronalen Netze beschränkt.

##### 4.1.1.1 Mehrschichtiges Perzeptron

Ein vereinfachtes künstliches neuronales Netz, das Perzeptron, wurde 1957 von Frank Rosenblatt vorgestellt [135]. Ein Perzeptron besteht aus nur einer Schicht mit künstlichen Neuronen, die zugleich die Netzausgaben repräsentieren. An jedem Neuron liegt der gesamte Eingabevektor an. Der Einfluss der einzelnen Elemente des Eingabevektors wird über Gewichte gesteuert. Ein Neuron besteht aus einer Aktivierungsfunktion, welche die Ausgabe bestimmt und einem Schwellenwert, der die Aktivierung steuert. Der Perzeptron-Algorithmus gehört zu der Gruppe der überwachten Lernverfahren; die Gewichte werden für die einzelnen Neuronen anhand von Trainingsbeispielen, die mit der tatsächlichen Ausgabeklasse annotiert sind, angepasst. Das Perzeptron ist ein linearer Klassifikator und eignet sich damit nur für Klassifikationsaufgaben, deren Lösung eine lineare Repräsentation im Eingabevektor aufweist. Im Vergleich zu einem Polynomklassifikator unterscheidet sich das Perzeptron durch eine nichtlineare Aktivierungsfunktion (Sprungfunktion) der Ausgabeneuronen; es ist damit kein universeller Klassifikator realisierbar [90, S.162].

Liegen die Informationen jedoch als nicht linear separierbares Klassifikationsproblem im Merkmalsraum vor, muss (mindestens) eine zusätzliche verdeckte Schicht mit Neuronen eingesetzt werden (mehrschichtiges Perzeptron, engl. *Multilayer Perceptron*, *MLP*). Bei der Angabe der Schichtanzahl wird die Eingabeschicht häufig nicht mitgezählt, da diese lediglich den Eingabevektor  $\vec{x}$  an die erste verdeckte Schicht weiterreicht. Im Rahmen der Arbeit wurden ausschließlich zweischichtige Perzeptrons<sup>2</sup> mit einer verdeckten Schicht eingesetzt (siehe Abbildung 4.1). Für jedes Neuron der verdeckten Schicht und der Ausgabeschicht werden die anliegenden Eingaben mit jeweils einem Gewichtswert (engl. *Weights*) multipliziert und anschließend summiert. Zusätzlich können Biaswerte als Schwellenwerte angewandt werden, um die Aktivitäten der Neuronen zu variieren [60, S.331]. Anschließend wird anstelle einer Sprungfunktion eine kontinuierliche sigmoide (S-geformte) Aktivierungsfunktion<sup>3</sup>  $\sigma$ , wie die logistische Sigmoidfunktion oder die hyperbolische Tangentenfunktion, eingesetzt [24, S.227ff]. Der Signalfluss im MLP erfolgt ausschließlich von der Eingabe- zur Ausgabeschicht, es existieren keine Querverbindungen oder Rückkopplungszweige (*Feed-Forward*-Netzstruktur) [90, S.158]. Weiterhin liegt die Ausgabe von jedem Neuron als Eingabe an jedem Neuron in der nachfolgenden Schicht an (vollständig verbunden) [60, S.328f].

Mit einem MLP ( $n$  Eingaben und  $m$  Ausgaben) mit nur einer verdeckten Schicht und sigmodialen Aktivierungsfunktionen lässt sich eine beliebige kontinuierliche Funktion approximieren, die eine Abbildung zwischen einem  $n$ -dimensionalen euklidischen Eingaberaum  $\mathbb{R}^n$  und einem  $m$ -dimensionalen euklidischen Ausgaberaum  $\mathbb{R}^m$  ermöglicht (*Universal Approximation Theorem*) [51].

---

<sup>2</sup>In der Ergebnisdarstellung wird die Bezeichnung MLP verwendet.

<sup>3</sup>Für das Training eines MLP mittels eines Backpropagations-Algorithmus ist die Differenzierbarkeit der Aktivierungsfunktion von Bedeutung.

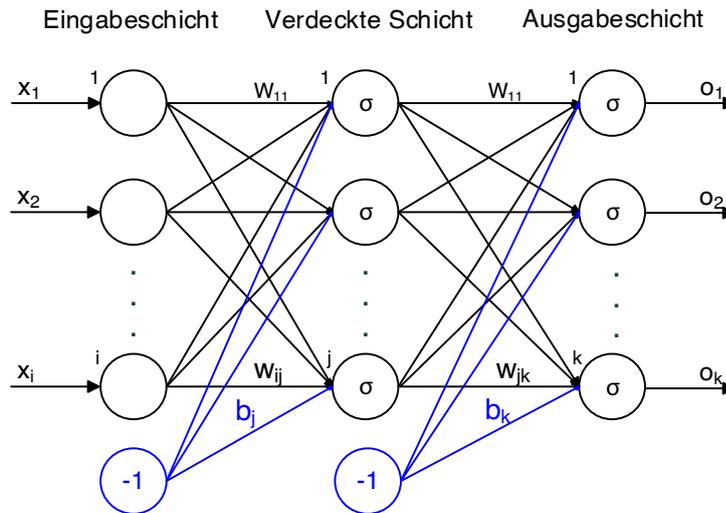


Abbildung 4.1.: Zweischichtiges Perzeptron mit einer *Feed-Forward*-Netzstruktur. Wobei  $x$  die Eingaben,  $o$  die Ausgaben,  $w$  und  $b$  die Gewichts- und Biaswerte der Neuronen und  $\sigma$  die Aktivierungsfunktion (unterschiedliche Funktionen sind möglich) bezeichnen.

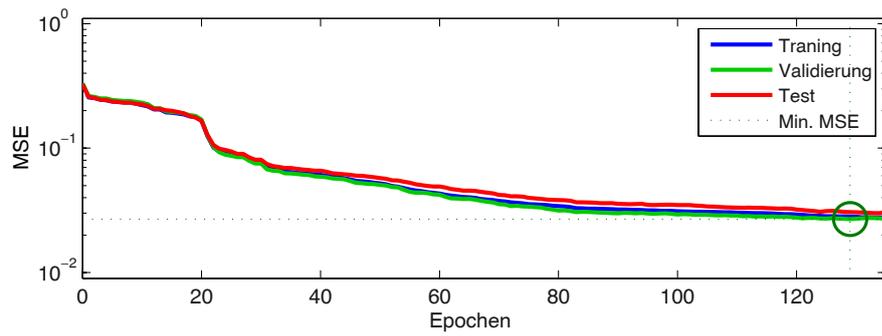
#### 4.1.1.2 Trainingsalgorithmen

Die Gewichte und Biaswerte eines mehrschichtigen Perzeptrons sind in der Ausgangssituation zufällig initialisiert [60, S.331], das Netz enthält somit zu diesem Zeitpunkt keine Informationen über das zugrunde liegende Klassifikationsproblem. Für *Feed-Forward*-Netzstrukturen werden häufig *Backpropagation*-Trainingsalgorithmen verwendet. *Backpropagation* bezeichnet den Einsatz eines Gradientenverfahrens, um eine Fehlerfunktion bezüglich der Neuronengewichte zu minimieren. Dem Netz werden dazu iterativ Trainingstupel präsentiert und der mittlere quadratische Fehler (engl. *Mean Squared Error*, MSE) zwischen den resultierenden Ausgaben (Schätzungen) des Netzes und den bekannten Klassenannotationen ermittelt (überwachtes Lernen). In jeder Iteration werden die Neuronengewichte entsprechend des Gradienten der Fehlerfunktion angepasst. Die Bezeichnung *Backpropagation* begründet sich damit, dass sich Fehler rückwärts gerichtet, startend mit der Ausgabe- in Richtung Eingabeschicht, ausbreiten [24, S.241f].

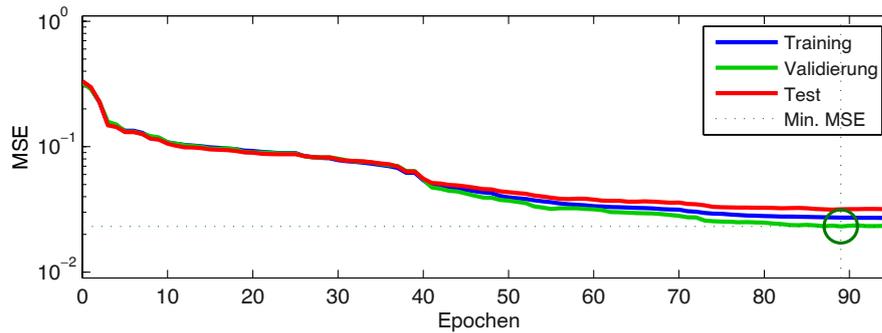
Der Parameter Lernrate steuert die Änderungsrate der Anpassung von Gewichts- und Biaswerten und dient der Vermeidung, frühzeitig das Training aufgrund eines niedrigen Fehlergradientens oder lokalen Minimums (selten) zu beenden. Ein lokales Minimum ist ein Zustand, in dem die Gewichte zu konvergieren scheinen, der jedoch nicht das globale Minimum (optimale Lösung) darstellt. Typischerweise wird für die Lernrate ein Wert zwischen 0 und 1 gewählt, wobei kleinere Werte den Trainingsvorgang verlangsamen. Eine hohe Lernrate birgt das Risiko des Oszillierens zwischen inadäquaten Lösungen<sup>4</sup>. Zusätzlich kann

<sup>4</sup>In der Praxis wird typischerweise der Kehrwert aus der Epochenanzahl angesetzt. Eine Epoche beschreibt eine einmalige Iteration über alle Tupel der Trainingsdatenreihe.

#### 4. Biokinematische Parameter



(a) Niedrigster Validierungsfehler (MSE) von 0,0268 (Epoche 129).



(b) Niedrigster Validierungsfehler (MSE) von 0,0232 (Epoche 89).

Abbildung 4.2.: Mittlerer quadratischer Fehler (MSE) während des Trainings eines MLPs, ermittelt für die Trainings-, Validierungs- und Testtupel. Aufgrund der zufälligen Initialisierung der Gewichte und der Biaswerte führt eine Wiederholung des Trainingsvorgangs (b) zu einem (leicht) abweichenden Ergebnis.

ein Trägheitsterm (Momentum) eingesetzt werden. Dabei wird zu jedem Gewicht ein Anteil des vorherigen Gewichtswertes addiert. Die Aktualisierung der Gewichte und Biaswerte kann entweder nach der Präsentation eines jeden Trainingstupels (*Case Updating*) oder alternativ nach der Verarbeitung aller Tupel der Trainingsdatenreihe erfolgen (*Epoch Updating*) [60, S.332f].

Im Allgemeinen konvergieren die Gewichte nach mehreren Epochen und das Training endet, dies ist jedoch nicht garantiert [60, S.330]. Um die Komplexität des Trainings zu steuern, ist daher die Definition eines Abbruchkriteriums von Bedeutung. Das einfachste deterministische Kriterium stellt die Vorgabe einer zu durchlaufenden Epochenanzahl dar. Eine weitere Möglichkeit besteht darin, eine Obergrenze an Epochen vorzugeben und den Klassifikationsfehler während des Trainingsvorgangs auf Tupel einer unabhängigen Validierungsdatenreihe zu überprüfen. Typischerweise erfolgt zunächst eine Abnahme des Fehlers während des Trainings. Ist die Anpassung des Netzes an die Trainingstupel jedoch zu hoch, steigt der Fehler auf den unbekanntem Validierungstupeln an; die Generalisierungsfähigkeit hat sich verschlechtert (engl. *Overfitting*). Beim *Early Stopping* wird das Training abgebrochen, sobald der Fehler auf den Validierungstupeln einen vorgegebenen Schwellenwert überschreitet. Es wird die

Netzkonfiguration mit dem niedrigsten Validierungsfehler genutzt [24, S.259f].

Die Abbildung 4.2 zeigt exemplarisch die Änderung des MSE während eines Trainingsvorgangs auf Tupel der Trainings-, Validierungs- und Testdatenreihe<sup>5</sup> aus Versuch V1.1. Ab Epoche 129 kommt es zu einem Anstieg des Validierungsfehlers (niedrigster MSE 0,0268, siehe Abbildung 4.2a), sodass die Netzkonfiguration aus Epoche 129 das Trainingsergebnis darstellt. Aufgrund der zufälligen Initialisierung der Gewichte und Biaswerte, führt eine Wiederholung des Trainingsvorgangs mit den gleichen Einstellungen zu einem (leicht) abweichenden Ergebnis. In diesem Fall wird der niedrigste MSE von 0,0232 der Validierung bereits bei Epoche 89 erreicht. Der erzielte MSE der Validierung ist in diesem Fall jedoch deutlich niedriger als der auf den Trainings- und Testtupeln erreichte MSE (höhere Abweichung zwischen den drei MSE, siehe Abbildung 4.2b). Aufgrund der unterschiedlich verlaufenden Trainingsvorgängen kann eine Wiederholung sinnvoll sein.

#### 4.1.1.3 MLP dieser Arbeit

Die Bestimmung der Laufgeschwindigkeit und der Identität einer Person, basierend auf Merkmalen extrahiert aus den Sensorsignalen, stellen nicht linear separierbare Klassifikationsprobleme dar (siehe Abbildungen 4.8 und 5.6). Für die Klassifikation werden MLP mit einer verdeckten Schicht eingesetzt. Es erfolgte jeweils eine Anpassung der Anzahl der Eingabeneuronen entsprechend der Dimensionalität des jeweiligen Merkmalsraums. Für die Ausgabe wird pro Klasse ein Neuron eingesetzt, sodass jedes Ausgabeneuron eine Schätzung der Auftretenswahrscheinlichkeit (0 bis 1) der jeweiligen Klasse liefert. Die Klasse korrespondierend zu dem Neuron mit der höchsten Auftretenswahrscheinlichkeit stellt das Klassifikationsergebnis dar (Realisierung einer Klassifikation mittels MLP). Als Aktivierungsfunktion der Neuronen der verdeckten Schicht und der Ausgabeschicht wird die folgende sigmoide Tangentenfunktion eingesetzt:

$$\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.1)$$

Das Training erfolgte mittels Backpropagation mit dem von M. F. Møller vorgestellten geschwindigkeitsoptimierten *Scaled Conjugate Gradient* (SCG)-Algorithmus [109]<sup>6</sup>. Um das Risiko eines höheren Klassifikationsfehlers aufgrund eines frühzeitigen Abbruchs des Trainings zu reduzieren, wurde der Trainingsvorgang fünfmal wiederholt und die Netzkonfiguration mit dem niedrigsten Fehler auf den Validierungstupeln ausgewählt.

#### 4.1.2 Entscheidungsbäume und Random Forest

Als Klassifikatoren werden weiterhin Entscheidungsbäume (EB) sowie Random Forests (Komitees aus Entscheidungsbäumen) eingesetzt.

<sup>5</sup>Die Überprüfung auf den Validierungstupeln beeinflusst den Trainingsvorgang (Abbruchkriterium). Die Evaluation der Generalisierungsfähigkeit des trainierten Netzes wurde daher auf Testtupel, die nicht im Trainingsprozess involviert sind, ermittelt.

<sup>6</sup>Das Training wurde vorwiegend mit der *NeuralNetwork Toolbox 7* in *MATLAB* (Version R2009b, Firma MathWorks) durchgeführt. Weiterhin stehen die Trainingsalgorithmen *Levenberg-Marquardt*, *Bayesian Regulation* und *Resilient Backpropagation* zur Verfügung [18].

##### 4.1.2.1 Entscheidungsbäume

Ein EB ist ein spezieller Graph, definierbar durch eine Menge an Knoten, die durch Kanten verbunden sind. Jeder Knoten muss dabei über einen Pfad von anderen Knoten aus erreicht werden können; dabei existieren jedoch keine kreisförmigen Verbindungen. Der Knoten ohne eingehende Kante (*No Parent*) wird als Wurzel bezeichnet und die Knoten ohne ausgehende Kanten als Blätter. Die inneren Knoten des EB entsprechen den Merkmalen, deren Werte über Intervalle entlang der Kanten unterschieden werden (Schwellenwertentscheidungen) [90, S.183f]. Bei einem gerichteten EB existiert ein Wurzelknoten und alle übrigen Knoten haben nur eine eingehende Kante (*One Parent*) [24, S.398f]. Als Binärbaum werden EB bezeichnet, von deren Knoten jeweils zwei Kanten ausgehen [24, S.663f].

Für eine automatische Konstruktion (Induktion) eines EB existieren verschiedene Verfahren wie das Framework CART (*Classification And Regression Trees*), das ID3-Verfahren (*Iterative Dichotomiser 3*) und der daraus hervorgegangene C4.5-Algorithmus. Gemeinsam ist der Einsatz eines rekursiven *Top-Down*-Verfahrens (*Divide-And-Conquer*) [60, S.292]. Die Konstruktion des EB erfolgt auf Trainingstupel mit bekannten Klassenannotationen, welche dazu in kleinere Teilmengen aufgeteilt werden. Begonnen wird mit einem einzelnen Knoten, der die gesamten Trainingstupel repräsentiert. Falls alle Tupel dieselbe Klassenzugehörigkeit aufweisen, handelt es sich um ein Blatt. Andernfalls wird das Merkmal ermittelt, welches die Trainingstupel am besten in die Klassen separiert (lokales Optimalitätskriterium). Eingesetzt werden dazu beispielsweise die Maße *Information Gain*, *Gain Ratio* und *Gini Index* [60, Kap.6.3.2]. Auf Grundlage der resultierenden Teilmengen wird ein Unterbaum konstruiert. Dieses Vorgehen wird rekursiv fortgesetzt bis eins der folgenden Abbruchkriterien eintritt. Alle Tupel der Teilmenge gehören zu einer Klasse. Es steht kein weiteres Merkmal zur Verfügung, anhand welchem eine Aufteilung vorgenommen werden kann<sup>7</sup>. Ein Abbruch erfolgt weiterhin, falls eine resultierende Teilmenge an Trainingstupel leer ist [60, S.296].

Das beschriebene Verfahren terminiert immer, da mit rekursivem Aufruf die Merkmalsmenge jeweils reduziert wird. Eine globale Optimalität des Entscheidungsbaums ist durch das Verfahren nicht garantiert, da in jeder Iteration eine Merkmalsauswahl anhand eines lokalen Optimalitätskriteriums erfolgt (auch als *Greedy*-Verfahren bezeichnet)<sup>8</sup> [90, S.186]. Eine Möglichkeit, die Größe eines konstruierten Baums zu reduzieren (Erhöhung der Generalisierungsfähigkeit), ist die Ersetzung von Unterbäumen durch Blätter oder die Verschiebung von Unterbäumen in Richtung Wurzelknoten (die ersetzten Knoten entfallen). Diese Art der Optimierung wird als *Pruning* (Beschneidung) bezeichnet; der C4.5 Algorithmus erweitert das ID3-Verfahren diesbezüglich.

Im Rahmen der Arbeit wurden gerichtete Entscheidungsbäume eingesetzt, die mit R. Quinlans C4.5-Verfahren [126] erzeugt wurden. Genutzt wurde dazu eine quelloffene Implementierung (J48) der WEKA-Bibliothek zum maschinellen Lernen [57].

---

<sup>7</sup>Es folgt eine Umwandlung des Knotens in ein Blatt. Als Klassenzugehörigkeit wird die Klasse mit der höchsten Auftretenswahrscheinlichkeit in den Trainingstupeln gewählt oder die Auftretenswahrscheinlichkeiten der einzelnen Klassen abgespeichert.

<sup>8</sup>Ohne diese Eingrenzung wäre die Anzahl an möglichen EB exponentiell in der Merkmalsanzahl.

#### 4.1.2.2 Random Forests

Die Klassifikationsgüte lässt sich häufig durch eine Kombination (Komitee / Ensemble) aus mehreren Klassifikationsmodellen steigern; im Englischen wird dies auch als *Ensemble (Machine) Learning* bezeichnet. Das Klassifikationsergebnis basiert in diesen Fällen nicht auf der Ausgabe eines einzelnen Modells sondern beispielsweise auf dem arithmetischen Mittel der Ausgaben der kombinierten Modelle [24, S.653f].

Motiviert durch die hohe Ausführungsgeschwindigkeit von EB stellte T. K. Ho 1995 die *Random Decision Forests* vor, um EB auch für komplexe Klassifikationsprobleme ohne Verlust der Generalisierungsfähigkeit verfügbar zu machen [68]. Das Prinzip beruht darauf, mehrere EB auf zufällig ausgewählten Teilmengen des Merkmalsraums zu konstruieren (*Randomly Selected Subspaces of the Feature Space*). Die einzelnen EB generalisieren das Klassifikationsproblem auf den Teilmengen besser und in Kombination lässt sich die Klassifikationsgüte steigern. L. Breiman und A. Cutler prägten im Jahr 2001 die Bezeichnung *Random Forests* (RF) [28]. Ihr Ansatz kombiniert die zufällige Auswahl von *Suspaces* (gleicher Verteilung) mit Breimans *Bootstrap Aggregating (Bagging)*-Methode zur Konstruktion eines Komitees (Ensembles) aus EB<sup>9</sup>. Mit *Bagging* werden verschiedene Versionen von Vorhersagemodellen, jeweils auf Grundlage von Teilmengen (*Bootstrap Replicates*) der Gesamtheit aller Trainingstupel, erstellt. Die Tupel der Teilmengen werden dabei zufällig aus der Gesamtheit an Trainingstupel ausgewählt, eine Mehrfachauswahl eines Tupel ist dabei möglich. Die Verteilung der Tupel der Teilmengen stellen eine Annäherung der Verteilung der Gesamtheit an Trainingstupel dar (*Bootstrap Replicates of Learning Set*). Die Konstruktion der Vorhersagemodelle erfolgt auf jeweils einer Teilmenge. Die Vorhersagen der einzelnen Modelle werden für numerische Ausgaben gemittelt und für die Vorhersage einer Klassenzugehörigkeit erfolgt ein Mehrheitsentscheid (*Plurality Vote*). Im Zusammenhang mit RF wurde der Algorithmus zur Konstruktion der einzelnen EB verändert, sodass für die Erstellung der einzelnen Knoten eine zufällige Auswahl der Merkmale (*Random Features*) erfolgt. Auf diese Weise treten besonders geeignete Merkmale nicht bevorzugt in den EB auf und eine Korrelation zwischen den EB wird vermieden. Dies verbessert die Robustheit gegenüber Ausreißern sowie Störungen und erhöht die Generalisierungsfähigkeit. Im Anschluss an die Konstruktion der EB wird kein *Pruning* angewandt [28]. In [148, Kap.6.3] wird ein Ansatz (*Model Map*) für die Visualisierung des resultierenden Klassifikationsmodells beschrieben.

Im Rahmen der vorliegenden Arbeit kam WEKA für das Training und die Evaluation der RF zum Einsatz. Der Trainingsvorgang kann über die folgenden Parameter gesteuert werden: Anzahl an zu erstellenden Entscheidungsbäumen, die maximale Baumtiefe, die zu berücksichtigende Anzahl an Merkmalen und den Startwert für den Zufallsgenerator.

#### 4.1.3 Merkmale von MLP, EB und RF

Im Folgenden wird eine Auswahl an Stärken (+) und Schwächen (–) der drei verwendeten Klassifikatoren aufgeführt:

<sup>9</sup>Weitere Methoden der Randomisierung von Bäumen sind in [28] beschrieben.

### Mehrschichtige Perzeptrons

- + Mit einem mehrschichtigen Perzeptron, mit einer ausreichenden Anzahl an verdeckten Neuronen, lässt sich ein universeller Klassifikator realisieren [60, S.329][90, S.162], dessen hoher praktischer Nutzen für die Mustererkennung durch eine Vielzahl an Anwendungen bestätigt wurde [24, S.230][102]. Die erzielte Klassifikationsgüte ist konsistent hoch für verschiedene Gütekriterien (jedoch nicht außergewöhnlich hoch) [32].
- Das konstruierte Vorhersagemodell (Gewichts- und Biaswerte) ist für Menschen schwer interpretierbar (*Black Box*) [60, S.335].

### Entscheidungsbäume

- + EB bieten eine hohe Ausführungsgeschwindigkeit [68] und sind daher besonders für den Einsatz auf Mikroprozessoren geeignet. Aus einem EB kann direkt eine regelbasierte Klassifikation abgeleitet werden. EB bieten ein für Menschen interpretierbares Vorhersagemodell [90, S.186f].
- Für komplexe Datenreihen können EB eine hohe Anzahl an Knoten und unter Umständen eine niedrigere Generalisierungsfähigkeit aufweisen (Überanpassung, *Overfitting*). Dies kann sich weiterhin nachteilig auf die Interpretierbarkeit auswirken.

### Random Forests

- + RF sind für umfangreiche Datenreihen geeignet und bieten eine sehr hohe Klassifikationsgüte, auch im Vergleich zu anderen Klassifikatoren [32]. Die Anzahl an EB eines RF kann erhöht werden, ohne dass eine Überanpassung eintritt. Die Trainingsdauer ist vergleichsweise kurz und steigt linear mit der Anzahl an EB. Die Klassifikation mit RF ist in hohem Maße parallelisierbar (unabhängige Ausführung der EB) [28].
- Im Gegensatz zu einem einzelnen EB ist die Entscheidungsfindung des RF für den Menschen schwerer zu interpretieren.

Im Rahmen der vorliegenden Arbeit wurde die Klassifikationsgüte für die unterschiedlichen Datenreihen für die drei Klassifikatoren gegenübergestellt. MLP wurden ausgewählt aufgrund ihrer praktikablen Einsetzbarkeit, konsistent hohen Klassifikationsgüte und ihrem weit verbreiteten Einsatz zur Mustererkennung in inertialen und physiologischen Sensorsignalen des Menschen [97; 102; 146; 149]. EB fanden ebenfalls in diesem Zusammenhang Anwendung [14; 16] und wurden aufgrund ihrer hohen Ausführungsgeschwindigkeit betrachtet, welche für den Einsatz auf einem Mikroprozessor eines Körpersensors von Bedeutung ist. Darüber hinaus erfolgte die Evaluation weiterer Klassifikatoren. Der RF-Klassifikator erzielt auf den unterschiedlichen Datenreihen der hier durchgeführten Versuche (siehe Anhang A) die besten Klassifikationsergebnisse und wurde daher mit in den Vergleich aufgenommen.

Die Auswahl der drei Klassifikatoren schließt nicht die Eignung weiterer Verfahren für die Verarbeitung von Sensormesswerten von Körpersensoren aus. In der Literatur fanden in diesem Zusammenhang unter anderem der k-Nächste-Nachbarn-Algorithmus, der Naïve

Bayes-Klassifikator, Support Vektor Maschinen, Hidden Markov Modelle und *Gaussian Mixture Models* Anwendung [14; 102].

#### 4.1.4 Datenpartitionierung für Evaluation

Das Training eines Klassifikators auf der vollständigen Datenreihe berücksichtigt zwar die Gesamtheit der Tupel während der Modellbildung, die Ergebnisse einer Evaluation auf denselben Tupel können jedoch durch eine (hohe) Überanpassung (engl. *Overfitting*) verzerrt sein. Diesem Problem wird mittels einer Partitionierung der Datenreihe in unabhängige Tupel für Training und Evaluation begegnet. Im Folgenden wird ein Überblick der in [130] beschriebenen (verbreiteten) Methoden gegeben.

Die einfachste Methode (*Hold-Out Validation*) teilt die Datenreihe in zwei nicht überlappende Partitionen mit Tupel für Training und Evaluation (Test). Auf diese Weise kann die Generalisierungsfähigkeit auf den unbekanntem Evaluationstupeln abgeschätzt werden. Nachteilig ist, dass nicht die vollständige Datenreihe für die Modellbildung genutzt wird und die Ergebnisse von der gewählten Datenpartitionierung abhängen.

Bei der  $k$ -fachen Kreuzvalidierung (engl. *k-Fold Cross-Validation*) wird die Datenreihe in  $k$  Segmente mit gleicher Tupelanzahl aufgeteilt. Häufig wird dabei eine stratifizierte Datenpartitionierung vorgenommen, bei der eine Gleichverteilung der Tupel bezüglich der Klassen in den  $k$ -Partitionen angestrebt wird. Das Training erfolgt auf  $k - 1$  Partitionen und die Evaluation wird auf der ausgelassenen Partition durchgeführt. Dieser Prozess wird  $k$ -mal wiederholt, bis eine Evaluation auf jeder Partition erfolgt ist<sup>10</sup>. Ein hohe Anzahl an Partitionen  $k$  hat den Vorteil, dass mehrere Werte des gewählten Gütekriteriums ( $k$ -Ergebniswerte) vorliegen und ein Großteil der Datenreihe in die Modellbildung mit einfließt. Nachteilig können die Überlappung der Trainingstupel und die niedrigere Anzahl an Tupel für die Evaluation sein (Aussagekraft der Ergebnisse). Im maschinellen Lernen gilt eine 10-fache Kreuzvalidierung als guter Kompromiss und ist die am häufigsten eingesetzte Form [130].

Ein Spezialfall ist die *Leave-one-out Cross-Validation*. Bei dieser Form der Kreuzvalidierung entspricht  $k$  der Anzahl an Probanden (allgemeiner: Instanzen). Die Tupel von einem Probanden werden jeweils während des Trainings ausgelassen und für die Evaluation verwendet. Dieser Vorgang wird für die  $k$  Probanden wiederholt. Der Ansatz bietet die Möglichkeit, die Generalisierungsfähigkeit des Vorhersagemodells zu prüfen, kann jedoch zu einer hohen Varianz in den Ergebnissen führen [130].

Im Rahmen der Arbeit wurden Ergebnisse sowohl für die *Hold-Out Validation* als auch für die stratifizierte 10-fache Kreuzvalidierung ermittelt. Insbesondere für die Überprüfung der Klassifikationsgüte in Abhängigkeit einzelner Konfigurationsparameter, wie dem Merkmalsraum, wurde aufgrund des niedrigeren Berechnungsaufwands bevorzugt die *Hold-Out Validation* durchgeführt. Beim Einsatz der 10-fachen Kreuzvalidierung wurde sichergestellt, dass sich die Datenfenster während der Merkmalsberechnung nicht überlappten, um eine Unabhängigkeit der Trainings- und Evaluationstupel zu gewährleisten.

---

<sup>10</sup>Darüber hinaus wird teils eine  $k$ -fache Kreuzvalidierung mehrfach wiederholt.

### 4.1.5 Gütemaße Sensitivität und Spezifität

Im Folgenden werden die statistischen Maße Sensitivität und Spezifität vorgestellt, die im Rahmen der Arbeit für die Ermittlung der Klassifikationsgüte genutzt wurden. Die Berechnung der Maße erfolgt basierend auf dem Vergleich zwischen den Klassenannotationen und den Klassifikatorausgaben. Dazu wurde zunächst die Anzahl an richtig positiven (*True Positives*,  $TP_i$ ), falsch positiven (*False Positives*,  $FP_i$ ), richtig negativen (*True Negatives*,  $TN_i$ ) und falsch negativen (*False Negatives*,  $FN_i$ ) Vorhersagen bestimmt.  $TP_i$  bezeichnet eine richtige und  $FP_i$  eine falsche Entscheidung für eine Klasse  $i$ .  $TN_i$  hingegen steht für eine richtige und  $FN_i$  für eine falsche Entscheidung gegen eine Klasse  $i$  [90, S.216f]. Für die Klasse  $i$  gibt die klassenspezifische Sensitivität  $R_i$  (auch als *Recall* bezeichnet) den prozentualen Anteil der richtig positiv klassifizierten Tupel (Entscheidungen für die Klasse) im Verhältnis zu allen Tupel mit der Klassenzugehörigkeit  $i$  an:

$$R_i = \frac{TP_i}{TP_i + FN_i} \cdot 100 \quad (4.2)$$

Entsprechend bezeichnet die klassenspezifische Spezifität  $S_i$  den Anteil an richtig negativ klassifizierten Tupel (Entscheidungen gegen die Klasse) im Verhältnis zu allen Tupel, die nicht der Klasse  $i$  angehören:

$$S_i = \frac{TN_i}{TN_i + FP_i} \cdot 100 \quad (4.3)$$

Eine kombinierte Betrachtung der beiden Gütemaße ist sinnvoll, da ein Vorhersagemodell (theoretisch) durch eine fortlaufende Bezeichnung der Tupel mit der Klassenzugehörigkeit  $i$  zwar die höchstmögliche Sensitivität von 100 %, jedoch 0 % Spezifität für diese Klasse  $i$  erzielen würde.

Für ein Mehrklassenproblem ist weiterhin eine klassenübergreifende Betrachtung der beiden Gütemaße von Bedeutung. Dazu wurde der gewichtete Mittelwert über die klassenspezifischen Sensitivitäts- und Spezifitätswerte gebildet,

$$\bar{R} = \sum_{i=1}^N p_i R_i \quad (4.4)$$

$$\bar{S} = \sum_{i=1}^N p_i S_i \quad (4.5)$$

wobei  $N$  die Anzahl an Klassen und  $p_i$  deren Auftretenswahrscheinlichkeit in der Datenreihe angibt. Im Rahmen der vorliegenden Arbeit wurde auf eine Gleichverteilung der Tupel geachtet ( $p_i = 1/N, \forall i$ ), um eine Benachteiligung einer Klasse während der Trainingsphase aufgrund von weniger Trainingstupel zu vermeiden. Für die im Rahmen dieser Arbeit durchgeführten Evaluationen entspricht die mittlere Sensitivität  $\bar{R}$  der (Gesamt-) Genauigkeit (engl. *Accuracy*, *ACC*) des Klassifikators [90, S.216ff]. Darüber hinaus ist in der Literatur das Gütemaß Präzision zu finden, welches in Kombination mit dem *Recall* (Sensitivität) das F-Maß ergibt; genutzt werden diese jedoch vorwiegend in dem Bereich des *Information Retrievals*.

## 4.2 Gang- und Laufgeschwindigkeit

Im Rahmen der vorliegenden Arbeit wurde eine Gang- / Laufgeschwindigkeitsbestimmung auf Grundlage von Beschleunigungsmessungen des BG-V4.x realisiert, die eine direkte Rückmeldung oder Abspeicherung der Geschwindigkeit ermöglicht. Die in diesem Abschnitt präsentierten Ergebnisse sind teilweise in [174] veröffentlicht.

### 4.2.1 Motivation und Ziele

Gehen stellt eine wichtige Komponente des Gesamtenergieumsatzes im Alltag eines Menschen dar, bereits 15 Minuten pro Tag können zur Verhinderung einer Gewichtszunahme beitragen [153]. Körpersensoren wie das BG-V4.x ermöglichen eine Erfassung der Ganggeschwindigkeit, die als Parameter für die Schätzung des täglichen Energiebedarfs eines Menschen genutzt werden kann (siehe Abschnitt 6.1). Darüber hinaus bestehen Anwendungsmöglichkeiten im Rahmen eines Aktivitätsmonitorings im Alltag, insbesondere in Kombination mit physiologischen Parametern (siehe ZIM-Kooperationsprojekt KF2639307KM3, Abschnitt 8) oder im Breiten- und Mannschaftssport. In diesem Zusammenhang ermöglicht eine Gegenüberstellung mit dem physiologischen Parameter Herzfrequenz, die Trainingsbelastung abzuschätzen, beispielsweise anhand des kardiovaskulären Drifts für Phasen mit konstanter Laufgeschwindigkeit. Der kardiovaskuläre Drift beschreibt einen Anstieg der Herzfrequenz und eine Reduktion des Herzschlagvolumens während einer andauernden körperlichen Belastung und steht in Zusammenhang mit einem Verlust von Wasser (Dehydrierung) und einem Anstieg der Körperkerntemperatur [1]. Weiterhin lässt sich die ermittelte Geschwindigkeit im Rahmen einer Fußgängernavigation in Innenbereichen (engl. *Pedestrian Dead-Reckoning*), in denen kein GPS-Empfang besteht, nutzen [78]. Ein vergleichbares Anwendungsszenario im Mannschaftssport stellt die zukünftige Unterstützung des videobasierten Trackingverfahrens der AG K&S dar (siehe Abschnitt 6.2), welches Bestandteil des *Sports Performance Analyzer* ist [110; 163].

Das Ziel im Rahmen der vorliegenden Arbeit bestand darin, die Gang- / Laufgeschwindigkeit basierend auf den Signalen eines Beschleunigungssensors zu bestimmen. Aufgrund ihres geringen Volumens von nur wenigen Kubikmillimetern und eines Energiebedarfs im Mikrowattbereich sind Beschleunigungssensoren heutzutage Bestandteil vieler Sportinstrumente, Körpersensoren und Smartphones und eignen sich, die Bewegungen des Trägers zu erfassen [35]. Weiterhin ermöglichen sie einen Einsatz im Außen- und Innenbereich, ohne auf eine externe Informationsquelle (z.B. GPS) angewiesen zu sein. Üblicherweise erfolgt die Anbringung eines Beschleunigungssensors zur Geschwindigkeitsbestimmung im Bereich des Fußrückens oder im Fußbett des Schuhs (z.B. kommerzielle *Foot-Pods*), oberhalb des Sprunggelenks oder im unteren Rückenbereich [12; 74; 166]. Die Messposition des BG-V4.x befindet sich auf Höhe des Sternums; dies hat für die Erfassung der Gangaktivität den Nachteil, dass zusätzlich statische Beschleunigungsanteile der Oberkörperhaltung und dynamische Anteile anderer Körperbewegungen erfasst werden. Die Messung im Brustbereich ermöglicht jedoch eine zusätzliche Erfassung wichtiger physiologischer Parameter wie der elektrischen Aktivität des Herzmuskels und der Atemtätigkeit sowie biokinematischer Parameter wie der Oberkörperhaltung. Daher wurde im Rahmen der vorliegenden Arbeit geprüft, ob sich für diese Messposition eine zuverlässige Geschwindigkeitsbestimmung realisieren lässt.

### 4.2.2 Stand der Technik und Forschung

Traditionell wird für eine Gang-/Laufgeschwindigkeitsbestimmung die zurückgelegte Strecke und die dafür benötigte Zeit erfasst und der Quotient gebildet. Besteht Kenntnis über die Länge der Strecke (z.B. 400 m-Laufbahn) wird zusätzlich nur ein Zeitmesser benötigt. In der Praxis (z.B. Breiten- und Mannschaftssport) ist jedoch die Streckenlänge unbekannt. Bereits im 18. Jahrhundert wurden dazu Pedometer entwickelt, die die Schritte des Trägers erfassen und auf diese Weise, unter Zuhilfenahme eines Schätzwerts für die Schrittlänge, eine Bestimmung der Geschwindigkeit sowie der Länge der zurückgelegten Strecke ermöglichen. Die ersten Realisierungen bestanden aus mechanischen Schaltern, die durch das Kippen einer Metallkugel im Schritttakt betätigt wurden. In aktuellen Messsystemen erfolgt die Gang-/Laufgeschwindigkeitsbestimmung unter anderem auf Grundlage von GPS, Ultraschall, Video- und Beschleunigungssensoren.

Eine GPS-basierte Positionsbestimmung weist dem Träger des Messsystems eine eindeutige Position (Längen- und Breitengrad) bezüglich des Referenzsystems Erde zu. Abhängig von der Empfindlichkeit der Antennen und der Empfangsmöglichkeiten der GPS-Informationen (z.B. Einschränkungen durch Gebäude oder Terrain) lässt sich die Position auf wenige Meter genau bestimmen. Für die Ortung ist eine Mindestanzahl von vier GPS-Satelliten nötig. Algorithmen zur Glättung und der Abgleich mit geographischen Informationen (Geodaten) in Form von kartierten Wegen oder Höheninformationen erlauben eine Verfeinerung der Positionsbestimmung in der Nachverarbeitung. Die Geschwindigkeit lässt sich im Anschluss aus der Positionsänderung ableiten, ein kommerzielles Beispiel ist das Sportinstrument *Forerunner 405CX* des Herstellers Garmin. Eine GPS-basierte Geschwindigkeitsbestimmung hat jedoch den Nachteil, dass sie im Allgemeinen<sup>11</sup> auf den Außenbereich beschränkt ist. Eine zusätzliche Kombination der Informationen eines GPS-Systems mit denen von Inertialsensoren ermöglicht die Vorteile beider Messprinzipien zu nutzen [108].

Zum Zeitpunkt der Entwicklung des BG-V4.2 (2011) fiel die Entscheidung aufgrund des primären Einsatzes im Innenbereich und des gegenüber Beschleunigungssensoren höheren Energiebedarfs gegen die Integration eines GPS-Empfängers aus.

Für die Positionsbestimmung im Innenbereich (engl. *Indoor Positioning System*) sind GPS-ähnliche Systeme verfügbar, die in der Regel aus im Raum verteilten Sendern bestehen, die elektromagnetische Wellen aussenden. Mittels Messung der Signalstärke (engl. *Received Signal Strength Indication*) oder der benötigten Signalausbreitungszeit (engl. *Time of Arrival Estimation*) kann der Empfänger seine Position relativ zu den Empfängern rekonstruieren. Aus der Änderungsrate der Position pro Zeit erfolgt die Bestimmung der Geschwindigkeit. K. Lorincz und M. Welsh demonstrierten eine Lokalisierung mittels Sensorknoten (*Beacon Nodes*) innerhalb eines Universitätsgebäudes basierend auf der Funktechnologie IEEE-802.11 [96]. Das Ortungssystem *Active Bat*<sup>12</sup> besteht aus einem Ultraschallsender, der an der zu ortenden Person befestigt wird und aus in der Decke integrierten Ultraschallempfängern; erreicht wird eine Ortungsgenauigkeit im Zentimeterbereich. Darüber hinaus ist eine Geschwindigkeits-

---

<sup>11</sup>Aktuelle hochempfindliche GPS-Systeme erlauben mittels Unterstützungsinformationen (A-GPS) des Mobilfunknetzes erste Ortungsmöglichkeiten im Innenbereich (z.B. *GNS 702* von Global Navigation Systems).

<sup>12</sup>Entwickelt an der Universität Cambridge: [www.cl.cam.ac.uk/research/dtg/attarchive/bat/](http://www.cl.cam.ac.uk/research/dtg/attarchive/bat/), letzter Zugriff 09.02.2015.

bestimmung mittels Videosystemen möglich, falls dies das Anwendungsszenario und die Räumlichkeiten erlauben; ein Beispiel für den Mannschaftssport ist der *Sports Performance Analyzer* der AG K&S.

Die hier vorgestellten Systeme sind auf eine Ausstattung des Gebäudes mit Zusatzgeräten angewiesen. Dies reduziert die Einsatzflexibilität der Positionsbestimmung, da diese nicht in unerschlossenen Gebäuden erfolgen kann.

**Beschleunigungssensoren** Für die Gang- / Laufgeschwindigkeitsbestimmung bieten Beschleunigungssensoren die Möglichkeit, die beschriebenen Probleme (Einsatz im Innen- und Außenbereich, Installation von Sendern, Empfängern oder Videokameras) zu vermeiden. Der folgende Abschnitt beschreibt, mit welchen Ansätzen die Geschwindigkeitsinformationen aus den Signalen von Beschleunigungssensoren gewonnen werden können. Zunächst wird erläutert, warum sich die Geschwindigkeit nicht mittels einer Integration der Beschleunigungssignale über die Zeit bestimmen lässt.

**Integration der Beschleunigungssignale** Für eine Bestimmung der Geschwindigkeit eines Läufers in die Vorwärtsrichtung (anterior) muss dazu das Beschleunigungssignal  $a_{AP}$  über die Zeitdauer des Laufs integriert werden. Damit ist mittels der Grundgleichung der Kinematik ( $v = a \cdot t + v_0$ ) die Geschwindigkeit  $v$  bestimmt. Wobei  $v_0$  die Startgeschwindigkeit bezeichnet, die beim Loslaufen aus dem Stand null ist oder andernfalls dem Messsystem bekannt sein muss. Ein Beschleunigungssensor misst jedoch die auftretenden Beschleunigungen in Abhängigkeit seiner Orientierung am menschlichen Körper (Körperkoordinatensystem). Die Geschwindigkeit der Person soll hingegen im Erdkoordinatensystem ermittelt werden. Dazu ist eine Abbildung der anteriorposterioren Beschleunigungen des Körperkoordinatensystems auf das Erdkoordinatensystem notwendig. Erreicht wird dies durch eine kontinuierliche Erfassung von Winkeländerungen, die in Form einer Rotationsmatrix mit dem Beschleunigungsvektor multipliziert werden.

In der Automobilindustrie wird diese Technik in Navigationssystemen eingesetzt, um die Genauigkeit der Positionsbestimmung bei unzureichendem GPS-Empfang durch Inertialsensoren<sup>13</sup> zu erhöhen. Ist kein Empfang von GPS-Signalen möglich (z.B. Tunnelfahrten), liefern Inertialsensoren auf diese Weise Stützinformationen, um eine Schätzung von Geschwindigkeit und Position fortführen zu können (engl. *Dead Reckoning*) [45]. Unter Verwendung von Methoden, wie der Kalman-Filterung, werden die Sensorsignale kombiniert (fusioniert), um den Einfluss von Störgrößen zu reduzieren. Es verbleibt jedoch stets ein Restfehler bei der Bestimmung der Rotationsmatrix, sodass es als Folge zu Verfälschungen bei der Geschwindigkeitsschätzung kommt [56]. Soll mittels einer zweiten Integration der Geschwindigkeit über die Zeit auf die zurückgelegte Strecke  $s$  geschlossen werden, fließt der Restfehler bereits quadratisch in die Schätzung ein ( $s = 1/2 \cdot a \cdot t^2$ ). Die Geschwindigkeitsschätzung benötigt daher wiederkehrend, in möglichst kurzen Zeitabständen, Stützinformationen einer externen Referenz wie beispielsweise eines GPS-Empfängers.

Im Vergleich zu einem Navigationssystem im Automobilbereich ändert sich die Lage eines am Oberkörper eines Menschen angebrachten Beschleunigungssensors jedoch kontinuierlich

<sup>13</sup>Die Genauigkeit der Rotationswinkelbestimmung wird durch die Zuhilfenahme von Gyroskopen und Magnetometern gesteigert.

innerhalb des Schrittzklus. Die Bestimmung der Rotationsmatrix ist mit einem dreiaxialen Beschleunigungssensor möglich und wird für die Annäherung des Oberkörperneigungswinkels während Phasen geringer körperlicher Aktivität eingesetzt (siehe Abschnitt 4.3). Dazu ist jedoch eine Trennung von statischen und dynamischen Beschleunigungen mittels eines Tiefpassfilters mit niedriger Grenzfrequenz (0,2 Hz - 0,6 Hz) notwendig. Im Allgemeinen reicht die Genauigkeit der Trennung insbesondere während hoher Spitzenbeschleunigungen (z.B. Fersen-Auftreffen) nicht aus, um die beschriebene Geschwindigkeitsbestimmung mittels Integration durchzuführen [107]. Als Konsequenz erfolgt eine fehlerhafte Abbildung der Beschleunigungsmesswerte der drei orthogonalen Achsen gemessen im Körperkoordinatensystem auf das Erdkoordinatensystem. Zusätzlich beeinflusst der Nullpunktfehler<sup>14</sup> (Bias oder engl. *Zero-G Level Offset*), bedingt durch Umwelteinflüsse, Alterung oder Herstellungsungenauigkeiten eines nicht speziell kalibrierten Beschleunigungssensors, die Messung der Beschleunigungen [56, S.48f]. Darüber hinaus treten Skalierungs- und Linearitätsfehler sowie Montagefehler (mechanische Belastung bei der Anbringung) auf und es „verbleibt ein stochastischer Restfehler, der als Nullpunktinstabilität bezeichnet wird“ [56, S.49-52]. Wird beispielsweise für einen Läufer während des Loslaufens die Beschleunigung über einen Zeitraum von 5 s um  $0,981 \text{ m/s}^2$  (0,1 g) zu hoch eingeschätzt, beträgt der Fehler der Geschwindigkeitsschätzung bereits  $4,9 \text{ m/s}$  (17,7 km/h).

**Integration der Beschleunigungssignale über das Schrittintervall** Eine Integration der Beschleunigungssignale ist jedoch innerhalb kurzer Zeitfenster möglich, die durch die Detektion der Zeitpunkte des Fersen-Auftreffens (Stützinformation) bestimmt werden. Die Messposition befindet sich dabei im Allgemeinen im Fußbereich, teils werden zusätzlich Gyroskope eingesetzt [166]. Die Firma *Dynastream Innovations* veröffentlichte 2005 diesbezüglich ein *White Paper*<sup>15</sup> zu ihren kommerziellen Fußsensoren (engl. *Foot-Pods*) [74]. Mittels eines Beschleunigungssensors werden kontinuierlich die Lageänderungen des Fußes verfolgt. Die ermittelten Rotationswinkel werden anschließend genutzt, um den vorwärts gerichteten Beschleunigungsanteil zu bestimmen und über das Schrittintervall zu integrieren. Der Hersteller gibt eine Genauigkeit von 97 % an, mittels Kalibrierung durch den Nutzer soll diese auf 99 % gesteigert werden können. Informationen zu der durchgeführten Evaluation sind nicht veröffentlicht.

**Gangmodelle** Ein weitere Methode besteht in der Nutzung von Modellen des menschlichen Gangs, um die Schrittlänge durch Messung der Beinbewegung zu ermitteln [166]. Das Bein wird dabei entweder als ein Segment oder aufgeteilt in Ober- und Unterschenkel modelliert. Diese Methode der Geschwindigkeitsbestimmung benötigt ebenfalls zusätzliche Gyroskope am Bein, um Winkeländerungen zu erfassen. Weiterhin benötigen die Modelle personenspezifische Informationen, wie die Unterschenkellänge. Die Komplexität solcher Modelle nimmt dabei signifikant mit der steigenden Genauigkeit zu [166]. J.-S. Hu u.a. nutzen für ihre Ganggeschwindigkeitsbestimmung mittels eines dreiaxialen Beschleunigungssensors an der Hüfte ein inverses Pendelmodell [72]. Ihre Evaluation mit 20 Probanden, die mit selbstgewählter Geschwindigkeit viermal über eine 38 m lange Teststrecke gingen, weist

---

<sup>14</sup>Abweichung des Ausgangssignals in Ruhe von der statischen Erdbeschleunigung. Für den Beschleunigungssensor LIS331HH des BG-V4.2 ist ein Nullpunktfehler von  $\pm 70 \text{ mg}$  angegeben.

<sup>15</sup>*White Paper* der Industrie liefern Hintergrundinformationen zu einer angewandten Technik oder Problemlösung.

einen Fehler der Geschwindigkeitsbestimmung von 3,4 % ( $\sigma = 2,3\%$ ) auf. Eine weiterführende durchgeführte Kalibrierung auf den ersten drei Datenreihen, unter Zuhilfenahme von personenspezifischen Informationen (Bein- und Fußlänge, Hüftweite), reduziert den Fehler auf 0,6 % ( $\sigma = 0,7\%$ ). K. Aminian u.a. setzen Gyroskope an beiden Unterschenkeln und dem rechten Oberschenkel ein und nutzen zusätzliche an der Ferse und den Zehen angebrachte Drucksensoren, um das Fersen-Auftreffen und das Zehen-Abstoßen zu detektieren [11]. Mit einer Wavelet-basierten Analyse und einem Gangmodell, das sowohl den Ober- als auch den Unterschenkel berücksichtigt, beträgt der Fehler der Ganggeschwindigkeitsbestimmung etwa 7 %. Ausgewertet wurden dazu drei Datenreihen von 20 Probanden mit jeweils mindestens 20 Schrittzyklen auf Laufbändern und einem 30 m langen Testparcours.

**Klassifikationsalgorithmen** Darüber hinaus ermöglichen Methoden des maschinellen Lernens, Vorhersagemodelle zu erstellen, die Beschleunigungssignale auf die Geschwindigkeit abbilden. Die Genauigkeit ist abhängig von der Vollständigkeit der Trainingsdaten. Während der Trainingsvorgang des Klassifikators zeitaufwändig sein kann, ist die Ausführung im Allgemeinen jedoch schnell und für eine Bestimmung der Geschwindigkeit in Echtzeit geeignet [166]. Weiterhin ist durch eine Wiederholung des Trainingsvorgangs eine Anpassung an personenspezifische Charakteristika automatisiert möglich.

Bereits 1995 beschäftigten sich K. Aminian u.a. mit der Bestimmung der Ganggeschwindigkeit mittels eines dreiaxialen Beschleunigungssensors platziert am unteren Rücken (Hüfthöhe) und eines weiteren einaxialen Sensors am rechten Fuß [12]. Untersucht wurden mit fünf Probanden Gehen und Laufen auf Laufbändern sowie auf einem Testparcours im Außenbereich. Die Geschwindigkeit wählten die Probanden dabei selbst (3,5 km/h bis 7 km/h), auftretende Steigungen betragen zwischen  $-15\%$  und  $+15\%$ . Für die Geschwindigkeitsbestimmung werden die Spitzenbeschleunigungen des Fersen-Auftreffens detektiert und genutzt, um eine Segmentierung der vier Beschleunigungssignale in Schritte vorzunehmen. Es folgt die Berechnung von zehn Merkmalen: Dauer des Schrittzklus, Median-Werte der AP-, ML- und V-Beschleunigungsachsen, Spitzenwert des Fersen-Auftreffens und Kovarianzen zwischen den Spitzenwerten der drei Beschleunigungssignale. Die Klassifikation erfolgt mit zwei MLPs mit jeweils fünf verdeckten Neuronen, wobei die Ausgabe des ersten MLPs die Steigung und die des zweiten MLPs die Geschwindigkeit schätzt. Das Training der beiden MLPs erfolgte auf den Daten, die auf den Laufbändern aufgezeichnet wurden und die Evaluation auf den Daten des Außentestparcours. Der Fehler der Geschwindigkeitsbestimmung beträgt weniger als 16 % und für die Steigungserkennung wird ein Korrelationskoeffizient von  $r = 0,98$  ( $\sigma = 2,3\%$ ) erzielt. Die Ergebnisse zeigen weiterhin eine signifikante Korrelation zwischen der Geschwindigkeit und den Varianz-Werten sowie der Zeitdauer der Schrittzyklen.

K. Zhang u.a. analysierten, inwiefern sich körperliche Alltagsaktivitäten erkennen und bewerten lassen [169]. Dazu wurden 32 Aktivitäten von 76 Probanden mit jeweils fünf Beschleunigungssensoren aufgezeichnet, die verteilt am Körper (Brust, Oberschenkeln und Füßen) angebracht waren. Zu den körperlichen Aktivitäten zählten Gehen und Laufen mit sechs von den Probanden auf einer 60 m Laufbahn selbst gewählten Geschwindigkeiten (jeweils langsam, normal und schnell). Die realisierte Geschwindigkeitsbestimmung erreicht eine hohe Übereinstimmung mit der realen Geschwindigkeit ( $r = 0,986$ ,  $p \leq 0,0001$ ).

Y. Song u.a. nutzen einen dreiaxialen Beschleunigungssensor im Brustbereich, um Gang-

#### 4. Biokinematische Parameter

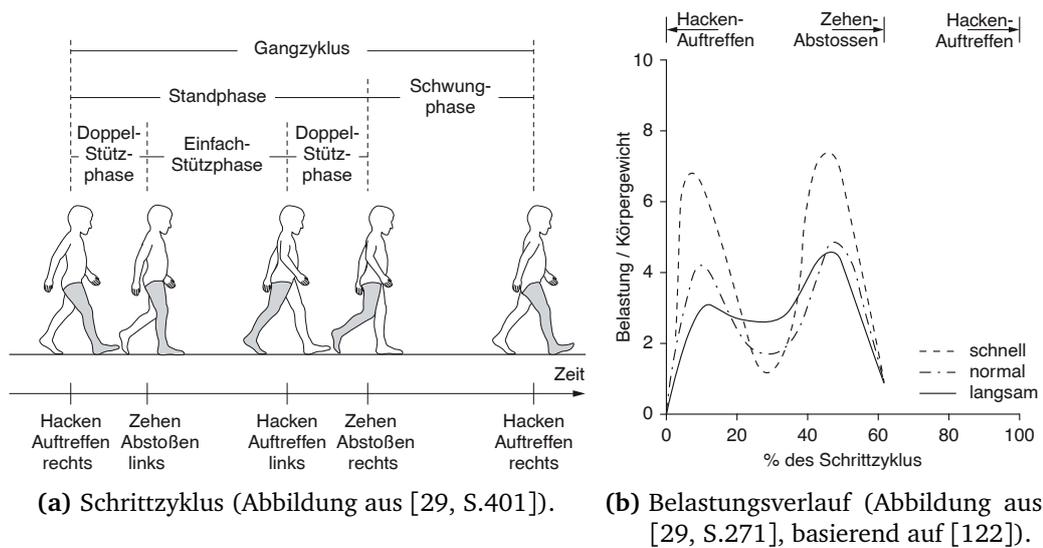


Abbildung 4.3.: Phasen des Schrittzklus des menschlichen Gangs (a) und der Belastungsverlauf während der Standphase am Hüftgelenk für verschiedene Ganggeschwindigkeiten (b).

und Laufgeschwindigkeiten zwischen 4,8 km/h und 15,4 km/h sowie Steigungen von 6 % bis 21,5 % zu erkennen [146]. Das Verfahren basiert auf einer Segmentierung der Beschleunigungssignale in Schritte mit einer anschließenden Berechnung der Zeitdauer des Schrittzklus und des Spitze-Tal-(ST)-Werts. In Verbindung mit den Probandeneigenschaften Größe und Gewicht dienen diese Merkmale als Eingabe eines Klassifikationssystems. Zum Einsatz kommt ein MLP mit zehn verdeckten Neuronen, welches zunächst zwischen Gehen und Laufen unterscheidet. Die Schrittlänge wird im Anschluss für Gehen und Laufen getrennt mit jeweils einem MLP (20 verdeckte Neuronen) geschätzt und die Geschwindigkeit aus der bestimmten Schrittlänge und -dauer berechnet. Die Evaluation mit 17 Probanden zeigt, dass sich Gehen und Laufen mit einer Genauigkeit von >99 % unterscheiden lassen. Für die Geschwindigkeitsbestimmung auf Laufbändern wird eine Korrelation von  $r = 0,987$  erzielt. Der Fehler der Geschwindigkeitsschätzung beträgt für einen 10 km-Lauf auf einer Laufbahn im Außenbereich 9,6 %.

H. Zhenyu und W. Zhang nutzen für ihre Geschwindigkeitsbestimmung einen an der Hüfte angebrachten dreiaxialen Beschleunigungssensor [63]. Als Merkmale werden die Schrittzahl, der RMS- und der ST-Wert der vertikalen und anteriorposterioren Beschleunigungen sowie die Größe des Probanden verwendet. Mit einem MLP mit 13 verdeckten Neuronen wird eine Genauigkeit von 97 % für eine Datenreihe mit 35 Probanden erreicht, die mit natürlicher Ganggeschwindigkeit einen 50 m langen Testparcours im Außenbereich absolvierten.

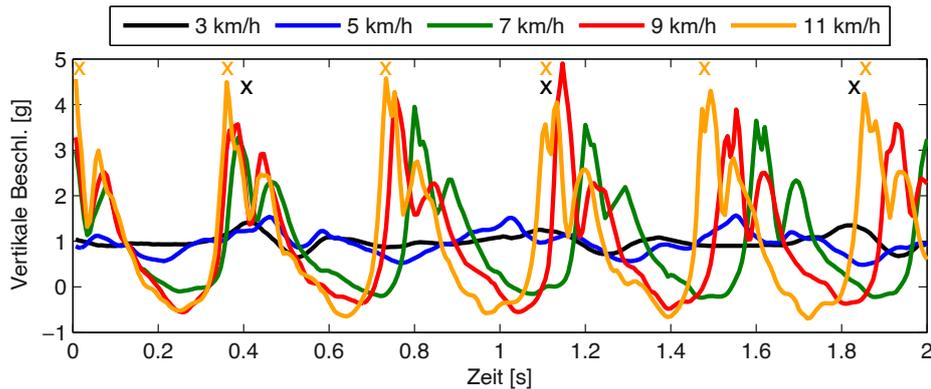


Abbildung 4.4.: Vertikales Beschleunigungssignal eines Probanden eingefärbt für fünf Geschwindigkeiten zwischen 3 und 11 km/h (Datenreihe V1.1). Die Markierungen (x) zeigen jeweils die Zeitpunkte des Fersen-Auftreffens für 3 und 11 km/h.

### 4.2.3 Geschwindigkeitsinformationen in Schrittmustern

Der menschliche Gang weist einen zyklischen Bewegungsablauf auf. Der Schrittzklus (Doppelschritt)<sup>16</sup> wird dabei in die Stand- und die Schwungphase eingeteilt [29, S.400f]. Die Standphase bezeichnet den Zeitraum, in dem Bodenkontakt besteht. Sie beginnt mit dem Auftreffen der Ferse (auch als Hacke bezeichnet) und reicht bis zum Abstoßen mit den Zehen. Es folgt die Schwungphase bis zum nächsten Fersen-Auftreffen (siehe Abbildung 4.3a). Während des Gehens haben beide Füße zu Anfang und in der Mitte des Schrittzklus für etwa 10 % der Zeit Bodenkontakt (Doppelstützphase). Beim Laufen hingegen tritt die Doppelstützphase nicht auf und beide Beine bewegen sich mit dem Körper vorwärts, dies vergrößert die Schrittlänge. Die zeitlichen Anteile der Stand- und Schwungphase betragen für Gehen etwa 60 % und 40 %, während des Laufens sind es jeweils 50 % [29, S.400f].

Bereits 1967 analysierte J.P. Paul den menschlichen Gang mit unter anderem Kraftplatten, Videokameras und Elektromyographie-Messgeräten. In der Abbildung 4.3b sind die Ergebnisse seiner Untersuchungen zum Belastungsverlauf am Hüftgelenk während der Standphase dargestellt [122]. Belastungsspitzen treten jeweils durch das Abbremsen beim Auftreffen der Ferse und beim Abstoßen mit den Zehen auf.

Der zyklische Bewegungsablauf, bestehend aus periodischem Beschleunigen und Abbremsen, Heben und Fallen des Körpers [42], lässt sich mit einem Beschleunigungssensor erfassen und stellt vereinfacht betrachtet eine Schwingung entsprechend der Schrittfrequenz dar. Aufgezeichnet mit dem dreiaxialen Beschleunigungssensor des BG-V4.1 ist dieser Ablauf für Gehen und Laufen in der Abbildung 4.4 dargestellt.

Die Ganggeschwindigkeit ist abhängig von der Schrittlänge und der Schrittfrequenz. Mit zunehmender Geschwindigkeit nimmt der zeitliche Anteil der Doppelstützphase ab, um die Schrittlänge zu vergrößern, bis beide Füße keinen gemeinsamen Bodenkontakt mehr ha-

<sup>16</sup>Im Englischen als *Stride* (2 Steps) bezeichnet.

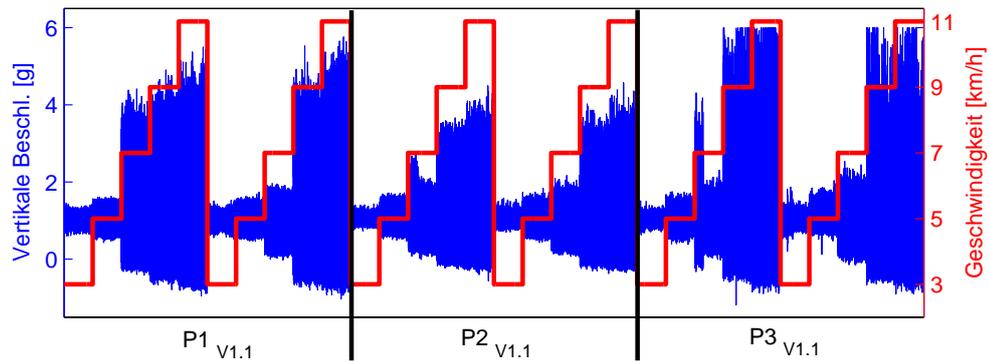


Abbildung 4.5.: Gegenüberstellung des vertikalen Beschleunigungssignals (Datenreihe V1.1) von drei Probanden (P1 bis P3) für Geschwindigkeiten zwischen 3 und 11 km/h (rote Markierung). P3<sub>V1.1</sub> wechselte bei der ersten Absolvierung der Geschwindigkeitsstufe 7 km/h von zunächst Laufen zu Gehen.

ben. Dazu müssen größere Kräfte auf den Boden übertragen werden (Bodenreaktionskraft), die resultierenden Beschleunigungen des Körpers nehmen zu [160]. Dieser Zusammenhang spiegelt sich im vertikalen Beschleunigungssignal durch eine signifikante Zunahme des ST-Werts wider. Zusätzlich wird die Geschwindigkeit über eine Erhöhung der Schrittfrequenz gesteigert, die eine Änderung der Frequenzkomponenten im Beschleunigungssignal bewirkt (Frequenzzunahme der Grundschiwingung). Während die Änderung des ST-Werts des vertikalen Beschleunigungssignals für den in der Abbildung 4.4 dargestellten Probanden für Gehen mit 3 km/h etwa 1 g betragen, waren es beim Laufen mit 11 km/h bereits 5 g. Zusätzlich verdoppelte sich die Schrittfrequenz annähernd.

Schrittmuster und die darin enthaltenen Geschwindigkeitsinformationen weisen jedoch im Allgemeinen eine hohe Variabilität auf. Bei 11 der 22 Probanden aus V1.1 traten bei 3 km/h bis 9 km/h Schwankungen von mehr als 0,5 g (Fersen-Auftreffen) innerhalb einer Geschwindigkeitsklasse auf (intraindividuelle Variabilität). Acht der Probanden wechselten dabei während 7 km/h zwischen Gehen und Laufen mit signifikanten Auswirkungen auf die Signalverläufe. Am Beispiel der positiven Spitzenbeschleunigung während des Laufens mit 11 km/h werden die zusätzlichen hohen Schwankungen im Signalverlauf zwischen den Probanden deutlich (interindividuelle Variabilität). Die Spitzenbeschleunigung von zwei Probanden überschritt bei (fast) jedem Fersen-Auftreffen den Messbereich von 6 g des vertikalen Beschleunigungssensors. Bei weiteren sechs Probanden traten Spitzenbeschleunigungen von oberhalb 5,5 g auf und es kam ebenfalls teils zu einer Überschreitung des Messbereichs. Dahingegen lagen die Spitzenbeschleunigungen von drei Probanden nur zwischen 4,5 g und 5,5 g und für weitere fünf Probanden unterhalb von 4,5 g (bei zwei der fünf Probanden sogar <4 g). Für drei Probanden wird die intra- und interindividuelle Variabilität des vertikalen Beschleunigungssignals in der Abbildung 4.5 sichtbar.

Die Variabilität des menschlichen Gangs ist auch Gegenstand von Arbeiten im Bereich der Biomechanik [20; 26]. Die beobachteten Unterschiede zwischen Personen sind ausreichend,

um eine Personenidentifikation anhand des individuellen Gangstils zu realisieren (siehe Kapitel 5). Die Variabilität erschwert jedoch die Ableitung der Geschwindigkeitsinformationen aus den Beschleunigungssignalen und bedarf daher eines entsprechend robusten Ansatzes.

#### 4.2.4 Verfahrensbeschreibung

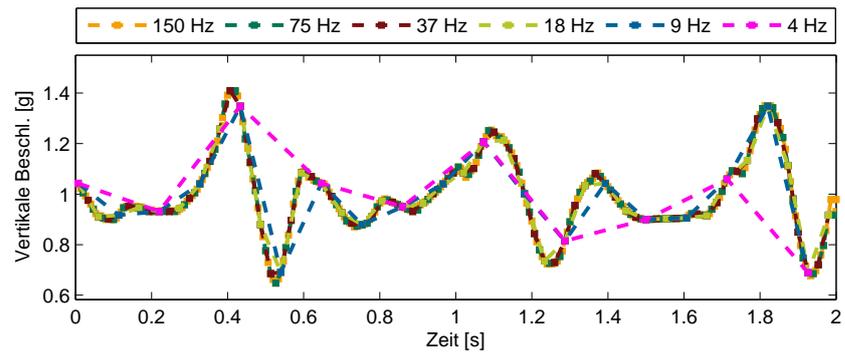
Im Rahmen der vorliegenden Arbeit ist die Geschwindigkeitsbestimmung mittels einer Merkmalsextraktion und einem sich anschließenden Klassifikator realisiert. Dabei werden Merkmale genutzt, die gezielt die Geschwindigkeitsinformationen der Schrittmuster (Schrittlänge und -frequenz) abbilden. Um eine einfache Handhabung und Anwendbarkeit des Körpersensors zu erzielen, wurde auf zusätzliche am Körper anzubringende Sensoren für die Geschwindigkeitsbestimmung verzichtet. Aufgrund der Messposition im Brustbereich scheiden Gangmodelle aus, die Beschleunigungen und Winkeländerungen des Ober- und Unterschenkels unter Zuhilfenahme von Gyroskopen analysieren. Weiterhin wird kein Verfahren eingesetzt, das auf einer Integration der Beschleunigungssignale über die Zeitdauer der Schrittdauer basiert. Zwar ist eine Segmentierung der Beschleunigungssignale in Schritte möglich, jedoch erschwert die zusätzlich gemessene (hohe) Oberkörperaktivität eine zuverlässige Bestimmung der anteriorposterioren Beschleunigung bezüglich des Erdkoordinatensystems, insbesondere für Einsatzszenarien wie dem Handball-Mannschaftssport. Darüber hinaus bestand das Ziel, ein Vorhersagemodell mit einem möglichst hohen Generalisierungsgrad zu realisieren, sodass keine personenspezifischen Zusatzinformationen (z.B. Beinlänge und Körpergröße) für die Geschwindigkeitsbestimmung erfasst werden müssen. Die im Rahmen einer bewegungsbasierten Spielsteuerung realisierte zustands- und schwellenwertbasierte Schritterkennung [37, Kap.4-5] zeigte, dass eine personenspezifische Anpassung von Schwellenwerten notwendig ist, um interindividuelle Variabilitäten in den Signalverläufen zu kompensieren. Bezüglich der beobachteten Variabilität in der Datenreihe der 20 Probanden aus V1.1 ist daher ein hoher manueller Anpassungsaufwand für eine zustands- und schwellenwertbasierte Geschwindigkeitsbestimmung zu erwarten.

Das im Folgenden beschriebene Verfahren fasst die Geschwindigkeitsinformationen der Beschleunigungssignale in einem Merkmalsraum zusammen und ermöglicht mittels des Trainings eines Klassifikators, ein (robustes) Vorhersagemodell zu erstellen, welches, falls nötig, in einem automatisierbaren Prozess durch zusätzliche Trainingsdaten an eine Person oder geänderte Bedingungen des Anwendungsszenarios angepasst werden kann.

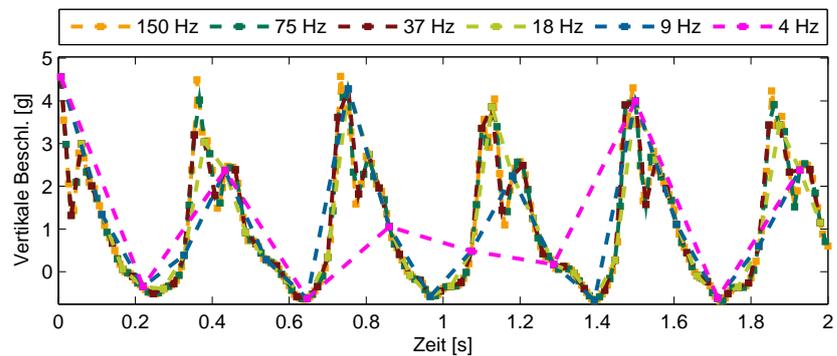
##### 4.2.4.1 Datenakquise

Für die Bestimmung der Geschwindigkeit beinhalten die vertikalen Beschleunigungsmessungen besonders viele Geschwindigkeitsinformationen des Schrittmusters (Schrittlänge und -frequenz). Für langsames Gehen bei 3 km/h ist eine Erfassung des Schrittmusters bereits ab einer niedrigen Aufzeichnungsfrequenz von 9 Hz möglich (siehe Abbildung 4.6a). Für höhere Geschwindigkeiten, wie das Laufen mit 11 km/h, sind jedoch mindestens 37 Hz nötig, um die auftretenden Spitzenbeschleunigungen zu erfassen (siehe Abbildung 4.6b). Für den Erhalt zusätzlicher Details des Signalverlaufs des Schrittmusters (z.B. des Fersen-Auftreffens) ist eine Aufzeichnungsfrequenz von mindestens 75 Hz sinnvoll. Der Einfluss der Aufzeichnungsfrequenz auf die Genauigkeit der Geschwindigkeitsbestimmung wurde im Rahmen einer Entwurfsraumexploration in Kapitel 7 gesondert betrachtet.

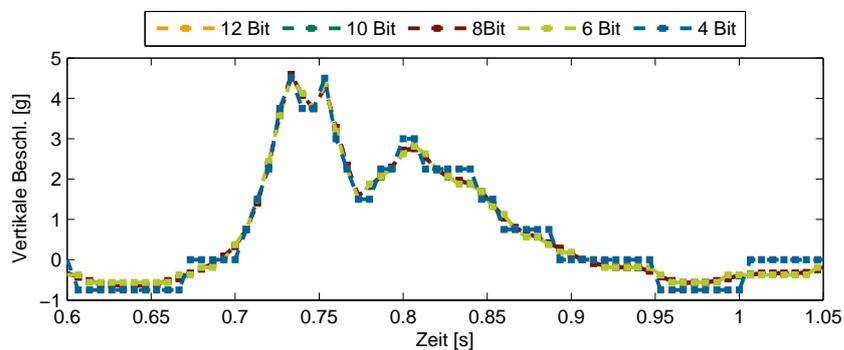
#### 4. Biokinematische Parameter



(a) Gehen mit 3 km/h.



(b) Laufen mit 11 km/h.



(c) Einzelner Schritt (Auswahl 0,6 s bis 1,05 s) während des Laufens mit 11 km/h.

Abbildung 4.6.: Schrittmuster im vertikalen Beschleunigungssignal während des Gehens und Laufens (Datenreihe V1.1). Gezeigt sind Aufzeichnungsmöglichkeiten mit verschiedenen Frequenzen (a, b) und Wortbreiten (c).

Die Aufzeichnung der in der Abbildung 4.6 dargestellten Schrittzyklen erfolgte mit dem im BG-V4.1 integrierten Beschleunigungssensor LIS3LV02DL von STMicroelectronics. Für einen Messbereich von  $\pm 6$  g liefert der Sensor Beschleunigungsmesswerte mit einer Wortbreite von 12 b. Der Verlauf des Schrittzklus bleibt jedoch auch bei einer Reduktion auf bis zu 6 b (64

Quantisierungsstufen) ohne signifikante Abweichungen erhalten (siehe Abbildung 4.6c).

Die Analyse der Datenreihe aus Versuch V1.1 ergab, dass für sportliche Aktivitäten, wie dem Laufen, ein Beschleunigungssensor mit einem Messbereich von mehr als  $\pm 6$  g eingesetzt werden sollte, um Spitzenbeschleunigungen des Fersen-Auftreffens erfassen zu können. Für das BG-V4.2 wurde daher der Beschleunigungssensor LIS331HH von STMicroelectronics gewählt, dessen Messbereich auf  $\pm 6$  g,  $\pm 12$  g und  $\pm 24$  g einstellbar ist. Die Aufzeichnung einer Handballmannschaft (V3) zeigte, dass auch in diesem hochdynamischen Anwendungsszenario mit Sprints, Sprüngen und Körperkontakten ein Messbereich von  $\pm 12$  g ausreicht. Für die Messung im Fußbereich sollten jedoch  $\pm 24$  g gewählt werden, um Beschleunigungsspitzen zu erfassen.

#### 4.2.4.2 Merkmalsextraktion

Um Geschwindigkeitsinformationen aus den Beschleunigungssignalen zu extrahieren, werden in der Zeitdomäne die Merkmale Spitze-Tal-Wert (ST), arithmetisches sowie quadratisches Mittel (engl. *Root Mean Square*, RMS), Varianz (Var) und das arithmetische Mittel über die Vektorlängen (hier dreidimensionale euklidische Norm) der Beschleunigungsvektoren des jeweiligen Datenfensters berechnet.

Der Spitze-Tal-Wert (siehe Gleichung 4.7) des vertikalen Beschleunigungssignals steht in Zusammenhang mit der Schrittlänge [160]. Eine Vergrößerung der Schrittlänge zur Geschwindigkeitssteigerung führt dabei zu einer Zunahme der Bodenreaktionskräfte. Eine Korrelation zwischen der Gang- / Laufgeschwindigkeit wird in der Literatur insbesondere für das Merkmal Varianz (siehe Gleichung 4.9) beschrieben [12; 91]. Die Varianz ist ein Streuungsmaß, welches Änderungen des Schrittmusters aufgrund von Schrittlängen- und Schrittfrequenzanpassungen widerspiegelt, die Varianz nimmt dabei mit der Geschwindigkeit zu. Das arithmetische Mittel (siehe Gleichung 4.8) über ein Datenfenster, das den vollständigen Schrittzzyklus (oder ganzzahlige Vielfache) umfasst, stellt eine Approximation des statischen Beschleunigungsanteils (Gravitationskraft) dar, da sich dynamische Anteile, wie die vertikale Auf- und Abwärtsbewegung, im Mittel aufheben. Dies gilt jedoch nicht für dynamische Beschleunigungsanteile, die zu einer Änderung der Gang- / Laufgeschwindigkeit führen. Der statische Beschleunigungsanteil beschreibt die Lage des Beschleunigungssensors und damit die Oberkörperhaltung. Gegenüber dem arithmetischen Mittel nehmen betragsmäßig größere Werte stärkeren Einfluss bei der Berechnung des quadratischen Mittels (siehe Gleichung 4.10). Zusätzlich wurde die Länge des Beschleunigungsvektors berechnet (siehe Gleichung 4.11). Aufgrund des Quadrierens fließen die Beschleunigungsinformationen der drei orthogonalen Achsen dabei vorzeichenlos ein. Anschließend wird das arithmetische Mittel über das Datenfenster gebildet, um einen Merkmalswert für jedes Datenfenster zu erhalten (relevant für zeitliche Synchronisierung zwischen Merkmalen und der Repräsentation im Merkmalsraum).

Ein Datenfenster  $\mathbf{a}$  wird dabei mittels einer Rechteck-Fensterfunktion gebildet und umfasst  $L$ -Beschleunigungsmesswerte (Fensterlänge) zum Zeitpunkt  $t$  von einer der drei orthogonalen Beschleunigungsachsen.

$$\mathbf{a} = \{a_t; a_{t+1}; \dots; a_{t+L-1}\} \quad (4.6)$$

Die jeweilige Achse wird tiefgestellt mit AP, ML und V angegeben. Auf Grundlage der Datenrei-

he aus dem Versuch V1.1 (siehe Anhang A.1.1) wurde heuristisch eine geeignete Fensterlänge von  $L = 300$  Beschleunigungsmesswerten (zwei Sekunden) ermittelt. Die Verschiebung des Datenfensters über die jeweils betrachtete Datenreihe erfolgt gleitend mit einem Versatz von 25 % der Fensterlänge. Im Folgenden ist die Berechnung der Merkmale für ein Datenfenster angeben:

$$\text{ST-Wert} \quad \hat{\mathbf{a}} = \max(\mathbf{a}) - \min(\mathbf{a}) \quad (4.7)$$

$$\text{Arith. Mittel} \quad \bar{\mathbf{a}} = \frac{1}{L} \cdot \sum_t^{t+L-1} a_t \quad (4.8)$$

$$\text{Varianz} \quad \sigma_a^2 = \frac{1}{L-1} \cdot \sum_t^{t+L-1} (a_t - \bar{\mathbf{a}})^2 \quad (4.9)$$

$$\text{Quadrat. Mittel} \quad \text{RMS}_a = \sqrt{\frac{1}{L} \cdot \sum_t^{t+L-1} a_t^2} \quad (4.10)$$

Die Merkmalsberechnung erfolgt dabei zu jedem Zeitpunkt  $t$  bis zu dreimal für anterior-posteriore ( $a_{AP}$ ), mediolaterale ( $a_{ML}$ ) und vertikale ( $a_V$ ) Beschleunigungen. Als zusätzliches Merkmal wird das arithmetische Mittel über die Längen der  $L$ -Beschleunigungsvektoren gebildet:

$$|\bar{\mathbf{a}}| = \frac{1}{L} \cdot \sum_t^{t+L-1} \sqrt{a_{AP\_t}^2 + a_{ML\_t}^2 + a_{V\_t}^2} \quad (4.11)$$

Um die Leistung der Geschwindigkeitsbestimmung in Bezug auf Genauigkeit, Robustheit und Generalisierungsgrad zu steigern, werden verschiedene Merkmale in einem mehrdimensionalen Merkmalsraum kombiniert. Für ein Zweiklassenproblem, bei dem zwischen Gehen und Laufen unterschieden werden soll, ermöglicht bereits eine Kombination der ST-Werte des vertikalen und mediolateralen Beschleunigungssignals eine Unterscheidung der beiden Klassen (siehe Abbildung 4.7). Gehen und Laufen einer einzelnen Person können in diesem Fall durch die Verwendung eines zweidimensionalen Merkmalsraums und einer *Support Vektor Maschine* (SVM) mit einer linearen Trennfunktion mit einer Genauigkeit von 83,8 % separiert werden<sup>17</sup>. Bereits in diesem stark vereinfachten Anwendungsszenario kann der Einsatz einer nichtlinearen Trennfunktion die Genauigkeit jedoch steigern, indem Fehlklassifikationen im Übergangsbereich zwischen 1,5 g und 2 g (vertikaler ST-Wert) reduziert werden.

Für eine zusätzliche Unterscheidung verschiedener Geschwindigkeitsklassen und ein personenunspezifisches Vorhersagemodell ist eine nichtlineare Trennfunktion notwendig. Die Abbildung 4.8a zeigt dazu die ST-Werte berechnet für die Beschleunigungssignale von 16 Probanden mit unterschiedlicher Farbgebung für die fünf Geschwindigkeitsstufen 3 km/h bis 11 km/h (V1.1). Der ST-Wert erhöht sich mit der Geschwindigkeitszunahme und die verschiedenen Geschwindigkeiten sind als Cluster bereits in einer dreidimensionalen Darstellung

<sup>17</sup>Datenreihe vom 30.08.2010 mit zwei Probanden. Die Aufzeichnung der Beschleunigungssignale erfolgte mit der in [65] entwickelten INS-Platine und die Erfassung der GPS-Informationen mit dem 747A+ von Transystem.

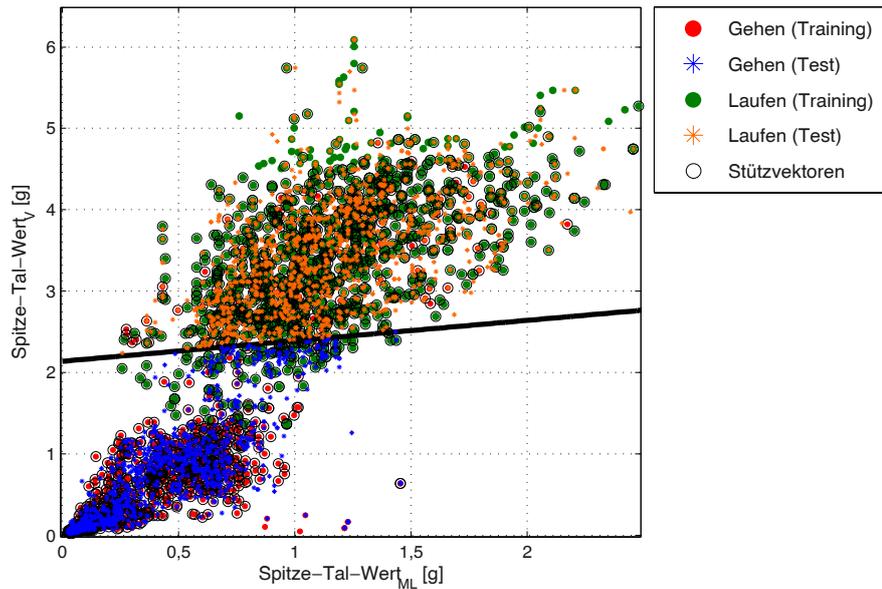


Abbildung 4.7.: Darstellung eines zweidimensionalen Merkmalsraums zur Unterscheidung von Gehen und Laufen anhand von Spitze-Tal-Werten berechnet aus Beschleunigungsmessungen. Eingezeichnet ist eine lineare Trennfunktion einer SVM.

unterscheidbar. Für die Klassifikation ist jedoch eine lineare Trennfunktion, insbesondere für 9 km/h und 11 km/h, nicht ausreichend. Weiterhin werden im Rahmen dieser Arbeit Kombinationen aus verschiedenen Merkmalen (höherdimensionaler Raum) eingesetzt, die eine nichtlineare Trennfunktion benötigen.

Eine besonders klare visuelle Unterscheidung der fünf Geschwindigkeitsklassen ist mit den Merkmalen Varianz und quadratisches Mittel möglich (siehe Abbildungen 4.8b-c). In Kombination bieten die drei Merkmale daher eine gute Repräsentation der markanten Änderungen des Schrittmusters in Form von Schrittlänge und -frequenz. Das arithmetische Mittel zeigt entlang der mediolateralen Achse eine Verschiebung von positiven Werten ( $\approx 0,3$  g) während des Gehens hin zu negativen Werten ( $\approx -0,4$  g) während des Laufens. Die dreidimensionale Darstellung des Merkmals zeigt dabei keine klar begrenzten Cluster sondern vielmehr eine Vermischung der Geschwindigkeiten (siehe Abbildung 4.8d). Für die Länge des Beschleunigungsvektors ergibt sich eine Zunahme mit der Geschwindigkeit. Während des Gehens mit 3 km/h liegt der dynamische Beschleunigungsanteil bei bis zu 250 mg, für Laufen mit 11 km/h sind es bis zu 600 mg.

Zusätzlich wird eine Analyse der Schrittmuster in der Zeit- und Frequenzdomäne mittels einer diskreten Wavelet Transformation (DWT) durchgeführt. Die DWT zerlegt ein Beschleunigungssignal  $a(t)$  in ein approximiertes Signal  $c_{2_j}$  und ein Detailsignal  $d_{2_j}$  unter Verwendung einer Skalierungs-  $\phi$  und einer Mutter-Wavelet-Funktion  $\psi$  [21]. Die Dekomposition ist wie folgt definiert.

$$c_{2_j}(k) = \sum_{k \in \mathbb{Z}} a(t) 2^{-j/2} \phi(2^{-j}t - k) \quad (4.12)$$

#### 4. Biokinematische Parameter

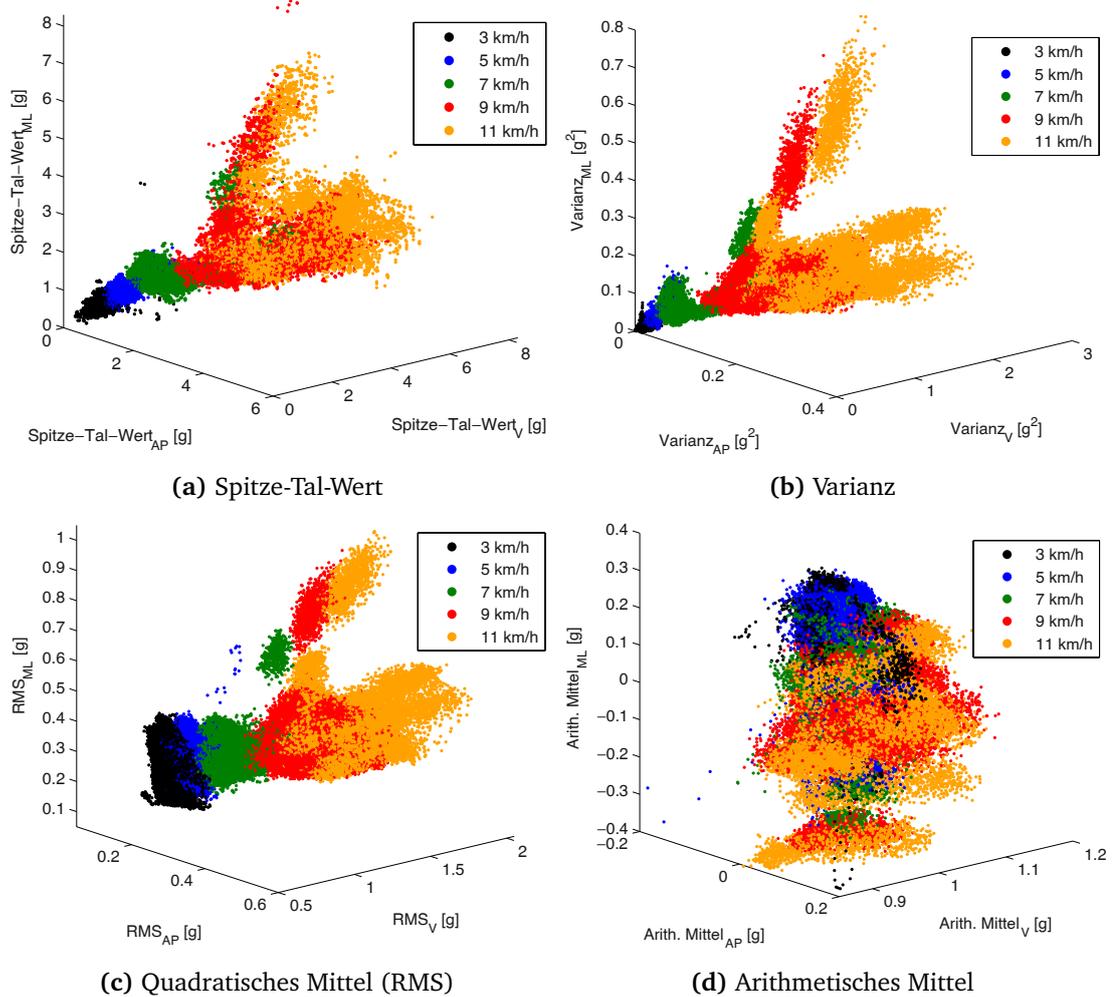
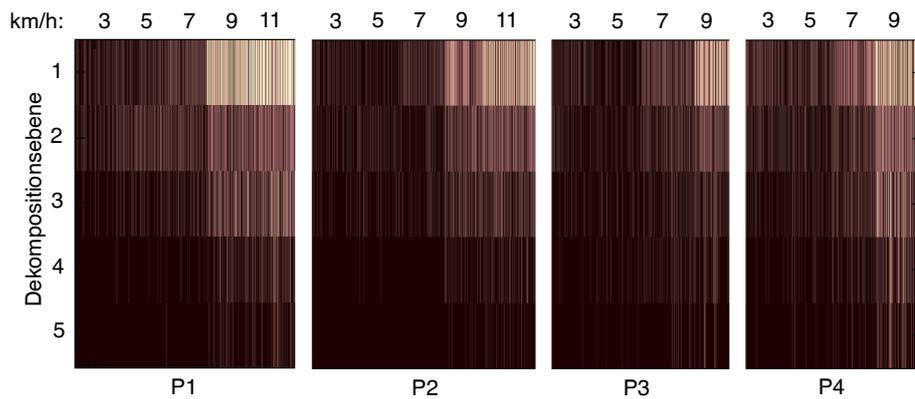


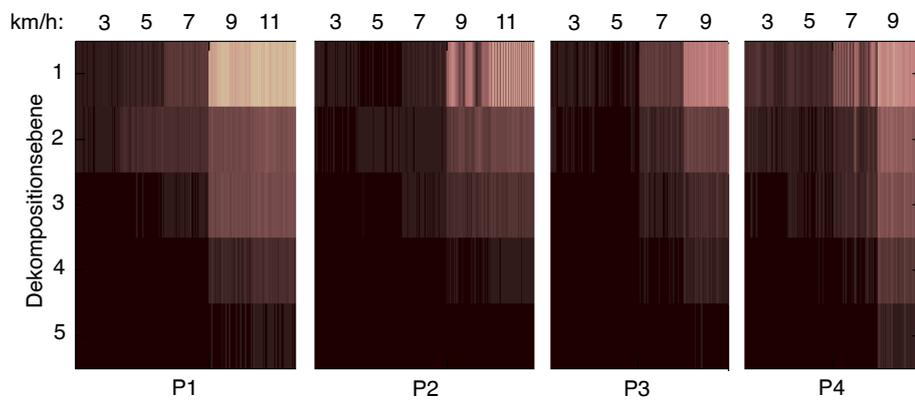
Abbildung 4.8.: Visualisierung der Merkmale ST-Wert, Varianz, RMS und arithmetisches Mittel berechnet aus den dreiaxialen Beschleunigungssignalen von 16 Probanden (Datenreihe V1.1), eingefärbt nach der eingestellten Laufbandgeschwindigkeit (3 bis 11 km/h).

$$d_{2,j}(k) = \sum_{k \in \mathbb{Z}} a(t) 2^{-j/2} \psi(2^{-j}t - k) \quad (4.13)$$

Dabei bezeichnen  $j$  die Frequenz- und  $k$  die Zeitauflösung. Die Einsatzmöglichkeiten einer DWT zur Ganganalyse wurden unter anderem in [17; 21; 97; 104] aufgezeigt. Insbesondere die diskrete Approximation des Meyer Wavelets eignet sich als Mutter-Wavelet-Funktion für die Schrittmustererkennung, da sie die zwei Spitzen des Fersen-Auftreffens und Zehen-Abstoßens widerspiegelt [104]. Als Merkmal für die Geschwindigkeitsbestimmung erfolgt eine Dekomposition des vertikalen Beschleunigungssignals auf fünf Ebenen. Während sich das Gehen im Ergebnis der DWT hauptsächlich auf die ersten beiden Ebenen beschränkt, ist das



(a) DWT des vertikalen Beschleunigungssignals.



(b) Ergebnis der zusätzlichen Glättung.

Abbildung 4.9.: Diskrete Wavelet Transformation (DWT) des vertikalen Beschleunigungssignals (Datenreihe V 1.1) für Geschwindigkeiten von 3 bis 11 km/h (Probanden P1, P2) und 3 bis 9 km/h (P3, P4).

Laufen, aufgrund der höheren Frequenzkomponenten, auf allen fünf Ebenen zu finden (siehe Abbildung 4.9a). Auf das Ergebnis der DWT wird ebenfalls die Rechteck-Fensterfunktion mit zwei Sekunden Fensterlänge angewendet und für jede Ebene innerhalb des Datenfensters das arithmetische Mittel gebildet (5 DWT-Merkmale pro Fenster). Diese Glättung reduziert Störungen und ermöglicht eine bessere Unterscheidbarkeit der Geschwindigkeiten auf den unterschiedlichen Ebenen (siehe Abbildung 4.9b). Weiterhin ist auf diese Weise eine zeitliche Synchronisation zwischen den Merkmalen möglich.

#### 4.2.4.3 Konfiguration der Klassifikatoren

MLPs erlauben die Modellierung komplexer Zusammenhänge zwischen einem Merkmalsraum, der die beschriebenen intra- und interindividuellen Variabilitäten enthält, und der Gang- oder Laufgeschwindigkeit. Der Fokus lag zunächst auf der Nutzung von MLPs, die in einer Vielzahl von Anwendungen zur Geschwindigkeitsbestimmung [12; 63; 146] sowie zur Bewegungsklassifizierung beim Menschen [102] bereits erfolgreich eingesetzt werden.

Weiterführend wurden die Klassifikatoren EB und RF evaluiert. Eine Beschreibung und Gegenüberstellung der Klassifikatoren befindet sich in Abschnitt 4.1.

Die Eingabeschicht des MLPs besteht aus 3 bis 14 Neuronen in Abhängigkeit von der Anzahl an Dimensionen des verwendeten Merkmalsraums (siehe Tabelle 4.1). Die Netzstruktur verfügt über eine zusätzliche verdeckte Schicht, um eine nichtlineare Trennung der Geschwindigkeitsklassen im Merkmalsraum zu ermöglichen. Die Bestimmung der Anzahl verdeckter Neuronen erfolgte dabei empirisch im Rahmen der Evaluation (iterative Erhöhung von 1 bis 25 Neuronen). Die Ausgabeschicht umfasst vier Neuronen für 3 km/h bis 9 km/h und fünf für Geschwindigkeiten bis zu 11 km/h. Für die Neuronen der verdeckten Schicht und der Ausgabeschicht wird eine sigmoide Tangentenfunktion eingesetzt (siehe Abschnitt 4.1.1.3). Jedes Ausgabeneuron gibt dabei eine Auftretenswahrscheinlichkeit der Geschwindigkeit zwischen 0 und 1 an, die Ausgabe des MLPs bildet die Geschwindigkeitsklasse mit der höchsten Wahrscheinlichkeit<sup>18</sup>. Der Trainingsvorgang des MLPs erfolgte mittels Backpropagation (weiterführende Informationen siehe Abschnitt 4.1.1.3). Während des Trainings wurde die Generalisierungsfähigkeit des MLPs anhand von Validierungstupel überwacht. Um eine Überanpassung (engl. *Overfitting*) des Vorhersagemodells zu vermeiden, erfolgte ein Abbruch des Trainings bei einem Anstieg des MSEs auf den Validierungstupel. Der Trainingsvorgang wurde fünfmal wiederholt und die Konfiguration mit dem niedrigsten MSE auf den Validierungstupeln ausgewählt (siehe frühzeitiger Trainingsabbruch und lokales Minimum).

Darüber hinaus wurden EB mit einer unterschiedlichen Anzahl an Knoten evaluiert. Die Induktion der EB erfolgte mit dem C4.5-Verfahren von R. Quinlan. EB sind aufgrund ihrer Interpretierbarkeit und hohen Ausführungsgeschwindigkeit interessant (siehe Abschnitt 4.1.2.1). Eine weiterführende Betrachtung der Konfigurationsparameter für die Induktion von EB sowie ein Vergleich mit dem MLP-Klassifikator erfolgte im Rahmen der Entwurfsraumexploration zur Sensorsignalverarbeitung auf Mikroprozessoren (Kapitel 7).

Zusätzlich wurde der Trainingsvorgang für den RF-Klassifikator (siehe Abschnitt 4.1.2.2) durchgeführt. Das resultierende Vorhersagemodell besteht aus 20 EB, für deren Induktion jeweils vier Merkmale genutzt wurden.

### 4.2.5 Evaluation (Offline-Bestimmung)

Die Evaluation der realisierten Gang- / Laufgeschwindigkeitsbestimmung erfolgte zunächst offline auf Grundlage von Datenreihen der beiden Versuche V1.1 und V2.

#### 4.2.5.1 Datenmaterial

Für die Durchführung des Versuchs V1.1 wurden Laufbänder der Firma Woodway und für die des Versuchs V2 eine Laufbahn im Außenbereich genutzt. Dieser Abschnitt gibt einen Überblick über die Versuchsdurchführung und die aufgezeichneten Daten, eine vollständige Dokumentation ist dem Anhang A zu entnehmen.

---

<sup>18</sup> Alternativ lassen sich die einzelnen Wahrscheinlichkeitswerte nutzen, um eine feinere Abstufung der Geschwindigkeitswerte zu erzielen und ein Konfidenzmaß zu erhalten.

**Versuch V1.1** Es nahmen 20 Probanden (14 Männer, 6 Frauen)<sup>19</sup> mit unterschiedlichen Körperkonstitutionen (Größe, Gewicht), Lauferfahrung und wöchentlichem Trainingspensum teil (siehe Tabelle A.1). Die Probanden absolvierten auf den Laufbändern Geschwindigkeiten zwischen 3 km/h und 11 km/h, korrespondierend zu langsamem, normalem und schnellem Gehen als auch Laufen. Die Obergrenze der Geschwindigkeit wählten die Probanden selbst. Dabei erreichten 15 Probanden die 9 km/h und die übrigen fünf die 11 km/h. Es wurden keine Vorgaben bezüglich des Laufstils gemacht, um natürliche Bedingungen zu erhalten. Einige Probanden wechselten während 7 km/h zwischen Gehen und Laufen oder nutzten die Handläufe.

Die Aufzeichnung der Beschleunigungen erfolgte mit dem BG-V4.1, angebracht im Oberkörperbereich, entlang der drei orthogonalen Beschleunigungsachsen. Der Messbereich betrug dabei bis zu  $\pm 6$  g, die Aufzeichnungsfrequenz 150 Hz und die Wortbreite 12 b. Die Datenreihe umfasst pro Geschwindigkeitsklasse und Proband 27000 Beschleunigungsvektoren (es wurden jeweils 30 s zwischen Geschwindigkeitsanpassungen entfernt).

**Versuch V2** Gegenstand des Versuchs waren Gang- und Laufgeschwindigkeiten zwischen 3 km/h und 11 km/h auf einer Laufbahn im Außenbereich. Referenzwerte für die Geschwindigkeit wurden dabei basierend auf GPS und mittels einer manuellen Zeiterfassung (Stoppuhr) ermittelt. Im Unterschied zu V1.1 wurde der Versuch mit einem zeitlichen Abstand von einer Woche wiederholt, um den Einfluss des erneuten Anlegens des Messsystems und von Variabilitäten der Schrittmuster (Tagesform) zu erfassen. Es nahmen 13 Probanden (11 Männer, 2 Frauen) an V2 (1) teil, von denen 11 den Versuch wiederholten V2 (2). Alle Probanden absolvierten Geschwindigkeiten bis 9 km/h und fünf darüber hinaus die zusätzlichen 11 km/h.

Die Aufzeichnung der Beschleunigungen mit dem BG-V4.2 erfolgte mit einem Messbereich von  $\pm 6$  g, einer Aufzeichnungsfrequenz von 100 Hz und einer Wortbreite von 12 Bit. Die Datenreihe V2 (1) umfasst 15800 Beschleunigungsvektoren für jede Geschwindigkeitsklasse und jeden Probanden, für die Datenreihe V2 (2) sind es 15600.

### 4.2.5.2 Ergebnisse V1.1

Zur Evaluation der Geschwindigkeitsbestimmung erfolgte eine Partitionierung der Datenreihe des Hauptversuchs (V1.1) in Trainings- (60 %), Validierungs- (20 %) und unabhängige Testtupel (20 %). Weiterhin wurde diese Art der Datenpartitionierung genutzt, um den Einfluss der einzelnen Merkmale und der Anzahl verdeckter Neuronen zu untersuchen. Zusätzlich erfolgte im Anschluss eine 10-fache stratifizierte Kreuzvalidierung. Diese Form der Datenpartitionierung bietet den Vorteil, dass die Testtupel die vollständige Datenreihe nach den 10 Iterationen abdecken (siehe Abschnitt 4.1.5). Aufgrund des erhöhten Berechnungsaufwands wurde diese Methode nur auf ausgewählte Konfigurationen des ersten Evaluationsschritts angewandt.

Die Bewertung der Geschwindigkeitsbestimmung erfolgte mit den statistischen Gütemaßen Sensitivität und Spezifität. Das arithmetische Mittel über die klassenspezifischen Sensitivitätswerte wird im Folgenden auch als Klassifikationsgenauigkeit  $\bar{R}$  bezeichnet (siehe

<sup>19</sup> Die Ergebnisse der 10-fachen Kreuzvalidierung basieren auf der erweiterten Datenreihe mit 22 Probanden. Erläuterung siehe Anhang A.1.1.

Tabelle 4.1.: Klassifikationsgenauigkeiten für die unterschiedlichen Merkmale einzeln und kombiniert ( $M_{G1}$  bis  $M_{G4}$ ) auf Grundlage der Datenreihe V1.1 mit Geschwindigkeiten von 3 bis 9 km/h und dem MLP-Klassifikator. \* Markiert die Verwendung von nur vertikalen Beschleunigungen anstelle des vollständigen Beschleunigungsvektors und  $D$  bezeichnet die Dimensionalität des resultierenden Merkmalsraums.

| $M$      | Merkmale |     |     |         |                      |     | $D$ | $\bar{R}_{MLP}$ [%] |
|----------|----------|-----|-----|---------|----------------------|-----|-----|---------------------|
|          | ST       | Var | RMS | Mittel. | $ \bar{\mathbf{a}} $ | DWT |     |                     |
| -        | X        | -   | -   | -       | -                    | -   | 3   | 91,9                |
| -        | -        | X   | -   | -       | -                    | -   | 3   | <b>94,1</b>         |
| -        | -        | -   | X   | -       | -                    | -   | 3   | 88,6                |
| -        | -        | -   | -   | X       | -                    | -   | 3   | 46,3                |
| -        | -        | -   | -   | -       | X                    | -   | 3   | 65,1                |
| -        | -        | -   | -   | -       | -                    | X*  | 5   | 80,7                |
| $M_{G1}$ | X*       | X*  | X*  | -       | -                    | -   | 3   | 93,9                |
| $M_{G2}$ | X        | X   | X   | -       | -                    | -   | 9   | 95,4                |
| $M_{G3}$ | X*       | X*  | X*  | -       | -                    | X*  | 8   | 96,0                |
| $M_{G4}$ | X        | X   | X   | -       | -                    | X*  | 14  | <b>97,4</b>         |

Abschnitt 4.1.5).

**Ergebnisse nach Merkmalsraum** Die Datenreihe aus V1.1 mit Daten von 20 Probanden und Geschwindigkeiten zwischen 3 km/h und 9 km/h wurde genutzt, um zunächst die Klassifikationsgenauigkeit der unterschiedlichen Merkmale einzeln zu ermitteln. Anschließend erfolgte eine Kombination der Merkmale mit der höchsten Genauigkeit in vier verschiedenen Merkmalsräumen  $M$ . Die höchste Klassifikationsgenauigkeit von 94,1 % erreicht das Merkmal Varianz, gefolgt von dem Spitze-Tal-Wert mit 91,9 % und dem RMS mit 88,6 % (siehe Tabelle 4.1). Die Norm des Beschleunigungsvektors ist nur bedingt (65,1 %) für die Geschwindigkeitsbestimmung geeignet. Das arithmetische Mittel hingegen zeigt mit 46,3 % eine signifikant niedrigere Genauigkeit; dies deckt sich mit der Beobachtung zur fehlenden Clusterbildung in der Visualisierung des Merkmals (siehe Abbildung 4.8d). Das DWT-Merkmal erzielt mit 80,7 % eine niedrigere Genauigkeit als die Kombination aus den Merkmalen Spitze-Tal-Wert, Varianz und RMS.

Ein Merkmalsraum mit unterschiedlichen Merkmalen ist für die Robustheit und die Generalisierungsfähigkeit eines Klassifikators von Bedeutung. Die Kombination der Merkmale Spitze-Tal-Wert, Varianz, RMS und DWT bildet einen Merkmalsraum ( $M_{G4}$ ) mit 14 Dimensionen, mit welchem die Geschwindigkeitsbestimmung mit einer Genauigkeit von 97,4 % möglich ist. Wird das DWT-Merkmal nicht genutzt ( $M_{G2}$ ), reduziert sich die Genauigkeit um 2 %. Die vertikalen Beschleunigungen sind für die Geschwindigkeitsbestimmung am wichtigsten. Die Erweiterung um mediolaterale und anteriorposteriore Beschleunigungen verbessert die Genauigkeit nur um etwa 1,5 % (vergleiche  $M_{G1}$  und  $M_{G3}$  mit  $M_{G2}$  und  $M_{G4}$ ).

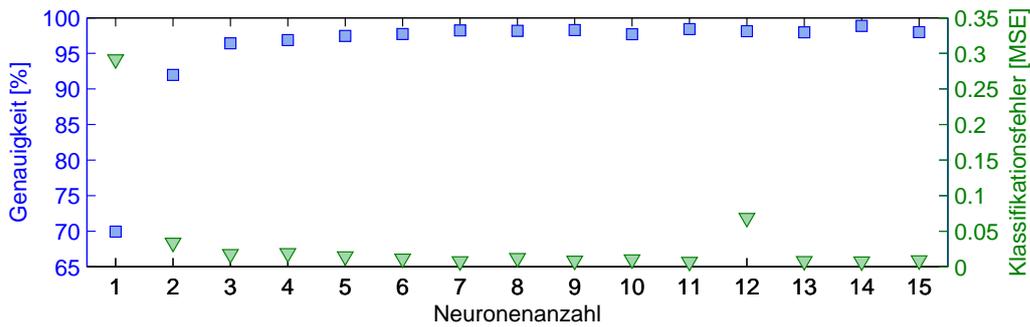


Abbildung 4.10.: Klassifikationsgenauigkeit und MSE der Geschwindigkeitsbestimmung in Abhängigkeit von der Neuronenanzahl auf Grundlage von  $M_{G4}$ . Darstellung begrenzt auf 15 Neuronen.

Insbesondere  $M_{G3}$ , bestehend aus den drei Merkmalen in der Zeit-Domäne berechnet aus vertikalen Beschleunigungen, eignet sich als dreidimensionaler Merkmalsraum für den Einsatz auf Systemen mit begrenzten Berechnungs- und Speicherressourcen, erreicht wird eine Genauigkeit von 93,9%.

**Ergebnisse nach Neuronenanzahl** Zusätzlich zu der Merkmalsselektion wurde der Einfluss der Anzahl verdeckter Neuronen auf die Klassifikationsgenauigkeit untersucht. Startend mit einem verdeckten Neuron wurde in jedem Iterationsschritt ein weiteres ergänzt. Die Evaluation erfolgte für die 20 Probanden mit den Geschwindigkeiten zwischen 3 km/h und 9 km/h auf Grundlage von  $M_{G4}$ . Der Einsatz von zwei verdeckten Neuronen verbessert bereits die Klassifikationsgenauigkeit und mit drei werden 96,4% erreicht. Weiterführend lässt sich eine kontinuierliche Genauigkeitssteigerung bis sieben Neuronen beobachten. Anschließend schwankt die Klassifikationsgenauigkeit nur leicht oberhalb von 97% (siehe Abbildung 4.10) aufgrund der zufälligen Initialisierung der Neuronengewichte und Biaswerte zu Trainingsbeginn. Das Genauigkeitsmaximum wird mit 14 Neuronen erreicht; es erfolgte eine Betrachtung bis insgesamt 25 Neuronen.

Insbesondere im Hinblick auf eine Portierung der Geschwindigkeitsbestimmung auf den Mikroprozessor des Körpersensors ist daher eine Begrenzung auf 5 bis 7 Neuronen möglich, um den Ressourcenbedarf (Takte und Speicher) zu reduzieren. Die benötigte Anzahl an Neuronen ist jedoch erneut zu prüfen, falls die Anzahl an Geschwindigkeitsklassen oder Probanden erhöht wird.

**Ergebnisse nach Geschwindigkeit** Die obigen Ergebnisse beziehen sich auf die Klassifikationsgenauigkeit ermittelt für alle 20 Probanden und vier Geschwindigkeitsklassen (3 km/h bis 9 km/h). Zusätzlich wurde die Genauigkeit auf Grundlage der Daten von nur den 15 Probanden, die zusätzlich die 11 km/h absolvierten, ermittelt. Basierend auf dem vollständigen Merkmalsraum  $M_{G4}$  reduziert sich die Klassifikationsgenauigkeit bei der Unterscheidung der fünf Geschwindigkeiten dabei auf 93,8%. Die Betrachtung der Klassifikationsergebnisse

#### 4. Biokinematische Parameter

Tabelle 4.2.: Konfusionsmatrizen mit den Klassifikationsergebnissen der Geschwindigkeitsbestimmung für die Datenreihe V1.1 auf Grundlage von  $M_{G4}$  und dem MLP-Klassifikator:  $v_R$  bezeichnet die am Laufband eingestellte Geschwindigkeit (Referenz) und  $v_C$  die Klassifikatorausgabe.

(a) Ergebnisse für 3 bis 9 km/h (20 Probanden),  $\bar{R}_{MLP} = 97,4\%$ .

| $v_C \backslash v_R$ | 3 km/h      | 5 km/h      | 7 km/h      | 9 km/h      |
|----------------------|-------------|-------------|-------------|-------------|
| 3 km/h               | <b>4221</b> | 38          | 0           | 0           |
| 5 km/h               | 96          | <b>4255</b> | 9           | 0           |
| 7 km/h               | 3           | 25          | <b>4154</b> | 119         |
| 9 km/h               | 0           | 2           | 157         | <b>4201</b> |

(b) Ergebnisse für 3 bis 11 km/h (15 Probanden),  $\bar{R}_{MLP} = 93,8\%$ .

| $v_C \backslash v_R$ | 3 km/h      | 5 km/h      | 7 km/h      | 9 km/h      | 11 km/h     |
|----------------------|-------------|-------------|-------------|-------------|-------------|
| 3 km/h               | <b>3404</b> | 18          | 0           | 0           | 0           |
| 5 km/h               | 47          | <b>3417</b> | 10          | 0           | 0           |
| 7 km/h               | 4           | 21          | <b>3346</b> | 40          | 2           |
| 9 km/h               | 1           | 0           | 100         | <b>3226</b> | 642         |
| 11 km/h              | 0           | 0           | 0           | 190         | <b>2812</b> |

für die einzelnen Geschwindigkeitsklassen zeigt bereits für die erste Datenreihe mit bis zu 9 km/h einen leichten Anstieg der Fehlklassifikationen zwischen 7 km/h und 9 km/h (siehe Tabelle 4.2a). Die zusätzliche Geschwindigkeitsklasse 11 km/h wird verstärkt fälschlicherweise als 9 km/h klassifiziert (642 Datenfenster, siehe Tabelle 4.2b). Gründe liegen dabei in der beobachteten hohen interindividuellen Variabilität der Schrittmuster, insbesondere für höhere Geschwindigkeiten (siehe Abschnitt 4.2.3). Die Spitzenbeschleunigungen des Fersen-Auftreffens variieren in den vertikalen Beschleunigungssignalen der Probanden aus V1.1 um 1,5 g während 9 km/h und 2 g für 11 km/h. Zusätzlich beruhen Fehlklassifikationen zwischen 7 km/h und 9 km/h auf intraindividuellen Variabilitäten der Schrittmuster aufgrund des Wechsels einiger Probanden zwischen Gehen und langsamen Laufen bei der Übergangsgeschwindigkeit 7 km/h. Den niedrigsten Fehler weist die Klassifikation von Ganggeschwindigkeiten auf, 5 km/h werden dabei am sichersten erkannt.

Um den Einfluss der interindividuellen Variabilität der Schrittmuster auf die Geschwindigkeitsbestimmung abschätzen zu können, wurde für jeden Probanden ein MLP mit probandenspezifischen Neuronengewichten und Biaswerten erstellt. Die Individualisierung des MLPs erhöht die Klassifikationsgenauigkeit auf 99,1 % (arithmetisches Mittel der 20 Einzelgenauigkeiten). Die probandenspezifische Anpassung zeigt dabei eine sehr geringe Standardabweichung.

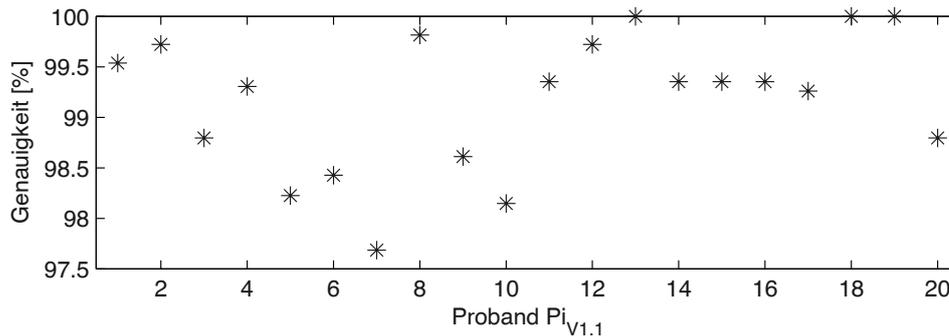


Abbildung 4.11.: Probandenspezifische Klassifikationsgenauigkeit (Datenreihe V1.1,  $M_{G4}$ ,  $MLP_{N5,S}$ ) auf Grundlage von für jeden Probanden individuell angepassten Neuronengewichten und Biaswerten (Ausschluss interindividueller Variabilitäten). Das arithmetische Mittel beträgt  $99,1 \pm 0,0068$  %.

chung von  $\pm 0,0068$  %. Das Minimum beträgt 97,7 % und bei drei Probanden (P13, P18 und P19) treten keine Fehlklassifikationen auf. Die Genauigkeitswerte zeigen keine tendenziellen Unterschiede für Probanden mit vier oder fünf zu klassifizierenden Geschwindigkeiten. Weiterhin lässt sich für die 20 Probanden keine Abhängigkeit der Genauigkeit von Geschlecht, Alter, Gewicht oder Lauferfahrung beobachten.

Die Evaluation zeigt, dass sich bei Ausschluss von interindividuellen Variabilitäten bereits mit fünf verdeckten Neuronen die verbleibenden intraindividuellen Variabilitäten in einem Vorhersagemodell zur Geschwindigkeitsbestimmung mit sehr hoher Genauigkeit abbilden lassen. Intraindividuelle Variabilitäten sind für die Datenreihe V1.1 für den Wechsel zwischen Gehen und Laufen bei 7 km/h und verstärkt während des schnellen Laufens mit 11 km/h zu beobachten.

**Ergebnisse 10-fache Kreuzvalidierung** Im Rahmen der Evaluation von Klassifikationsalgorithmen ist der Einsatz einer zehnfachen stratifizierten Kreuzvalidierung zur Datenpartitionierung verbreitet (siehe auch Abschnitt 4.1.4). Durchgeführt wurde diese Form der Partitionierung für die Datenreihe V1.1. Zusätzlich zu dem MLP wurden dabei die Klassifikatoren EB und RF betrachtet.

Die Durchführung der zehnfachen stratifizierten Kreuzvalidierung erfolgte mit der WEKA-Bibliothek (Version 3.6.6) zum maschinellen Lernen [57]. Die Ermittlung geeigneter Trainingseinstellungen erfolgte empirisch (Lernrate von 0,3 und Trägheitsterm<sup>20</sup> von 0,8). Für den EB wurde die quelloffene Implementierung (J48) genutzt. Während der Induktion des EBs wurde eine Beschneidung (Konfidenzschwellenwert von 0,25) zugelassen; der resultierende EB umfasst 263 Knoten. Als geeignete Trainingseinstellung für den RF zeigte sich eine Anzahl von 20 EB, wobei eine Induktion von jedem EB bis zu einer maximalen Baumtiefe von 10, unter Nutzung von jeweils vier zufällig ausgewählten Merkmalen, das beste Ergebnis erbrachte. Weiterführende Informationen zu den Klassifikatoren und deren Konfigurationsparameter

<sup>20</sup>Der erhöhte Trägheitsterm (Momentum) steigerte die Genauigkeit um 0,5 %.

Tabelle 4.4.: Ergebnisse der Geschwindigkeitsbestimmung (3 bis 11 km/h) für eine zehnfache Kreuzvalidierung basierend auf der Datenreihe V1.1. Angegeben ist die Genauigkeit in Abhängigkeit von der Geschwindigkeitsklasse und dem Klassifikator.

| $v$ [km/h]         | $\bar{R}_{MLP}$ [%] | $\bar{R}_{EB}$ [%] | $\bar{R}_{RF}$ [%] |
|--------------------|---------------------|--------------------|--------------------|
| 3                  | 98,8                | 99,2               | <b>99,4</b>        |
| 5                  | 98,3                | 98,8               | <b>99,4</b>        |
| 7                  | 97,4                | 98,1               | <b>99,0</b>        |
| 9                  | 90,6                | 89,1               | <b>95,7</b>        |
| 11                 | 92,7                | 91,2               | <b>95,3</b>        |
| Gesamt $\emptyset$ | 95,6                | 95,3               | <b>97,8</b>        |

sind in Abschnitt 4.1 beschrieben. Der Trainingsvorgang benötigte für den EB nur 0,47 s, für den RF 1,35 s und für das MLP 17,41 s<sup>21</sup>.

Die höchste Klassifikationsgenauigkeit für die fünf Geschwindigkeitsklassen (3 km/h bis 11 km/h) erzielt jeweils der RF, das arithmetische Mittel beträgt  $97,8 \pm 2,1$  %. Die Abweichungen der klassenspezifischen Sensitivitätswerte sind für den RF ebenfalls am niedrigsten. Während Geschwindigkeiten zwischen 3 km/h und 7 km/h mit mindestens 99 % unterschieden werden können, reduziert sich die Klassifikationsgenauigkeit für das Laufen um etwa 4 % (siehe Tabelle 4.4). Das zweitbeste Ergebnis erzielt das MLP ( $95,6 \pm 3,7$  %) gefolgt von dem EB ( $95,3 \pm 4,8$  %). Für alle drei Klassifikatoren wird Gehen mit 3 km/h am sichersten erkannt. Für die Laufgeschwindigkeiten 9 km/h und 11 km/h nimmt die Genauigkeit gegenüber den Ganggeschwindigkeiten um bis zu 4,1 % (RF), 8,2 % (MLP) und 10,1 % (EB) ab.

Für die Klassifikation von Geschwindigkeiten zwischen 3 km/h und 9 km/h erzielt ebenfalls der RF die höchste Genauigkeit ( $\bar{R}_{RF} = 98,8 \pm 0,5$  %). Die Differenz zwischen den Ergebnissen der Klassifikatoren fällt jedoch niedriger aus, das MLP erreicht  $98,4 \pm 0,6$  % und der EB  $97,8 \pm 0,6$  %. Das arithmetische Mittel der Spezifität liegt für die verschiedenen Geschwindigkeitsklassen (inklusive 11 km/h) oberhalb von 98,8 % (siehe Anhang Tabelle B.1).

Die mittels der zehnfachen Kreuzvalidierung erzielten Klassifikationsgenauigkeiten liegen um 1 % (3 km/h bis 9 km/h) und 1,8 % (3 km/h bis 11 km/h) oberhalb der Ergebnisse der zuvor durchgeführten *Leave-Out Validation*. Beeinflusst wird die Genauigkeit dabei durch die im Vergleich größeren Datenpartitionen während der Trainingsvorgänge und der nach Abschluss der 10 Iterationen vollständigen Berücksichtigung der Datenreihe als Testtupel.

#### 4.2.5.3 Ergebnisse V2

Während der Versuch V1.1 die Erfassung von Gang- / Laufgeschwindigkeiten unter kontrollierten Umgebungsbedingungen auf Laufbändern betrachtete, hatte V2 das Ziel, eine weiterführende Evaluation unter Außenbedingungen auf einer Laufbahn zu ermöglichen.

<sup>21</sup>Die Erstellung des Vorhersagemodells erfolgte dabei auf demselben Desktop-Computer (Intel Xeon CPU W3565 mit 3,2 GHz, 12 GB RAM und Ubuntu 10.04.02 LTS).

Tabelle 4.5.: Ergebnisse der Geschwindigkeitsbestimmung für die Datenreihe (V2) auf Grundlage von  $M_{G4}$  für drei Klassifikatoren. Das Training erfolgte auf der ersten und die Evaluation auf der zweiten Datenreihe eine Woche später.

(a) Mittlere Sensitivität und Spezifität mit Standardabweichung und Bereich.

| Klassifikator      | $\bar{R} \pm \sigma$ [Min.–Max.] [%] | $\bar{S} \pm \sigma$ [Min.–Max.] [%] |
|--------------------|--------------------------------------|--------------------------------------|
| MLP <sub>13</sub>  | 95,9 ± 3,9 [91,2 – 99,9]             | 98,6 ± 1,5 [96,5 – 100]              |
| EB <sub>55</sub>   | 96,9 ± 2,6 [94,5 – 99,9]             | 99,0 ± 1,3 [97,1 – 100]              |
| RF <sub>10,4</sub> | 97,3 ± 1,7 [95,9 – 99,7]             | 99,1 ± 1,2 [97,5 – 100]              |

(b) Klassifikationsgenauigkeit nach Geschwindigkeit.

| v [km/h] | $\bar{R}_{MLP}$ [%] | $\bar{R}_{J48}$ [%] | $\bar{R}_{RF}$ [%] |
|----------|---------------------|---------------------|--------------------|
| 3        | 98,3                | 94,5                | 95,9               |
| 5        | 94,2                | 98,2                | 97,3               |
| 7        | 91,2                | 94,9                | 96,4               |
| 9        | 99,9                | 99,9                | 99,7               |

Dazu stehen für jeden Probanden zwei Datenreihen mit einem zeitlichen Abstand von einer Woche zur Verfügung, die ein erneutes Anlegen des Messsystems und Variabilitäten der Schrittmuster (Tagesform) enthalten. Für jeden Probanden erfolgte die Evaluation dabei auf einer hohen Anzahl von 15600 Beschleunigungsvektoren. Für die Evaluation wurde der Merkmalsraum  $M_{G4}$  und die drei Klassifikatoren MLP, EB und RF betrachtet. Die verdeckte Schicht des MLPs umfasst 13 Neuronen und die Trainingseinstellungen eine Lernrate von 0,8 und einen Trägheitsterm von 0,5. Die Induktionen des EB und RF erfolgten mit unveränderten Einstellungen.

Die höchste Klassifikationsgenauigkeit von 97,3 ± 1,7 % erzielt der RF. Mit dem EB wird eine hohe Genauigkeit von 96,9 ± 2,6 % erreicht; im Vergleich zu V1.1 beträgt die Größe des EBs mit 55 Knoten nur etwa ein Fünftel. Das MLP erreicht hier 95,9 ± 3,9 % (siehe Tabelle 4.5a). Im Unterschied zu den Ergebnissen aus V1.1 wird Laufen mit 9 km/h fast vollständig korrekt erkannt (≥ 99,7 %, siehe Tabelle 4.5b). Die meisten Fehlklassifikationen treten für 3 km/h und 7 km/h auf, wobei es zu einer fälschlichen Einstufung als 5 km/h kommt (siehe Konfusionsmatrizen Anhang B.1.2). Die Spezifität liegt für die drei Klassifikatoren bei mindestens 98,6 %. Im direkten Vergleich zu den Ergebnissen aus V1.1 sind die Klassifikationsgenauigkeiten im Außenbereich leicht reduziert (MLP -2,5 %, EB -0,9 % und RF -1,5 %).

#### 4.2.6 Portierung auf das BG-V4.2

Die Evaluation der Geschwindigkeitsbestimmung auf den Datenreihen V1.1 und V2 hat deren Funktionalität für den Innen- und Außenbereich demonstriert. Der folgende Abschnitt beschreibt die anschließend durchgeführte Portierung der Geschwindigkeitsbestimmung auf

den Mikrocontroller MSP430FG4618 des BG-V4.2. Die Verarbeitung der Beschleunigungssignale auf dem Mikrocontroller ermöglicht dabei eine Reduzierung des zu speichernden oder kommunizierenden Datenvolumens. In die Realisierung der Portierung sind die Ergebnisse der Masterarbeit von F. Lehmke eingeflossen [187].

Im Gegensatz zu einem Desktop-Computer sind die auf einem Mikrocontroller zur Verfügung stehenden Berechnungs- und Speicherressourcen stark begrenzt, sodass Anpassungen des Quellcodes nötig sind. Der MSP430FG4618 ist auf eine Verarbeitung von Daten mit einer Wortbreite von 16 b ausgelegt und weist eine maximale Taktfrequenz von 8 MHz, 116 kB Flash-Speicher sowie 8 kB RAM auf (siehe Abschnitt 2.3). Weiterhin ist eine funktionale Einheit für 16 b x 16 b - Multiplikationen integriert, es fehlt jedoch eine Einheit für Divisionen, sodass eine Emulation dieser Operation erfolgen muss. Für eine Reduktion des Taktzyklenaufwands ist anstelle einer Gleitkommaarithmetik der Einsatz einer geeigneten Festkommaarithmetik für die Darstellung von Sensormesswerten und (Zwischen-) Ergebnissen sinnvoll [167]. Werden mehr als 16 b für die Speicherung von Werten benötigt, erhöht sich die Taktzyklenanzahl bei der Verarbeitung auf dem MSP430FG4618 teils signifikant [187, S.40]. Darüber hinaus sind komplexe Funktionen mit hohem Berechnungsaufwand, wie die Aktivierungsfunktion eines künstlichen Neurons, zu identifizieren und durch eine für den Mikrocontroller geeignete Implementierung zu ersetzen.

Im Folgenden wird zunächst die Portierung der Merkmalsextraktion und des MLPs auf den MSP430FG4618 beschrieben und anschließend der Ressourcenbedarf sowie die erzielte Klassifikationsgenauigkeit der Online-Geschwindigkeitsbestimmung angegeben.

##### 4.2.6.1 Merkmalsextraktion

Ausgewählt wurde für die Implementierung der Merkmalsraum  $M_{G2}$  bestehend aus dem ST-Wert, der Varianz und dem RMS berechnet für alle drei Beschleunigungsachsen (siehe Tabelle 4.1). Das DWT-Merkmal wird aufgrund des höheren Berechnungsaufwands im Verhältnis zu der beobachteten Steigerung der Klassifikationsgenauigkeit um 2 % nicht verwendet.

Für die Durchführung der Merkmalsberechnung erfolgt eine Zwischenspeicherung der Beschleunigungsmesswerte in einem *Ring Buffer* (Warteschlange). Die Größe der Datenstruktur ist über das Präprozessormakro RINGBUFFER\_SIZE anpassbar (entspricht der Fensterlänge WINDOW\_SIZE); erst nach dessen vollständiger Füllung wird die Merkmalsberechnung ausgeführt. Die Aufzeichnungsfrequenz der Beschleunigungsmesswerte wird mit D\_RATE und die Anzahl der zu nutzenden Beschleunigungssensorachsen mit AXISNUMBER spezifiziert. Für eine Erfassung der Charakteristika der Schrittmuster kann eine niedrigere Aufzeichnungsfrequenz als die 150 Hz (V1.1) genutzt werden (siehe Abschnitt 4.2.4.1). Gewählt wurde für die Online-Geschwindigkeitsbestimmung eine Aufzeichnung der Beschleunigungsmesswerte mit 75 Hz<sup>22</sup>, die Fensterlänge bleibt mit 2 s jedoch unverändert. Die Implementierung ist mittels einer Festkommaarithmetik realisiert. Die Darstellung der Sensormesswerte und (Zwischen-) Ergebnisse erfolgt dabei mit einer festen Anzahl von  $n$  Vorkommastellen und  $k$  Nachkommastellen; im Folgenden wird dazu die Notation  $Q_{n,k}$  verwendet.

Der ST-Wert wird aus der Differenz der beiden Extremwerte, den maximalen und minimalen Beschleunigungswerten innerhalb des zu betrachteten Datenfensters, berechnet.

---

<sup>22</sup>Im Rahmen der in Kapitel 7 durchgeführten Entwurfsraumexploration der Konfigurationsparameter wird eine weiterführende Reduktion der Aufzeichnungsfrequenz betrachtet.

Die Bestimmung der Extremwerte kann dabei mittels einer Suchfunktion, die iterativ jeden Beschleunigungswert prüft, realisiert werden. Für Merkmale wie den Median ist jedoch bereits eine aufsteigende Sortierung der Beschleunigungswerte innerhalb des Datenfensters notwendig. Das Sortierergebnis kann weiterführend genutzt werden, um den Spitze-Tal-Wert effizient durch die Subtraktion des ersten vom letzten Element zu bestimmen. Die Berechnung profitiert nicht von der Nutzung der Festkommaarithmetik. Die Speicherung des ST-Werts erfolgt mit einer Wortbreite von 16 b.

Die Berechnung des Mittelwerts besteht aus der Akkumulation der Beschleunigungswerte innerhalb des Datenfensters und einer anschließenden Division durch die Elementanzahl  $L$  des Fensters. Aufgrund der fehlenden Funktionseinheit des MSP430FG4618 für Divisionen erfolgt eine Multiplikation mit dem vorberechneten Kehrwert der Fensterlänge  $1/L$ . Das Format für die Speicherung des Kehrwerts ist über FRACTIONALBITS konfigurierbar, voreingestellt ist Q0.16. Die Akkumulation der  $L$  Beschleunigungsmesswerte vor der Durchführung der Multiplikation würde jedoch zu einer hohen Wortbreite des Zwischenergebnisses führen. Gewählt wurde daher eine elementweise Multiplikation der  $L$  Beschleunigungsmesswerte mit dem vorberechneten Kehrwert unter Verwendung der funktionalen Einheit für  $16\text{ b} \times 16\text{ b}$ -Multiplikationen des MSP430FG4618. Die resultierenden Zwischenergebnisse (Format Q16.16) werden anschließend akkumuliert und das Merkmal Mittelwert mit einer Wortbreite von 32 b abgespeichert.

Für die Berechnung des RMS werden die einzelnen Beschleunigungsmesswerte zunächst mit sich selbst und anschließend mit dem vorberechneten Kehrwert  $1/L$  multipliziert. Die Zwischenergebnisse (Format Q32.16) werden akkumuliert und die Wurzel über den ganzzahligen Anteil des Werts gebildet. Genutzt wird dazu die von J. W. Crenshaw [40] vorgestellte Wurzelfunktion, die auf dem MSP430FG4618 nur 833 Taktzyklen benötigt. Dies stellt eine Ersparnis von 1304 Taktzyklen gegenüber der Wurzelfunktion (sqrt) der C-Standardbibliothek (cmath) dar<sup>23</sup>.

Für die Berechnung der Varianz wird der bestimmte Mittelwert des Datenfensters von den  $L$  Beschleunigungsmesswerten einzeln subtrahiert. Es folgt eine Multiplikation der  $L$  Zwischenergebnisse (Format Q16.16) mit sich selbst (Format Q32.32) und anschließend mit dem vorberechneten Kehrwert  $1/L$ . Für eine (effiziente) Nutzung der funktionalen Einheit für  $16\text{ b} \times 16\text{ b}$ -Multiplikationen ist aufgrund der Wortbreite von 64 b eine Aufteilung notwendig [23]. Im Anschluss an die Multiplikationen erfolgt eine Akkumulation der Zwischenergebnisse. Das resultierende Ergebnis weist dabei eine Wortbreite von 80 b auf, falls im letzten Multiplikationsschritt auf eine Vergrößerung des Nachkommabereichs verzichtet wird sind es 64 b. Darüber hinaus lässt sich die für die Berechnung der Varianz notwendige Taktzyklenanzahl reduzieren, indem eine Berechnung auf Grundlage des Mittelwerts und des  $\text{RMS}^2$  erfolgt [187, S.45f].

Abschließend erfolgt eine Normierung der Merkmalswerte auf den Bereich von 0 bis 1. Weiterführend wird in Kapitel 7 eine Reduktion der Wortbreite bei der Speicherung von Sensormesswerten und Zwischenergebnissen auf die Klassifikationsgenauigkeit betrachtet.

<sup>23</sup>Angaben gelten für den IAR C/C++ Compiler for MSP430 (Version 5.40.2) ohne Optimierungen.

##### 4.2.6.2 Klassifikation mit MLP

Die Bestimmung der Gang- / Laufgeschwindigkeit aus den Merkmalen ist mit einem MLP-Klassifikator auf dem MSP430FG4618 realisiert. Die Auswahl des Klassifikators begründet sich primär chronologisch, da die Portierung im Anschluss an die *Leave-Out Validation* auf der Datenreihe aus V1.1 durchgeführt wurde. Aufgrund der dabei erzielten hohen Klassifikationsgenauigkeit erfolgte zunächst keine Betrachtung weiterer Klassifikatoren. Im weiteren Verlauf der vorliegenden Arbeit wurde zusätzlich der in Abbildung C.1 dargestellte Entscheidungsbaum portiert. Ein weiterführender Vergleich zwischen den beiden Klassifikatoren bezüglich Taktzyklenaufwand und Klassifikationsgenauigkeit erfolgte im Rahmen der Entwurfsraumexploration der Geschwindigkeitsbestimmung (siehe Kapitel 7).

Die Grundlage für die Implementierung des MLP-Klassifikators bildet die quelloffene plattformübergreifende Bibliothek *Fast Artificial Neural Network* (FANN) für mehrschichtige künstliche neuronale Netze [116]. Die Bibliothek ist in der Programmiersprache C realisiert und stellt verschiedene Backpropagation-Trainingsalgorithmen und Aktivierungsfunktionen (inklusive einer stückweise linear approximierten Funktion) zur Verfügung. Weiterhin besteht die Möglichkeit anstelle einer Gleitkomma- eine Festkommaarithmetik zu verwenden, um die Ausführungsgeschwindigkeit weiter zu steigern.

**Validierung Klassifikationsgenauigkeit FANN** Im Folgenden wird zunächst die mittels FANN erzielte Klassifikationsgenauigkeit mit der ursprünglichen Implementierung basierend auf der Matlab Neural Network Toolbox [18] verglichen. Eingesetzt wurde dazu die Datenreihe aus V1.1 mit 22 Probanden<sup>24</sup> und Geschwindigkeiten von bis zu 9 km/h. Das Training des MLPs und die Evaluation erfolgten mit der FANN-Bibliothek. Berechnet wurden die Merkmalsräume  $M_{G2}$  und  $M_{G4}$  (siehe Tabelle 4.1) für eine Fensterlänge von zwei Sekunden (300 Beschleunigungsvektoren). Die Merkmalsberechnung erfolgte in diesem Schritt noch mit der ursprünglichen Implementierung in Matlab, die die (Zwischen-) Ergebnisse als Gleitkommazahlen mit doppelter Genauigkeit darstellt. Ziel war es, die Validierung unabhängig von der Genauigkeit der Merkmalsberechnung durchführen zu können. Gewählt wurde eine Netzkonfiguration mit sieben verdeckten Neuronen, da sich dadurch mit der *Matlab Neural Network Toolbox* eine hohe Genauigkeit von über 97% erreichen lässt (siehe Abbildung 4.10). Mit FANN erfolgte das Training des MLPs mittels der Lernmethode `FANN_TRAIN_INCREMENTAL`. Die dabei erzielte Klassifikationsgenauigkeit beträgt für den Merkmalsraum  $M_{G2}$  ebenfalls 95,4%. Die exakte Übereinstimmung mit den Ergebnissen der *Matlab Neural Network Toolbox* ist als Zufall zu bewerten, da die Datenreihe um zwei Probanden erweitert und unterschiedliche Datenpartitionierungen vorgenommen wurden. Die Erweiterung des Merkmalsraums um das DWT-Merkmal ( $M_{G4}$ ) verbessert die Genauigkeit auf 96,8%; dies sind 0,6% weniger als mit der *Matlab Neural Network Toolbox* erreicht werden.

**Auswahl der Aktivierungsfunktion** Der Aufruf der Aktivierungsfunktion erfolgt bei jeder Klassifikation für alle Neuronen in der verdeckten Schicht und der Ausgabeschicht. Daher ist der Einsatz einer für die Ausführung auf einem Mikrocontroller geeigneten Aktivierungsfunktion bezüglich des Taktzyklenaufwands entscheidend. Beispielsweise benötigt

---

<sup>24</sup>Erweiterung um zwei Probanden, Erläuterung siehe Anhang A.1.1.

die Berechnung der Exponentialfunktion einer Sigmoidfunktion auf dem MSP430FG4618 etwa 3700 Taktzyklen [187, S.57]. Die FANN-Bibliothek bietet für eine Reduzierung des Berechnungsaufwands<sup>25</sup> eine mittels sechs Stützstellen stückweise lineare Approximation der Sigmoidfunktion:

$$f_{act}(x) = \frac{1}{1 + e^{-2 \cdot s \cdot x}} \quad (4.14)$$

Dabei bezeichnet  $x$  die Eingabe der Aktivierungsfunktion und  $s$  die Steigung mit  $s = 0,5$ . Die Stützstellen bilden die Funktionswerte bei 0,5 %, 5 %, 25 %, 75 %, 95 % und 99,5 % ab [116, S.59]. Die Evaluation der approximierten Sigmoidfunktion ergibt für die Datenreihe aus V1.1 mit Geschwindigkeiten von 3 km/h bis 9 km/h und dem Merkmalsraum  $M_{G2}$  einen Klassifikationsfehler (MSE) von  $25,34 \cdot 10^{-3}$ . Der Fehler der nicht approximierten Sigmoidfunktion beträgt hingegen  $8,50 \cdot 10^{-3}$ . Im Anschluss an die Portierung erfolgte daher eine erneute Evaluation der Klassifikationsgenauigkeit des Gesamtsystems, die ebenfalls die reduzierte Aufzeichnungsfrequenz und die portierte Merkmalsberechnung berücksichtigt.

**Realisierung des MLPs** Die auf dem MSP430FG4618 realisierte Netzkonfiguration besteht aus neun Eingabeneuronen, fünf verdeckten Neuronen, zwei Biasneuronen und vier Ausgabeneuronen, die jeweils eine der vier Geschwindigkeitsstufen 3, 5, 7 und 9 km/h repräsentieren. Dargestellt wird dies mittels der drei Strukturen FANN, FANN\_LAYER und FANN\_NEURON. Die Speicherung der Schichtenanzahl, der Zeiger auf die Schichten und der Neuronenanzahl erfolgt in FANN. Für jede Schicht des Netzes wird eine FANN\_LAYER-Struktur angelegt, die Zeiger auf das erste und letzte Neuron der Schicht enthält. Die Struktur FANN\_NEURON speichert für jedes Neuron Zeiger auf die mit diesem verbundenen Neuronen sowie den Gewichtswerten der Verbindungen [116, S.16f]. Die Gewichts- und Biaswerte werden zunächst mit einem Hilfsprogramm auf einem Desktop-Computer bestimmt. Genutzt wird dazu die realisierte Merkmalsberechnung und die Trainingsfunktionen der FANN-Bibliothek. Die Ergebnisse werden anschließend von einer Darstellung als Gleitkommazahlen in Festkommazahlen mit einer Wortbreite von 32 b konvertiert. Die Übertragung der Netzstruktur, der Aktivierungsfunktion und der ermittelten Gewichts- und Biaswerte in den Programmspeicher des MSP430FG4618 erfolgt mittels der Konfigurationsdatei `net_config.c` (Beschreibung siehe [187, S.60]).

Eingesetzt wird die beschriebene stückweise approximierten Aktivierungsfunktion. Jedes Ausgabeneuron gibt dabei einen Wahrscheinlichkeitswert (0 bis 1) für das Auftreten der jeweiligen Geschwindigkeitsklasse an; es wird die Klasse mit dem höchsten Wahrscheinlichkeitswert als Ergebnis ausgegeben.

#### 4.2.6.3 Taktzyklen- und Speicheraufwand

Der folgende Abschnitt gibt einen Überblick über den Taktzyklen- und Speicheraufwand der Geschwindigkeitsbestimmung auf dem MSP430FG4618, der sich jeweils aus der Merkmalsberechnung und der Klassifikation zusammensetzt. Für die Merkmalsberechnung besteht eine Abhängigkeit von der Messwertanzahl  $L$  pro Datenfenster und der Art sowie Anzahl an verwendeten Merkmalen. Die Dimensionalität des Merkmalsraums nimmt weiterhin Einfluss

<sup>25</sup>Ein Vergleich der Ausführungsdauer der verschiedenen in FANN verfügbaren Aktivierungsfunktionen wird in [116, Kap. 6.3] für einen Desktop-Computer und ein tragbares *Handheld*-Gerät gegeben.

Tabelle 4.7.: Taktzyklenaufwand der Merkmalsberechnung  $T_M$  und des MLPs  $T_{MLP}$  für verschiedene Optionen  $O$  des MSP430-Compilers.  $L$  repräsentiert die Anzahl an Beschleunigungsmesswerten des Datenfensters (hier 150). † Die Berechnung der Varianz nutzt den Mittel- und RMS-Wert. ‡ Der Taktzyklenaufwand ist abhängig von den Eingabewerten. Tabelle nach [187, S.62].

|                   | $O_0$           | $O_1$           | $O_2$           | $O_3$           |
|-------------------|-----------------|-----------------|-----------------|-----------------|
| Mittelwert        | $L \cdot 15$    | $L \cdot 13$    | $L \cdot 13$    | $L \cdot 5$     |
| RMS <sup>2</sup>  | $L \cdot 118$   | $L \cdot 87$    | $L \cdot 83$    | $L \cdot 77$    |
| Varianz †         | 175             | 166             | 122             | 122             |
| Spitze-Tal-Wert ‡ | $L \cdot 19$    | $L \cdot 17$    | $L \cdot 17$    | $L \cdot 12$    |
| MLP ‡             | $\approx 12500$ | $\approx 11300$ | $\approx 11700$ | $\approx 10200$ |

auf den Berechnungsaufwand der sich anschließenden Klassifikation.

**Taktzyklenaufwand** Der Taktzyklenaufwand für die Merkmalsberechnung wird im Folgenden in Abhängigkeit von der Messwertanzahl aufgezeigt. Die Taktangaben gelten dabei für eine Simulation der Berechnungen mit der *IAR Workbench* (IAR Systems) unter Verwendung des *IAR C/C++ Compilers for MSP430* (Version 5.40.2). Geprüft wurden dabei vier verschiedene Optimierungsoptionen  $O_0$  bis  $O_3$  des MSP430-Compilers; jede Optimierungsstufe erweitert dabei die vorherige um zusätzliche Optimierungen, die in [75, S.48] beschrieben sind. Dabei reduziert sich der Taktzyklenaufwand mit zunehmender Optimierungsstufe für die Merkmalsberechnung (siehe Tabelle 4.7); ausgewählt wurde die Option  $O_3$ . Den höchsten Taktzyklenaufwand benötigt die Berechnung des RMS<sup>2</sup> ( $L \cdot 77$ ) und den niedrigsten die des Mittelwerts ( $L \cdot 5$ ). Das Merkmal Varianz bedarf zwar noch weniger Taktzyklen (122), es wird jedoch auf Grundlage der zuvor berechneten Merkmale Mittelwert und RMS<sup>2</sup> gebildet. Für die im Rahmen der Portierung gewählten Konfigurationsparameter, bestehend aus drei Beschleunigungsachsen ( $A = 3$ ), 75 Hz Aufzeichnungsfrequenz und 2 s Fensterlänge ( $L = 150$ ), ergibt sich für die Merkmalsberechnung ein Aufwand von  $T_M = 42666$ .

$$T_M = A \cdot (L \cdot 5 + L \cdot 77 + 122 + L \cdot 12) \quad (4.15)$$

Der Gesamttaktzyklenaufwand  $T$  der Geschwindigkeitsbestimmung umfasst darüber hinaus den Aufwand  $T_{MLP}$  für die Berechnung der Neuronenausgaben für den jeweils anliegenden Merkmalsvektor.  $T_{MLP}$  setzt sich dabei aus dem Taktzyklenaufwand für die Propagation  $T_P$  und für die Berechnung der Aktivierungsfunktion  $T_A$  für die  $n_A$  Neuronen der verdeckten Schicht und der Ausgabeschicht zusammen.

$$T_{MLP} = T_P + n_A \cdot T_A \quad (4.16)$$

Die hier betrachtete Netzstruktur besteht aus drei Schichten (Eingabe- / Ausgabeschicht und eine verdeckte Schicht,  $K = 3$ ). Die Neuronenanzahl  $n$  für eine Schicht  $i$  wird im Folgenden

mit  $n_i$  angegeben. Für eine Schicht  $i$  mit einem zusätzlichen Biasneuron ergibt sich somit eine Anzahl von  $(n_i + 1) \cdot n_{i+1}$  gewichteten Verbindungen, für die jeweils eine Multiplikation mit einem Gewichtswert erfolgt (*MUL*). Die resultierenden Gewichtsvektoren werden im Anschluss für jedes Neuron addiert; es ergeben sich dabei  $n_i \cdot n_{i+1}$  Additionen (*ADD*):

$$T_p = \sum_{i=0}^{K-2} ((n_i + 1) \cdot n_{i+1} \cdot MUL + (n_i \cdot n_{i+1}) \cdot ADD) \quad (4.17)$$

Die Berechnung der ausgewählten, stückweise linear approximierten Aktivierungsfunktion benötigt jeweils:

$$T_A = 1 \cdot ADD + 3 \cdot SUB + 1 \cdot MUL + 1 \cdot DIV \quad (4.18)$$

Für den MSP430FG4618 ergeben sich für die Ausführung der unterschiedlichen Instruktionen  $T_{MLP} \approx 12500$  Taktzyklen ( $O_0$ ). Unter Ausnutzung der Compileroption  $O_3$  reduziert sich der Aufwand auf  $T_{MLP} \approx 10200$  Taktzyklen.

Insgesamt sind somit für die Geschwindigkeitsbestimmung  $T = 52866$  Takte notwendig, dies entspricht einem Energiebedarf von etwa  $95,2 \mu\text{J}$  pro Ausführung (1 MHz Taktfrequenz und 3 V Versorgungsspannung, siehe [76, S.31]). Für eine drahtlose Übertragung der bestimmten Geschwindigkeitsklasse erhöht sich der Energiebedarf um zusätzliche  $1,3 \mu\text{J}$  auf  $96,5 \mu\text{J}$ . Der Abschätzung ist ein ANT-basierter Transceiver mit  $73 \text{ nJ/b}$  [121] und eine Erweiterung des bestehenden Datenpakets auf 18 b zugrunde gelegt; 3 b entfallen dabei auf die Geschwindigkeitsklasse und 15 b auf eine fünffache Redundanz zur Kompensation von Störungen im Funkkanal. Erfolgt die Geschwindigkeitsbestimmung extern auf beispielsweise einem Desktop-Computer, beträgt der Energiebedarf für die drahtlose Kommunikation der  $3 \times 150$  Beschleunigungsmesswerte (3 Achsen und 2 s Zeitfenster) bei einer Wortbreite von 16 b das 5,4-fache ( $525,5 \mu\text{J}$ )<sup>26</sup>. Die Energiebedarfsangaben addieren sich zu dem Grundbedarf des Körpersensors für den Betrieb der Hardwarekomponenten und die Ausführung der Betriebssoftware.

**Speicheraufwand** Für die Merkmalsberechnung müssen die drei Beschleunigungssignale (Wortbreite jeweils 16 b) entsprechend der eingestellten Länge des Datenfensters zwischengespeichert werden. Der dazu eingesetzte *Ring Buffer* wird statisch in der Klasse angelegt und nach Initialisierung in den RAM kopiert [187, S.35ff]. Der Speicheraufwand  $S_M$  ergibt sich daher aus dem Zweifachen der Faktoren Achsenanzahl  $A = 3$  und der Beschleunigungsmesswerte  $L = 150$  mit einer Wortbreite von 16 b (2 B).

$$S_M = 2 \cdot A \cdot 16 \text{ b} \cdot L \quad (4.19)$$

Für die ausgewählte Konfiguration sind dies 1800 B. Die Speicherung der berechneten Merkmale benötigt weitere 2 B für den Mittel- und ST-Wert sowie 4 B für den Varianz- und RMS-

<sup>26</sup>Zu berücksichtigen ist weiterführend, ob die Beschleunigungssignale von weiteren biokinematischen Parametern genutzt werden.

Wert.

Der Speicheraufwand des MLPs setzt sich aus dem Bedarf für die Netzstruktur  $S_{Struk.}$ , die  $K$ -Schichten mit jeweils  $S_{Schicht}$ , die  $n$ -Neuronen (Gesamtanzahl inklusive Biasneuronen) mit jeweils  $S_{Neur.}$  und die gewichteten Verbindungen der verdeckten Schicht und der Ausgabeschicht mit jeweils  $S_{Gew.}$  zusammen:

$$S_{MLP} = S_{Stru.} + K \cdot S_{Schicht} + n \cdot S_{Neur.} + \sum_{i=0}^{K-2} ((n_i + 1) \cdot n_{i+1} \cdot S_{Gew.}) \quad (4.20)$$

Für die Realisierung des MLPs auf dem MSP430FG4618 wird vornehmlich der statische Programmspeicher genutzt. Für die Optimierungsstufe  $O_3$  des MSP430-Compilers ergibt sich ein Gesamtspeicheraufwand der Geschwindigkeitsbestimmung von  $S = 9665$  B, dies entspricht etwa 8 % des zur Verfügung stehenden Flash-Speichers des MSP430FG4618. Die für die Ausführung zusätzlich benötigte Betriebssoftware belegt weitere 8673 B [187, S.63]. Daher lassen sich zusätzliche Funktionen zur Merkmalsberechnung, eine größere Netzstruktur oder weitere Parameterbestimmungen auf das BG-V4.2 portieren.

#### 4.2.7 Evaluation (Online-Bestimmung)

Die Evaluation der realisierten Online-Geschwindigkeitsbestimmung erfolgte auf Laufbändern mit neun männlichen Probanden, die die vier Geschwindigkeitsstufen zwischen 3 km/h und 9 km/h absolvierten (Versuchsablauf wie in V1.1). Für jeden Probanden wurden zwei Aufzeichnungen mit einem zeitlichen Abstand von einer Woche (V1.2(1) und V1.2(2)) durchgeführt. Im Unterschied zu V1.1 erfolgte die Aufzeichnung in den Flash-Speicher des BG-V4.2 mit einer auf 75 Hz reduzierten Aufzeichnungsfrequenz. Weiterhin kam der Beschleunigungssensor LIS331HH mit einem auf  $\pm 12$  g erweiterten Messbereich zum Einsatz (weiterführende Informationen siehe Anhang A.1.2).

Das Training des MLPs erfolgte nach der Durchführung von V1.2(1)<sup>27</sup>. Um eine Gleichverteilung der Trainingstupel für die Erstellung des Vorhersagemodells zu gewährleisten, wurde für die verschiedenen Geschwindigkeitsklassen und Probanden das gemeinsame Minimum ermittelt und die Anzahl an Trainingstupel der einzelnen Klassen entsprechend reduziert. Zunächst erfolgte eine Überprüfung der Klassifikationsgenauigkeit auf der Datenreihe V1.2(1) unter Verwendung der zehnfachen Kreuzvalidierung. Mit 97,7 % wird trotz stückweise approximierter Aktivierungsfunktion eine hohe Klassifikationsgenauigkeit erreicht. Für die zweite Aufzeichnung eine Woche später wurde die ermittelte Netzkonfiguration in den Flash-Speicher des MSP430FG4618 übertragen.

Die Wiederholung diente als unabhängiger Test, wobei die Geschwindigkeiten direkt klassifiziert und die Ergebnisse in dem Flash-Speicher für eine spätere Auswertung abgelegt wurden. Für die Evaluation der Klassifikationsergebnisse erfolgte im Anschluss eine Annotation mit den auf dem Laufband eingestellten Geschwindigkeiten; Zeitabschnitte zwischen Geschwindigkeitsanpassungen auf dem Laufband wurden entfernt. Für jeden Proband stehen

---

<sup>27</sup>Die Neuronengewichts- und Biaswerte aus V1.1 wurden aufgrund des unterschiedlichen Beschleunigungssensors und der reduzierten Aufzeichnungsfrequenz hier nicht wiederverwendet.

Tabelle 4.8.: Klassifikationsgenauigkeit in [%] in Abhängigkeit von der Geschwindigkeitsstufe. Im Mittel ergibt sich eine Gesamtgenauigkeit von 96,1 %.

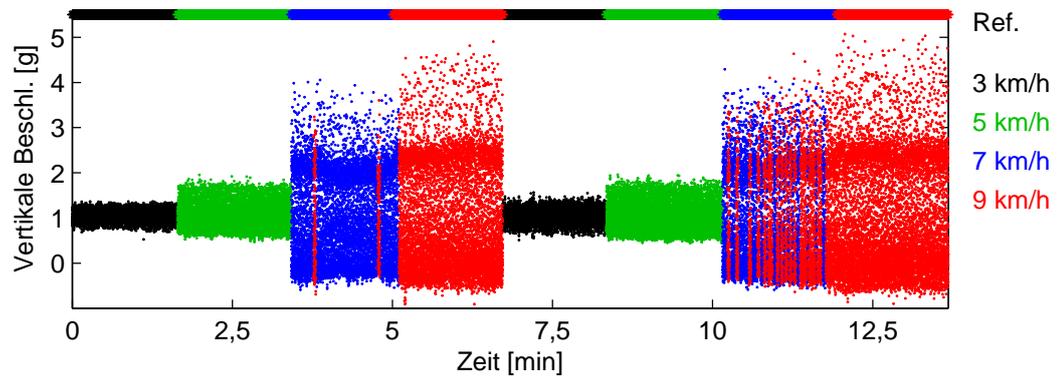
| $v$ [km/h] | $\bar{R}$ [%] | $\sigma$ [%] | Min. [%] | Max. [%] |
|------------|---------------|--------------|----------|----------|
| 3          | 99,4          | 0,98         | 97,3     | 100      |
| 5          | 99,2          | 2,07         | 93,8     | 100      |
| 7          | 90,2          | 10,66        | 73,2     | 100      |
| 9          | 95,5          | 4,26         | 88,0     | 100      |

402  $\pm$  11,9 Geschwindigkeitsbestimmungen zur Verfügung<sup>28</sup>.

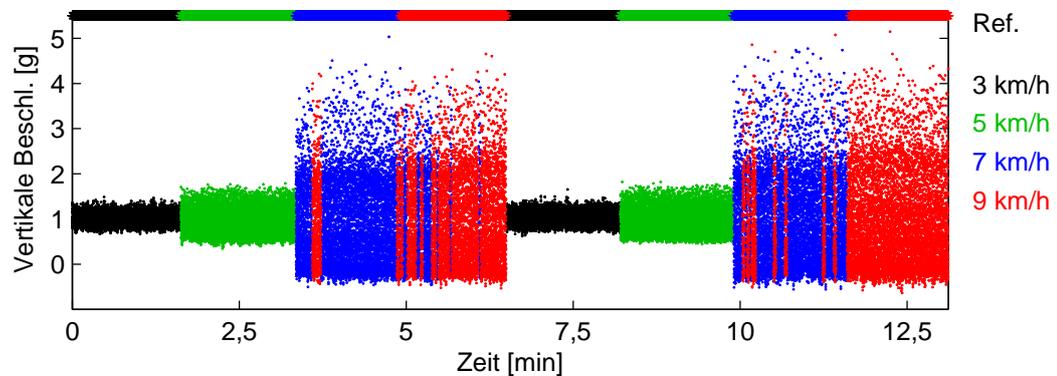
Das arithmetische Mittel der Klassifikationsgenauigkeiten der neun Probanden beträgt 96,1  $\pm$  2,6 %. Die Genauigkeit variiert dabei zwischen den Probanden in einem Bereich von 92,8 % bis 99,5 %. Eine sehr hohe Genauigkeit von über 99 % wird für zwei Probanden erzielt. Dabei lassen sich Gehen mit 3 km/h und 5 km/h mit einer besonders hohen Genauigkeit von >99 % erkennen (siehe Tabelle 4.8). Fehlklassifikationen treten, wie in der Auswertung von V1.1 beobachtet, insbesondere bei der Übergangsgeschwindigkeit 7 km/h zwischen Gehen und Laufen auf. Fehlklassifikationen diesbezüglich sind insbesondere für die Probanden  $P2_{V1.2}$  (73,2 %),  $P8_{V1.2}$  (79,7 %) und  $P5_{V1.2}$  (80,5 %) zu beobachten. Bei  $P5_{V1.2}$  betrifft dies erst die Wiederholung der Geschwindigkeitsstufe. Diese Problematik führt zu einer beim Laufen mit 9 km/h um knapp 4 % reduzierten Genauigkeit gegenüber dem Gehen. Dargestellt sind die einzelnen Klassifikationsergebnisse in den Abbildungen 4.12, B.1 und B.2.

Darüber hinaus bestätigen die Ergebnisse ebenfalls die Robustheit der realisierten Online-Geschwindigkeitserkennung gegenüber leichten Veränderungen der Orientierung des Beschleunigungssensors bedingt durch das erneute selbständige Anlegen des BG-V4.2 (Kriterium für Praxistauglichkeit).

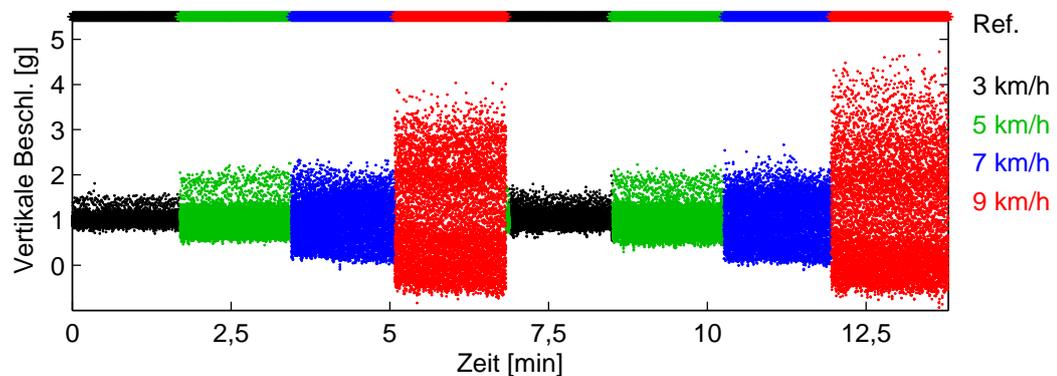
<sup>28</sup>Die Anzahl schwankte geringfügig zwischen den Probanden aufgrund von beispielsweise einer Unterbrechung durch eine abgerissene Sicherungsschnur (P1 bei 3 km/h).



(a) Proband  $P2_{V1.2}$  mit einer Klassifikationsgenauigkeit von 92,8% (schlechtestes Ergebnis).



(b) Proband  $P4_{V1.2}$  mit einer Klassifikationsgenauigkeit von 93,5% (2. schlechtestes Ergebnis).



(c) Proband  $P3_{V1.2}$  mit einer Klassifikationsgenauigkeit von 99,5% (bestes Ergebnis).

Abbildung 4.12.: Vertikales Beschleunigungssignal mit unterschiedlicher Färbung für die mit dem BG-V4.2 bestimmte Geschwindigkeitsklasse (Klassifikatorausgabe). Als Referenz ist die am Laufband eingestellte Geschwindigkeit jeweils oben in den Abbildungen eingezeichnet.

### 4.2.8 Diskussion

Im Folgenden werden die Ergebnisse der vorliegenden Arbeit mit ausgewählten wissenschaftlichen Arbeiten verglichen und die realisierte Geschwindigkeitsbestimmung diskutiert. Die Vorhersagemodelle von [11; 63; 72] sind auf Ganggeschwindigkeiten ausgelegt und die Evaluation erfolgte für natürliches Gehen mit einer vom Probanden selbstgewählten Geschwindigkeit. Die Modelle von [12; 146] berücksichtigen zusätzlich Steigungen. Als Messpositionen werden insbesondere die Hüfte und der untere Rücken [12; 63; 72], der Fußbereich und das Bein [11; 12] oder das Brustbein [146] gewählt. Die Modelle von [63; 72] nutzen dabei Informationen von mehreren, am Körper verteilt angebrachten Sensoren. Teils sind für die Geschwindigkeitsbestimmung zusätzliche Probandeneigenschaften wie Größe und Gewicht nötig [63; 146]. Die Genauigkeiten der nicht personenspezifisch kalibrierten Vorhersagemodelle liegen zwischen 84 % [12] und 97 % [63]. Y. Song u.a., die zusätzlich Laufgeschwindigkeiten und Steigungen erfassen, erreichen für die Messposition Brustbein eine Genauigkeit von 90,4 % [146]. Die im Rahmen der Dissertation erzielten Ergebnisse liegen zwischen 96,1 % (V1.2, portierte Geschwindigkeitsbestimmung) und 98,8 % (V1.1). Für die Evaluation auf einer Laufbahn im Außenbereich sind es 97,3 % (V2). Eine Gegenüberstellung der Ergebnisse befindet sich in der Tabelle 4.9.

Ein Kriterium bezüglich des Taktzyklen- und Speicheraufwands der Portierung eines MLPs auf einen Körpersensor ist die Anzahl verdeckter Neuronen. Im Vergleich zu den von [146] verwendeten 30 Neuronen<sup>29</sup> sind für die in der vorliegenden Arbeit realisierte Geschwindigkeitsbestimmung weniger als die Hälfte an Neuronen notwendig; die Portierung auf den Körpersensor nutzt sogar nur fünf. Das im Rahmen der Dissertation realisierte Vorhersagemodell berücksichtigt derzeit nicht die Steigung der Laufstrecke, realisieren ließe sich dies jedoch anhand der Median-Werte der ML-Beschleunigungen und der Kovarianzen zwischen den Spitzenwerten der V- und ML-Beschleunigungssignale [12]. J.-S. Hu u.a. führen eine personenspezifische Kalibrierung ihres Vorhersagemodells durch und erzielen auf diese Weise eine sehr hohe Genauigkeit von 99,4 %. Für die Datenreihe mit 20 Probanden aus V1.1 wird auf Grundlage personenspezifischer Neuronengewichte und Biaswerte ebenfalls eine Steigerung der Genauigkeit auf 99,1 % erzielt. Die Verbesserung aufgrund der Kalibrierung zeigt die hohe interindividuelle Variabilität der Schrittmuster zwischen Probanden.

Fehlklassifikationen treten verstärkt bei höheren Laufgeschwindigkeiten auf; die dabei beobachtete interindividuelle Variabilität der Schrittmuster nimmt zu. In diesem Zusammenhang ist eine Kombination von mehreren Merkmalen der Zeit- und Frequenzdomäne von Bedeutung. Die Leistung einzelner Merkmale kann unterschiedlich für verschiedene Geschwindigkeitsbereiche ausfallen. Ein Beispiel ist der ST-Wert, der besser für die Bestimmung von Ganggeschwindigkeiten geeignet ist. Eine Unterscheidung der Laufgeschwindigkeiten 9 km/h und 11 km/h ist anhand der ST-Werte teils nicht möglich und die Werte weisen eine hohe interindividuelle Variabilität auf (siehe Abschnitt 4.2.3).

Für die betrachteten Datenreihen erreicht der RF-Klassifikator eine höhere Sensitivität und Spezifität als das MLP und der EB. Im direkten Vergleich zwischen MLP und EB ist die

<sup>29</sup>Eingesetzt werden drei MLP mit insgesamt 50 Neuronen. Davon ist ein MLP mit 20 Neuronen für die Steigungsbestimmung nötig.

#### 4. Biokinematische Parameter

Tabelle 4.9.: Gegenüberstellung der Ergebnisse von Verfahren zur Geschwindigkeitsbestimmung in der Literatur mit denen für V1.1, V1.2 und V2. *S* bezeichnet das Szenario (*L* Laufband, *P* Testparcours / Laufbahn) und *N* die Probandenanzahl. † Markiert natürliches Gehen mit selbstgewählter Geschwindigkeit und ‡ eine personenspezifische Kalibrierung.

| Referenz            | S                      | Messposition                | Typ                | Geschwindigkeiten                         | N          | Ergebnis                |
|---------------------|------------------------|-----------------------------|--------------------|---|------------|-------------------------|
| Aminian (1995) [12] | <i>L</i> ,<br><i>P</i> | Unt. Rücken,<br>rechter Fuß | 2 MLP              | 3,5 km/h bis 7 km/h,<br>−10 % bis +10 %   | 5          | >84 %                   |
| Aminian (2002) [11] | <i>P</i>               | Fuß, Bein                   | Wavelet,<br>Gangm. | Gehen †                                   | 20         | 93 %                    |
| Song (2007) [146]   | <i>L</i> ,<br><i>P</i> | Brustbein                   | 2 MLP              | 4,8 km/h bis 15,4 km/h,<br>6 % bis 21,5 % | 17         | $r = 0,987 /$<br>90,4 % |
| He (2011) [63]      | <i>P</i>               | Hüfte                       | MLP                | Gehen †                                   | 35         | 97,0 %                  |
| Hu (2013) [72]      | <i>P</i>               | Hüfte                       | Gangm.             | Gehen †                                   | 20         | 96,6 % /<br>99,4 % ‡    |
| V1.1                | <i>L</i>               | Brustbein                   | RF<br>MLP          | 3 km/h bis 9 km/h                         | 20         | 98,8 % /<br>99,1 % ‡    |
| V1.2 (online)       | <i>L</i>               | Brustbein                   | RF                 | 3 km/h bis 11 km/h                        | 15         | 97,8 %                  |
| V2                  | <i>P</i>               | Brustbein                   | MLP<br>RF          | 3 km/h bis 9 km/h<br>3 km/h bis 11 km/h   | 9<br>11-13 | 96,1 %<br>97,3 %        |

Genauigkeit für V1.1 beim MLP höher; für V2 hingegen erzielt der EB das bessere Ergebnis.

### 4.2.9 Zusammenfassung und Ausblick

Die Aufzeichnung und Analyse des Parameters Gang- / Laufgeschwindigkeit bietet vielfältige Anwendungsmöglichkeiten unter anderem zur Bestimmung des Energieumsatzes, der Erfassung der Trainingsbelastung und zur Unterstützung externer Trackingverfahren. Im Rahmen der Arbeit wurde eine Geschwindigkeitsbestimmung realisiert, die auf Beschleunigungsmessungen im Brustbereich basiert und auf keine personenspezifischen Zusatzinformationen des Trägers angewiesen ist. Für einen Körpersensor, wie dem BG-V4.2, der im Brustbereich weitere physiologische Parameter erfasst, hat dies den Vorteil, dass keine zusätzlichen Sensoren im Fußbereich, am Bein oder der Hüfte nötig sind. Die Geschwindigkeitsinformationen der Schrittmuster in den Beschleunigungssignalen werden mit Merkmalen in der Zeit- und Frequenzdomäne erfasst und mittels eines Klassifikators (MLP, EB oder RF) ausgewertet. Die Evaluation erfolgte auf Grundlage der Daten von drei Versuchen mit insgesamt 40 Probanden.

Für die Datenreihe aus V1.1 wird für 3 km/h bis 9 km/h eine Genauigkeit von bis zu 98,8 % mit dem RF erzielt (10-fache Kreuzvalidierung). Unter Berücksichtigung der Probanden, die zusätzlich 11 km/h liefen, reduziert sich die Genauigkeit leicht auf 97,8 %. Vertikale Beschleunigungen sind für die Geschwindigkeitsbestimmung dabei am wichtigsten, die Genauigkeit reduziert sich um nur 1,5 %, wenn AP- und ML-Beschleunigungen nicht genutzt werden (*Hold-Out Validation* und MLP). Die Merkmale Varianz, ST- und RMS-Wert enthalten die meisten Geschwindigkeitsinformationen, kombiniert wird bereits eine Genauigkeit von 95,4 % erreicht ( $M_{G2}$  und MLP). Fehlklassifikationen treten vornehmlich für höhere Geschwindigkeiten, wie dem Laufen mit 9 km/h und 11 km/h, aufgrund von Variabilitäten in den Schrittmustern auf. Um den Einfluss von interindividuellen Variabilitäten zu bestimmen, erfolgte eine personenspezifische Anpassung der Neuronengewichte und Biaswerte an die einzelnen Probanden, erreicht werden 99,1 % bei einer niedrigen Standardabweichung von  $\pm 0,0068$  %. Weiterführend erfolgte eine Evaluation der Geschwindigkeitsbestimmung auf einer Laufbahn im Außenbereich (V2) mit zwei zeitlich unabhängigen Datenreihen (Training und Test). Der RF-Klassifikator erzielt auch in diesem Szenario mit 97,3 % die höchste Genauigkeit. Der hohe Genauigkeitswert zeigt weiterhin die Robustheit der Bestimmung gegenüber leichten Veränderungen in der Orientierung des Beschleunigungssensors bedingt durch ein erneutes Anlegen des BG-V4.2.

Bei der realisierten Online-Geschwindigkeitsbestimmung auf dem MSP430FG4618 werden die Beschleunigungssignale zunächst in einem *Ring Buffer* zwischengespeichert und im Anschluss die Merkmale berechnet. Für die Gang- / Laufgeschwindigkeitsbestimmung aus den Merkmalen kommt ein MLP mit nur fünf Neuronen in der verdeckten Schicht zum Einsatz. Die Verarbeitung von Eingabewerten und (Zwischen-) Ergebnissen erfolgt dabei in einer Fixpunktarithmetik unter Ausnutzung der funktionalen Einheit des MSP430FG4618 für  $16 \text{ b} \times 16 \text{ b}$  Multiplikationen. Wiederkehrende Divisionen der Merkmalsberechnung wurden durch Multiplikationen mit einem vorberechneten Kehrwert ersetzt, um Emulationen der Divisionen mit hohem Taktzyklenaufwand zu vermeiden. Die Geschwindigkeitsbestimmung benötigt pro Ausführung 52866 Takte, dies entspricht einem Energiebedarf von  $95,2 \mu\text{J}$ , der Speicheraufwand beträgt 9665 B. Der größte Anteil entfällt auf die Berechnung der Varianz, des RMS- und des ST-Werts ( $\approx 42666$  Takte). Aus energetischer Sicht ist eine Verarbeitung der Beschleunigungssignale zwecks Geschwindigkeitsbestimmung auf dem MSP430FG4618 sinnvoll, die drahtlose

Kommunikation der Sensormesswerte benötigt mit einem ANT-Transceiver die 5,4-fache Energiemenge. Die Genauigkeit der realisierten Online-Geschwindigkeitsbestimmung beträgt 96,1 % (Evaluation in V1.2).

Zukünftig könnte eine Bestimmung der Steigung der Laufstrecke mittels zusätzlicher aus den Beschleunigungssignalen extrahierter Merkmale erfolgen. Weiterhin lässt sich die derzeitige Klassifikation von Geschwindigkeitsstufen um eine kontinuierliche Schätzung erweitern. Ein Ansatz besteht darin, das Neuron mit der höchsten Wahrscheinlichkeit zu bestimmen und die beiden umliegenden Neuronen, die die höhere und niedrigere Geschwindigkeit repräsentieren, anhand deren Wahrscheinlichkeitswerte gewichtet in die Geschwindigkeitsausgabe einfließen zu lassen. Anstelle einer Klassifikation könnte auch eine Regression erfolgen, dies lässt sich unter anderem mit dem RF realisieren. Zur Evaluation ist dazu jedoch eine Annotation der Beschleunigungssignale mit kontinuierlichen oder feiner abgestuften Geschwindigkeitsangaben nötig. Eingesetzt werden können dazu externe Trackingverfahren, die beispielsweise auf GPS oder Videokameras basieren. Ein Einsatzszenario stellt dabei der Mannschaftssport dar, um Geschwindigkeitsprofile der Athleten zur Erfassung der körperlichen Belastung zu erstellen. Weiterführend lassen sich diese Profile zukünftig in Kombination mit der realisierten Personenidentifikation (siehe Kapitel 5) nutzen, um externe Trackingverfahren zu unterstützen (siehe Abschnitt 6.2).

### 4.3 Oberkörperhaltung

Die Erfassung der Körperhaltung stellt eine relevante Größe für unter anderem die folgenden Anwendungsszenarien dar. Im Rahmen der Arbeitsmedizin bietet die Erkennung der charakteristischen Merkmale einer ungünstigen Körperhaltung, beispielsweise während sitzenden und stehenden Arbeitsbedingungen, die Möglichkeit, deren Auswirkungen [139] präventiv entgegenzuwirken. Im Rahmen der Sportmedizin ist eine Bestimmung der Körperhaltung beispielsweise während des Golfspiels und Kricketts nützlich, um Verletzungen aufgrund einer falschen Haltung zu vermeiden [35]; weitere Anwendungsmöglichkeiten ergeben sich beim Krafttraining. Im Rahmen von zwei ZIM-Kooperationsprojekten (siehe Kapitel 8) wird eine Überprüfung der Haltung im Breitensport sowie für die Kalibrierung von Beinprothesen geprüft. Darüber hinaus ist die Erfassung der Oberkörperhaltung im Rahmen eines Aktivitätsmonitorings ein relevantes Merkmal, um Alltagsaktivitäten zu unterscheiden. Ein Einsatz besteht darüber hinaus zur Plausibilisierung und Interpretation erfasster physiologischer und biokinematischer Parameter. So bietet ein im Brustbereich angebrachter Beschleunigungssensor nicht die Möglichkeit, die Aktivität zu erfassen, falls eine Übung, wie beispielsweise während des Langhantelprogramms *BODYPUMP*, auf dem Rücken liegend durchgeführt wird. Ein Widerspruch entsteht während der Parameterinterpretation zwischen der fehlenden Aktivität in den Beschleunigungssignalen und dem Anstieg der Herzfrequenz (siehe Abbildung 4.14). Ohne die Zusatzinformation der Oberkörperhaltung kann dies beispielsweise zu der Fehlinterpretation führen, dass ein mentaler Stressor vorliegt.

Die Bestimmung der Rotationsmatrix, die die Oberkörperhaltung beschreibt, erfolgt üblicherweise auf Grundlage der Sensorinformationen einer *Inertial Measurement Unit (IMU)*, die Beschleunigungssensoren, Gyroskope und Magnetometer kombiniert [56]. Das BG-V4.2 verfügt jedoch nur über einen dreiaxialen Beschleunigungssensor. Im Folgenden wird be-

schrieben, wie sich dennoch die Rotationsmatrix approximieren lässt.

In Ruhe wirkt auf die drei Achsen des Beschleunigungssensors die statische Erdbeschleunigung von  $1\text{ g}$  ( $9,80665\text{ m}\cdot\text{s}^{-2}$ ). Befindet sich der Körpersensor in einer aufrechten Orientierung in Ruhe, sind diese  $1\text{ g}$  ausschließlich auf der vertikalen Beschleunigungsachse messbar (Idealfall). Ändert sich die Orientierung, wirkt die statische Erdbeschleunigung verteilt auf die drei orthogonalen Beschleunigungsachsen. Aus der Verteilung kann mittels trigonometrischer Funktionen der seitliche Oberkörperneigungswinkel  $\phi$  (Rollen um AP-Achse, engl. *Roll*) und der vorwärts-rückwärts Neigungswinkel  $\theta$  (Nicken um ML-Achse, engl. *Pitch*)<sup>30</sup> bestimmt werden. In der Praxis ist jedoch die statische Erdbeschleunigung im Allgemeinen mit einer dynamischen Beschleunigungskomponente, resultierend aus Körperbewegungen, überlagert. Zunächst erfolgt daher eine Approximation des statischen Anteils mittels eines Median-Filters (Tiefpasscharakter), der sich besonders robust gegenüber Ausreißern kurzer Zeitdauer und hoher Intensität verhält. Die realisierte Approximation der statischen Erdbeschleunigung ist dabei für Anwendungsszenarien mit niedriger bis leichter körperlicher Aktivität geeignet. Im Anschluss erfolgt die Bestimmung des Roll- und Pitch-Winkels aus den statischen Beschleunigungsanteilen  $a_{AP}$ ,  $a_{ML}$  und  $a_V$  mittels des Arkustangens (Nutzung der atan2-Funktion mit zwei Argumenten).

$$\phi = \text{atan2}\left(a_{ML}, \sqrt{a_V^2 + a_{AP}^2}\right) \cdot \frac{360^\circ}{2\pi} \quad (\text{Roll}) \quad (4.21)$$

$$\theta = \text{atan2}\left(-a_{AP}, \sqrt{a_V^2 + a_{ML}^2}\right) \cdot \frac{360^\circ}{2\pi} \quad (\text{Pitch}) \quad (4.22)$$

Gewählt wurde die atan2-Funktion, um eine Bestimmung des Roll- und Pitch-Winkels ohne Singularitäten bei der Anbringung des BG-V4.2 im Brustbereich für einen Bereich von  $-90^\circ$  bis  $+90^\circ$  zu ermöglichen.

Zu berücksichtigen ist bei der Bestimmung der Oberkörperhaltung ein initialer Versatz aufgrund des Anlegens des Körpersensors. Im Rahmen eines Versuchs mit 15 Probanden betrug das arithmetische Mittel des Versatzes  $11,3 \pm 5,7^\circ$  [185, S.43f]. Es zeigte sich dabei tendenziell eine Neigung des Beschleunigungssensors in Rückwärts- und Seitwärtsrichtung (rechts). Eine Korrektur des Versatzes ist zu Aufzeichnungsbeginn mit dem realisierten Anlegeassistenten [185, S.39f] möglich. Weiterführend könnte zukünftig eine Validierung der Oberkörperhaltungsbestimmung während körperlicher Belastung mittels einer optischen Bewegungserfassung (z.B. der Firma Vicon Motion Systems) durchgeführt werden.

## 4.4 Aktivitätserfassung

Beschleunigungssensoren werden in vielfältigen Anwendungsszenarien zur Erfassung von körperlichen Aktivitäten [14; 42; 43; 86] genutzt. Im Folgenden wird ein Überblick zur Aktivitätserkennung mit dem BG-V4.2 gegeben.

**Aktivitätserkennung (Klassifikation)** Gehen stellt eine Form der körperlichen Aktivität des privaten und beruflichen Alltags dar. Anwendung findet eine Erkennung der Gangaktivität

<sup>30</sup>Der Gierwinkel (V-Achse, engl. *Yaw*) lässt sich mit der statischen Erdbeschleunigung nicht erfassen.

beispielsweise bei der Bestimmung des Leistungsumsatzes im Alltag (siehe Abschnitt 6.1). Für das BG-V4.2 wurde dazu eine Schritterkennung realisiert<sup>31</sup>, die aus den V- und AP-Beschleunigungen Schritte mit einer Sensitivität von  $97,9 \pm 0,013\%$  und einer Spezifität von  $94,5 \pm 0,085\%$  ermittelt (Evaluation auf der Datenreihe aus V2). Die realisierte Schritterkennung lässt sich außerdem für eine automatisierte Segmentierung der Beschleunigungssignale in Schritte zwecks Ganganalyse nutzen.

Die Schätzung des Leistungsumsatzes lässt sich weiter verbessern, indem zusätzlich zu den Schritten Alltagsaktivitäten erkannt und berücksichtigt werden. Eine Möglichkeit besteht dabei in der Nutzung des entsprechenden metabolischen Äquivalents [7] für die ermittelte Aktivität (siehe Abschnitt 6.1). Realisiert wurde dazu im Rahmen einer Projektgruppenarbeit eine Erkennung der Alltagsaktivitäten Sitzen, Stehen, Liegen und Gehen sowie der sportlichen Betätigungen Liegestützen und Kniebeugen sowie der Bauchmuskelübung *Sit-up* [183]. Für die Aktivitätserkennung wird dazu primär ein im Brustbereich angebrachtes BG-V4.2 genutzt. Zusätzlich wurden der Einsatz eines zweiten BG-V4.2 oberhalb des Handgelenks sowie eines Smartphones (Inertialsensorinformationen) in der Hosentasche geprüft. Für die Aktivitätserkennung werden aus den drei Beschleunigungssignalen die folgenden Merkmale innerhalb von Zeitfenstern berechnet: Häufigkeitsverteilung der Messwerte (Histogramm), arithmetisches Mittel, Varianz, mittlere Differenz zwischen den einzelnen Beschleunigungswerten und dem Mittelwert des Zeitfensters. Außerdem erfolgt eine Normalisierung der Herzfrequenzwerte mittels der personenspezifischen Ruhe- und Maximalherzfrequenz. Im Anschluss werden das arithmetische Mittel, die Varianz und die Änderungsrate berechnet. Für die Erkennung der unterschiedlichen Aktivitäten aus den Merkmalen wurde unter anderem der Einsatz eines EB geprüft. Die Evaluation erfolgte für 10 Probanden mit jeweils drei aufgezeichneten Datenreihen von 12 min Länge. Mit dem EB ist eine Unterscheidung der Aktivitäten mit einer Genauigkeit von 91,9% möglich.

**Universelles Aktivitätsmaß** Die Schätzung des Energiebedarfs auf Grundlage der Schrittanzahl, der Gang- / Laufgeschwindigkeit oder der beschriebenen Aktivitäten ist nur möglich, falls die ausgeübte Aktivität dem Erkennungsalgorithmus bekannt ist und richtig ermittelt wird. Diese Problematik stellt sich unter anderem bei der Anwendung im hochdynamischen Handballsport, bei dem sich Stehen, Gehen, Laufen, Sprints, Sprung- und Wurfbewegungen sowie Körperkontakte zwischen den Handballspielern schnell abwechseln und interindividuelle Variabilitäten in den Bewegungsausführungen auftreten. Im Folgenden werden daher Möglichkeiten einer universellen Darstellung der körperlichen Aktivität aufgezeigt.

Die Visualisierung von ML- und V-Beschleunigungen im zeitlichen Verlauf eines Alltagsszenarios zeigt, dass die Beschleunigungssignale selbst eine detaillierte Repräsentation der körperlichen Aktivität bieten (siehe Abbildung 4.13). Zusätzlich sind als Vergleich die Änderungen der Herzfrequenz, die eine etablierte Größe zur Belastungserfassung darstellt [1], aufgetragen<sup>32</sup>. Das dargestellte Szenario besteht aus einer ersten Phase mit Gehen (x1) mit

---

<sup>31</sup>K. Stockmann. „Eine Schritterkennung für Fußgänger und Läufer unter Verwendung der vertikalen und horizontalen Beschleunigungssignale“. IT-Sportanalyse, Projektarbeit. AG K&S, Universität Bielefeld, Dez. 2012.

<sup>32</sup>Datenreihe vom 30.08.2012 aufgezeichnet mit dem BG-V4.2 und einem Probanden.

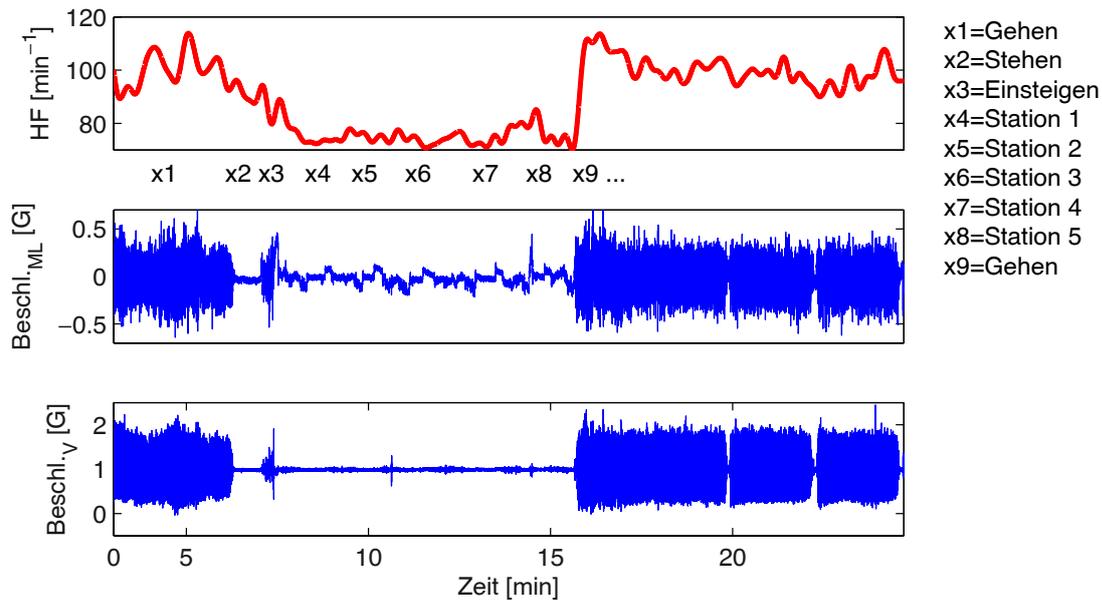


Abbildung 4.13.: Herzfrequenz, ML- und V-Beschleunigungen aufgezeichnet mit dem BGV-4.2 während des Gehens und einer Stadtbahnfahrt (seitwärts zur Fahrtrichtung sitzend). Unterschiedliche Skalierung der Beschleunigungssignale zur besseren Übersicht.

Belastungsvariationen aufgrund von Änderungen des Höhenprofils. Das Warten (x2) grenzt sich durch eine sehr niedrige Aktivität in den Beschleunigungssignalen ab. Der Einstieg (x3) in eine Stadtbahn wird durch eine sprunghafte kurzzeitige Zunahme der Aktivität sichtbar. Es folgt eine Ruhephase im Sitzen, in der die Herzfrequenz absinkt und ebenfalls nur eine sehr niedrige Aktivität auf der vertikalen Beschleunigungsachse zu verzeichnen ist. Aufgrund der Ausrichtung des Sitzes seitwärts zur Fahrtrichtung sind die Beschleunigungsvorgänge der einzelnen Ein- und Ausfahrten in die Stadtbahnstationen auf der entsprechenden sensitiven ML-Beschleunigungsachse mit einer vergleichsweise niedrigen Intensität zwischen  $-200\text{ mg}$  und  $+100\text{ mg}$  erkennbar<sup>33</sup>. Es folgt eine gleichmäßige Gangphase (x9), die von zwei kurzen Wartephase für Straßenüberquerungen unterbrochen ist. Insbesondere solche Belastungsänderungen von nur sehr kurzer Zeitdauer sind anhand der Beschleunigungssignale deutlicher als im Zeitverlauf der Herzfrequenz zu erkennen.

Eine weiterführende Darstellung, die die Aktivität entlang der drei Beschleunigungsachsen zusammenfasst, ist durch die Berechnung der Länge des Beschleunigungsvektors möglich. Für die Aufzeichnung eines Langhantelprogramms (*BODYPUMP*)<sup>34</sup> wurde zusätzlich im

<sup>33</sup>Für die Interpretation kann daher eine Signalvorverarbeitung und ein Abgleich mit Zusatzinformationen (z.B. Geoinformationen anhand von GPS-Positionsdaten) nötig sein.

<sup>34</sup>Datenreihe vom 19.04.2012 aufgezeichnet mit dem BG-V4.2 und drei Probanden im Sport- und Gesundheitszentrum Raulwing in Minden.

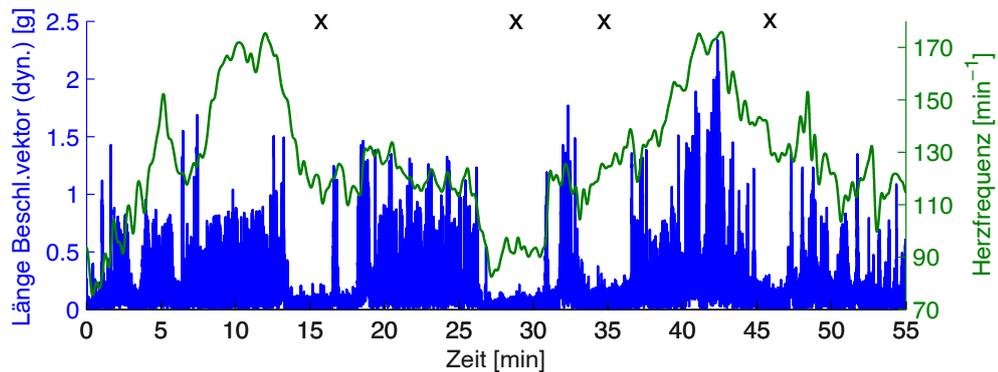


Abbildung 4.14.: Dynamischer Beschleunigungsanteil und Herzfrequenz eines Probanden im zeitlichen Verlauf aufgezeichnet mit einem BG-V4.2 während eines Langhantelprogramms (*BODYPUMP*).

Anschluss die statische Erdbeschleunigung subtrahiert, sodass nur die dynamischen Anteile verbleiben (siehe Abbildung 4.14). Der Verlauf zeigt dabei die Änderung der körperlichen Aktivität fein abgestuft. Auffällig ist jedoch, dass für die markierten Phasen (x), in denen die dynamischen Beschleunigungsanteile weniger als 0,5 g betragen, Schwankungen der Herzfrequenzwerte zwischen 83 1/min und 143 1/min auftreten. Unter Zuhilfenahme der ebenfalls mit dem BG-V4.2 ermittelten Körperhaltung zeigt sich, dass die Übungen dabei mit dem Oberkörper ruhend in einer horizontalen Position durchgeführt wurden (z.B. Langhantelübungen auf dem Rücken liegend). Die dabei auftretende Aktivität der Arm- und Schultermuskulatur ist in diesen Situationen jedoch nicht mit einem Beschleunigungssensor im Brustbereich messbar. Daher ist eine zusätzliche Verwendung weiterer biokinematischer und physiologischer Parameter im Rahmen einer Aktivitätserfassung sinnvoll. Mit einem Beschleunigungssensor kann zwar die Körperhaltung bestimmt werden, die Bewertung einer verrichteten statischen Haltearbeit ist jedoch nicht möglich. Bei hoher Anstrengung wird statische Haltearbeit indirekt über einen Werteanstieg der physiologischen Parameter sichtbar.

Weiterführend zeigt sich, dass für ein hochdynamisches Anwendungsszenario, wie dem Handballsport, das Integral der Längen der Beschleunigungsvektoren über ein Zeitfenster von 30 s Dauer bezüglich der Darstellung und Analysierbarkeit der Aktivität geeignet ist. Die Varianz des Aktivitätsverlaufs aufgrund von Spitzenbeschleunigungen hoher Intensität und kurzer Zeitdauer reduziert sich, sodass der Zusammenhang zwischen der körperlichen Aktivität und der Herzfrequenz ersichtlich wird. Die Abbildung 4.15 zeigt dazu den Herzfrequenzverlauf und die Aktivitätsverläufe (Brustbereich sowie oberhalb des Hand- und Fußgelenks) des Handballspielers P7 während eines Trainingsspiels (V3). Für eine bessere Übersicht erfolgte für die Darstellung eine Normalisierung der Ergebnisse auf einen Wertebereich zwischen 0 und 1. Der Vergleich der drei Verläufe zeigt, dass der Brustbereich als Messposition für die Aktivitätserfassung geeignet ist. Abweichungen zu den Verläufen der Messung oberhalb des Hand- und Fußgelenks zeigen sich in Form von teils höheren Aktivitätsspitzen.

In weiterführenden Arbeiten lässt sich das Aktivitätsmaß nutzen, um den zeitlichen Versatz zwischen der Herzfrequenz und der körperlichen Aktivität zu bestimmen, beispielsweise mit-

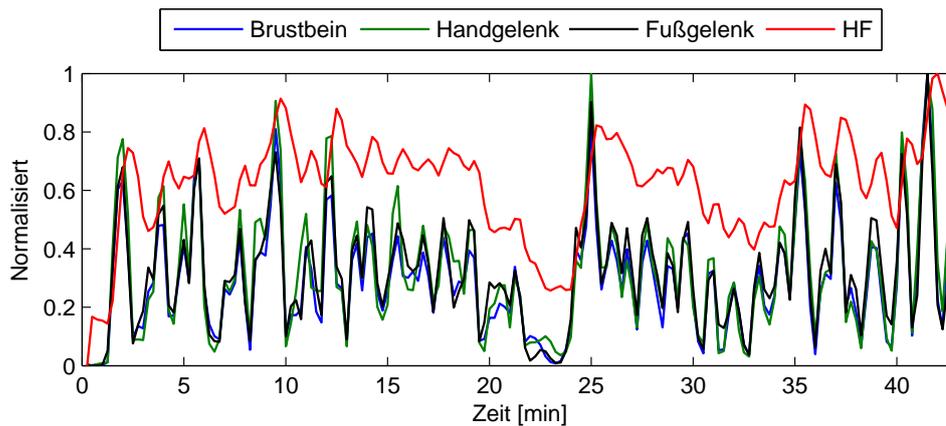


Abbildung 4.15.: Daten des Handballspielers P7 während eines Trainingsspiels und der Halbzeitpause (V3). Herzfrequenzverlauf und Aktivität dargestellt als Integral der Längen der Beschleunigungsvektoren über ein Zeitfenster von 30 s, aufgezeichnet mit drei BG-V4.2 (Brustbein, Handgelenk und Fußgelenk).

tels einer Kreuzkorrelation. Der Versatz stellt die Antwortzeit der Herzfrequenz bezüglich der Anpassung auf einen Belastungsreiz dar und dient als Maß, die Erholungsfähigkeit zu bewerten. Die Zeitdauer des Versatzes ist dabei abhängig von dem individuellen Trainingszustand und der Intensität der Belastung. Für P7 zeigt sich beispielsweise, dass die Halbzeitpause von 5 min nicht ausreicht, um die Ausgangsherzfrequenz (Spielanfang) wieder zu erreichen. Weiterhin steht eine Herzfrequenzsteigerung mit zunehmender Belastungsdauer, bei einem gleichbleibenden Aktivitätslevel (kardiovaskulärer Drift), in Zusammenhang mit einem Verlust von Wasser (Dehydrierung) und einer Zunahme der Körperkerntemperatur [1]. Mittels einer entsprechenden Analyse der Herzfrequenz- und Aktivitätsverläufe ist eine Detektion von Erschöpfung aufgrund einer körperlichen Belastung denkbar.



## 5 Biosignalbasierte Personenidentifikation

Der Leitgedanke der vorliegenden Arbeit ist, mittels des vorgestellten Körpersensors wichtige physiologische und biokinematische Parameter unter natürlichen Umgebungsbedingungen zu ermitteln. Die Analysen der Datenreihen der dazu durchgeführten Versuche zeigen, dass sich Signalverläufe zwischen den Probanden teils signifikant unterscheiden; beschrieben wurde dies für interindividuelle Variabilitäten in Schrittmustern im Rahmen der Gang- / Laufgeschwindigkeitsbestimmung in Abschnitt 4.2.3. Dies motivierte zu untersuchen, ob sich interindividuelle Variabilitäten nutzen lassen, um den Träger anhand der Biosignale zu identifizieren. Ferner galt es zu prüfen, ob eine Identifikation auch unter körperlicher Belastung trotz der dadurch hervorgerufenen signifikanten Veränderungen in den Signalverläufen möglich ist. Für die Identifikation während des Gehens und Laufens sind dies Veränderungen der Schrittmuster in den Beschleunigungssignalen mit zunehmender Geschwindigkeit und bewegungsbedingte Artefakte im EKG.

Eine automatische Identifizierung des Trägers kann genutzt werden, um Messreihen mit der entsprechenden Probandennummer zu annotieren, personenspezifische Zusatzinformationen in der Signalverarbeitung verwenden zu können und die erhobenen Parameter zwecks Rückmeldung an den Nutzer (z.B. Alarmfunktion) personenspezifisch interpretieren zu können. Sinnvoll ist die Anwendung des vorgeschlagenen Verfahrens, wenn es sich bei der Identifikation um einen stets wiederkehrenden Prozess mit denselben Probanden handelt und ein Körpersensor von unterschiedlichen Probanden getragen wird (Kostengründe oder begrenzte Verfügbarkeit eines Prototyps). Ein Anwendungsszenario ist beispielsweise der Mannschaftssport.

Dieses Kapitel beschreibt die Personenidentifikation auf Grundlage des EKG- und Beschleunigungssensors und ist wie folgt aufgebaut: In Abschnitt 5.1 werden die Ziele und Anwendungen der Personenidentifikation benannt. Ein Überblick über den Stand der Technik gibt Abschnitt 5.2. Das Verfahren zur Identifikation bestehend aus Vorverarbeitung, Merkmalsextraktion und Klassifikation wird in Abschnitt 5.4 vorgestellt. Die Ergebnisse der Evaluation basierend auf Datenreihen aus Laufbandversuchen und dem Mannschaftssport sind in Abschnitt 5.5 beschrieben. Eine Zusammenfassung erfolgt in Abschnitt 5.6.

Die in diesem Abschnitt präsentierten Ergebnisse sind in [175] und [176] veröffentlicht.

### 5.1 Ziele und Anwendungen

Ziel ist es, eine Personenidentifikation mit einem nicht-klinischen Messsystem durchführen zu können, welches aus einem (praxistauglichen) Körpersensor besteht, der über einen Brustgurt selbst angelegt werden kann. Die Identifikation erfolgt durch Kombination von Charakteristika des Bewegungsablaufs (hier Schwerpunkt auf Schrittmustern) und der Physiologie des Probanden (hier EKG). Eine besondere Herausforderung stellt dabei die Durchführung einer zuverlässigen Identifikation ohne klinische Messinstrumente und während nicht stationärer Identifikationsbedingungen dar. In der vorliegenden Arbeit wurde der Körpersensor BG-V4.x genutzt, wobei die EKG-Erfassung mittels im Brustgurt integrierten Textilelektroden erfolgte. Dabei können Artefakte und Störungen durch ein Verrutschen der Elektroden oder einen hohen Übergangswiderstand entstehen. Weiterhin führen Veränderungen im Bewegungsablauf (Wechsel zwischen Gehen und Laufen, Anwendung im hochdynamischen

Handballsport) zu einer Variabilität der Signalverläufe. Beispiele sind Änderungen in den Schritt- und EKG-Mustern bei steigender Geschwindigkeit und Herzfrequenz sowie eine Zunahme der Leitfähigkeit der EKG-Elektroden aufgrund einer erhöhten Transpirationsrate.

Die Identifikation wurde mit dem Ziel einer automatisierten Annotation von Sensormesswerten, Parametern sowie einer Personalisierung von Einstellungen (Signalverarbeitung, Interpretation) entwickelt. Dabei war es nicht Ziel, die biometrische Güte im Hinblick auf Einmaligkeit und Konstanz eines klassischen Fingerabdruck-basierten Verfahrens zu erreichen. Angestrebt wurde eine Unterscheidung von etwa 20 Personen.

**Automatische Annotation** Nach einer initialen Aufzeichnung eines Probanden soll das Identifikationsverfahren es ermöglichen, in zukünftigen Aufzeichnungen automatisiert Sensormesswerte und ermittelte Parameter mit dessen Identität zu annotieren. Als Anwendung ist die wiederholte Aktivitätsaufzeichnung von Sportlergruppen angedacht, um die Entwicklung von physiologischen und biokinematischen Parametern über einen längeren Zeitraum verfolgen zu können. Im Rahmen der vorliegenden Arbeit stellt der Mannschaftssport Handball ein Anwendungsszenario dar. Die Forschung, die (Präventiv-) Medizin und die Rehabilitation stellen weitere Szenarien dar. Die automatische Identifikation soll eine manuelle wiederkehrende Zuordnung des Messsystems zu einem Probanden ersparen. In den hier durchgeführten Versuchen zeigte sich dieser Prozess als zeitaufwändig, im Handball waren mindestens 15 min nötig, obwohl die Mannschaft bereits mit dem Messsystem vertraut war.

Eine Identifikation mittels einer eindeutigen Seriennummer oder RFID bietet für dieses Szenario keine Alternative, da in diesem Fall die Hardware und nicht der Spieler identifiziert wird. Aufgrund der Identifikation der Person sind die Spieler nicht an einen auf sie registrierten Körpersensor gebunden. Eine freie Wahl des Körpersensors bei Aufzeichnungsbeginn kann dabei den Prozess des Anlegens in der Praxis beschleunigen und Fehler durch Verwechslung vorbeugen.

Die automatisierte Annotation ist zum einen relevant für die Interpretation der erhobenen Daten durch beispielsweise Trainer oder (Sport-) Mediziner. Zum anderen bestand im Rahmen der vorliegenden Arbeit die Motivation, Zusatzinformationen in Form von Identität und Schätzung der Momentangeschwindigkeit einem externen videobasierten Algorithmus zur Spielerverfolgung (Teil der SPA-Software [110; 163]) zur Verfügung zu stellen, um den Algorithmus zukünftig zu unterstützen. In diesem Zusammenhang bietet die Personenidentifikation die Möglichkeit, den Prozess der manuellen Identifikation der Mannschaftsspieler in den Videodaten zu automatisieren (siehe Abschnitt 6.2).

**Personalisierung von Einstellungen** Die Erkennungsleistung eines Klassifikationsalgorithmus kann durch eine Anpassung an den Nutzer weiter verbessert werden. Für die Bestimmung der Laufgeschwindigkeit konnte mit einem MLP, das speziell auf Grundlage der Daten eines einzelnen Probanden trainiert wurde, die Genauigkeit auf 99,1 % (+1,7 %) gesteigert werden (siehe Abschnitt 4.2.5.2). Das Laden einer personenspezifischen Netzkonfiguration, die keine interindividuellen Variabilitäten in den Schrittmustern abbilden muss, erlaubt eine optimale Anpassung der Neuronengewichte an die Charakteristika der Schrittmuster des jeweiligen Probanden. Darüber hinaus benötigen Algorithmen, die beispielsweise

auf einem Gangmodell basieren, personenspezifische Zusatzinformationen wie die Beinlänge oder den Hüftumfang (siehe Abschnitt 4.2.2).

Für zustandsorientierte Verfahren, bei denen die Zustandsübergänge von Schwellenwerten abhängen, kann eine Individualisierung der Grenzwerte ebenfalls wichtig sein. Ein Beispiel ist die Erkennung von Schritten, Sprüngen und der Oberkörperhaltung, die für eine bewegungsbasierte Spielsteuerung mittels des Körpersensors BG-V4.0 realisiert wurde [170; 37]. Die Voreinstellung beruht dabei auf generalisierten Schwellenwerten, ermittelt für ein Probandenkollektiv. Eine Personalisierung ermöglicht eine Optimierung dieser Werte, um beispielsweise eine Abstimmung auf das individuelle Sprungverhalten vorzunehmen.

Weiterhin sind Informationen über die Identität des Trägers des Messsystems wichtig, um die ermittelten Parameter wie beispielsweise die Herzfrequenz interpretieren zu können. Für die Bewertung eines Herzfrequenzwertes müssen die individuellen Grenzwerte des Trägers bekannt sein, um im Rahmen einer Trainingssteuerung eine direkte Rückmeldung geben zu können. Parameter können außerdem in ihrer Berechnung von Zusatzinformationen abhängen. Ein Beispiel ist die Schätzung des Energieumsatzes, die sich anhand der Herzfrequenz in Verbindung mit den Zusatzinformationen Körpergewicht, Geschlecht und Alter annähern lässt (siehe Abschnitt 6.1).

## 5.2 Stand der Forschung

Die Identität einer Person ist für eine Vielzahl von Anwendungen relevant wie beispielsweise Überwachungssysteme, Zugangskontrollen an Türen oder elektronischen Geräten (z.B. Computer oder Smartphones). Für die Durchführung der Personenidentifikation sind in der Literatur eine Reihe an Biometrien beschrieben, besonders verbreitet ist die Nutzung von Charakteristika des Fingerabdrucks, der Iris und der Retina des Auges, dem Gesicht oder der Stimme [22; 33; 117; 142]. Darüber hinaus existieren Verfahren, die Informationen aus dem Gang und dem EKG einer Person für eine Identifizierung nutzen. Die folgende Darstellung konzentriert sich auf letztere Verfahren.

### 5.2.1 Gangbasierte Verfahren

Der Gang variiert zwischen Menschen [20], wobei unterschiedliche Bewegungsabläufe zu einem personenspezifischen Gangbild führen. Das Gangbild einer Person ist relativ konstant, eine absichtliche Imitation des Gangbilds einer anderen Person ist schwierig [103]. Dies macht eine Nutzung von Charakteristika des Gangs für eine Personenidentifikation interessant. Typischerweise werden dazu videobasierte Verfahren eingesetzt, eine Zusammenfassung gibt [52]. Eine Identifikation ist jedoch auch mithilfe von Beschleunigungssensoren möglich, im Folgenden wird dazu ein Überblick gegeben.

H. J. Ailisto u.a. (2005) beschreiben ein auf der Messung von Ähnlichkeiten zwischen Schrittsegmenten basierendes Identifikationsverfahren zur Sicherung von portablen Geräten wie Smartphones oder Personal-Digital-Assistants (PDAs) [5]. Die Datenverarbeitung besteht aus einer Segmentierung der Beschleunigungssignale in Schritte mit einer anschließenden Normalisierung der einzelnen Schrittsegmente (Zeit und ST-Wert). Das unbekannte Schrittsegment wird anschließend an einem Referenzsegment des jeweiligen Probanden ausgerichtet. Ein Proband gilt als erkannt, falls der Koeffizient der durchgeführten Kreuzkorrelation einen

vorgegebenen Schwellenwert der Übereinstimmung überschreitet. Die Evaluation erfolgte anhand von 36 Probanden, die an zwei Aufzeichnungstagen eine Teststrecke von jeweils 20 m abgingen und dabei ein Aufzeichnungsgerät am unteren Rücken (Hüfthöhe) trugen. Daten der ersten Aufzeichnung wurden für die Generierung der Referenzsegmente verwendet und die zweite Aufzeichnung für die Validierung des Verfahrens. Die ermittelte Gleichfehlerrate ERR<sup>1</sup> beträgt 6,4 %.

J. Mäntyjärvi u.a. (2005) erhoben zusätzliche Daten mit den 36 Probanden für langsames, normales und schnelles Gehen [103]. Die Arbeit vergleicht die Identifikationsleistung basierend auf drei unterschiedlichen Methoden: einem korrelationsbasiertem Vergleich des unbekanntes Schrittsegments mit abgespeicherten Referenzschrittmustern, einer Analyse im Frequenzbereich und einem Vergleich basierend auf Statistiken, die aus Histogrammen der Beschleunigungssignale berechnet wurden. Die niedrigste Gleichfehlerrate von 7 % wird mit den abgespeicherten Referenzsegmenten erzielt. Für die frequenzbasierte Identifikation beträgt die Gleichfehlerrate 10 % und für die Histogramme 18 % bis 19 %.

D. Gafurov u.a. (2006) identifizieren Probanden während des Gehens aus Beschleunigungsmessungen, aufgezeichnet am rechten Unterschenkel oberhalb des Sprunggelenks [52]. Dazu werden zwei verschiedene Verfahren vorgestellt. Das erste basiert auf Ähnlichkeiten in Histogrammen, wobei nach einer Normalisierung die absolute Distanz zwischen den Histogrammen der Trainings- und Testdaten gebildet und verglichen wird. Das zweite Verfahren gruppiert Schrittsegmente anhand ihrer Zeitdauer und es wird gruppenbasiert ein Ähnlichkeitsmaß zwischen den Schrittsegmenten berechnet. Die Evaluation erfolgte mit 21 Probanden, die mit normaler Geschwindigkeit eine Teststrecke von 70 m abgingen. Die erzielte Gleichfehlerrate beträgt 5 % und 9 %.

L. Rong u.a. (2007) nutzen für die Identifikation ebenfalls Beschleunigungssignale, die am unteren Rücken (Hüfthöhe) aufgezeichnet werden [134]. Zunächst erfolgt eine Segmentierung der Beschleunigungssignale in Schritte. Anschließend werden Referenzschrittsegmente aus den Trainingsdaten mit Schrittsegmenten aus den Testdaten verglichen. Für den Vergleich wird eine nicht-lineare zeitliche Normalisierung (*Dynamic-Time-Warping*<sup>2</sup>) der beiden Schrittsegmente durchgeführt, um Unterschiede in den Schrittmustern durch Geschwindigkeitsänderungen zu kompensieren. Die eigentliche Identifizierung erfolgt mit einem 1-nächste-Nachbarn-Klassifikator. Zusätzlich wurde ein Ansatz basierend auf der Analyse der Schrittsegmente in der Frequenzdomäne (FFT) geprüft. Die Evaluation wurde mit 21 Probanden durchgeführt, die mit selbstgewählter Geschwindigkeit jeweils fünfmal eine Teststrecke innerhalb eines Testzeitraums von drei Wochen abgingen. Es wurde jeweils nur eine Datenreihe zum Training verwendet und auf den übrigen Daten getestet. Die Gleichfehlerrate beträgt 5,6 % und 21,1 %.

---

<sup>1</sup>Die Gleichfehlerrate (engl. *Equal-Error-Rate*, ERR auch *Cross-Over-Rate*) ist ein Gütemaß zur Bewertung von biometrischen Systemen und beschreibt die Fehlerrate, bei der die Falschakzeptanzrate und die Falschrückweisungsrate gleich sind; ein niedrigeres EER bedeutet eine höhere Güte des Systems [54, S.32ff].

<sup>2</sup>Dynamic-Time-Warping ist ein Verfahren zur zeitlichen Abbildung zweier Sequenzen aufeinander. Für weitere Informationen siehe [113].

### 5.2.2 EKG-basierte Verfahren

Das Elektrokardiogramm (EKG) ist ein wichtiges Verfahren in der kardiologischen Diagnostik. Moderne EKG-Messgeräte bieten dazu neben der Darstellung des EKGs eine automatische Vermessung und Interpretation der EKG-Signale. L. Biel u.a. (2001) zeigen, wie die Ausgaben der automatischen Vermessung (z.B. Dauer und Signalamplituden von P-, QRS- und T-Wellen) als Merkmale für eine Personenidentifikation genutzt werden können [22]. Dazu wurden 12-Kanal EKGs von 20 Probanden in Ruhe mit dem EKG-Messgerät Megacart der Firma Siemens aufgezeichnet. Die Aufnahme wurde nach Ab- und erneutem Anlegen der EKG-Elektroden für jeden Probanden vier bis zehnmal (hintereinander) wiederholt, um Einflüsse in der Platzierung der Elektroden zu minimieren. Die Identifikation basiert auf 30 Merkmalen, die automatisch von dem Megacart pro EKG-Kanal für eine klinische Diagnose ermittelt werden. Für die Klassifikation findet ein statistisches Verfahren, das *Soft Independent Modelling by Class Analogy* (SIMCA), Einsatz. Zunächst erfolgt dazu eine Bestimmung der linear unabhängigen Komponenten der Trainingsdaten mittels einer Hauptkomponentenanalyse (engl. *Principal Component Analysis*, PCA). Basierend auf den ermittelten Hauptkomponenten wird anschließend ein Klassifikationsmodell erstellt. Das Verfahren klassifiziert 49 der 50 Testbeispiele korrekt. Weiterhin wurde der Einfluss der 12 EKG-Kanäle analysiert und gezeigt, dass eine Identifikation auch mit Einkanal-EKGs möglich ist. Der Klassifikationsfehler erhöht sich dadurch nicht.

T. W. Shen u.a. (2002) verwenden für die Identifikation ebenfalls Einkanal-EKGs aus der MIT-BIH Datenbank [142]. Zur Identifikation werden für jeden Probanden 20 Referenz-Herzschlagsegmente abgespeichert, mit denen anschließend unbekannte Herzschlagsegmente über Kreuzkorrelation verglichen werden. Basierend auf einer Datenreihe mit 20 Probanden lässt sich auf diese Weise eine Genauigkeit von 95 % erreichen. Wird zusätzlich ein KNN eingesetzt, lassen sich alle Personen in den Testdaten anhand der Korrelationskoeffizienten korrekt identifizieren.

Die Ergebnisse zeigen, dass eine Personenidentifikation bereits mit Einkanal-EKGs möglich ist, dazu wurden in den beschriebenen Arbeiten jedoch klinische EKGs eingesetzt. Für die hier durchgeführte Personenidentifikation sind insbesondere die Ergebnisse von A. D. C. Chan u.a. (2008) relevant [33]. Zur Identifikation zeichneten sie EKGs mit Silber-Silberchlorid-Knopfelektroden zwischen Daumen und Zeigefinger der linken und der rechten Hand auf. Die erfassten EKGs von 50 Probanden stammen aus drei unabhängigen Aufzeichnungen von jeweils 90 s Länge. Für die Identifikation erfolgt zunächst eine Segmentierung der EKGs in Herzschläge. Anschließend werden durch Mittelung von Herzschlagsegmenten ein Referenzsegment für jeden Probanden generiert (erste Datenreihe). Für die Identifikation untersuchten sie drei verschiedene quantitative Maße: den prozentualen Unterschied zum Residuum, den Korrelationskoeffizienten und ein neu vorgestelltes Distanzmaß, basierend auf einer Wavelet-Analyse. Für die Evaluation wurden die EKGs der zwei weiteren Datenreihen ebenfalls segmentiert und über die drei Distanzmaße mit den Referenzsegmenten verglichen. Mit 89 % erreicht das, auf einer Wavelet-Analyse basierende Distanzmaß, die höchste Identifikationsgenauigkeit (80 % für Korrelationskoeffizienten und 70 % für Residuum).

### 5.2.3 Abgrenzung vom Stand der Forschung

Im Folgenden wird beschrieben, wie sich das im Rahmen der Dissertation realisierte Verfahren von der Literatur abgrenzt.

**Datenaufzeichnung** Die Personenidentifikation erfolgt auf Grundlage des nichtklinischen Einkanal-EKGs des BG-V4.x. Eingesetzt werden für die Aufzeichnung zwei handelsübliche Textilelektroden (Polar WearLink-Brustgurt), deren Leitfähigkeit mit der Transpirationsrate variiert. Im Gegensatz zu den vorgestellten Arbeiten wird das EKG auch unter körperlicher Belastung aufgezeichnet, was zu einem Verrutschen der Textilelektroden, einer Änderung des Übergangswiderstandes und dadurch zu einer Überlagerung des EKGs mit Bewegungsartefakten und Störungen führen kann. Weiterhin hängt der Signalverlauf des EKGs von der Platzierung der Elektroden ab (standardisierte Ableitungspunkte für klinische EKGs). Durch die Nutzung eines Brustgurts kann es zu Veränderungen im Signalverlauf bei einem erneuten Anlegen des Messsystems kommen. Auch die Erfassung der Schrittmuster ist empfindlich gegenüber der Anbringung des Gurtes (Artefakte bei zu lockerem Sitz) und der Orientierung des Beschleunigungssensors. Diese Störungen werden durch den realisierten Anlegeassistenten adressiert, der ein korrektes selbständiges Anlegen des Körpersensors mittels eines handelsüblichen Brustgurts ermöglicht.

**Identifikationsbedingung** Die vorgestellten Identifikationsverfahren der Literatur beschränken sich auf normale Ganggeschwindigkeiten und wurden teils nur für kurze Teststrecken von 20 m bis 70 m in der Ebene durchgeführt (mit Wiederholungen). J. Mäntyjärvi u.a. untersuchten zusätzlich Variationen in der Ganggeschwindigkeit zwischen langsamen, normalen und schnellen Gehen [103]. Das hier vorgestellte Verfahren ermöglicht jedoch eine Identifikation von langsamem Gehen bei 3 km/h bis hin zum Laufen mit 11 km/h (hohe Variabilität der Schrittmuster mit der Geschwindigkeit). Durch die unterschiedlichen körperlichen Belastungsstufen schwankt die Herzfrequenz der Probanden, was Einfluss auf die Charakteristika im EKG hat. Weiterhin wird als Ausblick gezeigt, dass die extrahierten Charakteristika der Probanden auch eine Identifikation im hochdynamischen Handballsport ermöglichen.

**Identifikationsverfahren** Die in der Literatur beschriebenen Identifikationsverfahren beruhen stets auf einer Informationsquelle, entweder den Charakteristika des Gangs oder des EKGs. In dieser Arbeit werden jedoch beide Informationsquellen für die Identifikation kombiniert. Es wird gezeigt, dass trotz der Artefakte im Signalverlauf und der erschwerten Identifikationsbedingung hierdurch eine sichere Identifikation ermöglicht wird. Das realisierte Verfahren benötigt keine Segmentierung der Beschleunigungssignale in einzelne Schritte, sodass es potentiell auch auf weitere körperliche oder sportliche Aktivitäten anwendbar ist.

## 5.3 Personenspezifische Charakteristika

Der folgende Abschnitt beschreibt personenspezifische Charakteristika in den Beschleunigungs- und EKG-Signalen.

### 5.3.1 Charakteristika im Gang

Bereits in den frühen Arbeiten von M. P. Murray u.a. (1964) [114] und A. Pedotti (1977) [124] wird auf Unterschiede in der Gangart von Menschen hingewiesen. Ein Vergleich von EMG-Signalverläufen, der Länge von elf Muskeln und von Drehmomenten an den Gelenken der Beine zwischen Probanden führte Pedotti zu der Schlussfolgerung, dass der menschliche Gang nicht als stereotyp angesehen werden kann [124]. Mit einer auf Fotoaufnahmen basierenden Methode untersuchten M. P. Murray u.a. den Gang von 60 Männern unter Berücksichtigung von Alter, Gewicht und Körpergröße. Hohe Übereinstimmungen zeigten die zeitliche Dauer von aufeinanderfolgenden Stand-, Schwung- und Doppelstützphasen sowie von Schrittlängen und -breiten innerhalb einer Aufzeichnung eines Probanden und der Wiederholung der Aufzeichnung. Bei den sieben analysierten Bewegungsmustern der 60 Probanden zeigten die Becken- und die Oberkörperrotationen eine hohe Variabilität zwischen den Probanden [114]. M. P. Murray u.a. schlussfolgerten, dass die Becken- und Oberkörperrotationen daher nicht zwingend Bestandteile des normalen Ganges sind. In der Literatur sind weitere individuelle Charakteristika der menschlichen Fortbewegung beschrieben wie beispielsweise die Rotation des Sprunggelenks<sup>3</sup>. Für einen weiterführenden Überblick wird an dieser Stelle auf [117, Kap.2] verwiesen.

L. Bianchi u.a. (1998) führten in ihrer Veröffentlichung an, dass bei der Beschreibung von Bewegungsabläufen des Menschen interindividuelle Variabilitäten teils vernachlässigt werden, weil sich häufig auf die Beschreibung von durchschnittlichen Werten von Eigenschaften der Probanden konzentriert wird [20]. Dabei wird die Annahme zugrunde gelegt, es handle sich um eine rein stochastische Variabilität zwischen den Probanden anstelle von unterschiedlichen Bewegungsstrategien. L. Bianchi u.a. sehen Gründe für die Variabilität in der Fortbewegung bei Menschen jedoch vor allem in unterschiedlichen kinematischen Strategien, da sich die Variabilität nicht alleine auf Grundlage von biomechanischen Charakteristika erklären lässt. Die Autoren verweisen auf Arbeiten, die die Annahme bestätigen, dass die menschliche Fortbewegung nach dem Prinzip der Energieminimierung ausgeführt wird. Menschen unterscheiden sich jedoch in der Fähigkeit der Energieübertragung zwischen Körpersegmenten [20].

**Charakteristika abhängig von der Geschwindigkeit** Ein Beschleunigungssensor im Brustbereich bietet nicht die Möglichkeit, die in der Literatur beschriebene interindividuelle Variabilität in dem Maße differenziert erfassen zu können, wie dies mit einer (manuellen) Datenauswertung von Video-, EMG- oder mehreren Inertialsensoren möglich ist. Zusätzlich wird die mit dem Beschleunigungssensor erfasste interindividuelle Variabilität durch nicht stationäre Identifikationsbedingungen mit variablen Gang- und Laufgeschwindigkeiten (3 km/h bis 11 km/h) beeinflusst. Die Schrittmuster im vertikalen Beschleunigungssignal ändern sich daher zusätzlich kontinuierlich als Anpassungsergebnis des Ganges, um eine Zielgeschwindigkeit zu erreichen; dies wurde im Rahmen der Laufgeschwindigkeitsbestimmung betrachtet (siehe Abschnitt 4.2.3).

In der Abbildung 5.1 sind 100 Schrittsegmente der ersten vier Probanden des Versuchs  $V_{1,1}$

<sup>3</sup>Das Sprunggelenk ist ein Scharniergelenk, wodurch ein Senken und Heben des Fußes ermöglicht wird. Zusätzlich ist eine Rotationsbewegung in geringem Umfang möglich.

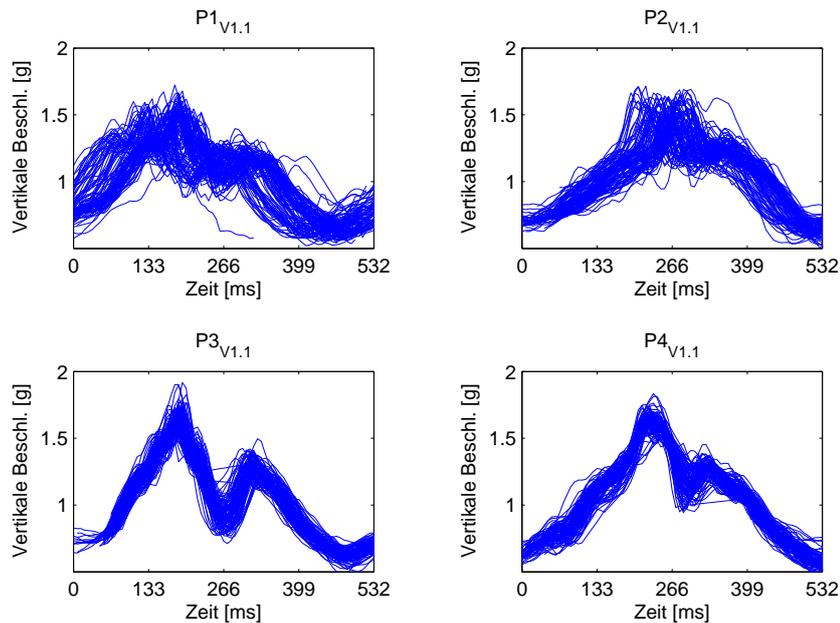
überlagert dargestellt. Dazu erfolgte eine Segmentierung des vertikalen Beschleunigungssignals in Schritte. Die Schrittmuster wurden anschließend überlagert und mittels Kreuzkorrelation aneinander ausgerichtet<sup>4</sup>. Insbesondere für die Verhältnisse aus Flankensteilheit und Spitzenbeschleunigung des Fersen-Auftreffens und Zehen-Abstoßens konnten probandenspezifische Muster beobachtet werden. Während des Laufens bei 9 km/h erreichte die Spitzenbeschleunigung des Fersen-Auftreffens von vier Probanden einen hohen Wert von etwa 4 g oberhalb der Grundlinie des Schrittmusters verbunden mit einer hohen Flankensteilheit. Bei neun anderen Probanden war die Spitzenbeschleunigung des Fersen-Auftreffens jedoch weniger dominant im Signalverlauf ausgeprägt (siehe  $P2_{V1.1}$  und  $P4_{V1.1}$ ).

Zusätzlich konnte eine Veränderung des für einen Probanden charakteristischen Signalverlaufs der Schrittmuster mit der Geschwindigkeit beobachtet werden. Beispielsweise ist bei  $P1_{V1.1}$  das Fersen-Auftreffen im Signalverlauf für Laufen bei 9 km/h gegenüber dem Zehen-Abstoßen signifikant als Spitze ausgebildet, während des Gehens ist dies jedoch nicht zu beobachten. Um die personenspezifischen Charakteristika der Schrittmuster für eine Identifikation nutzen zu können, ist es daher wichtig, dass die Trainingsdatenreihe Schrittsegmente verschiedener Geschwindigkeiten umfasst.

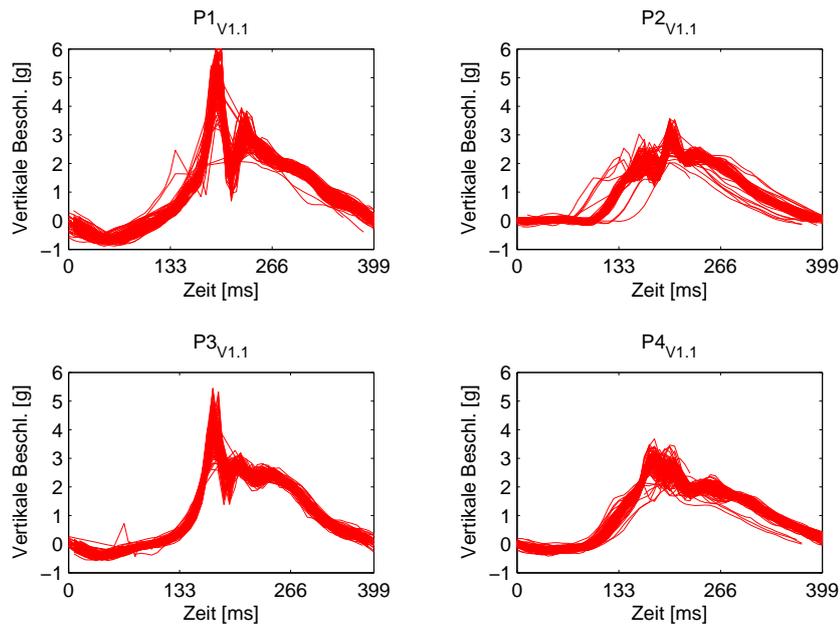
Im Allgemeinen zeigten die Schrittmuster für die einzelnen Geschwindigkeitsstufen eine zeitliche Konsistenz. So ist die intraindividuelle Variabilität zwischen den Schrittmustern von etwa der Hälfte der Probanden des Laufbandversuchs V1.1 während des Gehens bei 5 km/h als niedrig, ähnlich der dargestellten Schrittmuster von  $P1_{V1.1}$  und  $P2_{V1.1}$ , einzustufen. Während des Laufens bei 9 km/h ließen sich für alle 22 Probanden nur eine sehr geringfügige intraindividuelle Variabilität beobachten; die zeitliche Konsistenz entsprach den hier dargestellten 100 Schrittmustern der vier Probanden. Im Rahmen der Evaluation wurde die zeitliche Konsistenz auf Grundlage von zwei Datenreihen mit unterschiedlichen Aufzeichnungsdaten (V1.2) geprüft.

---

<sup>4</sup>Verschiebung der Segmente entsprechend der ermittelten höchsten Korrelation.



(a) 5 km/h Ganggeschwindigkeit.



(b) 9 km/h Laufgeschwindigkeit.

Abbildung 5.1.: Überlagerung von 100 aufeinanderfolgenden Schrittsegmenten der Probanden  $P1$  bis  $P4$  aus  $V_{1.1}$ . Insbesondere die Signalverläufe des Fersen-Auftreffens und des Zehen-Abstoßens (zwei aufeinanderfolgende Maxima) zeigen ein probandenspezifisches Muster, welches jedoch zusätzlich von der Geschwindigkeit abhängig ist.

### 5.3.2 Charakteristika im EKG

Ein EKG dient der Erfassung der elektrischen Erregungsausbreitung und -rückbildung des Herzmuskels und ist ein wichtiges Instrument der kardiologischen Diagnostik. EKGs zeigen jedoch eine hohe interindividuelle Variabilität, die teils Schwierigkeiten bei der Erkennung von Pathologien bereitet, jedoch für die Identifikation einer Person genutzt werden kann [33]. Die Variabilität ist unter anderem abhängig von der Position, der Größe und der Anatomie des Herzens, dem Alter, dem Geschlecht, dem relativen Körpergewicht oder dem Thoraxaufbau [55; 143]. Personenspezifische Unterschiede sind in dem QRS-Komplex sowie der P- und T-Welle zu finden (siehe Einteilung des EKGs, Abschnitt 2.2.1.1). Zur Veranschaulichung sind dazu in der Abbildung 5.2 die Herzschlagsegmente von sechs verschiedenen Probanden überlagert dargestellt. Die Aufzeichnung der zugrunde liegenden EKGs erfolgte mit dem Körpersensor BG-V4.1 während des langsamen Gehens in Versuch V1.1. Der Gleichanteil der AD-Wandlung wurde aus den Herzschlagsegmenten entfernt. Die Segmente wurden normalisiert und entsprechend ihrer höchsten Übereinstimmung (Kreuzkorrelation) aneinander ausgerichtet.

Die Untersuchungen von A. D. C. Chan u.a. zeigen, dass die Informationen des QRS-Komplexes den höchsten Grad an Reproduzierbarkeit über verschiedene Aufzeichnungen hinweg bieten [33]. Die Studie beschreibt weiterhin eine höhere Identifikationsleistung für Herzschlagsegmente, die an der P- anstelle der T-Welle ausgerichtet werden.

**Besonderheit körperliche Belastung** Während sich personenspezifische Charakteristika mit klinischen EKG-Messgeräten unter Ruhe sicher erfassen lassen, ist ein genaues Vermessen des EKGs, wie es in [22] erfolgte, während körperlicher Belastung mit einem nicht-klinischen EKG nur bedingt möglich. Das Einkanal-EKG des Körpersensors wird über Textilelektroden erfasst, die anders als klinische Klebe- oder Saugelektroden verrutschen können und deren Leitfähigkeit stark abhängig von der Transpirationsrate ist. Weiterhin ändert sich der EKG-Signalverlauf während körperlicher Belastung. Die PQ- und die ST-Intervalle verkürzen sich zeitlich mit erhöhter Herzfrequenz [144; 164]. Die Amplituden der P- und T-Welle verringern sich während einer körperlichen Belastung. In der ersten Minute nach einer Belastung nehmen P- und T-Welle deutlich zu. Anschließend ändert sich der Signalverlauf nach und nach bis zur Ausgangsform in Ruhe [144; 164]. Im Vergleich zu dem übrigen Signalverlauf wird der QRS-Komplex im Allgemeinen in der Literatur als relativ stabil hinsichtlich morphologischer Änderungen während einer Belastung beschrieben; M. Simoons und P. Hugenholtz bezeichnen die Variabilität als nicht signifikant [144]. Aufgezeigt sind unter anderem eine geringfügige zeitliche Verkürzung des QS-Intervalls [161, Kap.5] und Änderungen der Amplituden der R- und S-Zacke [164]. Die Variabilität innerhalb des ST-Intervalls werden dahingegen als sehr hoch („*dramatically*“) beschrieben [164].

Für die Identifikation, basierend auf dem Einkanal-EKG des Körpersensors, ist vor allem der QRS-Komplex relevant. Insbesondere für EKG-Segmente, die mit Bewegungsartefakten und Störungen überlagert sind (siehe auch Abbildung 5.4), weist der Signalverlauf dort die höchste Stabilität auf. Die P-Welle konnte in EKG-Aufzeichnungen mit dem BG-V4.1 bei nur wenigen Probanden in Ruhe beobachtet werden und war im Allgemeinen unter Belastung mit Bewegungsartefakten überlagert. Die zeitliche Veränderung des ST-Intervalls und die

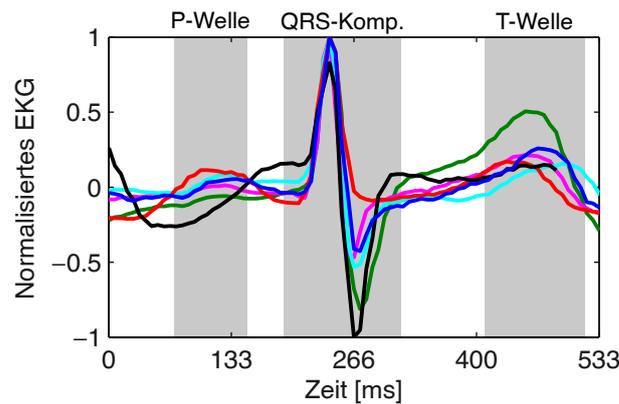


Abbildung 5.2.: Überlagerte Darstellung von Herzschlagsegmenten von sechs Probanden (unterschiedliche Färbung). Die Segmente wurden mit Hilfe einer Kreuzkorrelation entsprechend der größten Übereinstimmung aneinander ausgerichtet. Interindividuelle Variabilitäten sind in dem QRS-Komplex, der P- und T-Welle sichtbar.

Amplitudenänderung der T-Welle traten aufgrund der variierenden körperlichen Belastung in den EKG-Aufzeichnungen auf. Dieser Bereich des EKG-Signalverlaufs bietet daher für die Identifikation nur relevante Informationen, wenn die Herzfrequenz ebenfalls berücksichtigt wird. Die Trainingsdatenreihe umfasst daher EKGs unterschiedlicher Belastungsstufen. Weiterhin besteht das Problem, dass eine Erfassung der beschriebenen Charakteristika von der Leitfähigkeit der Textilelektroden abhängt, die maßgeblich von der Transpirationsrate des Probanden bestimmt wird. Die technische Vorgehensweise, um den Einfluss der resultierenden Variabilität im Signalverlauf zu reduzieren, wird im Abschnitt 5.4.1 (Signalvorverarbeitung) beschrieben.

## 5.4 Verfahrensbeschreibung Personenidentifikation

In dem vorhergehenden Abschnitt 5.3 sind personenspezifische Charakteristika in den EKG- und Beschleunigungssignalen beschrieben und welche Auswirkungen eine variierende körperliche Belastung auf diese Charakteristika in den Signalverläufen hat. Der folgende Abschnitt beschreibt das Identifikationsverfahren, welches Signalcharakteristika aus beiden Informationsquellen kombiniert. Es erfolgt in drei sequentiellen Verarbeitungsschritten: der Vorverarbeitung der Signale (Unterabschnitt 5.4.1), der Merkmalsberechnung (Unterabschnitt 5.4.2) und der Identifikation mittels eines Klassifikationsverfahrens (Unterabschnitt 5.4.3).

### 5.4.1 Vorverarbeitung EKG- und Beschleunigungssignale

Die Vorverarbeitung der EKG- und Beschleunigungssignale stellt sicher, dass hardwareseitige Signalcharakteristika entfernt werden. Weiterhin erfolgt eine Reduzierung von Störgrößen in der EKG-Aufzeichnung.

**EKG** Ein hardwareseitiges Charakteristikum in dem EKG-Signal ist ein für jeden Körpersensor unterschiedlicher Nulllinienoffset (Gleichanteil). Beispielsweise beträgt dieser für das EKG von Proband *P1* aus *V1.1* etwa 1540 und für *P2* 1150 (siehe Abbildungen 5.3a und 5.3b). Der Gleichanteil ist abhängig von Fertigungsschwankungen der Bauteile des Instrumentenverstärkers und des Analog-Digital-Wandlers (engl. *Analog-Digital-Converter*, ADC) des Körpersensors sowie von den EKG-Elektroden. Der Gleichanteil muss daher aus dem EKG entfernt werden, um zu gewährleisten, dass die Identifikation nur auf personenspezifischen Charakteristika basiert. Diese Fertigungsschwankungen können weiterhin zu Abweichungen im Verstärkungsverhalten führen (z.B. Nichtlinearitäten und Abweichungen des ST-Werts). Zusätzlich zu diesen technischen Einflussfaktoren ändert sich der Übergangswiderstand zwischen Haut und EKG-Elektroden fortlaufend mit dem Anpressdruck und der Transpirationsrate. Der Anpressdruck ist dabei von der Positionierung beim Anlegen des Messsystems und der Atembewegung abhängig. Die Leitfähigkeit der Textilelektroden verändert sich mit der Transpirationsrate und führt zu einer signifikanten Variabilität des ST-Werts des EKGs.

Für eine Reduzierung des Gleichanteils im EKG wird ein Hochpassfilter (Butterworth) vierter Ordnung mit einer Grenzfrequenz von  $f_c = 0,67$  Hz angewandt, der die isoelektrischen Bereiche des EKGs gleich null setzt. Die Ermittlung der Filtereinstellungen erfolgte empirisch auf Grundlage der Datenreihe *V1.1*. Die Schwankungen des ST-Werts werden mittels einer Normalisierung des EKGs auf den Bereich  $\pm 1$  ausgeglichen. In den Abbildungen 5.3a und 5.3b sind die Ergebnisse der Vorverarbeitung für ein Zeitfenster von zwei Sekunden Länge dargestellt.

Aufgrund der körperlichen Betätigung kann das EKG weitere Störungen enthalten, die die Identifikationsleistung negativ beeinflussen können: Grundlinienschwankungen durch die Atmungsaktivität, Bewegungsartefakte durch ein Verrutschen der Textilelektroden, elektrische Potentiale der Skelettmuskulatur oder Signalrauschen (z.B. Netzbrummen), siehe auch Abschnitt 2.2.1. Die Grundlinienschwankungen werden durch den Hochpassfilter und das Signalrauschen mittels eines Tiefpassfilters (Butterworth) vierter Ordnung mit einer Grenzfrequenz von  $f_c = 40$  Hz reduziert. Bewegungsartefakte können nach der Vorverarbeitung weiterhin im EKG enthalten sein; auf ein schmaleres Frequenzband bei der Filterung wurde verzichtet, um Details des EKGs zu erhalten.

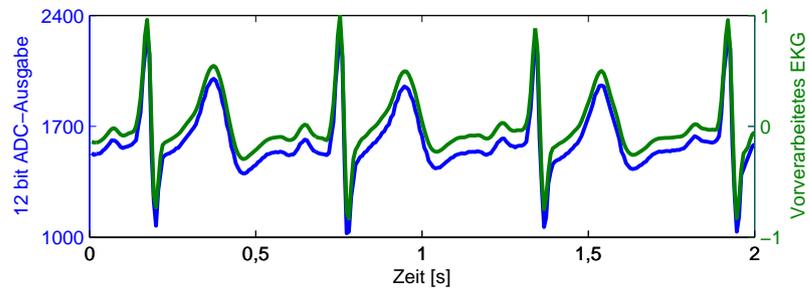
**Beschleunigungssignale** Die Frequenzanalyse des Beschleunigungssignals wird auf Grundlage des Betrags des Beschleunigungsvektors  $|\vec{a}| = (a_{AP}, a_{ML}, a_V)$  durchgeführt (siehe Gleichung 5.1), da dieser Beschleunigungsinformationen aller drei Achsen zusammenfasst und so eine eindimensionale Fourieranalyse ermöglicht.

$$|\vec{a}| = \sqrt{a_{AP}^2 + a_{ML}^2 + a_V^2} \quad (5.1)$$

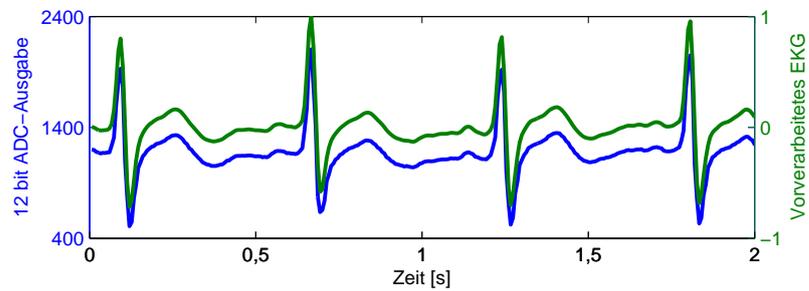
Neben den relevanten dynamischen Beschleunigungsanteilen enthält  $|\vec{a}|$  die statische Erdbeschleunigung (Normfallbeschleunigung  $1\text{ g} \approx 9,81\text{ m} \cdot \text{s}^{-2}$ ), die für die Frequenzanalyse keine relevanten Informationen beinhaltet. Um den Einfluss von diesem Gleichanteil zu reduzieren, wird ein Hochpassfilter (Butterworth) vierter Ordnung mit einer Grenzfrequenz von  $f_c = 0,1$  Hz angewandt. Die Bestimmung der Grenzfrequenz erfolgte ebenfalls empirisch

auf Grundlage der Datenreihe V1.1 unter Berücksichtigung der unterschiedlichen Gang- und Laufgeschwindigkeiten. Das Ergebnis der Filterung ist in Abbildung 5.3c exemplarisch für das Laufen dargestellt.

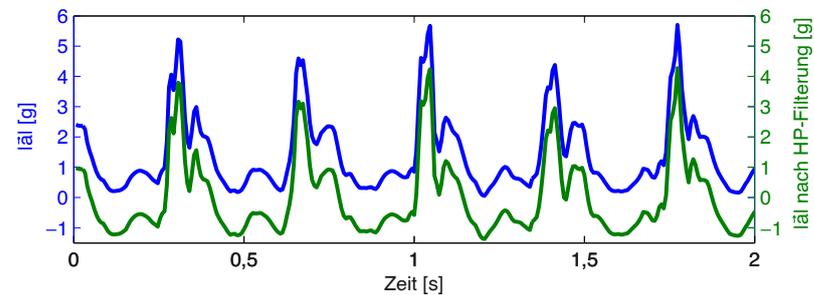
Die Hochpassfilterung erfolgt nicht für die Merkmalsberechnung in der Zeitdomäne, da der Gleichanteil in den drei Beschleunigungssignalen Informationen der Oberkörperhaltung enthält und in Form des Merkmals Mittelwert mit in die Identifikation einfließt. Solange die Identifikation auf gleicher geographischer Breite und Höhe durchgeführt wird, ist die Erdbeschleunigung für alle Personen gleich. Im Vergleich zu der intraindividuellen Variabilität in den Beschleunigungssignalen ist die Änderung der statischen Erdbeschleunigung aufgrund eines Ortswechsels weiterhin für die Identifikation als nicht signifikant einzustufen.



(a) ADC-Ausgabe und vorverarbeitetes EKG von Proband  $P1_{V1.1}$ .



(b) ADC-Ausgabe und vorverarbeitetes EKG von Proband  $P2_{V1.1}$ .



(c) Länge des Beschleunigungsvektors  $|\vec{a}|$  und das Ergebnis der Reduzierung des Gleichanteils mittels Hochpassfilter ( $f_c = 0,1$  Hz).

Abbildung 5.3.: a), b) Darstellung der 12 b ADC-Ausgabe der EKG-Erfassung und des vorverarbeiteten EKGs. Die Vorverarbeitung normalisiert das EKG innerhalb des Zeitfensters und entfernt den Gleichanteil. c) Reduzierung des Gleichanteils (statische Beschleunigungen und Zero-g-Level Offset) im Beschleunigungssignal für die Frequenzanalyse.

## 5.4.2 Merkmalsextraktion

An die Vorverarbeitung der EKG- und Beschleunigungssignale schließt sich die Merkmalsextraktion an, deren Ziel es ist, die personenspezifischen Charakteristika in Form eines Merkmalsraums für die Identifikation verfügbar zu machen.

### 5.4.2.1 Erfassung der Charakteristika im EKG

Die im Abschnitt 5.3.2 beschriebenen Charakteristika im EKG werden mittels eines Vergleichs auf Ähnlichkeiten zwischen unbekanntem Herzschlagsegmenten und abgespeicherten Referenzsegmenten sowie mit einer Frequenzanalyse bereitgestellt.

**Vergleich mit Referenzherzschlagsegmenten** Der Vergleich auf Ähnlichkeiten erfolgte in der Zeitdomäne und fand bereits in [33; 142] Anwendung zur Identifikation (siehe Stand der Forschung). Zu berücksichtigen ist, dass durch das nichtklinische EKG und das Identifikationsszenario mit variierender körperlicher Belastung der Ähnlichkeitsvergleich erschwert wird; Gründe dafür sind Bewegungsartefakte und Änderungen des ST-Werts des EKGs, eine teils nicht erkennbare P-Welle sowie eine hohe Variabilität im ST-Intervall und der Amplitude der T-Welle<sup>5</sup>. In der Abbildung 5.4 sind exemplarisch 20 Herzschläge von sechs Probanden überlagert eingezeichnet. Die Herzschlagsegmente stammen aus V1.1 und sind in gleichmäßigen Zeitabständen aus der gesamten Datenreihe des jeweiligen Probanden entnommen. Für die linke Spalte der Abbildung 5.4 wurden drei Probanden mit ungestörten EKGs gewählt. In der rechten Spalte sind EKGs mit Bewegungsartefakten gegenübergestellt. Zu erkennen sind zeitliche Unterschiede im ST-Intervall ( $P_{4_{V1.1}}$ ,  $P_{8_{V1.1}}$  und  $P_{18_{V1.1}}$ ) und der Amplitude der T-Welle ( $P_{4_{V1.1}}$  und  $P_{18_{V1.1}}$ ) bedingt durch die Herzfrequenzänderungen aufgrund der unterschiedlichen Belastungsstufen (Gehen und Laufen). Im Allgemeinen ist eine sichere Ausrichtung der Herzschlagsegmente aneinander anhand des QRS-Komplexes trotz der Variationen im Signalverlauf möglich. Der QRS-Komplex ist relativ stabil und weist einen charakteristischen Signalverlauf für die einzelnen Probanden auf.

Grundlage für eine Identifikation, basierend auf einem Ähnlichkeitsvergleich zwischen Herzschlagsegmenten, ist die Abspeicherung von Referenzherzschlagsegmenten für die einzelnen Probanden und für die verschiedenen Belastungsstufen. Dieser Schritt erfordert eine Segmentierung des EKGs in Herzschläge. Eingesetzt wird dazu ein QRS-Detektor basierend auf dem Algorithmus von V. X. Afonso u.a. [3] in der Implementierung von A. Schlögl als Teil der BioSig-Toolbox [154]. Anschließend werden für jeden Probanden fünf Referenzherzschlagsegmente gleichmäßig verteilt über die unterschiedlichen Belastungsstufen ausgewählt, sodass Segmente während niedriger bis hoher Belastungen als Referenz vorliegen. Im Anschluss erfolgt eine manuelle Überprüfung, ob die Referenzherzschlagsegmente einen vollständigen Herzschlag abdecken und der EKG-Signalverlauf deutlich zu erkennen ist (Ausschluss bei zu hohen Bewegungsartefakten). Diese Überprüfung ist wichtig, da Bewegungsartefakte zu einer falsch-positiven Erkennung eines QRS-Komplexes und damit zu einer fehlerhaften Segmentierung führen können. Die gewählten Segmente werden im Anschluss aus den Datenreihen der Probanden entfernt, um keinen Einfluss auf das Training und die Evaluation

---

<sup>5</sup>Variabilität bedingt durch Schwankungen der Herzfrequenz. Für V1.1 wurden während des Gehens 90 - 115 Schläge/min und für Joggen 145 - 180 Schläge/min ermittelt.

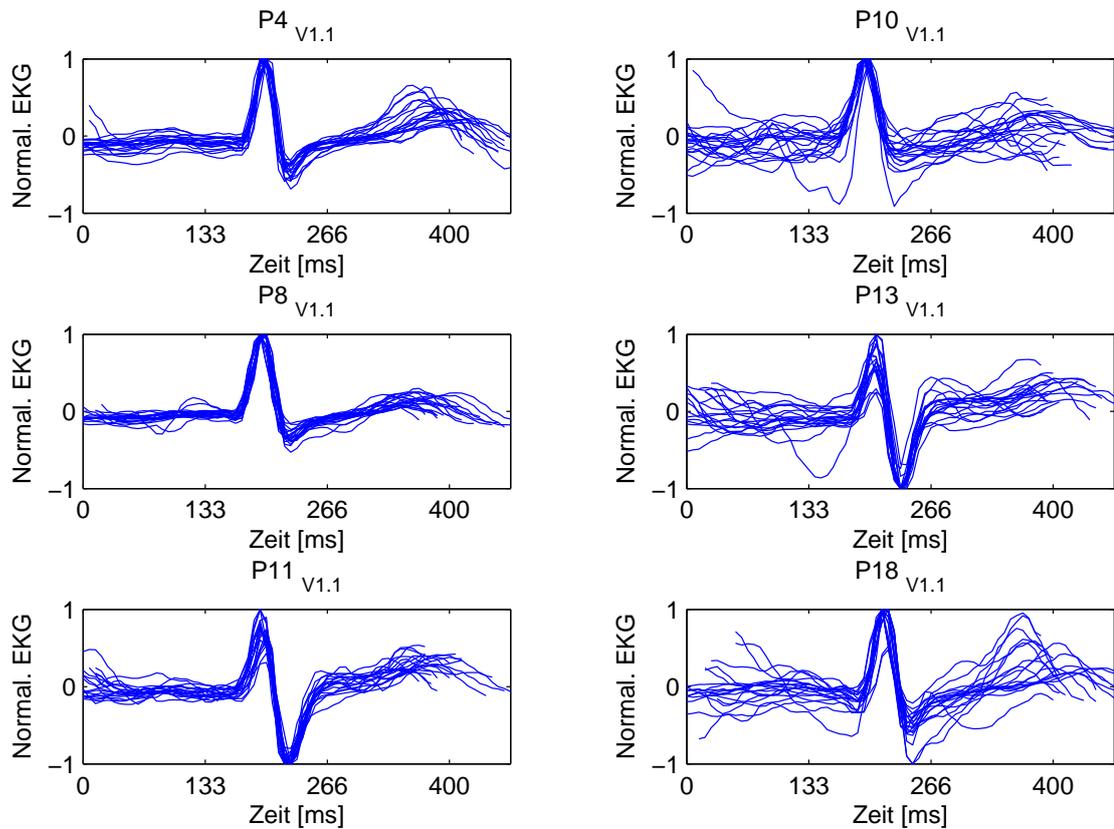


Abbildung 5.4.: Die Abbildungen zeigen jeweils überlagert 20 Herzschlagsegmente von sechs Probanden aus V1.1. Die Segmente wurden zu Zeitpunkten mit unterschiedlicher körperlicher Belastung entnommen. Vor allem der QRS-Komplex ist, aufgrund seiner Konsistenz über verschiedene Belastungsstufen (Herzfrequenzänderungen, Bewegungsartefakte) hinweg, für die Identifikation relevant.

des Klassifikators zu nehmen. Die Erzeugung von Referenzherzschlagsegmenten muss für jeden neuen Probanden zu Anfang nur einmal durchgeführt werden.

Für die Identifikation wird ein unbekanntes Herzschlagsegment  $x$  an jedem Referenzsegment  $y$  mithilfe der Kreuzkorrelation  $R_{xy}$  ausgerichtet,

$$R_{xy}(m) = \frac{1}{L} \sum_{j=0}^{L-m-1} y(j+m) x(j) \quad (5.2)$$

wobei  $L$  die Länge des Segments und  $m$  den zeitliche Versatz mit  $m=0, 1, \dots, 2 \cdot L-1$  angibt. Für Herzschlagsegmente ohne schwere Bewegungsartefakte zentriert die Ausrichtung diese um den QRS-Komplex (siehe Abbildung 5.4). Als Maß für die Ähnlichkeit zwischen den Segmenten

wird anschließend der Pearson-Korrelationskoeffizient berechnet. Dieser ist definiert als die Kovarianz  $cov$  der Signalwerte der beiden Segmente dividiert durch das Produkt der Standardabweichung  $\sigma$  der Signalwerte.

$$r(x, y) = \frac{cov(x, y)}{\sigma_x \sigma_y} \quad (5.3)$$

Der Wertebereich beträgt  $-1$  bis  $+1$ ; bei  $-1$  liegt eine vollständige Antikorrelation (negative Korrelation) und bei  $+1$  eine vollständige positive Korrelation vor. Ein Wert von  $0$  bedeutet, dass die Signalwerte unkorreliert sind.

Das Ergebnis des Vergleichs ist ein Vektor  $S$  mit Angaben zu den Ähnlichkeiten zwischen dem unbekanntem Herzschlagsegment und den abgespeicherten Referenzsegmenten der Probanden.  $S$  umfasst damit  $5 \cdot N$  Korrelationswerte, wobei  $N$  die Anzahl der zu unterscheidenden Personen angibt. Um die Dimensionalität des Merkmalsraums zu reduzieren, wurde der Mittelwert über die fünf Korrelationswerte eines Probanden gebildet und für die Identifikation verwendet (siehe Merkmalsselektion). Eine Reduktion der Dimensionen des Merkmalsraums verkürzt im Allgemeinen den Rechenaufwand für das Training und die Ausführung des Klassifikators.

Im Folgenden ist exemplarisch der Vektor mit den Korrelationswerten des Ähnlichkeitsvergleichs der Herzschlagsegmente aus Abbildung 5.4 angegeben. Wird das zweite Herzschlagsegment von  $P4_{V1.1}$  als unbekanntes (zu identifizierendes) Segment angenommen, ergibt sich beim Vergleich mit dem jeweils ersten Herzschlagsegment der sechs Probanden folgender Vektor:  $S_{P4} = \{0, 98; 0, 84; 0, 92; 0, 83; 0, 75; 0, 96\}$ <sup>6</sup>. Die höchste Übereinstimmung besteht mit dem eigenen Referenzsegment. Auch für  $P10_{V1.1}$  mit Bewegungsartefakten im EKG ist dies der Fall:  $S_{P10} = \{0, 83; 0, 85; 0, 96; 0, 72; 0, 69; 0, 91\}$ . Die Evaluation auf Grundlage der Datenreihe  $V1.1$  hat gezeigt, dass es auch zu einer höheren Übereinstimmung mit einem Referenzsegment eines anderen Probanden kommen kann, unter anderem bedingt durch die unterschiedlichen körperlichen Belastungsstufen. Weiterhin ließen sich Ähnlichkeiten zwischen Probanden beobachten, sodass deren Korrelationswerte nur geringfügig niedriger ausfielen. Eine Identifikation erfolgt daher auf der Basis einer Kombination von Merkmalen. Für die EKG-Signale wird zusätzlich eine Frequenzanalyse durchgeführt und es werden Charakteristika aus den Beschleunigungssignalen genutzt.

**Merkmale Frequenzdomäne** Die Frequenzanalyse des EKGs wird mittels einer diskreten Fourier-Transformation (DFT) für Zeitfenster von zwei Sekunden Länge durchgeführt, um mindestens einen Herzschlag und einen Schritt zu erfassen. Es ist jedoch zu erwarten, dass ein Zeitfenster im Allgemeinen nicht ganzzahlige Vielfache von Herzschlägen und Schritten enthält. Die Beschneidung des Signalverlaufs mittels einer Rechteck-Fensterfunktion würde an den Fenstergrenzen den Signalverlauf abbrechen, was zu einer Verfälschung des Frequenzspektrums führt. Um diesen spektralen Leckeffekt zu reduzieren, wird vor der DFT eine Hamming-Fensterfunktion auf die Signalwerte angewendet, um den Einfluss von Signalwerten in den Außenbereichen des Zeitfensters zu reduzieren. Die DFT ist wie folgt

<sup>6</sup>Sortierung der Korrelationswerte nach der Probandennummer aufsteigend:  $P4, P8, P10, P11, P13, P18$ .

definiert,

$$X(k) = \sum_{j=t}^{t+K-1} x(j)e^{-i2\pi k \frac{j}{K}}, \quad k=0, \dots, K-1 \quad (5.4)$$

wobei  $K$  der Anzahl von Ausgaben  $X(k)$  entspricht. Durchgeführt wird eine 512-Punkt *Fast Fourier-Transformation* (FFT), um die DFT effizient zu berechnen. Dazu wird jedes  $L = 300$  Signalwerte<sup>7</sup> umfassende Zeitfenster  $x(t : t+L-1)$  mit Nullen auf die Länge  $K = 512$  erweitert.

Für die Datenreihe V1.1 zeigen die Amplitudenspektren eine leichte Abhängigkeit von der Laufgeschwindigkeit hinsichtlich der Höhe und Verteilung der Amplitudenwerte über den Frequenzbereich. Unterschiede zwischen den Probanden lassen sich insbesondere in den Amplitudenwerten unterhalb von 20 Hz beobachten. Eingesetzt werden für die Identifikation Fourierkoeffizienten bis 40 Hz (siehe auch Leistungsspektrum des EKGs, Abbildung 2.11). In Abbildung 5.5 sind exemplarisch die Amplitudenspektren für die EKGs (a) und für einen direkten Vergleich (vorgezogen) für die Beschleunigungsmessungen (b) von drei Probanden während des Gehens mit 3 km/h und des Laufens mit 9 km/h abgebildet (Datenreihe V1.1).

Zusätzlich zu den Frequenzkoeffizienten werden das Amplitudenspektrum beschreibende Merkmale berechnet, folgend als FFT-Merkmale bezeichnet<sup>8</sup>. Genutzt werden dabei die Varianz, der Mittelwert, der Fourierkoeffizient mit der höchsten Amplitude und die Shannon Entropie  $SE$  des Amplitudenspektrums. Die Shannon Entropie ist definiert als:

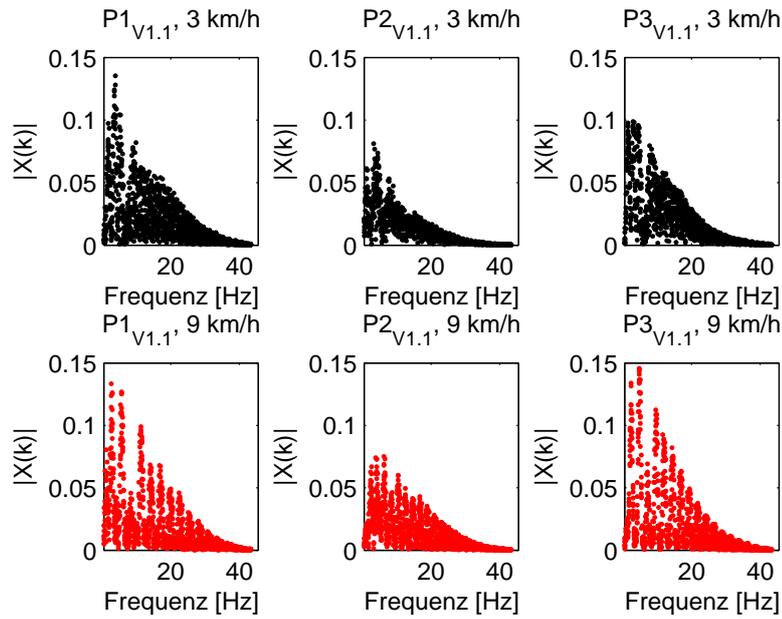
$$SE = - \sum_{k=0}^{K-1} |X(k)| \log_2(|X(k)|) \quad (5.5)$$

wobei  $X(k)$  die Ausgabe der DFT der Länge  $K$  darstellt.

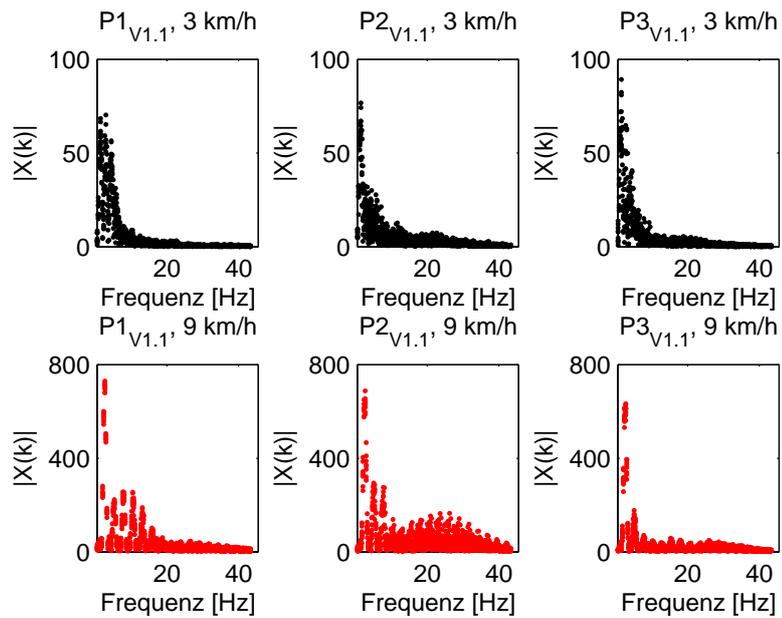
---

<sup>7</sup>In Abhängigkeit von der verwendeten Aufzeichnungsfrequenz (entspricht zwei Sekunden für V1.1).

<sup>8</sup>In der Literatur wird der Einsatz von FFT-Merkmalen als Unterscheidungskriterium im Rahmen verschiedener Anwendungsszenarien beschrieben [14; 16; 64; 102].



(a) Amplitudenspektren (bis 40 Hz) der EKGs.



(b) Amplitudenspektren (bis 40 Hz) der Beschleunigungssignale.

Abbildung 5.5.: Die Amplitudenspektren von EKG- und Beschleunigungssignalen dreier Probanden im Vergleich für Gehen (3 km/h) und Laufen (9 km/h).

### 5.4.2.2 Erfassung der Charakteristika im Gang

Im Folgenden wird die Merkmalsextraktion aus den Beschleunigungssignalen vorgestellt, deren Ziel es ist, die in Abschnitt 5.3.1 beschriebenen personenspezifischen Charakteristika in den Schrittmustern zu erfassen.

**Entscheidung für merkmalsbasierten Ansatz** Für die gangbasierte Identifikation wird kein Vergleich auf Ähnlichkeiten zwischen den unbekanntem Schrittsegmenten und den abgespeicherten Referenzschrittsegmenten durchgeführt. In der Literatur ist dies beispielsweise von L. Rong u.a. für eine Identifikation während des Gehens beschrieben [134]. Aufgrund der in Datenreihe V1.1 beobachteten hohen Variabilität der Schrittmuster, bedingt durch die Geschwindigkeitsanpassungen von langsamen Gehen bis hin zu Laufen, ist die Wahl von Referenzsegmenten schwierig. Für einen Ähnlichkeitsvergleich wäre daher vorab eine Einschätzung der Geschwindigkeit nötig, um das jeweils geeignete Referenzsegment auszuwählen. Als Anmerkung soll hier erwähnt werden, dass ein Dynamic-Time-Warping zur Abbildung des unbekanntem Schrittsegments auf die Referenzschrittsegmente unterschiedlicher Geschwindigkeiten evaluiert wurde, welches jedoch durch die nichtlineare zeitliche Verzerrung personenspezifischer Charakteristika signifikant reduzierte. Weiterhin würde die Segmentierung in Schritte einen zukünftigen Einsatz im Mannschaftsport, zum Beispiel beim Handballspielen, erschweren, da mit einer hohen falsch-positiv-Rate der Schritterkennung während Sprung- und Wurfbewegungen sowie Körperkontakten zwischen den Spielern zu rechnen ist.

Die für die Identifikation gewählten Merkmale beschreiben die Charakteristika des Gangs in den Beschleunigungssignalen. Prinzipiell beschränken die Merkmale jedoch das Identifikationsszenario nicht auf Schrittmuster.

**Merkmale in der Zeitdomäne** Eingesetzt werden der Spitze-Tal-Wert (ST-Wert), die Varianz, das arithmetische Mittel und das quadratische Mittel (engl. *Root Mean Square*, RMS), jeweils berechnet aus den Beschleunigungssignalen der drei orthogonalen Achsen *AP*, *ML* und *V*. Der ST-Wert erfasst dabei die hohen Spitzenbeschleunigungen des Fersen-Auftreffens und deren signifikante Variabilität zwischen den Probanden. Die Varianz ist ein Maß für die Unruhe im Signalverlauf und erfasst damit unter anderem die Unterschiede zwischen den Spitzenbeschleunigungen des Fersen-Auftreffens und des Zehen-Abstoßens. Zusammen mit dem ST-Wert bilden besonders diese Merkmale zusätzlich die Laufgeschwindigkeit mit ab (siehe auch Abschnitt 4.2.5.2). Das arithmetische Mittel approximiert den Gleichanteil der Beschleunigungssignale und enthält Informationen der Oberkörperhaltung (siehe auch Abschnitt 4.3). Die Berechnung des quadratischen Mittels hingegen betont Abweichungen von dem Mittelwert. Die Merkmale werden innerhalb von Zeitfenstern mit zwei Sekunden Länge berechnet, um mindestens einen Schritt zu erfassen.

In der Abbildung 5.6 ist exemplarisch ein Merkmalsraum bestehend aus der Varianz, dem Mittel- und dem ST-Wert dargestellt. Die Merkmale wurden aus mediolateralen Beschleunigungen von zehn Probanden während verschiedener Laufgeschwindigkeiten (3, 5, 7, 9 km/h) berechnet. Aufgrund der Beschränkung des Merkmalsraums auf drei Dimensionen zwecks Visualisierung wurden, zur besseren Übersicht, nur die ersten zehn Probanden der Datenreihe

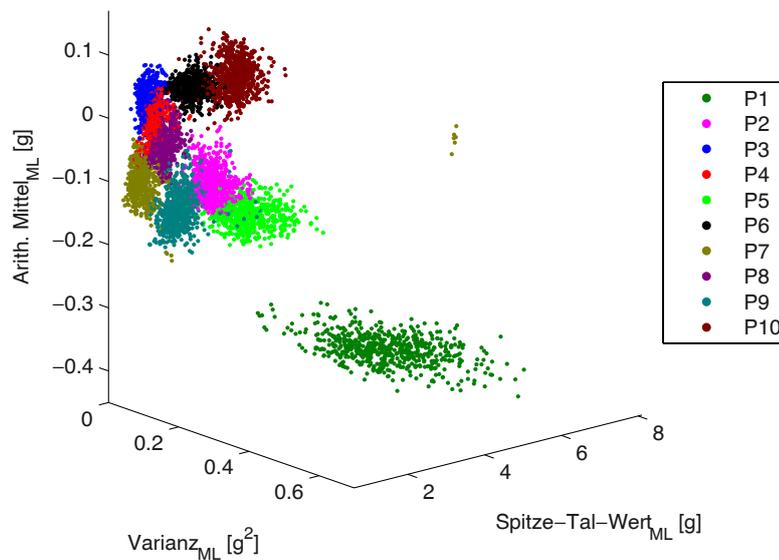


Abbildung 5.6.: Visualisierung der Merkmale in der Zeitdomäne berechnet für mediolaterale Beschleunigungen (ML) bei 9 km/h, eingefärbt für die ersten zehn Probanden aus V1.1. Die Merkmale der Probanden bilden Cluster, die bereits im dreidimensionalen Raum eine (nichtlineare) Trennungsmöglichkeit aufzeigen.

V1.1 ausgewählt und farblich unterschiedlich dargestellt. Die berechneten Merkmale bilden Cluster für die Probanden, sodass bereits im Dreidimensionalen eine Unterscheidung der Probanden vorstellbar wird. Die Merkmale von Proband  $P1_{V1.1}$  weisen eine hohe Varianz auf und grenzen sich damit wertmäßig deutlich von den übrigen Probanden ab. Die Merkmale von Proband  $P7_{V1.1}$  zeigen Ausreißer mit hohen Varianzwerten (rechts oben) hervorgerufen durch einen kurzen intensiven Stoß auf den Beschleunigungssensor. Bezüglich der Klassifikation ist zu beachten, dass es sich auch hier um ein nichtlineares Trennungproblem handelt.

**Merkmale in der Frequenzdomäne** Für die Beschleunigungssignale erfolgt ebenfalls eine Frequenzanalyse. Dazu werden in der Vorverarbeitung die Längen der Beschleunigungsvektoren berechnet und der Gleichanteil der Erdbeschleunigung mittels eines Hochpassfilters ( $f_c = 0,1$  Hz) reduziert. Die DFT erfolgt mit dem FFT-Algorithmus auf Grundlage von Zeitfenstern mit zwei Sekunden Länge, auf die zuvor ebenfalls eine Hamming-Fensterfunktion angewendet wird. Die resultierenden Amplitudenspektren zeigen einerseits signifikante Unterschiede für die verschiedenen Geschwindigkeitsstufen (3 km/h bis 9 km/h); insbesondere die Amplitudenwerte von Frequenzen unterhalb von 10 Hz erreichen während des Laufens ein Vielfaches gegenüber dem Gehen. Andererseits weisen die Amplitudenspektren für jede Geschwindigkeitsstufe ein probandenspezifisches Muster auf (siehe auch Abbildung 5.5b). Für die Amplitudenspektren der Probanden lässt sich dabei eine Abnahme der einzelnen Amplitudenwerte mit zunehmender Frequenz beobachten. Für den Merkmalsraum werden daher

nur Fourierkoeffizienten bis 40 Hz sowie die auch schon für die EKG-Amplitudenspektren berechneten FFT-Merkmale verwendet.

### 5.4.3 Konfiguration des Klassifikators

Als Ergebnis der Merkmalsextraktion liegen die personenspezifischen Charakteristika aus den EKG- und Beschleunigungssignalen in einem Merkmalsraum vor. Als Klassifikatoreingabe werden jeweils zwei aufeinanderfolgende Merkmale verknüpft (korrespondierend zu einem Zeitraum von vier Sekunden); diese Vergrößerung des Merkmalsraums zeigte in einer vorbereitenden Untersuchung eine Steigerung der Klassifikationsgenauigkeit. Die eigentliche Identifikation erfolgt entweder mit einem MLP oder RF als Klassifikator. Einzelne Entscheidungsbäume wurden in der vorbereitenden Untersuchung ausgeschlossen, da ihre Identifikationsleistung niedriger ausfiel<sup>9</sup>. Die Klassifikatoren und deren Auswahlkriterien sind in Abschnitt 4.1 beschrieben.

Das eingesetzte MLP verfügt über eine verdeckte Schicht, um die nichtlineare Trennung der Merkmale der einzelnen Personen zu ermöglichen. Die benötigte Anzahl an verdeckten Neuronen wurde empirisch bestimmt. Mit mehr als 25 Neuronen konnte für den vollständigen Merkmalsraum keine weitere Steigerung der Identifikationsgenauigkeit beobachtet werden. Die Anzahl an Ausgabeneuronen richtet sich nach der Anzahl an zu unterscheidenden Probanden (bis zu 22 für V1.1). Jedes Ausgabeneuron gibt einen Wahrscheinlichkeitswert (0 bis 1) für den jeweiligen Probanden an; der Proband mit dem höchsten Wert wird als Identifikationsergebnis ausgegeben. Alle Neuronen verfügen über sigmoide Aktivierungsfunktionen. Das Training des MLP erfolgt mittels Backpropagation, verwendet wird der SCG-Algorithmus [109]. Die Anpassung der Gewichte und Biaswerte erfolgt mit einem Gradientenverfahren mit einem Trägheitsterm (Momentum); für weiterführende Informationen siehe Abschnitt 4.1.1.3. Im Folgenden wird diese Konfiguration als MLP<sub>25,S</sub> bezeichnet.

Zusätzlich wurde der Einsatz des RF-Klassifikators geprüft, der sich für die Laufgeschwindigkeitsbestimmung durch eine hohe Klassifikationsgenauigkeit bei einer vergleichsweise kurzen Trainingsdauer auszeichnet. Im Gegensatz zu der Laufgeschwindigkeitsbestimmung führt eine Erhöhung der Anzahl an Entscheidungsbäumen zu einer Verbesserung der Identifikationsgenauigkeit. Eine empirisch ermittelte geeignete Konfiguration umfasst 100 EBs, wobei jeder EB aus zehn zufällig ausgewählten Merkmalen besteht, im Folgenden als RF<sub>100,10</sub> bezeichnet.

## 5.5 Evaluation Personenidentifikation

Die Evaluation des Identifikationsverfahrens erfolgte für die Datenreihen der beiden Laufbandversuche V1.1 und V1.2 sowie als Ausblick für die Handballspielaufzeichnung V3.

### 5.5.1 Datenmaterial

Im Folgenden wird eine Übersicht über die Versuche sowie die Auswahlkriterien für diese Datenreihen gegeben. Die ausführliche Dokumentation ist im Anhang A zu finden.

---

<sup>9</sup>Gegenüber der Geschwindigkeitsbestimmung ist die Anzahl der verwendeten Merkmale für die Identifikation höher (komplexerer Merkmalsraum).

**Versuch V1.1** Die Datenreihe umfasst EKG- und Beschleunigungssignale von 22 Probanden (15 Männer, 7 Frauen) während des Gehens und Laufens auf Laufbändern. Die Probanden absolvierten die Geschwindigkeiten 3, 5, 7 und 9 km/h. Jede Belastungsstufe dauerte 2 min und wurde jeweils ein zusätzliches Mal wiederholt. Für die Aufzeichnung wurde der Körpersensor BG-V4.1 eingesetzt, den sich die Probanden selbständig auf ihren Brustumfang anpassten und anlegten. Der korrekte Sitz des Messsystems wurde nicht explizit überprüft, da dies unter natürlichen Bedingungen ebenfalls nicht möglich ist. Die Aufzeichnung der EKG- und Beschleunigungssignale (Messbereich  $\pm 6$  g) erfolgte mit einer Frequenz von 150 Hz und einer Wortbreite von 12 b. Die Übergangsbereiche für die Geschwindigkeitsanpassung wurden im Anschluss aus der Datenreihe entfernt. Für jede Geschwindigkeitsklasse und jeden Probanden stehen jeweils 27000 Tupel zur Verfügung.

**Versuch V1.2** Der Versuchsablauf von V1.1 wurde mit neun männlichen Probanden wiederholt, die bis 11 km/h schnell liefen (fünf Geschwindigkeitsstufen). Jeder Proband absolvierte den Stufentest zweimal an unterschiedlichen Aufzeichnungstagen mit einem zeitlichen Abstand von einer Woche: V1.2(1) und V1.2(2). Auf diese Weise standen für das Training und die Evaluation des Identifikationsverfahrens zwei Datenreihen zu Verfügung, um die zeitliche Unabhängigkeit der Identifikationsergebnisse zu prüfen. Weiterhin war es möglich, die Alltagstauglichkeit des Identifikationsverfahrens zu testen, da sich Variabilitäten in den EKG- und Beschleunigungssignalen durch das erneute Anlegen des Messsystems ergeben können. Der EKG-Signalverlauf ist abhängig von der Platzierung der Textilelektroden in Relation zum Herzen, darüber hinaus verändert eine unterschiedliche Transpirationsrate den Übergangswiderstand zwischen Elektroden und Haut. Die Verteilung von dynamischen Beschleunigungsanteilen auf die drei orthogonalen Achsen variiert ebenfalls aufgrund von Änderungen in der Sensororientierung durch ein erneutes Anlegen des Messsystems. Die Aufzeichnung der EKG- und Beschleunigungssignale (Messbereich  $\pm 12$  g) erfolgte mit einer Frequenz von 75 Hz und einer Wortbreite von 12 b. Für jede Geschwindigkeitsklasse und jeden Probanden umfasst die Datenreihe V1.2(1) 10000 Tupel und V1.2(2) 12000 Tupel.

**Versuch V3** Die Datenreihe beinhaltet EKG- und Beschleunigungssignale von 14 Handballspielern der Herrenmannschaft des Soester Turnvereins während eines Trainingsspiels. Die Aufzeichnung dauerte etwa 45 min, die Spielzeit betrug zweimal 20 min. Die fünfminütige Pause und die Spielunterbrechungen wurden nicht aus den Daten entfernt. Für die Identifikation kamen die Daten des im Brustbereich angebrachten BG-V4.2 zum Einsatz, die beiden zusätzlichen Körpersensoren an den Extremitäten wurden nicht genutzt. Die Aufzeichnung der EKG- und Beschleunigungssignale (Messbereich  $\pm 12$  g) erfolgte mit einer Frequenz von 150 Hz und 12 b Wortbreite. Aufgrund des hochdynamischen Handballsports mit Körperkontakten zwischen den Spielern löste sich vereinzelt einer der beiden Druckknöpfe zwischen Körpersensor und Brustgurt. Bei zwei Spielern kam es dadurch zu längeren Aussetzern in den EKG-Signalen. Die Datenreihen der zwei Spieler umfassen mit 192868 (*P2*) und 279799 (*P12*) daher weniger nutzbare Tupel (gesonderte Betrachtung im Rahmen der Evaluation). Um eine Gleichverteilung der Tupelanzahl zwischen den übrigen 12 Spielern zu erreichen, wurden deren Datenreihen auf jeweils 341473 Tupel begrenzt.

## 5.5.2 Ergebnisse Laufbandversuche

Im Folgenden werden die Ergebnisse der Identifikation während des Gehens und Laufens vorgestellt. Primär erfolgte die Evaluation auf der Datenreihe V1.1 mit 22 zu unterscheidenden Probanden. V1.2 diente der Abschätzung der zeitlichen Stabilität und der Praxistauglichkeit der Identifikation (erneutes Anlegen des Messsystems).

### 5.5.2.1 Ergebnisse V1.1

Für die Evaluation erfolgte eine Aufteilung der Datenreihe mittels einer zehnfachen Kreuzvalidierung (siehe Abschnitt 4.1.4). Die Merkmalsberechnung wurde dazu ohne Überlappung der Zeitfenster durchgeführt. Für die Klassifikation kamen das MLP<sub>25,5</sub> und der RF<sub>100,10</sub> zum Einsatz. Die Bewertung der Klassifikationsergebnisse erfolgte mit den Gütemaßen Sensitivität und Spezifität (siehe Abschnitt 4.1.5).

Die höchste mittlere Sensitivität  $\bar{R}$  von 98,1 % erzielt der RF-Klassifikator; beim MLP sind es knapp 4 % weniger. Die mittlere Spezifität ( $\bar{S}$ ) beider Klassifikatoren liegt auf einem ähnlichen, sehr hohen Niveau von 99,9 % (RF) und 99,8 % (MLP). Die Ergebnisse gelten für den Merkmalsraum  $M_{I8}$ , der alle Merkmale aus der Zeit- und Frequenzdomäne für EKG- und Beschleunigungssignale kombiniert (siehe Tabelle 5.1).

In Abbildung 5.7 ist die klassenspezifische Sensitivität ( $R_i$ ) und Spezifität ( $S_i$ ) für die Identifikation mit dem RF dargestellt, wobei  $i$  die Probandennummer (Klasse) angibt. Die Standardabweichung von  $R_i$  beträgt  $\pm 1,7\%$  für die 22 Probanden, das Minimum liegt bei 94,6 % und für vier Probanden sind es 100 %. Insgesamt weisen nur vier Probanden ein  $R_i$  von unterhalb 97 % auf. Die Standardabweichung von  $S_i$  beträgt sehr niedrige  $\pm 0,1\%$ . Das Minimum von  $S_i$  sind 99,7 % und das Maximum 100 %.

Um die besonders leistungsfähigen Merkmale zu identifizieren, wurden sieben weitere Merkmalsräume gebildet, die jeweils nur Informationen des EKGs ( $M_{I1}$ ,  $M_{I2}$ ), des Gangs ( $M_{I3}$ ,  $M_{I5}$ ) und Kombinationen aus beiden Informationsquellen umfassten (siehe Tabelle 5.1). Die Merkmalsselektion erfolgte unter Verwendung des MLPs; genutzt wurde dazu die im Kontext der Geschwindigkeitsbestimmung (siehe Abschnitt 4.2) realisierte Umgebung zur Merkmalsselektion<sup>10</sup>. Die ausschließliche Nutzung von Informationen des Gangs ( $M_{I6}$ ) führt zu einer mittleren Sensitivität von  $\bar{R} = 86,6\%$ , für das EKG ( $M_{I4}$ ) sind es  $\bar{R} = 84,8\%$ . Eine Kombination beider Informationsquellen ist sinnvoll und resultiert für das betrachtete Identifikationsszenario in einer Steigerung der mittleren Sensitivität um mindestens 7,6 %.

Das EKG enthält in der Frequenzdomäne mehr personenspezifische Informationen als die Beschleunigungssignale; im direkten Vergleich wird eine 12,3 % höhere Sensitivität erzielt. Höhere Frequenzen sind dabei für die Frequenzanalyse des EKGs wichtiger als für die Beschleunigungssignale. Eine Beschränkung des Frequenzbands des EKGs von 40 Hz auf 15 Hz reduziert  $\bar{R}$  um 8,8 %. Für die Merkmale in diesem Frequenzbereich des EKGs (FFT-Koeffizienten und FFT-Merkmale,  $M_{I1}$ ) werden  $\bar{R} = 72,4\%$  erreicht. Die personenspezifischen Charakteristika in den Beschleunigungssignalen sind hauptsächlich im niederfrequenten Bereich enthalten, eine Reduzierung des Frequenzbands auf 10 Hz verringert  $\bar{R}$  um nur 3,8 %. Mit  $\bar{R} = 53,2\%$  sind die aus den Beschleunigungssignalen berechneten Fourierkoeffizien-

---

<sup>10</sup>Im Rahmen der Sensorsignalverarbeitung auf Mikroprozessoren (Kapitel 7) wurde zu einem späteren Zeitpunkt eine Analyseumgebung mit einem austauschbaren Klassifikator realisiert.

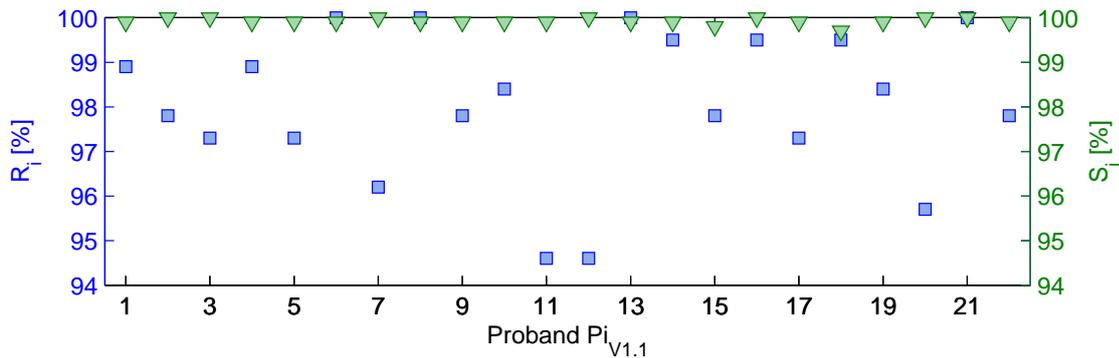


Abbildung 5.7.: Klassenspezifische Sensitivität  $R_i$  und Spezifität  $S_i$  der Identifikation der 22 Probanden  $Pi_{V1.1}$ , wobei  $i$  die Probandennummer angibt. Die Ergebnisse basieren auf  $M_{I8}$  und dem  $RF_{100,10}$ . Das Minimum von  $S_i$  beträgt 99,7 %.

ten im Vergleich zu den übrigen Merkmalen weniger aussagekräftig. Die hohe Variabilität der Schrittmuster in Abhängigkeit von der Laufgeschwindigkeit erschwert den Einsatz der Frequenzanalyse als Identifikationsmerkmal.

Mit  $\bar{R} = 80,3\%$  enthalten die Korrelationskoeffizienten  $M_{I2}$  aus dem Ähnlichkeitsvergleich von Herzschlagsegmenten nützliche Informationen für die Identifizierung der Probanden. Mit fünf Korrelationskoeffizienten pro Proband erhöht dieses Merkmal jedoch deutlich die Dimensionalität des Merkmalsraums und damit den Aufwand für die Klassifikation. Um diesen zu reduzieren, wird das arithmetische Mittel aus den fünf Korrelationskoeffizienten der einzelnen Probanden gebildet. Isoliert betrachtet verringert sich  $\bar{R}$  dadurch um 7,7%. In Kombination mit weiteren Merkmalen ist die Mittelwertbildung sinnvoll, da sich  $\bar{R}$  nur um 0,4% reduziert ( $M_{I8}$ ), die Dimensionalität des Merkmals jedoch ein Fünftel beträgt.

Bereits die dreidimensionale Darstellung (siehe Abbildung 5.6) des Merkmalsraums  $M_{I3}$ , berechnet aus den drei Beschleunigungssignalen in der Zeitdomäne, zeigt deutlich unterscheidbare Cluster für die Merkmale der verschiedenen Probanden. Die Eignung von  $M_{I3}$  für die Identifikation bestätigt eine mittlere Sensitivität von  $\bar{R} = 83,3\%$ . Kombiniert mit den Korrelationskoeffizienten des Ähnlichkeitsvergleichs zwischen Herzschlagsegmenten werden  $\bar{R} = 93,6\%$  ( $M_{I7}$ ) erreicht; dies sind 0,6% weniger als mit dem vollständigen Merkmalsraum ( $M_{I8}$ ).

Die obigen Ergebnisse basieren auf allen drei Beschleunigungsachsen. Um den Einfluss der einzelnen Achsen auf die Identifikationsgenauigkeit analysieren zu können, wurde die Evaluation für jeweils nur eine Achse durchgeführt. Die Ergebnisse für anteriorposteriore Beschleunigungen liegen um  $\bar{R} = 4,4\%$  höher als für mediolaterale und um 16,2% höher als für vertikale Beschleunigungen.

Eine zehnfache Kreuzvalidierung ist eine etablierte Evaluationsmethode, bei der jeweils 10% der Datenreihe zum Testen verwendet werden. Um den Umfang an Testtupel zu erhöhen, wurde zusätzlich eine Aufteilung der Datenreihe in 66% Trainings- und 34% Testtupel betrachtet (*Hould-Out Validation*, siehe Abschnitt 4.1.4).  $\bar{R}$  reduziert sich dadurch um 0,9% auf 97,2% ( $RF_{100,10}$ -Klassifikator). Mögliche Gründe stellen die erhöhte Anzahl an Testtupel

Tabelle 5.1.: Ergebnisse der Evaluation der einzelnen Merkmale für die Identifikation unter Verwendung des MLP-Klassifikators. Darstellung von acht ausgewählten Merkmalsräumen  $M$ . \* Bezeichnet die Verwendung des arithmetischen Mittels über die fünf Korrelationskoeffizienten des jeweiligen Probanden.

| $M$      | Beschleunigungsmerkmale |              |           | EKG-Merkmale |           |            | $\bar{R}_{MLP}$ [%] |
|----------|-------------------------|--------------|-----------|--------------|-----------|------------|---------------------|
|          | Zeitdom.                | Frequenzdom. |           | Frequenzdom. |           | Zeitdom.   |                     |
|          |                         | FFT-Koef.    | FFT-Merk. | FFT-Koef.    | FFT-Merk. | Korr.Koef. |                     |
| $M_{I1}$ | -                       | -            | -         | X            | X         | -          | 72,4                |
| $M_{I2}$ | -                       | -            | -         | -            | -         | X          | 80,3                |
| $M_{I3}$ | X                       | -            | -         | -            | -         | -          | 83,3                |
| $M_{I4}$ | -                       | -            | -         | X            | X         | X          | 84,8                |
| $M_{I5}$ | X                       | -            | -         | -            | X         | -          | 86,5                |
| $M_{I6}$ | X                       | X            | X         | -            | -         | -          | 86,6                |
| $M_{I7}$ | X                       | -            | -         | -            | -         | X          | 93,6                |
| $M_{I8}$ | X                       | X            | X         | X            | X         | X*         | 94,2                |

sowie die Betrachtung von nur einer Teilmenge der Datenreihe dar.

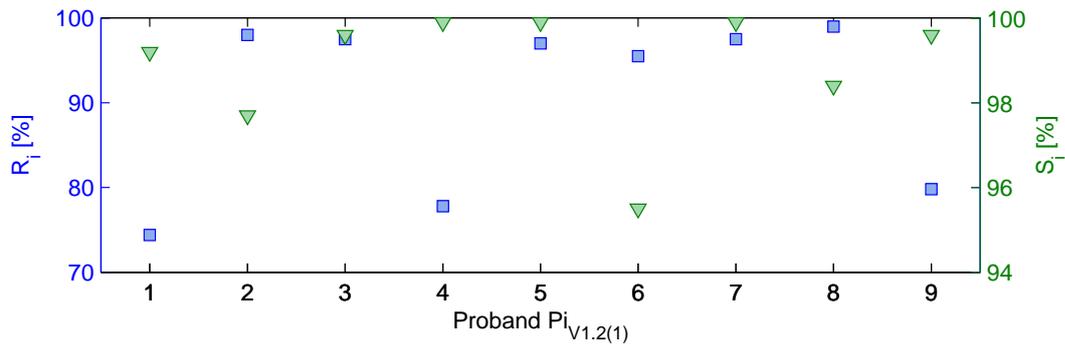
Darüber hinaus wurde geprüft, ob eine geringere Anzahl an zu unterscheidenden Personen die Identifikationsgenauigkeit verbessert. Dazu wurden 11 aus den 22 Probanden zufällig ausgewählt und die Evaluation für diese wiederholt. Die Identifikationsgenauigkeit erhöht sich dadurch um 1,2% auf 99,3% ( $M_{I8}$  und  $RF_{100,10}$ ).

### 5.5.2.2 Ergebnisse V1.2

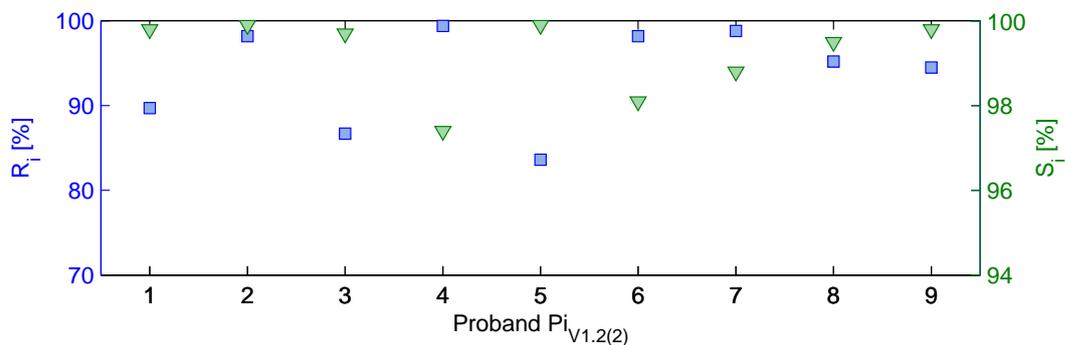
Die Evaluation auf den Datenreihen des Versuchs V1.2 betrachtet weiterführend den Einfluss von Veränderungen in den Herzschlag- und Schrittsegmenten durch ein erneutes Anlegen des Messsystems. Dazu wurden für jeden Probanden zwei Datenreihen V1.2(1) und V1.2(2) mit einer Woche Zeitversatz aufgezeichnet. Das Training des Klassifikators erfolgte auf jeweils nur einer der beiden Datenreihen und die Evaluation auf der zweiten (unbekannten) Datenreihe. Die Evaluation wurde mit  $M_{I8}$  und dem  $RF_{100,10}$ -Klassifikator durchgeführt, da mit diesem die höchste Identifikationsgenauigkeit für V1.1 ermittelt werden konnte. Die Identifikation erfolgte ebenfalls auf nicht überlappenden Zeitfenstern von vier Sekunden Länge.

Mit dem auf der Datenreihe aus V1.2(1) trainierten  $RF_{100,10}$  wird für die Datenreihe V1.2(2) ein  $\bar{R}$  von 90,7% bei einer Standardabweichung von  $\pm 10,2\%$  erreicht. Für drei Probanden ist  $R_i < 90\%$  und der niedrigste Wert beträgt 74,4% für  $P1_{V1.2(1)}$  (siehe Abbildung 5.8a). Fehlklassifikationen treten vor allem mit jeweils einem anderen Probanden auf; für  $P1^{11}$  und  $P4$  ist es  $P6$ , für  $P9$  ist es  $P2$  (siehe Konfusionsmatrix Anhang Tabelle B.6a). Das höchste  $R_i$  von 99% wird für  $P8$  erreicht. Die mittlere Spezifität beträgt  $\bar{S} = 98,6\%$  (Bereich: 95,5% bis

<sup>11</sup>Die der Probandennummer untergestellte Versuchsnummer wird nachfolgend zwecks einer besseren Übersicht weggelassen.



(a) Training auf der Datenreihe aus V1.2(1) und Test auf V1.2(2). Die mittlere Sensitivität beträgt  $\bar{R} = 90,7 \pm 10,2\%$  bei einer Spezifität von  $\bar{S} = 98,6 \pm 1,5\%$ .



(b) Training auf der Datenreihe aus V1.2(2) und Test auf V1.2(1). Die mittlere Sensitivität beträgt  $\bar{R} = 93,8 \pm 5,8\%$  bei einer Spezifität von  $\bar{S} = 99,2 \pm 0,9\%$ .

Abbildung 5.8.: Klassenspezifische Sensitivität  $R_i$  (Quadrat) und Spezifität  $S_i$  (Dreieck) der Identifikation der neun Probanden auf Grundlage der beiden Datenreihen aus V1.2. Die neun Probanden sind mit  $i$  durchnummeriert.

99,9%) mit einer niedrigen Standardabweichung von  $\pm 1,5\%$ . Zusätzlich wurden die beiden Datenreihen getauscht, sodass das Training auf den Daten aus V1.2(2) und die Evaluation auf V1.2(1) erfolgte<sup>12</sup>.  $\bar{R}$  erhöht sich dadurch auf 93,8% ( $\approx +3\%$ ) bei einer niedrigeren Standardabweichung von  $\pm 5,8\%$ . Für drei Probanden beträgt  $R_i$  83,6% bis 89,7%, für die übrigen sechs Probanden ist  $R_i > 94,5\%$  und maximal werden 99,4% erreicht. Die mittlere Spezifität beträgt  $\bar{S} = 99,2\%$  und schwankt nur zwischen 97,4% und 99,9%. Ein Einfluss durch die unterschiedlichen Längen der Datenreihen wurde dabei ausgeschlossen, indem die Tupelanzahl von V1.2(2) auf die von V1.2(1) reduziert wurde.

Im Vergleich zu den Ergebnissen aus V1.1 (22 / 11 Probanden) ist hauptsächlich  $\bar{R}$  um 4,3% bis 7,4% verringert. Dabei ist zu beachten, dass  $R_i$  insbesondere für drei Probanden niedriger ausfällt. Für  $\bar{S}$  beträgt der Unterschied maximal 1,3%. Einerseits reduziert sich für die Datenreihe V1.2 zwar die Komplexität der Identifikation, da nur neun Probanden unterschieden

<sup>12</sup>Für die Praxis ist dieses Vorgehen jedoch nicht relevant, da für das Training des Vorhersagemodells nur die erste Aufzeichnung zur Verfügung steht.

werden müssen; andererseits enthält diese jedoch die zusätzliche Geschwindigkeitsklasse 11 km/h und die Evaluation erfolgt auf Grundlage einer höheren Anzahl an aufeinanderfolgenden Testtupel (10000 und 12000). Die wichtigste Veränderung ist jedoch, dass das Messsystem von den Probanden (ohne Anweisung) erneut angelegt werden musste, was für die Praxistauglichkeit des Identifikationsverfahrens essentiell ist. Der zeitliche Abstand von einer Woche zeigt weiterhin, dass eine Identifikation trotz Veränderungen der Schrittmuster in Abhängigkeit von der „Tagesform“ des Probanden sowie einer (initial) unterschiedlichen Leitfähigkeit der EKG-Textilelektroden möglich ist.

### 5.5.2.3 Vergleich mit Literatur

Im Folgenden werden die Ergebnisse mit Identifikationsmethoden der Literatur verglichen. Auf Benchmark-Datenreihen konnte in dem Zusammenhang nicht zurückgegriffen werden, sodass die Ergebnisse auf verschiedenen Identifikationsbedingungen und einer unterschiedlichen Anzahl an Probanden basieren.

Für einen Vergleich mit gangbasierten Methoden wurden die Arbeiten von [5; 52; 103; 134] gewählt. Deren Evaluationen erfolgten auf dreidimensionalen Beschleunigungssignalen, die während langsamen, normalen und schnellen Gehen aufgezeichnet wurden, die Datenreihen umfassen keine Laufgeschwindigkeiten. Es wurden zwischen 21 und 36 Probanden unterschieden (siehe Tabelle 5.2). Als Gütemaß ist in den Vergleichsarbeiten die Gleichfehlerrate ERR der Identifikation angegeben, sodass diese zunächst für die Evaluationsergebnisse von V1.1 und V1.2 ebenfalls ermittelt wurde. Für den  $RF_{100,10}$ -Klassifikator und den Merkmalsraum  $M_{18}$  beträgt das arithmetische Mittel der Gleichfehlerrate  $1,0 \pm 0,79\%$  [ 0 - 3,3 %] für die 22 Probanden aus V1.1 und  $2,5 \pm 1,52\%$  [ 0,4 - 4,6 %] für die neun Probanden aus V1.2. Die in den Vergleichsarbeiten erzielte Gleichfehlerrate liegt zwischen 5 % und 7 %, wobei zu beachten ist, dass die Identifikation von [5; 103] eine höhere Anzahl an Probanden ( $N = 36$ ) abdeckt.

Für die Evaluation, basierend auf Charakteristika im EKG, wurden die Ergebnisse von A. D. C. Chan u.a. gewählt, da die Identifikation ebenfalls auf nicht-klinischen EKGs erfolgte, die mittels Silber-Silberchlorid-Knopfelektroden an den Fingern aufgezeichnet wurden [33]. Die Evaluation erfolgte auf zwei Datenreihen, die mindestens einen Tag auseinander lagen. Hervorzuheben ist die hohe Probandenanzahl ( $N = 50$ ) und die dabei erreichte Genauigkeit von 89 %. Die im Rahmen der vorliegenden Arbeit erzielte Identifikationsgenauigkeit ist im Vergleich höher. Dies wird durch die Kombination der beiden Informationsquellen erreicht; beschränkt auf nur EKG-Charakteristika ( $M_{14}$ ) werden 84,8 % erzielt. Weiterhin ist eine Identifikation bei unterschiedlichen Herzfrequenzen aufgrund von beispielsweise schwankender körperlicher Belastung oder mentalem Stress möglich. Ein weiteres diesbezüglich relevantes Anwendungsszenario ist der Mannschaftssport, in welchem das Anlegen des Körpersensors zu Belastungsbeginn oder nach einer Belastungsphase (z.B. Aufwärmen) mit einer bereits erhöhten Herzfrequenz erfolgen kann.

Tabelle 5.2.: Gleichfehlerrate ( $EER$ ) und mittlere Genauigkeit ( $\bar{R}$ ) von Gang- und EKG-basierten Identifikationsmethoden in der Literatur. Gegenübergestellt sind die Ergebnisse für die Datenreihen V1.1 und V1.2.  $N$  bezeichnet die Anzahl an zu unterscheidenden Probanden.

|                              | Typ        | Identifikationsszenario                 | $N$ | $EER$ | $\bar{R}$       |
|------------------------------|------------|---|-----|-------|-----------------|
| Mäntyjärvi u.a. (2005) [103] | Gang       | langsames, normales und schnelles Gehen | 36  | 7,0%  | –               |
| Ailisto u.a. (2005) [5]      | Gang       | normales Gehen                          | 36  | 6,4%  | –               |
| Gafurov u.a. (2006) [52]     | Gang       | normales Gehen                          | 21  | 5,0%  | –               |
| Rong u.a. (2007) [134]       | Gang       | normales Gehen                          | 21  | 5,6%  | –               |
| Chan u.a. (2008) [33]        | EKG        | Sitzen in Ruhe                          | 50  | –     | 89,0%           |
| V1.1 (1 Datenreihe)          | Gang & EKG | Gehen & Laufen: 3, 5, 7 und 9 km/h      | 22  | 1,0%  | 98,1%           |
| V1.2 (2 Datenreihen)         | Gang & EKG | Gehen & Laufen: 3, 5, 7, 9 und 11 km/h  | 9   | 2,5%  | 90,7%/<br>93,8% |

### 5.5.3 Ergebnisse Mannschaftssport

Die initiale Motivation für die Identifikation bestand darin, Handballspieler im Spielverlauf zu erkennen, um eine automatisierte Zuordnung der einzelnen Spieler zu ihren Sensormesswerten oder abgeleiteten Parametern im *Sports Performance Analyzer (SPA)*, einer Software zur Trainingsunterstützung im Mannschaftssport [163, Kap.3], zu erreichen. Insbesondere sollen die Identitäten und die Geschwindigkeits- / Aktivitätsprofile der Spieler genutzt werden, um den Algorithmus zur videobasierten Verfolgung zu unterstützen; dies wird in Abschnitt 6.2 erläutert.

Die realisierte Identifikation ist nicht auf das bereits in V1.1 und V1.2 betrachtete Szenario beschränkt, insbesondere die EKG-basierte Identifizierung ist unabhängig von der Art der körperlichen Betätigung. Die unterschiedlichen Belastungsstufen der Laufbandversuche haben gezeigt, dass eine Identifizierung innerhalb eines großen Herzfrequenzbereichs möglich ist. Weiterhin ist zu erwarten, dass die für die Beschleunigungssignale gewählten Merkmale es ermöglichen, auch personenspezifische Charakteristika anderer Bewegungsformen zu erfassen. So sind der Spitze-Tal-Wert, die Varianz, das arithmetische und quadratische Mittel sowie die Frequenzanalyse nicht auf die Erfassung von Charakteristika von Schrittmustern beschränkt, sondern eignen sich allgemein für eine Bewegungsanalyse.

Eine erste Evaluation des Identifikationsverfahrens wurde für die Datenreihe V3 eines Trainingsspiels der Handballmannschaft des Soester Turnvereins (siehe Anhang A.3) durchgeführt. Dazu erfolgte eine Aufteilung der 14 Spieler umfassenden Datenreihe mittels einer zehnfachen Kreuzvalidierung und es wurde der Merkmalsraum  $M_{18}$  berechnet, welcher Informationen der EKG- und Beschleunigungssignale kombiniert. Der zuvor verwendete  $RF_{100,10}$ -Klassifikator erzielt dafür eine mittlere Sensitivität von  $\bar{R} = 87,4\%$ . Eine Steigerung auf 91,4% ist jedoch möglich indem die Anzahl an zufällig ausgewählten Merkmalen pro

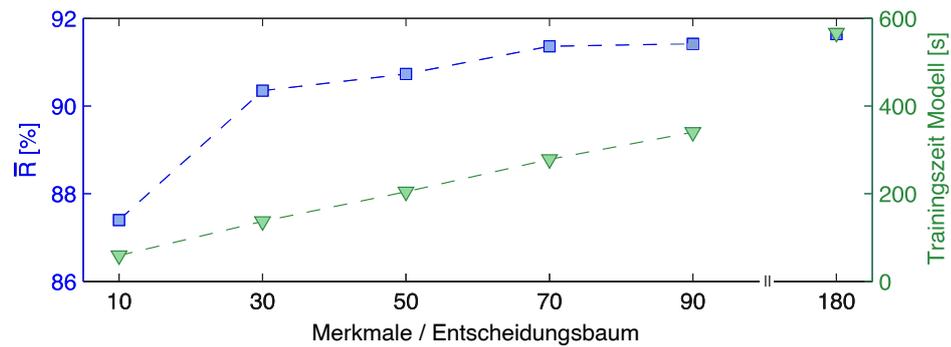


Abbildung 5.9.: Gegenüberstellung der mittleren Sensitivität ( $\bar{R}$ ) der Identifikation von 14 Handballspielern und der benötigten Trainingszeit des RF-Klassifikators in Abhängigkeit von der Anzahl eingesetzter Merkmale pro Entscheidungsbaum. Schrittweise Erhöhung der Merkmalsanzahl bis 90, anschließend Verdoppelung auf 180 zur Darstellung der Entwicklung.

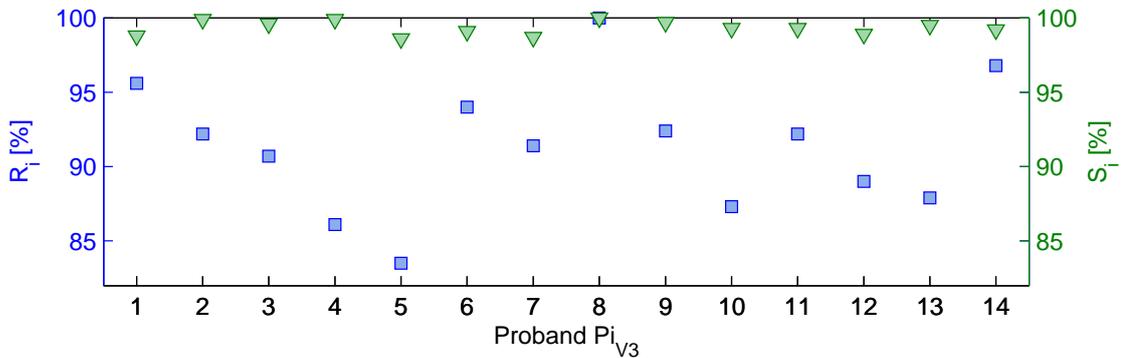


Abbildung 5.10.: Klassenspezifische Sensitivität  $R_i$  und Spezifität  $S_i$  der Identifikation der 14 Handballspieler (RF<sub>100,70</sub>-Klassifikator, Merkmalsraum  $M_{18}$ ).

Entscheidungsbaum von 10 auf 70 erhöht wird (siehe Abbildung 5.9). Eine signifikante Verbesserung zeigt sich dabei ab 30 Merkmalen pro EB, anschließend erhöht sich  $\bar{R}$  langsamer; zwischen 70 und 180 Merkmalen pro EB kann keine signifikante Zunahme mehr beobachtet werden. Zusätzlich wurde die benötigte Zeitdauer für das Training des Vorhersagemodells erfasst<sup>13</sup>. Die Trainingszeit erhöht sich dabei linear mit der Anzahl eingesetzter Merkmale. Für die ausgewählte Konfiguration mit 70 Merkmalen pro EB dauert das Training 278 s.

Die mittlere Sensitivität  $\bar{R}$  von 91,4 % weist dabei eine Standardabweichung von  $\pm 4,4$  % auf. Die niedrigste klassenspezifische Sensitivität  $R_i$  beträgt 83,5 % für  $P_5$  (siehe Abbildung 5.10), wobei Fehlklassifikationen vor allem mit fünf weiteren Handballspielern auftreten (siehe Konfusionsmatrix, Anhang Tabelle B.7). Die Testtupel von  $P_8$  hingegen werden vollständig

<sup>13</sup>Testumgebung: Intel Xeon W3565 mit 3,20 GHz Taktfrequenz (Nutzung von nur einem Prozessorkern), 24 GB Arbeitsspeicher, WEKA 3.6.6, Java 1.7, Ubuntu 10.04.

Tabelle 5.3.: Ergebnisse der Identifikation der 14 Handballspieler für verschiedene Merkmalsräume basierend auf dem  $RF_{100,70}$ -Klassifikator.

| Merkmalsraum             | $\bar{R} \pm \sigma$ [Min $R_i$ – Max $R_i$ ] % | $\bar{S} \pm \sigma$ [Min $S_i$ – Max $S_i$ ] % |
|--------------------------|---|---|
| $M_{I6}$ (Beschl.)       | 70,1 $\pm$ 13,5 [49,8 – 88,5]                   | 97,7 $\pm$ 1,1 [95,8 – 99,9]                    |
| $M_{I4}$ (EKG)           | 88,5 $\pm$ 5,5 [77,8 – 99,8]                    | 99,9 $\pm$ 0,6 [98,0 – 100]                     |
| $M_{I8}$ (Beschl. + EKG) | 91,4 $\pm$ 4,4 [83,5 – 100]                     | 99,7 $\pm$ 0,5 [98,6 – 100]                     |

korrekt klassifiziert. Die Ergebnisse für die beiden Torwarte und die zwei Handballspieler mit den verkürzten Datenreihen ( $P2$  und  $P12$ ) zeigen keine auffälligen Abweichungen. Nach Ausschluss der Daten von  $P2$  und  $P12$ , um eine Gleichverteilung der Datentupel für die übrigen 12 Spieler zu erreichen, erhöht sich  $\bar{R}$  nur leicht auf 91,9 %. Diese Veränderung kann jedoch bereits durch die verringerte Anzahl an zu unterscheidenden Probanden bedingt sein.

Für die Identifikation im Rahmen des Handballspielszenarios wurde geprüft, ob eine Kombination von Informationen aus EKG- und Beschleunigungssignalen ebenfalls sinnvoll ist. Insbesondere die Beschleunigungssignale enthalten Anteile sehr unterschiedlicher Körperbewegungen wie unter anderem Stehen, Gehen, Laufen, Sprints, Sprung- und Wurfbewegungen sowie von Körperkontakten zwischen Spielern. Teilweise erfolgen die Übergänge in den Signalverläufen in sehr kurzen Zeitabständen. Weiterhin stehen während Spielunterbrechungen und Pausen vornehmlich nur EKG-Informationen als Unterscheidungskriterium zwischen den Spielern zur Verfügung. Die Merkmalsselektion bestätigt diese Problematik. Für die aus den Beschleunigungssignalen berechneten Merkmalen ( $M_{I6}$ ) wird eine mittlere Sensitivität von  $\bar{R} = 70,1$  % ermittelt, für die EKG-basierte Identifikation ( $M_{I4}$ ) sind es 18,4 % mehr ( $RF_{100,70}$ -Klassifikator). Weiterhin zeigt  $R_i$  für  $M_{I6}$  signifikante Abweichungen zwischen den Handballspielern ( $\pm 13,5$  %, [49,8 – 88,5] %), welche auf die beschriebene hohe Variabilität in den Daten der einzelnen Spieler und die Unterscheidungsproblematik während Spielunterbrechungen zurückgeführt werden kann. Die zweite Informationsquelle EKG ( $M_{I4}$ ) ermöglicht jedoch auch in diesen Situationen eine Unterscheidung. Erreicht werden  $\bar{R} = 88,5$  %, wobei die Standardabweichung mit  $\pm 5,5$  % niedriger und das Minimum und Maximum von  $R_i$  mit 77,8 % bis 99,8 % höher ausfallen. Damit ist das Ergebnis leicht oberhalb der EKG-basierten Identifikation innerhalb des Laufbandszenarios V1.1 ( $\bar{R} = 84,8$  %), wobei zu beachten ist, dass die Merkmalsselektion dort mittels eines MLPs evaluiert und acht weitere Probanden identifiziert wurden.

Die mittlere Spezifität liegt für alle drei Merkmalsräume oberhalb von 97,7 % (siehe auch Tabelle 5.3).

## 5.6 Zusammenfassung und Ausblick

Die realisierte Personenidentifikation ermöglicht es den Träger des Körpersensors anhand von Charakteristika in den Signalverläufen des EKG- und Beschleunigungssensors zu erkennen. Das Verfahren ist damit unabhängig von der eingesetzten Hardware wie etwa der Seriennummer des Körpersensors oder der Nutzung einer RFID-Komponente (*Radio-Frequency*

*Identification*). Benötigt werden für die Identifikation Datenfenster von vier Sekunden Zeitlänge, dabei müssen keine Rahmenbedingungen, wie beispielsweise ruhiges Sitzen, eingehalten werden. Das Verfahren ist darauf ausgelegt auch bei einer stark variierenden Herzfrequenz und hohen Variabilität der Bewegungsmuster in den Beschleunigungsmesswerten (Schrittmuster 3 km/h bis 11 km/h sowie Handballsport) eine Identifikation durchzuführen. Weiterhin gewährleistet die kontinuierliche Identifikation zu überprüfen, ob dieselbe Person den Körpersensor weiterhin trägt; Anwendungsmöglichkeiten liegen unter anderem im medizinischen Bereich. Die realisierte Identifikation hat nicht das Ziel, die biometrische Güte eines klassischen Fingerabdruck-basierten Verfahrens zu erreichen, angestrebt wird eine Unterscheidung innerhalb von Gruppen mit etwa 20 Personen. Das Verfahren ist geeignet, um den Prozess der Annotation von Sensormesswerten von mehreren Probanden mit deren Identität zu automatisieren. Anwendungsmöglichkeiten bestehen unter anderem im Kontext der Durchführung von wiederholten Aufzeichnungen mit einem Probandenkollektiv in der Forschung, der (Präventiv-) Medizin und der Leistungsdiagnostik. Weiterhin lässt sich das Laden von Zusatzinformationen über den Probanden automatisieren, beispielsweise für eine individualisierte Trainingssteuerung oder zur Energieumsatzbestimmung und Verbesserung der Detektionsgenauigkeit von Algorithmen.

Für die Identifikation werden nach einer Signalvorverarbeitung personenspezifische Charakteristika aus den EKG- und Beschleunigungssignalen in sowohl der Zeit- als auch Frequenzdomäne extrahiert und ein Klassifikator für die Bestimmung der Identität eingesetzt. Die Evaluierung des Verfahrens erfolgte mit 22 Probanden, die auf Laufbändern Gingen und Liefen (3 km/h bis 11 km/h, V1.1). Die Probanden legten den Körpersensor mittels eines Brustgurts selbständig an und es wurden keine speziellen Vorkehrungen für die Identifikation getroffen. Die erzielte Sensitivität der Identifikation beträgt 98,1 % bei einer Spezifität von 99,9 % (RF-Klassifikator). Die durchgeführte Merkmalsselektion zeigt, dass sich die hohe Güte durch eine Kombination von physiologischen und biokinematischen Charakteristika ergibt. Mit ausschließlich Informationen des EKGs werden 84,8 % und mit den Beschleunigungsmesswerten 86,6 % erreicht. Die Kombination grenzt die realisierte Identifikation weiterhin von den im Stand der Forschung beschriebenen Verfahren ab und ermöglicht darüber hinaus eine Identifikation bei stark variierender körperlicher Belastung und Herzfrequenz.

Um weiterführend den Einfluss von Variationen in den EKG- und Beschleunigungssignalen begingt durch ein erneutes Anlegen des Körpersensors und einem zeitlichen Abstand zwischen den Aufzeichnungen (Tagesform) zu evaluieren, wurde der Versuch mit neun Probanden mit zwei Aufzeichnungen, die eine Woche auseinander lagen, wiederholt (V2). Die erste Aufzeichnung diente dem Training des Klassifikators und die zweite der Evaluation. Die erzielte Sensitivität beträgt 93,8 % bei einer Spezifität von 99,2 % (RF-Klassifikator).

Darüber hinaus erfolgte eine Evaluation im Rahmen des Mannschaftssports Handball (V3). Die Unterscheidung von 14 Handballspielern ist mit einer Sensitivität von 91,4 % bei einer Spezifität von 99,7 % möglich (RF-Klassifikator). Aufgrund von fehlenden Bewegungsmustern in den Beschleunigungsmesswerten während Spielunterbrechungen und der hohen Dynamik mit unterschiedlichen sich schnell abwechselnden Körperbewegungen, führt die Nutzung von ausschließlich der biokinematischen Charakteristika zu einer niedrigeren Sensitivität von 70,1 %; für die EKG-Informationen sind es hingegen 88,5 %.

In weiterführenden Versuchen ist die Langzeitstabilität der personenspezifischen Charakteristika zu analysieren. Zu erwarten ist, dass sich (leichte) Veränderungen über die Zeit in Abhängigkeit von beispielsweise einer Anpassung oder Optimierung der Bewegungsausführung über die Trainingseinheiten hinweg ergeben. Begegnen lässt sich diesen Veränderung durch eine automatische Aktualisierung des Vorhersagemodells indem der Klassifikator, nach einer erfolgreichen Identifikation, mit neuen Tupel trainiert wird. Weiterführend ist außerdem eine Bewertung des Taktzyklen- und Speicherbedarfs für die Portierung der Identifikation auf den Mikroprozessor des BG-V4.2 nötig, einsetzen lässt sich dazu die realisierte Analyseumgebung (siehe Kapitel 7).



## 6 Anwendungen der Parameter

Die im Rahmen der vorliegenden Arbeit realisierte Bestimmung physiologischer und biokinematischer Parameter mittels des Körpersensors BG-V4.2 sowie der Identität der tragenden Person bietet die Grundlage, in vielfältigen Anwendungen eingesetzt zu werden. Im Folgenden wird primär die Möglichkeit zur Energieumsatzbestimmung beschrieben. Darüber hinaus wird ein Ausblick auf die Nutzung zur Unterstützung externer Trackingverfahren gegeben.

### 6.1 Energieumsatzschätzung

Der tägliche Gesamtenergieumsatz (engl. *Total Daily Energy Expenditure*, TDEE) eines Menschen setzt sich aus dem Grundumsatz (engl. *Basal Metabolic Rate*, BMR), der nahrungsinduzierten Thermogenese (engl. *Thermic Effect of Food*, TEF) und dem Arbeits- / Leistungsumsatz (engl. *Physical Activity Related Energy Expenditure*, PAEE) zusammen.

$$\text{TDEE} = \text{BMR} + \text{TEF} + \text{PAEE} \quad (6.1)$$

Darüber hinaus benötigt der Mensch Energie für Wachstum, während einer Schwangerschaft und für die Laktation [165, S.7]. Die Möglichkeit, den TDEE eines Menschen in dessen natürlichem Alltag erfassen zu können, ist unter anderem im Kontext von Fehlernährung, Adipositas und Erkrankungen wie Diabetes von Bedeutung [66].

Der Goldstandard für die Erfassung des TDEEs während natürlichen Alltagsbedingungen beruht auf der Einnahme von doppelt markiertem Wasser. Anhand der Analyse täglicher Harnproben wird auf die Kohlendioxidproduktion und daraus auf den TDEE geschlossen. Die Art der körperlichen Betätigung, die Intensität und Dauer lassen sich jedoch nicht erfassen [66]. Eine weitere Methode zur Erfassung des TDEEs ist die direkte Kalorimetrie, die die Wärmeabgabe eines Menschen innerhalb einer thermisch isolierten Kammer misst. Das Verfahren gilt als sehr genau, es hat jedoch den Nachteil, dass sich die Erfassung des PAEEs auf körperliche Aktivitäten beschränkt, die in den typischerweise 15 m<sup>3</sup> großen Kammern durchgeführt werden können. Weit verbreitet ist die Methode der indirekten Kalorimetrie, die den Sauerstoffverbrauch und die Kohlendioxidproduktion in der Atemluft analysiert und daraus eine Bestimmung des TDEEs ermöglicht; neben stationären sind auch mobile Messsysteme verfügbar.

Darüber hinaus existieren Methoden, die auf physiologischen und biokinematischen Parametern aufbauen, wie sie sich mit dem Körpersensor BG-V4.2 unter Alltagsbedingungen kostengünstig und ohne Einschränkung von der Handlungsfähigkeit des Anwenders erfassen lassen. Der Fokus der im Folgenden vorgestellten Methoden liegt auf der Bestimmung des PAEEs. Nötig sind dazu zusätzlich zu den physiologischen und biokinematischen Parameter Eigenschaften wie Geschlecht (S), Alter (A) in Jahren, Körpergewicht (M) in Kilogramm und Körpergröße (H) in Zentimeter. Die realisierte Personenidentifikation ermöglicht diese Eigenschaften automatisiert aus einer Datenbank zu laden.

**Herzfrequenz** Ein von L. R. Keytel u.a. vorgestelltes Modell zur Schätzung des PAEEs beruht auf der Messung der Herzfrequenz (HF) während der Ausübung einer körperlichen Betätigung [85]. Die Grundlage des Modells bilden Belastungsuntersuchungen auf Fahrrad-

ergometern und Laufbändern mit 115 Probanden verschiedenen Geschlechts, Alters (18 bis 45 Jahre) und Körpergewichts (47 kg bis 120 kg). Während der Belastung erfolgte eine Aufzeichnung der Herzfrequenz sowie des PAEEs, ermittelt aus der mit einem Ergospirometriesystem gemessenen Sauerstoffaufnahme und Kohlendioxidabgabe. Die Analyse des Zusammenhangs zwischen den PAEE- und HF-Werten zeigte, dass für die Modellfindung zusätzlich das Geschlecht, Gewicht und Alter zu berücksichtigen sind:

$$\text{PAEE}_{\sigma} [\text{kJ}/\text{min}] = -55,0969 + 0,6309 \cdot \text{HF} + 0,1988 \cdot M + 0,2017 \cdot A \quad (6.2)$$

$$\text{PAEE}_{\phi} [\text{kJ}/\text{min}] = -20,4022 + 0,4472 \cdot \text{HF} - 0,1263 \cdot M + 0,074 \cdot A \quad (6.3)$$

Der Korrelationskoeffizient zwischen der Energieumsatzschätzung mittels des aufgestellten Modells und den Referenzwerten des Ergospirometriesystems beträgt 0,857. Ist darüber hinaus das Fitnessmaß  $\text{VO}_{\text{sub2max}}$  bekannt, kann dieses in den Modellgleichungen berücksichtigt werden und der Korrelationskoeffizient verbessert sich auf 0,913.

In das Modell von L. R. Keytel fließt die HF gewichtet mit den Faktoren 0,63 (Männer) und 0,447 (Frauen) ein. Fehler in der Herzfrequenzbestimmung wirken sich für Männer entsprechend höher aus. Die mittlere Sensitivität des auf den BG-V4.2 portierten QRS-Detektionsalgorithmus liegt für Gehen mit 3 km/h bei 99,9 %, für Laufen mit 9 km/h nimmt diese leicht auf 97,9 % ab.

**Beschleunigungsmesswerte** Weiterhin lassen sich die mit dem Körpersensor BG-V4.2 erfassbaren Beschleunigungsinformationen nutzen, um den PAEE abzuschätzen. K. Y. Chen und M. Sun berücksichtigen in ihrem Modell zur Energieumsatzschätzung die Daten von 125 Probanden (53 Männer, 72 Frauen), deren TDEE in zwei Aufzeichnungen über jeweils einen Zeitraum von 24 Stunden erfasst wurden [34]. Die Probanden hielten sich dazu in einem Raum auf, der eine Analyse des Sauerstoffverbrauchs und der Kohlendioxidproduktion ermöglichte, zusätzlich wurden Harnproben genommen. Die Schätzung mittels des realisierten nichtlinearen Vorhersagemodells berücksichtigt horizontale  $a_H$  und vertikale  $a_V$  Beschleunigungsanteile, die mittels eines dreiaxialen Beschleunigungssensors an der Hüfte der Probanden aufgezeichnet wurden:

$$\text{PAEE} [\text{kJ}/\text{min}] = b_0 \cdot a_H^{c_0} + b_1 \cdot a_V^{c_1} \quad (6.4)$$

$$b_0 = (12,81 \cdot M + 843,22)/1000 \quad (6.5)$$

$$b_1 = (38,90 \cdot M - 682,44 \cdot S + 692,50)/1000 \quad (6.6)$$

$$c_0 = (2,66 \cdot M + 146,72)/1000 \quad (6.7)$$

$$c_1 = (-3,85 \cdot M + 968,28)/1000 \quad (6.8)$$

Männer werden in der Gleichung durch  $S = 1$  und Frauen durch  $S = 2$  dargestellt. Für die zwei Aufzeichnungen beträgt die erreichte Korrelation zwischen den Ergebnissen der Energieumsatzschätzung und den Referenzwerten  $r = 0,925$  und  $r = 0,855$ . Einen weiterführenden Überblick zur Nutzung von Beschleunigungsinformationen für die Energieumsatzschätzung gibt [66].

**Gang- / Laufgeschwindigkeit und Aktivitätsart** Darüber hinaus lässt sich die mittels BG-V4.2 bestimmbare Gang- / Laufgeschwindigkeit (siehe Abschnitt 4.2) oder erkannte Aktivität (siehe Abschnitt 4.4) für die Schätzung des PAEEs nutzen. Ermittelt wird dazu das metabolische Äquivalent (engl. *Metabolic Equivalent of Task*, MET) der Tätigkeit; mit Hilfe von Angaben zur Belastungsintensität erfolgt eine weiterführende Differenzierung beispielsweise anhand des Geschwindigkeitswerts. Dabei entspricht ein MET dem ruhigen Sitzen mit einem Ruheenergieumsatz von 4,184 kJ je Kilogramm Körpergewicht und pro Stunde. Entsprechend dieser Definition wird Schlafen mit 0,9 MET und Laufen mit 10,9 km/h mit 18 MET eingeordnet [7]. Einschränkungen dieser Methode liegen in der Berücksichtigung von interindividuellen Unterschieden zwischen Menschen bezüglich Körpergewicht, Alter, Geschlecht, Effizienz der Bewegungsausführung sowie geographischen Faktoren und Umgebungsbedingungen.

A. Panagiota u. a. nutzen diesen Ansatz, um zunächst mittels eines Beschleunigungssensors im Hüftbereich die Ganggeschwindigkeit und anschließend den Energieumsatz zu schätzen [120]. Für normale Ganggeschwindigkeiten ergab der Vergleich mit Referenzwerten eines Ergospirometriesystems eine Überschätzung von 4 % (0,71 kcal), während des Laufens trat hingegen eine Unterschätzung von -3,2 % (-0,12 kcal) auf.

**Kombination physiologischer und biokinematischer Parameter** Ein Körpersensor wie der BG-V4.2 ermöglicht die Bestimmung unterschiedlicher Parameter, die sich kombiniert für die Energieumsatzschätzung nutzen lassen. Die Verwendung der Herzfrequenz und der körperlichen Aktivität, ermittelt anhand von Beschleunigungssensoren, ermöglichen es, die Genauigkeit der Energieumsatzbestimmung zu steigern [168]. Änderungen der Herzfrequenz lassen sich dazu anhand der detektierten Intensität der körperlichen Aktivität auf Plausibilität prüfen [6].

Um komplexe, dynamische und nichtlineare Beziehungen zwischen dem Energieumsatz, der Herzfrequenz und der körperlichen Aktivität im zeitlichen Verlauf abbilden zu können, schlagen I. F. Zakeri u.a. die Nutzung von *Multivariaten Adaptiven Regression Splines* (MARS) vor [168]. Die Grundlage für die Erstellung der MARS-Modelle bilden die Daten von 109 normal- und übergewichtigen Kindern, deren Energieumsatz mittels indirekter Kalorimetrie in einem Raum über eine Zeitdauer von 24 Stunden erfasst wurde. Die MARS-Modelle bestehen dabei aus einer linearen Kombination von 23 bis 28 Basisfunktionen, die zusätzlich zur Herzfrequenz und körperlichen Aktivität, die Eigenschaften Alter, Geschlecht, Gewicht, Größe, Ruheherzfrequenz (Minimum) und Herzfrequenz während des Sitzens berücksichtigen. Der mittlere prozentuale Fehler der MARS-Modelle liegt für die betrachteten unterschiedlichen Aktivitätszustände zwischen  $-0,3 \pm 8,9\%$  und  $-11,9 \pm 17,9\%$ .

Die für den BG-V4.2 realisierte Energieumsatzschätzung nutzt die physiologischen Parameter Herz- und Atemfrequenz sowie Informationen des dreiaxialen Beschleunigungssensors. Aufgrund der unterschiedlichen Einsatzbedingungen während Ruhe bis hin zu hoher körperlicher Belastung erfolgt zunächst eine Störgrößenanalyse. Bezüglich der Herzfrequenzbestimmung wird die Qualität der EKG-Erfassung (Elektrodenübergangswiderstand und Bewegungsartefakte) und für die Atemfrequenzbestimmung die Kraftmessungen der Thoraxerweiterung und -verengung (ST-Wert und Regelmäßigkeit der Spitzen) überprüft. Die

Ergebnisse der Störgrößenanalyse sind in  $HF_Q$  und  $AF_Q$  hinterlegt. Falls eine ungestörte Bestimmung möglich ist, gilt  $Q = 1$  andernfalls  $Q = 0$ . Treten Abweichungen in der Orientierung des Beschleunigungssensors durch die Anbringung auf, können diese durch eine Kalibrierung mit dem Anlegeassistent korrigiert werden. Weiterführende Informationen zu der Störgrößenanalyse sind in [185, Kap.3] beschrieben.

Für die Einordnung und Bewertung des TDEEs eines Menschen ist eine relative Darstellung sinnvoll, die von personenspezifischen Eigenschaften abstrahiert; für den BG-V4.2 wurde dazu das *Physical Activity Ratio* (PAR) gewählt. Dazu erfolgt eine Normierung des TDEEs über den individuellen Grundumsatz des Menschen [185, S.50f]. Dieser lässt sich beispielsweise mittels einer Spirometrie bestimmen oder über die folgenden Regressionsgleichungen von J. A. Harris und F. G. Benedict abschätzen [61].

$$BMR_{\sigma} [\text{kcal/Tag}] = \frac{13,7516 \cdot M}{1 \text{ kg}} + \frac{5,0033 \cdot H}{1 \text{ cm}} + \frac{6,7550 \cdot A}{1 \text{ Jahr}} + 66,4730 \quad (6.9)$$

$$BMR_{\varphi} [\text{kcal/Tag}] = \frac{9,5634 \cdot M}{1 \text{ kg}} + \frac{1,8496 \cdot H}{1 \text{ cm}} + \frac{4,6756 \cdot A}{1 \text{ Jahr}} + 655,0955 \quad (6.10)$$

Für die Bestimmung des PARs werden die physiologischen und biokinematischen Parameter des BG-V4.2 analysiert. Dazu erfolgt innerhalb von Zeitfenstern von 10 s Länge die Berechnung der arithmetische Mittel von  $HF$ ,  $AF$ ,  $|\vec{a}| = \sqrt{a_v^2 + a_{ML}^2 + a_{AP}^2}$  (alle drei Beschleunigungsachsen),  $|\vec{a}_H| = \sqrt{a_{ML}^2 + a_{AP}^2}$  (horizontale Beschleunigungsachsen) und  $|a_v| = \sqrt{a_v^2}$  (vertikale Beschleunigungsachse). Die Bestimmung des PARs berücksichtigt darüber hinaus den sportlichen Aktivitätsumfang in Stunden pro Woche ( $F$ ), das Körpergewicht ( $M$ ), die Körpergröße ( $H$ ) und den *Body Mass Index* (BMI).

$$BMI = M [\text{kg}] \cdot H [\text{m}]^{-2} \quad (6.11)$$

Die Schätzung des PARs erfolgt mittels eines MARS-Modells, welches auf Grundlage von Referenzwerten eines Ergospirometriesystems erstellt wurde. Wiederholt wurde dazu Versuch V1.3 (siehe Abschnitt A.1.3) mit 15 Probanden (10 männlich und 5 weiblich). Es erfolgte eine Erweiterung des Versuchsablaufs um eine Ruhephase zur Grundumsatzbestimmung im Sitzen (10 min) und Stehen (5 min) zu Versuchsbeginn. Es folgten Gehen und Laufen mit den Geschwindigkeiten 3, 5, 7, 9 und 11 km/h für jeweils 3 min mit einer anschließenden Ruhephase im Stehen, bis die Sauerstoffaufnahme wieder ihren Ausgangswert (Ruhe stehend) erreichte oder 10 min verstrichen waren [185, S.71f]. Das konstruierte MARS-Vorhersagemodell besteht aus 22 Basisfunktionen BF (siehe Tabelle 6.1). Ist die Bestimmung der Herzfrequenz ohne Störungen möglich (BF2 erfüllt), fließt diese über BF4 und BF14 in das Vorhersagemodell ein. Liegen Störungen vor (BF3 erfüllt), werden hingegen die Beschleunigungsinformationen mittels BF9, BF16 und BF18 verstärkt genutzt. Die Atemfrequenz fließt bei einer ungestörten Bestimmung über BF20 ein und steuert die Vorhersage mittels BF8 und BF19.

Wird die Harris-Benedict Gleichung zur Bestimmung des Grundumsatzes genutzt, weist das Vorhersagemodell im Vergleich zu den Referenzwerten des Spirometriesystems eine

Tabelle 6.1.: MARS-Modell zur Vorhersage des PARs.

|               |  |                     |   |
|---------------|--|---------------------|---|
| PAR = 6,35287 | - 0,84974 · BF1                          | - 3,36023 · BF2     | + 0,025537 · BF4 ...                    |
|               | - 0,884387 · BF5                         | - 0,000588032 · BF6 | + 0,462268 · BF10 ...                   |
|               | + 0,00771936 · BF12                      | - 0,00388988 · BF13 | + 0,10845 · BF14 ...                    |
|               | - 0,0121826 · BF15                       | - 5,84993 · BF16    | + 0,865732 · BF18 ...                   |
|               | + 0,342153 · BF20                        | + 7,06897 · BF21    | - 0,000872095 · BF22                    |
| <hr/>         |  |                     |   |
| BF1           | = max(0, 2,682 - $ \vec{a}_V $ ),        | BF12                | = max(0, M - 90) · BF8                  |
| BF2           | = (HF <sub>Q</sub> == 1),                | BF13                | = max(0, 1,74 - H) · BF11               |
| BF3           | = (HF <sub>Q</sub> == 0),                | BF14                | = max(0, HF - 111,6) · BF2              |
| BF4           | = max(0, HF - 49) · BF2,                 | BF15                | = max(0, 26,196 - BMI) · BF14           |
| BF5           | = max(0, 10,177 - $ \vec{a} $ ),         | BF16                | = max(0, 10,726 - $ \vec{a} $ ) · BF3   |
| BF6           | = max(0, M - 72) · BF4,                  | BF17                | = max(0, BMI - 25,195) · BF6            |
| BF7           | = max(0, 72 - M) · BF4,                  | BF18                | = max(0, $ \vec{a}_H $ - 2,182) · BF3   |
| BF8           | = (AF <sub>Q</sub> == 1) · BF4,          | BF19                | = (AF <sub>Q</sub> == 1) · BF16         |
| BF9           | = max(0, $ \vec{a}_V $ - 6,977) · BF3,   | BF20                | = max(0, AF - 3,996) · BF19             |
| BF10          | = max(0, 3 - F) · BF9,                   | BF21                | = max(0, 1,74 - H) · BF9                |
| BF11          | = max(0, 4,3021 - $ \vec{a}_H $ ) · BF7, | BF22                | = max(0, $ \vec{a}_H $ - 4,5623) · BF17 |

Abweichung von  $3,3 \pm 8,3$  kJ/min auf. Die Nutzung der Harris-Benedict Gleichung zeigt in Studien jedoch eine Tendenz zur Überschätzung des Grundumsatzes um 10 % bis 15 % [44]. Die Berücksichtigung des individuellen Grundumsatzes, ermittelt mit dem Spirometriesystem, reduziert die Abweichungen als Folge auf nur  $-0,05 \pm 4,8$  kJ/min.

Die Ergebnisse sind teils in [179] veröffentlicht. In die Realisierung der Schätzung des PARs sind die Ergebnisse der Masterarbeit von T. Hörmann [185] eingeflossen.

## 6.2 Unterstützung externer Trackingverfahren

In der AG K&S wird eine videobasierte Verfolgung (engl. *Tracking*) von Spielern im Mannschaftssport entwickelt, um die Lauftrajektorien von unter anderem Handball- und Basketballspielern zu bestimmen [110; 163]. Zu Beginn der Spielerverfolgung erfolgt derzeit eine manuelle Identifikation und Markierung der Spieler, um dem Trackingalgorithmus die Körpergröße und Startposition zu übergeben. In Spielsituationen mit abrupten Richtungswechseln, sich kreuzenden Lauftrajektorien und sich dicht nebeneinander oder in den Außenbereichen des Spielfelds (reduzierte Bildauflösung) aufhaltenden Spielern können Fehler in der Spielerverfolgung auftreten. Derzeit ist daher eine Überwachung durch den Nutzer nötig und es müssen teils manuelle Korrekturen vorgenommen werden.

Informationen des Körpersensors BG-V4.2 bieten zukünftig die Möglichkeit, Spieler automatisch zu identifizieren, Diskrepanzen zwischen der körperlichen Aktivität und der Lauftrajektorie aufzudecken und entsprechende Zusatzinformationen dem Trackingalgorithmus zur Verfügung zu stellen. Die initiale Identifikation der Spieler wird dabei nach dem Anlegen des

Körpersensors BG-V4.2 durchgeführt, die dabei erreichte mittlere Sensitivität beträgt 91,4 % bei einer Spezifität von 99,7 % (siehe Abschnitt 5.5.3). Der integrierte Beschleunigungssensor bietet die Möglichkeit, die Standphasen des Spielers von Phasen mit körperlicher Aktivität zu unterscheiden und weiterführend die Bewegungsintensität zu bewerten (siehe Abschnitt 4.4 universelles Aktivitätsmaß). Verfeinern lässt sich die Aktivitätsbestimmung durch Nutzung der realisierten Gang- / Laufgeschwindigkeitsbestimmung (siehe Abschnitt 4.2). So ergab eine erste Evaluation auf der Datenreihe V3 des Handball-Trainingsspiels, dass sich Gehen und Laufen mit einer Genauigkeit von mehr als 90 % unterscheiden lassen. Eine Einteilung der Geschwindigkeit in Klassen sollte in diesem Zusammenhang jedoch durch eine kontinuierliche Schätzung der Geschwindigkeit ersetzt werden, beispielsweise indem keine Maximierungsfunktion auf die Ausgabeklassen angewandt wird. Ein Abgleich der ermittelten körperlichen Aktivität und der Geschwindigkeit mit der durch den Trackingalgorithmus bestimmten Lauftrajektorie ermöglicht es, Diskrepanzen aufzudecken; ein Beispiel ist der Übersprung des *Trackers* auf einen anderen Spieler nach einem Körperkontakt oder Richtungswechsel. Wird ein Spieler durch den Trackingalgorithmus nicht mehr erkannt, können die Informationen des Körpersensors genutzt werden, um eine Interpolation der Lauftrajektorie vorzunehmen und die Aufenthaltsposition des Spielers vorherzusagen. Darüber hinaus bietet eine Fusion der Informationen des Körpersensors und des Trackingverfahrens die Möglichkeit, das Rauschen der Positionsbestimmung (z.B. während der Standphase eines Spielers) und Fehler kurzer Zeitdauer zu reduzieren; einsetzen lässt sich dazu beispielsweise ein Kalman-Filter [24, Kap.13].

Die Unterstützung beschränkt sich nicht auf das beschriebene Szenario im Mannschaftssport. Die Zusatzinformationen des Körpersensors können auch im Kontext von GPS-basierten Trackingalgorithmen genutzt werden, beispielsweise zur Fußgängernavigation im Innenbereich, wenn kein ausreichender GPS-Empfang besteht [78].

# 7 Sensorsignalverarbeitung auf Mikroprozessoren

Eine Sensorsignalverarbeitung zur Bestimmung von physiologischen und biokinematischen Parametern besteht üblicherweise aus den Verarbeitungsschritten Vorverarbeitung (z.B. Signalfilterung und Normalisierung), Extraktion von Informationen der Problemdomäne (Merkmale) und einem sich anschließenden Detektionsalgorithmus. Diese einzelnen Verarbeitungsschritte sind wiederum vielfältig anpassbar mit Auswirkungen auf die Detektionsgenauigkeit und den dazu nötigen Ressourcenbedarf. Insbesondere für die Durchführung der Sensorsignalverarbeitung auf dem Mikroprozessor eines Körpersensors sind Anpassungen nötig, um eine Ausführung in Echtzeit mit möglichst hoher Genauigkeit und langer Laufzeit des Körpersensors zu erreichen. Im folgenden Kapitel wird eine Analyseumgebung vorgestellt, die es ermöglicht, geeignete Konfigurationsparameter einer Signalverarbeitung für die Ausführung auf einem Mikroprozessor zu ermitteln. Dazu werden die Konfigurationsparameter Sensortyp und -anzahl, Aufzeichnungsfrequenz, Merkmalsraum und Detektionsalgorithmus hinsichtlich erzielter Genauigkeit und benötigtem Taktzyklen- / Energiebedarf bewertet. Das Ergebnis der Analyseumgebung stellt die diesbezüglich Pareto-optimalen Konfigurationen dar.

Das Kapitel gliedert sich wie folgt: Abschnitt 7.1 beschreibt die Motivation für die Sensorsignalverarbeitung auf Mikroprozessoren und erläutert die Ziele der Analyseumgebung. Anschließend wird in Abschnitt 7.2 ein Überblick über eingebettete Sensorsignalverarbeitung auf Mikroprozessoren von Körpersensoren gegeben. Ein möglicher Mikroprozessor für die Signalverarbeitung ist der an der AG K&S entwickelte CoreVA-Mikroprozessor [81, Kap. 8]. Der Mikroprozessor sowie Gründe für dessen Auswahl werden in Abschnitt 7.3 beschrieben. Einen Überblick der realisierten Analyseumgebung gibt Abschnitt 7.4. Dazu wird zunächst der Begriff Pareto-Optimalität eingeführt und Optimierungsansätze der Sensorsignalverarbeitung aufgezeigt. Abschnitt 7.5 beschreibt die Parametrisierung und die Ergebnisse einer exemplarisch durchgeführten Analyse der in Abschnitt 4.2 vorgestellten Geschwindigkeitsbestimmung. Eine Zusammenfassung gibt Abschnitt 7.6.

Teile dieses Kapitels sind in [173] und [180] veröffentlicht. In die Realisierung des Mikroprozessorcodes der Sensorsignalverarbeitung ist die Masterarbeit von F. Lehme [187] eingeflossen und in die Analyseumgebung die Masterarbeit von J. Einhaus [184].

## 7.1 Motivation und Ziele

Die Verarbeitung von Sensorinformationen auf dem Mikroprozessor eines Körpersensors ermöglicht es, die zu kommunizierende oder abzuspeichernde Datenmenge zu reduzieren. Für die Rohdaten eines Beschleunigungssensors fallen beispielsweise 600 b/s pro Achse (50 Hz Aufzeichnungsfrequenz und 12 b Wortbreite) an, wohingegen für die ausgewertete Laufgeschwindigkeit bereits 6 b/s ausreichen (1 Hz Aktualisierungsfrequenz und 64 Geschwindigkeitsabstufungen). Dies ist für Anwendungen, in denen Signale von mehreren Sensoren über einen mehrstündigen Zeitraum analysiert und aufgezeichnet werden sollen, von Bedeutung. Ein Beispiel ist die angestrebte kontinuierliche Überwachung von physiologischen und biokinematischen Parametern in der Rehabilitation und der Arbeitsmedizin (siehe ZIM-Kooperationsprojekte Kapitel 8). Weiterhin ist dies für Anwendungsszenarien relevant, in

denen die Bandbreite oder die Reichweite der drahtlosen Kommunikation eingeschränkt sind, sodass eine Übertragung von Sensormesswerten auf einen externen Computer zwecks Parameterbestimmung nicht störungsfrei möglich ist. Aufgrund der reduzierten Datenmenge lassen sich Zwischenspeicher realisieren, die die ermittelten Parameter vorhalten, bis eine Kommunikation möglich ist. Für den Einsatz im Mannschaftssport können dem Trainer auf diese Weise trotz eingeschränktem Kommunikationskanal Informationen zur Belastung der Sportler übermittelt werden. Darüber hinaus ermöglicht eine Verarbeitung auf dem Mikroprozessor eine direkte Rückmeldung an den Nutzer, beispielsweise haptisch (Vibrationsmotor) oder akustisch.

Die Analyse von Sensormesswerten auf einem Mikroprozessor teilt sich die zur Verfügung stehenden Ressourcen (Berechnungszeit, Speicher, Energie) mit der Betriebssoftware und der zusätzlich ausgeführten Sensorsignalverarbeitung. Dabei muss sichergestellt sein, dass neben der Verarbeitung kontinuierlich Sensormesswerte erfasst, kommuniziert und abgespeichert werden können. Weiterhin ist der Taktzyklen- / Energiebedarf minimal zu halten, um eine möglichst lange Betriebsdauer zu erreichen. Demgegenüber steht jedoch die Anforderung, eine möglichst hohe Klassifikationsgenauigkeit zu erzielen. Die Vorgaben diesbezüglich sind für das jeweilige Anwendungsszenario zu prüfen.

Klassifikationsalgorithmen sind im Allgemeinen nicht für die Ausführung auf Mikroprozessoren vorbereitet, da bei deren Entwicklung deutlich leistungsfähigere Desktop-Prozessoren die Zielplattform darstellen. Ein Wechsel von einer Gleit- auf eine Festkommaarithmetik, eine Realisierung von Multiplikationen und Divisionen als Bitschiebeoperationen, eine Verringerung der Wortbreite für Zwischenergebnisse, eine Reduzierung der Dimensionalität des Merkmalsraums oder eine Anpassung des Klassifikators sind einige Beispiele, die bei einer Portierung eines Klassifikationsalgorithmus betrachtet werden müssen. Diese Konfigurationsparameter beeinflussen einerseits den Ressourcenbedarf und andererseits die erzielte Klassifikationsgenauigkeit, sodass in Abhängigkeit von der Spezifikation des Anwendungsszenarios eine geeignete Konfiguration ermittelt werden muss. Hieraus leitete sich die Motivation ab, eine Analyseumgebung zu realisieren, die dem Entwickler eine Entscheidungsgrundlage bietet, eine geeignete Konfiguration auszuwählen.

Das Ziel ist, automatisiert eine Entwurfsraumexploration für eine eingebettete Anwendung durchführen zu können, insbesondere von Klassifikationsalgorithmen. Der Entwurfsraum umfasst dazu Konfigurationsparameter wie Sensortyp und -anzahl, Aufzeichnungsfrequenz, Fenstergröße, Merkmalskombination, Klassifikatortyp und dessen Parametrisierung. Zusätzlich sollen Eigenschaften der Hardware des Mikroprozessors, wie Anzahl und Art von funktionalen Einheiten, evaluiert werden können. Die Analyseumgebung muss dazu die Simulationen der vorgegebenen Konfigurationsmöglichkeiten durchführen. Zu einer Simulation gehört die automatisierte Datenpartitionierung, das Training und die Übertragung des gewonnenen Vorhersagemodells in einen Mikroprozessor-kompatiblen Quellcode und eine anschließende Instruktionssatzsimulator (ISS)-basierte Evaluation. Die Simulationsergebnisse sollen dabei mit den Maßen Klassifikationsgenauigkeit und benötigter Taktzyklenanzahl sowie dem daraus geschätzten Energiebedarf bewertet und automatisch die Pareto-optimalen Konfigurationen des Entwurfsraums ausgegeben werden.

Als Anwendungsbeispiel wurde eine Entwurfsraumexploration für die Geschwindigkeitsbe-

stimmung (siehe Kapitel 4.2) durchgeführt und der Kompromiss zwischen Klassifikationsgenauigkeit und benötigten Taktzyklen charakterisiert. Als Zielplattform für die Simulationen wurde der CoreVA Mikroprozessor gewählt.

## 7.2 Stand der Forschung eingebetteter Signalverarbeitung

Der Berechnungsaufwand für eine Signalverarbeitungsaufgabe und der daraus resultierende Energiebedarf des eingesetzten Mikroprozessors lassen sich auf verschiedenen Optimierungsebenen verbessern. T. Šimunić u.a. identifizierten dazu eine dreischichtige Optimierungshierarchie [145]. Auf der obersten Abstraktionsebene werden algorithmische Optimierungen an den Prozeduren vorgenommen, die den höchsten Berechnungs- / Energieaufwand aufweisen. Für diese Prozeduren können anschließend alternative Implementierungen ausgewählt werden. Auf der zweiten Ebene schlagen Šimunić u.a. Anpassungen der Datenrepräsentation vor, um Eigenschaften der Architektur der Zielplattform zu berücksichtigen. Beispielsweise fehlt Mikrocontrollern von Körpersensoren häufig ein zusätzliches Rechenwerk für Gleitkommaoperationen (engl. *Floating Point Unit*, FPU) [132], sodass diese Operationen aufwändig emuliert werden müssen. Für Gleitkommazahlen kann eine Festkommadarstellung gewählt werden, sodass sich die Berechnungen als Ganzzahloperationen durchführen lassen<sup>1</sup>. Auf der untersten Abstraktionsebene ordnen die Autoren Optimierungen am Instruktionsfluss ein, um beispielsweise die Ausführungseffizienz kritischer Schleifen durch unter anderem Auflösung mittels Abwicklung (engl. *Loop Unrolling*), Umformung oder Zusammenfassung zu erhöhen. Ein weiteres Beispiel ist die Inline-Ersetzung von Programmcode, um die Anzahl an Funktionsaufrufen zu reduzieren. Als Beispiel führen sie die Dekodierung einer MP3-Audiodatei an, bei der sich, nach Optimierung auf den vorgeschlagenen drei Ebenen, die Ausführungszeit um 92 % verkürzt.

F. Rincón u.a. analysierten einen auf einer digitalen Wavelet-Transformation basierenden EKG-Segmentierungsalgorithmus, um diesen auf einem 16 b MSP430F1611 Mikrocontroller auszuführen [132]. Für ihre in Echtzeit durchgeführte Mehrkanal-Analyse waren im Hinblick auf die begrenzten Berechnungs- und Speicherressourcen Optimierungen an dem Algorithmus und der Datenrepräsentation notwendig. Zur Bestimmung von Schwellenwerten muss der RMS-Wert von Datenblöcken berechnet werden. Die ursprüngliche Implementierung der RMS-Berechnung basierte dabei zunächst auf der Standard-C-Wurzelfunktion, die Gleitkommaoperationen benötigt. Eine Eigenimplementierung auf Grundlage des Longhand-Square-Algorithmus verbessert die Ausführungszeit. Aufgrund der fehlenden FPU des Mikrocontrollers ersetzten die Autoren Gleitkomma- durch 16 b Ganzzahloperationen. Weiterhin wurden die Puffergrößen für Eingabedaten und Wavelet-Transformation beschränkt, um eine Ausführung mit den zur Verfügung stehenden 10 kB RAM zu ermöglichen. Evaluiert wurde die optimierte Mehrkanal-Analyse in Bezug auf Segmentierungsgenauigkeit, Ausführungszeit und Speicherverbrauch. Aus energetischer Sicht führt der erhöhte Berechnungsaufwand zu einer kürzeren Betriebsdauer des Körpersensors, obwohl sich der Energieaufwand für die Funkübertragung aufgrund des reduzierten Kommunikationsvolumens um den Faktor 8,6 reduziert. Eine Ausnahme stellt die Verwendung von nur einkanaligen EKGs dar. Die Autoren

---

<sup>1</sup>Der MSP430FG4618 des BG-V4.2 bietet eine entsprechende Funktionseinheit für 16 b x 16 b Multiplikationen [76].

kamen zu dem Ergebnis, dass die Wahl eines Mikrocontrollers mit niedrigem Energiebedarf daher ein signifikantes Energieeinsparpotential für den Körpersensor bietet. Für die in der Arbeit untersuchte Shimmer-Plattform ist jedoch zu beachten, dass bereits 65,2 % des Energiebedarfs auf die mit hoher Abtastfrequenz (250 Hz) durchgeführte Analog-Digital-Wandlung des EKGs entfällt.

S. Knezevic u.a. führen eine Wavelet-Transformation zwecks Filterung von EKG-Daten mit einer sich anschließenden QRS-Detektion auf einem MSP430 Mikrocontroller durch [87]. Die Realisierung mittels einer Ganzzahlarithmetik ermöglicht dabei eine Verarbeitung in Echtzeit mit einer Genauigkeit von 99,1 %; die Evaluation erfolgte auf den MIT-BIH Datenreihen 101, 103, 202, 230 und 234.

Für die Analyse von Sensormesswerten stehen auf Desktop-Computern Methoden des maschinellen Lernens zur Verfügung. Im Folgenden wird beschrieben, wie bereits trainierte Vorhersagemodelle auch auf dem Mikrocontroller eines Körpersensors genutzt werden können. B. Lo u.a. realisierten eine Aktivitätserkennung auf Grundlage eines dreiaxialen Beschleunigungssensors (integriert in der e-AR Plattform) mit einem Bayes-Klassifikator auf Basis einer multivariaten Gaußverteilung [95]. Aufgrund des hohen Speicherbedarfs wurde das Training des Klassifikators offline durchgeführt.

N. Cotton behandelte die Umsetzung von KNNs auf Mikrocontrollern eingebetteter Systeme [39]. Die vorgestellte Bibliothek erlaubt das Training eines KNN und bietet einen automatisierten Prozess für die Portierung auf den Mikrocontroller (C-Code-Generierung) sowie für die Verifizierung der Funktionalität. Darüber hinaus wird ein auf Maschinencode-Ebene (Assembler) hoch optimiertes KNN für die Ausführung auf einem 8 b PIC-Mikrocontroller vorgestellt. J. Dunfield beschäftigte sich ebenfalls mit der Einbettung eines MLP auf einem 16 b Mikrocontroller [47]. Das MLP dient dabei der Auswertung von Inertialsensormesswerten für die Steuerung eines Quadropters. Eingesetzt wird der Mikrocontroller HC12DG128 von Motorola mit 8 kB RAM, 128 kB Programmspeicher und einer Taktfrequenz von 4 MHz. Das MLP mit einer verdeckten Schicht mit sechs Neuronen wurde offline mit einem Backpropagation-Algorithmus trainiert, um Gewichts- und Bias-Werte zu ermitteln. Dem eingesetzten Mikrocontroller fehlt ebenfalls eine FPU, sodass eine Anpassung auf eine Ganzzahlarithmetik vorgenommen wurde. Die Reduktion der Wortbreite von 32 b Ganzzahlen (Matlab-Umgebung) auf 16 b Ganzzahlen ergibt bereits eine 26-fache Beschleunigung. Für das untersuchte Anwendungsszenario reicht letztendlich eine Skalierung der Ein- und Ausgaben der Neuronen auf einen Wertebereich von 0 bis 255 (8 b) aus. Auf algorithmischer Ebene wurde eine diskrete Approximation der sigmoiden Aktivierungsfunktion durch eine Umsetzungstabelle (engl. *Lookup-Table*) mit vorab berechneten Werten vorgenommen, um den Berechnungsaufwand für die Exponentialfunktion zu vermeiden.

U. Maurer u.a. beschreiben den Einsatz von Entscheidungsbäumen für eine Aktivitätserkennung mittels der Multi-Sensor Plattform eWatch [106]. Sensormesswerte von einem zweiaxialen Beschleunigungssensor, einem Licht- und Temperatursensor sowie einem Mikrofon werden dazu auf einem 32 b Mikrocontroller (Philips LPC2106) mit 64 kB RAM, 128 kB Programmspeicher und 60 MHz Taktfrequenz verarbeitet. Auf algorithmischer Ebene verglichen die Autoren den Einfluss verschiedener Abtastfrequenzen und unterschiedlicher Merkmalskombinationen in Bezug auf die Erkennungsgenauigkeit und die benötigte Ausfüh-

rungszeit. In der Zeitdomäne wurden dazu Funktionen für die Berechnung des empirischen Mittelwerts, des RMS, der Standardabweichung, der Varianz, der Nulldurchgangspunkte, der mittleren Nulldurchgangsrates und von kumulativen Histogrammen (256 Klassen) implementiert. Zusätzlich wurde ein aus 18 Knoten bestehender Entscheidungsbaum auf dem Mikrocontroller realisiert. Die Autoren kamen zu dem Ergebnis, dass die Abtastfrequenz von 50 Hz auf 20 Hz reduziert werden kann und nicht alle implementierten Merkmale für die Aktivitätserkennung notwendig sind. Der vorgeschlagene Merkmalsraum benötigt 12114 Taktzyklen (Einsparung von 44128 Taktzyklen), was einer Ausführungszeit von 205,4  $\mu$ s entspricht. Auf einem Desktop-Computer bestimmten die Autoren die Klassifikationsgenauigkeit zusätzlich für einen K-Nächste-Nachbarn- und einen Naïve-Bayes-Klassifikator. Die höchste Genauigkeit für die Aktivitätserkennung wird mit dem Entscheidungsbaum und dem Naïve-Bayes erzielt. Die Autoren verweisen darauf, dass in [46] gezeigt wurde, dass die diskretisierte Version des Naïve-Bayes die Klassifikationsgüte von Entscheidungsbäumen übertreffen kann. Die Autoren wählten jedoch Entscheidungsbäume aufgrund des guten Kompromisses zwischen Erkennungsgenauigkeit und Berechnungsaufwand.

M. Ring u.a. untersuchten unter anderem die folgenden Klassifikationsalgorithmen auf ihre Eignung für die Nutzung auf eingebetteten Systemen [133]: lineare Diskriminanzanalyse, *Support Vector Machine*, Naïve-Bayes-Klassifikator, Nächste-Nachbarn-Klassifikator, Entscheidungsbaum und mehrschichtiges Perzeptron. Die von Ihnen vorgestellte Analyseumgebung ermöglicht es, die Klassifikatoren zu trainieren und die Klassifikationsgenauigkeit, die Anzahl an mathematischen Operationen sowie den Speicherbedarf zu bestimmen. Für die Evaluation wurde ein Zweiklassenproblem gewählt, bei dem zwischen Diabetikern und einer gesunden Kontrollgruppe unterschieden werden sollte. Für die Klassifikation von 768 Datentupel mit jeweils acht Merkmalen erzielt die *Support Vector Machine* die höchste Genauigkeit, benötigt jedoch auch die meisten Operationen und den größten Speicher. Die Autoren kamen zu dem Ergebnis, dass für eine Portierung auf einen Mikroprozessor insbesondere der Entscheidungsbaum (niedrigste Anzahl an Operationen) und die lineare Diskriminanzanalyse (niedrigster Speicherbedarf) geeignet sind.

Die Energieeffizienz eingebetteter Signalverarbeitung lässt sich weiterhin auf der Hardware-Architektur-Ebene steigern. C. Walravens und W. Dehaene zeigten, wie sich der Energiebedarf reduzieren lässt, wenn spezialisierte Hardware für die parallele Berechnung von Präfixsummen, die Bestandteil vieler Algorithmen sind, eingesetzt wird [157]. Die Autoren zeigten, dass sich der Energiebedarf um den Faktor 10 bis 20 gegenüber einem vergleichbaren handelsüblichen Mikrocontroller verringern lässt. A. Khatib u.a. nutzen eine symmetrische Mehrprozessor-Architektur, basierend auf VLIW DSPs<sup>2</sup> von STMicroelectronics, für die Analyse eines 12-Kanal-EKGs mit hoher zeitlicher Auflösung, um eine Erkennung von Fehlfunktionen des Herzens durchführen zu können [8]. Unter Verwendung von einem *System-on-a-Chip* (SoC) (hier Verarbeitungseinheit) pro EKG-Kanal ist es möglich, die Daten mit hoher Präzision in Echtzeit zu verarbeiten und den Energiebedarf für die Kommunikation zu reduzieren. B. Bösze u.a. entwickelten einen programmierbaren biomedizinischen SoC mit sehr niedrigem Energiebedarf für die Verarbeitung von EKG- und EEG-Signalen in Körpersensornetzwer-

---

<sup>2</sup>VLIW: *Very Long Instruction Word*, DSP: *Digital Signal Processor*.

ken [30]. Der SoC beinhaltet einen 32 b VLIW-Prozessor auf dem ein ASIP<sup>3</sup> realisiert wurde, um die Energieeffizienz der Biosignalverarbeitung zu erhöhen. Gefertigt in einem 90 nm CMOS-Prozess und betrieben mit einer variablen Anpassung der Versorgungsspannung beträgt die Leistungsaufnahme des SoCs 10  $\mu$ W (0,7 V Versorgungsspannung).

Im Vergleich zu den vorgestellten Arbeiten ermöglicht die realisierte Analyseumgebung eine Analyse auf der Algorithmus-Ebene (z.B. Konfigurationsparameter eines Klassifikationsalgorithmus), der Implementierungsebene (z.B. Realisierung der Aktivierungsfunktion eines MLPs mittels Umsetzungstabelle) sowie der Mikroprozessorarchitektur-Ebene (z.B. Art und Anzahl an Funktionseinheiten). Automatisiert werden dazu aus dem sich ergebenden Entwurfsraum die Pareto-optimalen Konfigurationen in Bezug auf Klassifikationsgenauigkeit, Taktzyklen- oder Energieaufwand bestimmt. Die Analyseumgebung ist flexibel realisiert, sodass der Funktionsumfang um beispielsweise Merkmale und weitere Klassifikatoren ergänzt werden kann. Durch den Austausch des ISS kann der Mikroprozessor der jeweiligen Zielplattform simuliert werden.

### 7.3 CoreVA Mikroprozessor

Die in diesem Kapitel vorgestellten Ergebnisse der Entwurfsraumexploration der Geschwindigkeitsbestimmung wurden für den CoreVA-Mikroprozessor der AG K&S ermittelt. Der CoreVA steht dabei exemplarisch für einen 32 b Mikroprozessor, der sich aufgrund der konfigurierbaren *Very Long Instruction Word* (VLIW)-Architektur für eingebettete Signalverarbeitungsaufgaben eignet, wie sie auf einem Körpersensor benötigt werden [100].

Eine VLIW-Architektur erlaubt es, mehrere Operationen oder Instruktionen zu einem langen Befehlswort zu kodieren und parallel auszuführen [105, S.121 f]. Die Ausführungszeit von Programmen kann durch die Parallelität von Instruktionen (engl.: *Instruction Level Parallelims*, ILP) erhöht werden, auch wenn diese dem System als eine Folge von aufeinanderfolgenden Instruktionen übergeben werden [48, S. 45]. Mit zunehmender Schaltungsdichte wird es möglich, ILP auch in eingebetteten Systemen anzuwenden [48, S. 45]. Der Einsatz von VLIW kann dabei die Energieeffizienz der Signalverarbeitung erhöhen, indem es die Ausführungszeit mittels Parallelität verkürzt, sodass Stromsparfunktionen des Mikroprozessors, wie beispielsweise eine Taktreduzierung, über längere Zeiträume genutzt werden können. Für weitere Informationen zu VLIW-Architekturen wird an dieser Stelle auf das Buch von J.A. Fischer u.a. verwiesen [48, Kap. 2].

Der CoreVA ist als Harvard-Architektur realisiert mit separatem Speicher für Daten und Instruktionen [84]. Diese Trennung ermöglicht es, Daten und Instruktionen in nur einem Taktzyklus zu laden. Der CoreVA verfügt über eine sechsstufige Pipeline-Architektur für das Laden und Dekodieren von Instruktionen, das Laden von Operanden, die Ausführung von Instruktionen, den Zugriff auf Datenspeicher und das Schreiben von Ergebnissen in Registern. Mittels *Pipelining* kann der Gesamtdurchsatz an Instruktionen durch Zerlegung in Zwischenschritte, die wiederum parallel ausgeführt werden, weiter erhöht werden.

Der CoreVA ist in der Hardwarebeschreibungssprache VHDL<sup>4</sup> implementiert. Für eine

---

<sup>3</sup>ASIP: *Application Specific Instruction-Set Processor*

<sup>4</sup>VHDL: *Very High Speed Integrated Circuit Hardware Description Language*.

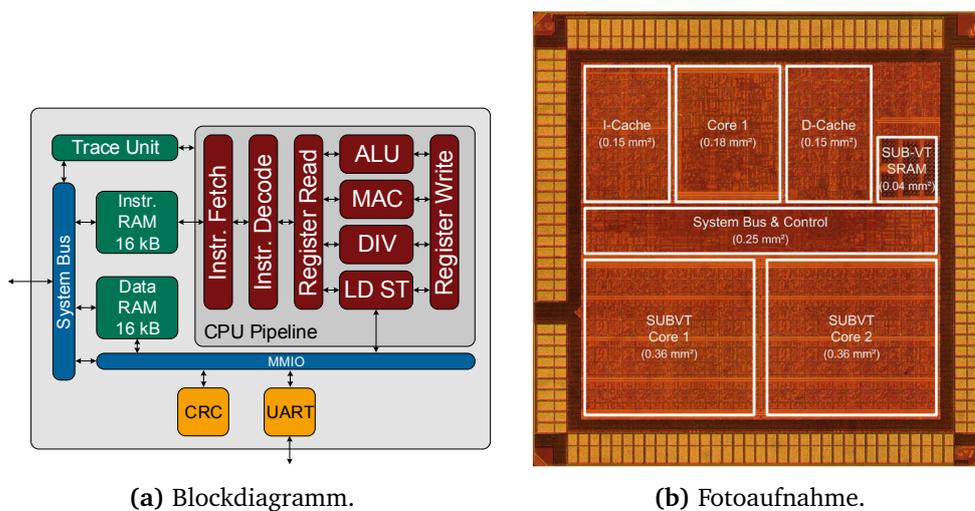


Abbildung 7.1.: (a) Blockdiagramm des CoreVA-ULP Mikroprozessors mit einer sechsstufigen Pipeline (Abbildung aus [180]). (b) Fotoaufnahme des SoC mit zwei CoreVA-ULP Prozessorkernen (Abbildung aus [100]).

Funktions- und Leistungserweiterung ist es möglich, zusätzliche funktionale Einheiten einzubinden und die Anzahl an VLIW-Slots zu definieren. Realisiert sind arithmetische logische Einheiten (engl.: *Arithmetic Logic Unit*, ALU), Multiplikationsakkumulatoren (engl.: *Multiplier Accumulator*, MAC), Dividierer (DIV)<sup>5</sup> sowie Einheiten zum Laden und Speichern (LD/ST); siehe Abbildung 7.1a. Die ALU- und MAC-Einheiten unterstützen einen SIMD (*Single Instruction Multiple Data*)-Modus für die unabhängige Ausführung zweier 16 b Datenströme. Für weiterführende Informationen wird auf die Dissertation von T. Jungeblut verwiesen [81, Kap. 4-6].

Von dem CoreVA wurden zwei Konfigurationen als ASICs<sup>6</sup> in einer 65 nm Fertigungstechnik realisiert: eine Variante in der Standardzellentechnologie von STMicroelectronics [81, Kap. 8] und eine mit einem sehr niedrigen Energiebedarf, der CoreVA-ULP von S. Lütkemeier, mittels Subschwelligwerttechnik [99; 100]. Insbesondere der CoreVA-ULP ist aufgrund des niedrigen Energiebedarfs für den Einsatz in eingebetteten Anwendungen mit beschränktem Energiebudget, wie einem Körpersensor, interessant. Mit 9,94 pJ pro Takt erreicht der 0,36 mm<sup>2</sup> große Prozessorkern sein Energieoptimum bei einer Taktfrequenz von 133 kHz und einer Versorgungsspannung von 0,325 mV. Mit der maximalen Versorgungsspannung von 1,2 V wird eine mittlere Taktfrequenz von 94,32 MHz erreicht (110,22 pJ/Takt) [100]. Für den Einsatz auf einem Körpersensor ist zukünftig insbesondere der Betrieb mit 4,2 MHz bei 500 mV Versorgungsspannung interessant. Der CoreVA-ULP wurde als Skalarprozessor realisiert mit den Funktionseinheiten MAC, DIV und LD/ST. Die ALU und die MAC unterstützen den 16 b SIMD-Modus. Auf dem Prototyp des SoC von S. Lütkemeier (siehe Abbildung 7.1b) wurden zwei CoreVA-ULP Prozessorkerne mit 32 kB konventionellem Cache-Speicher sowie einem

<sup>5</sup>Realisiert als *Division-Step-Unit* mit einer Latenz von 32 Taktzyklen.

<sup>6</sup>ASIC: *Application-Specific Integrated Circuit*.

2 kB 9-Transistor-SRAM mit einer sehr niedrigen Versorgungsspannung realisiert. Gefertigt in einem 65 nm CMOS-Prozess von STMicroelectronics hat der SoC eine Größe von 2,7 mm<sup>2</sup>. Für zusätzliche Informationen wird auf [99; 100] verwiesen.

Im Rahmen der hier durchgeführten Entwurfsraumexploration wurden zunächst Taktangaben für den CoreVA als Skalarprozessor ohne zusätzliche VLIW-Slots ermittelt. Auf Grundlage dieser erfolgte die Berechnung des Energiebedarfs für den CoreVA und den CoreVA-ULP. Die Taktangaben gelten für den UPSLA-basierten Compiler des Fachgebiets Programmiersprachen & Übersetzer der Universität Paderborn [82]. Zusätzlich wurde eine zweite Entwurfsraumexploration für den CoreVA mit zwei, drei und vier VLIW-Slots durchgeführt, um eine Optimierung des Energiebedarfs mittels Ausnutzung der Parallelität der VLIW-Befehlsarchitektur zu untersuchen.

**Gegenüberstellung MSP430FG4618** Auf dem Körpersensor der AG K&S kommt bis zur Version 4.2 der weit verbreitete Mikroprozessor MSP430FG4618 zum Einsatz (Beschreibung siehe Abschnitt 2.3); Entscheidungskriterien waren die vielfältige Peripherie und der zum Fertigungszeitpunkt 2011 niedrige Energiebedarf. Für eine zukünftige Version des Körpersensors könnte prinzipiell der CoreVA-ULP Anwendung finden. Insbesondere Sensorsignalverarbeitung, die auf eine hohe Genauigkeit angewiesen ist, profitiert von der 32 b Wortbreite. Während die 32 b Addition und Subtraktion auf dem MSP430FG4618 sechs Taktzyklen<sup>7</sup> benötigt, ist es bei dem CoreVA jeweils nur ein Takt. Für 32 b Multiplikationen benötigt der MSP430FG4618 43 Taktzyklen, für Divisionen, aufgrund der fehlenden Hardwarefunktionseinheit, sogar 436 Taktzyklen. Der CoreVA braucht einen Taktzyklus für die Multiplikationen und 32 Taktzyklen für die Divisionen. Weiterhin kann mit dem CoreVA durch den Einsatz von SIMD bei Datenströmen mit einer Wortbreite von 16 b die Leistung weiter gesteigert werden. Vorteilhaft für Anwendungen mit hohem Berechnungsaufwand<sup>8</sup> ist weiterhin, dass der CoreVA mit Taktfrequenzen von deutlich mehr als 8 MHz betrieben werden kann. Weiterhin können aufgrund des flexiblen Entwurfs des CoreVAs wiederkehrende rechenintensive Prozesse in der Signalverarbeitungskette durch spezielle Funktionseinheiten beschleunigt und unter Umständen auch energieeffizienter ausgeführt werden; als Beispiel sei der bereits realisierte Dividierer genannt.

Ein Vergleich der beiden Mikroprozessoren aus energetischer Sicht kann hier nicht erfolgen, da die Angaben zum Energiebedarf für den MSP430FG4618 neben dem Prozessorkern zusätzlich die Peripherie und den Speicher enthalten. In der Arbeit von [100] wird auf eine Realisierung eines 16 b MSP430s inklusive SRAM in ebenfalls 65 nm Subschwellewert-Technik verwiesen. Im Energieoptimum benötigt der Mikroprozessor 27,2 pJ/Takt bei 500 mV Versorgungsspannung.

Die durchgeführten Entwurfsraumexplorationen untersuchen exemplarisch den CoreVA als Zielplattform. Darüber hinaus existieren weitere Mikroprozessoren mit geringem Energiebedarf, die für den Einsatz geeignet sind (siehe auch Abschnitt 2.3). Mittels der Einbindung des jeweiligen ISS in die Analyseumgebung könnte deren Evaluation Bestandteil weiterführender

---

<sup>7</sup>Die Taktangaben wurden mit dem *IAR C/C++ Compiler for MSP430* ermittelt (Version 5.40.2).

<sup>8</sup>Komplexe Signalverarbeitungsaufgaben wie die Durchführung einer FFT (siehe Voruntersuchung Bachelorarbeit [182]) oder einer DWT mit 32 b Fixpunkt-Präzision.

Arbeiten sein.

## 7.4 Analyseumgebung zur Entwurfsraumexploration

Der folgende Abschnitt beschreibt die realisierte Analyseumgebung, die es ermöglicht, mittels einer Entwurfsraumexploration Pareto-optimale Konfigurationen zu ermitteln. Die bestimmten Konfigurationen bieten eine Entscheidungshilfe, um eine bezüglich Klassifikationsgenauigkeit und Taktzyklen- / Energiebedarf geeignete Portierung einer Anwendung auf einen Mikroprozessor vorzunehmen.

### 7.4.1 Pareto-Optimalität und Entwurfsraumexploration

Der Begriff der Pareto-Effizienz wird auf den italienischen Ingenieur, Ökonom und Soziologe V. F. Pareto (1848-1923) zurückgeführt. Formulieren lässt sich dieser als ökonomischer Effizienzbegriff: „Ein Zustand heißt Pareto-effizient, wenn keine Person besser gestellt werden kann, ohne dass eine andere Person schlechter gestellt werden kann.“ [162, S.25]. Die Eigenschaften effizient und nicht effizient erlauben noch keine Rangordnung zwischen Zuständen festzulegen; dies ist mit dem Prinzip der Pareto-Verbesserung möglich: „Ein Zustand A heißt Pareto-besser als ein Zustand B, wenn keine Person in A schlechter gestellt ist als in B und mindestens eine Person in A besser gestellt ist als in B. (...) Offenbar ist ein Pareto-effizienter Zustand genau dann erreicht, wenn eine Pareto-Verbesserung nicht mehr möglich ist“ [162, S.25]. Ein nicht Pareto-effizienter Zustand wird daher stets von mindestens einem Pareto-effizienten Zustand dominiert. Im Folgenden wird der Begriff Pareto-Optimalität synonym für Pareto-Effizienz verwendet [2; 162].

Übertragen auf das Problem einer Mehrzieloptimierung<sup>9</sup> kann die Bestimmung der Pareto-optimalen Zustände genutzt werden, um Kompromisslösungen zwischen konkurrierenden Zielgrößen zu finden, bei denen es nicht möglich ist, alle Ziele optimal zu erreichen [2, S.31]. Für die Analyse der Sensorsignalverarbeitung auf Mikroprozessoren ergeben sich für einen Klassifikationsalgorithmus die konkurrierenden Zielgrößen erzielte Klassifikationsgenauigkeit und der sich dazu ergebende Taktzyklenbedarf. Weitere Zielgrößen stellen beispielsweise der Energie- und Speicherbedarf dar. Die Zielgrößen werden bei einem Klassifikationsalgorithmus durch dessen Konfiguration beeinflusst, wie beispielsweise der Sensoranzahl, der Aufzeichnungsfrequenz, dem Merkmalsraum oder dem Klassifikator und dessen Parametrisierung.

Die Konfigurationsmöglichkeiten (Entwurfsentscheidungen) bilden dabei einen Entwurfsraum. Für sehr umfangreiche Entwurfsräume kann eine Eingrenzung der Anzahl an Entwurfsentscheidungen nötig werden, um eine vertretbare Analysezeit zu erreichen. Für die im Rahmen der vorliegenden Arbeit exemplarisch durchgeführte Entwurfsraumexploration der Gang- / Laufgeschwindigkeit wurde der Entwurfsraum anhand der Ergebnisse aus Abschnitt 4.2 eingegrenzt, sodass die resultierenden Konfigurationsmöglichkeiten in einer vertretbaren Analysezeit ohne weitere Eingrenzungen geprüft werden konnten. Die Analyse des Entwurfsraums (Entwurfsraumexploration) stellt ein Mehrzieloptimierungsproblem dar [62, S.18], bei dem sich der Gedanke der Pareto-Optimalität nutzen lässt, um nicht Pareto-optimale Konfigurationen und damit Konfigurationen, die vermieden werden sollen, nicht weiter zu

---

<sup>9</sup>Gegenüber der Einzieloptimierung gibt es nicht eine optimale Lösung, die mit einer Minimum- / Maximumfunktion bestimmt werden kann.

betrachten. Das Ergebnis der Entwurfsraumexploration besteht in der Regel aus einer Menge an Pareto-optimalen Lösungen [62, S.18], welche auch als Pareto-Front (auch: Pareto-Set, Pareto-Frontier) bezeichnet werden.

### 7.4.2 Parametrisierung der Entwurfsraumexploration

Ausgangspunkt einer Entwurfsraumexploration kann eine Referenzimplementierung sein, bei der die Sensorsignale mit hoher Aufzeichnungsfrequenz und Wortbreite vorliegen, ein komplexer Merkmalsraum eingesetzt wird, die Konfiguration des Klassifikators auf eine möglichst hohe Genauigkeit ausgelegt ist und Berechnungen als Gleitkommaoperationen ausgeführt werden. Ziel ist es, mit der Analyseumgebung und unter Berücksichtigung der Spezifikation des Anwendungsszenarios eine bezüglich Genauigkeit und zu Verfügung stehenden Ressourcen geeignete Pareto-optimale Konfiguration zu ermitteln. Folgender Abschnitt erläutert Konfigurationsmöglichkeiten von Klassifikationsalgorithmen, die mittels der Analyseumgebung simuliert werden können.

Auf der Ebene der Datenrepräsentation wird geprüft, mit welcher Wortbreite und Aufzeichnungsfrequenz die Sensorsignale erfasst und gespeichert werden müssen. Für die Verarbeitung auf Mikroprozessoren ohne FPU ist in diesem Zusammenhang insbesondere die Umstellung von einer Gleitkomma- auf eine Festkommaarithmetik von Bedeutung [105, S.119 ff]. Üblicherweise liegen Sensorsignale mit einer Wortbreite zwischen 12 b und 16 b vor. Für Zwischenergebnisse kann die Wortbreite jedoch höher ausfallen; ein Beispiel ist die Berechnung des RMS oder der Varianz eines Datenfensters für die Geschwindigkeitsbestimmung [187, Kap.7]. Eine Beschränkung der Wortbreite kann aufgrund von Rundungsfehlern die Genauigkeit verringern, jedoch auch zu einer Reduzierung des Taktzyklen- und Speicherbedarfs genutzt werden. Ziel ist es daher, eine für die Spezifikation des Anwendungsszenarios geeignete Festkommadarstellung zu ermitteln.

Die Aufzeichnungsfrequenz beeinflusst den Informationsgehalt der Sensorsignale (Bandbreite). Für die Ausführung auf einem Mikroprozessor kann jedoch eine Anpassung der Aufzeichnungsfrequenz nötig sein, um die nötige Taktzyklenanzahl sowie den Arbeitsspeicherbedarf (z.B. Signalpuffer und Zwischenergebnisse) zu reduzieren. So steigt etwa die Komplexität der Berechnung des Mittelwertes linear mit der Aufzeichnungsfrequenz an. Für die Geschwindigkeitsbestimmung sollte die Aufzeichnungsfrequenz jedoch ausreichend hoch gewählt werden, um die wichtigen Merkmale, wie Spitz-Tal-Wert und Varianz, auch bei einer hohen Laufgeschwindigkeit zuverlässig aus den Schrittmustern erfassen zu können.

In diesem Zusammenhang ist auch eine geeignete Fensterlänge zu bestimmen. Sie hat direkten Einfluss auf die zur Verfügung stehende Anzahl an Sensormesswerten und muss derart gewählt sein, dass die Signalcharakteristika der zu bestimmenden physiologischen oder biokinematischen Parameter enthalten sind; sie beeinflusst daher die Klassifikationsgenauigkeit. Eine zu große Fensterlänge erhöht jedoch den Speicherbedarf und verzögert die Klassifikation. Falls möglich sollte die Länge als Zweierpotenz darstellbar sein, um die Realisierung von Multiplikationen und Divisionen als Bitschiebeoperationen zu ermöglichen.

Der Ressourcenbedarf der Merkmalsberechnung macht einen wesentlichen Anteil des Gesamtbedarfs aus (siehe auch Ergebnisse Abschnitt 4.2.7). Eine Reduktion der Komplexität des Merkmalsraums bietet daher ein hohes Optimierungspotential. Mithilfe einer Merk-

malss Selektion lassen sich dazu die Merkmale und deren Kombinationen mit dem höchsten Informationsgehalt ermitteln. Insbesondere ist anhand der Ergebnisse abzuwägen, ob rechenaufwändige Funktionen, wie die FFT oder die DWT, benötigt werden oder ob Einbußen in der Klassifikationsgenauigkeit für einen niedrigeren Berechnungsaufwand eingegangen werden können. Weiterhin sollte geprüft werden, welche Sensoren für die Klassifikation besonders wichtig sind, da bei gleicher Merkmalsberechnung beispielsweise der Berechnungsaufwand und der Speicherbedarf linear mit der Anzahl an Sensoren ansteigen.

Eine Optimierung der Konfiguration des Klassifikators bietet ebenfalls die Möglichkeit, den Ressourcenbedarf zu reduzieren. Bei einem MLP muss sich eine zu hohe Anzahl an Neuronen in der verdeckten Schicht nicht negativ auf die Klassifikationsgenauigkeit auswirken, sie erhöht allerdings den Taktzyklen- und Speicheraufwand (siehe auch Abschnitt 4.2.6.3). Eine zu starke Reduzierung der Neuronenanzahl birgt hingegen die Gefahr, dass die Netzstruktur unterbesetzt ist und das Klassifikationsproblem nicht ausreichend abgebildet wird.

Weiterhin sind Optimierungen der Implementierung rechenintensiver wiederkehrender Funktionen zu evaluieren. Für die Merkmalsberechnung sind dies beispielsweise die Wurzelfunktion oder das Sortierverfahren, für das MLP ist es die Berechnung der Aktivierungsfunktion. Die Auswirkungen der Optimierungen auf die Klassifikationsgenauigkeit können mittels der Entwurfsraumexploration geprüft werden. Insbesondere eine diskrete Approximation der Aktivierungsfunktion durch eine Umsetzungstabelle (engl. *Lookup-Table*) kann die Ausgabe eines MLPs signifikant beeinflussen [47]. In Zusammenhang mit Entscheidungsbäumen ist zu prüfen, ob die Knotenanzahl reduziert werden kann (Beschneidung), um Taktzyklen und Arbeitsspeicher einzusparen.

Zusätzlich zu den Optimierungen der Datenrepräsentation und der Konfiguration des Klassifikationsalgorithmus kann eine Reduzierung des Ressourcenbedarfs durch die Nutzung von Compileroptimierungen oder manuell vorgenommener Anpassungen des Assemblercodes geprüft werden. Weitere Optimierungsmöglichkeiten bietet die Realisierung zusätzlicher Rechenwerke oder Ausführungseinheiten. Mittels des ISS lassen sich diesbezüglich gezielt verschiedene Hardwarekonfigurationen untersuchen.

### 7.4.3 Analyseumgebung

Die Genauigkeit und der Taktzyklenbedarf eines Klassifikationsalgorithmus sind von den angesprochenen verschiedenen Konfigurationsparametern abhängig, deren Anforderungen sich aus der Anwendungsspezifikation ableiten. Anstelle einer Standardkonfiguration für Signalabtastung, Datenrepräsentation, Merkmalsextraktion und Klassifikator ist es daher sinnvoll, eine geeignete Konfiguration in Abhängigkeit von einer Anwendungsspezifikation zu ermitteln. Häufig ist es jedoch eine Vielzahl an möglichen Konfigurationen, die simuliert werden müssen. Eine Automatisierung der Simulationen ist daher notwendig, um die Entwurfsraumexploration praktikabel zu machen. Der folgende Abschnitt stellt die dazu realisierte Analyseumgebung vor.

#### 7.4.3.1 Funktionalität

Die realisierte Analyseumgebung ermöglicht es, die beschriebenen Optimierungsmöglichkeiten auf den unterschiedlichen Ebenen zu evaluieren. Auf der Anwendungsebene bietet die Analyseumgebung dazu die Möglichkeit, typische Klassifikationsalgorithmen der Mustererken-

nung, die aus einer Merkmalsextraktion mit einer sich anschließenden Klassifikationsphase bestehen, zu analysieren.

Startend auf der Ebene der Datenerfassung kann der Einfluss der Aufzeichnungsfrequenz simuliert werden. Dazu lassen sich Frequenzen vorgeben und die höherfrequenten Sensorsignale werden in den einzelnen Simulationsschritten auf die jeweils niedrigere Frequenz heruntergerechnet (engl. *Downsampling*). In diesem Zusammenhang ist es auch möglich, den Sensortyp sowie die Sensoranzahl und die für die Merkmalsberechnung wichtige Fensterlänge zu definieren. Anschließend können die zu untersuchenden Merkmale und deren Kombinationen angegeben werden. Derzeit verfügt die Merkmalsberechnung über Funktionen zur Berechnung der Varianz, des RMS und des Spitze-Tal-Werts. Die Analyseumgebung erlaubt die Einbindung und Evaluation unterschiedlicher Klassifikatoren (derzeit MLP und EB). Zusätzlich zu dem Klassifikatortyp können für diesen unterschiedliche Konfigurationen getestet werden. Für das MLP ist es die Anzahl an Neuronen in der verdeckten Schicht und die Aktivierungsfunktion. Für den EB kann eine Mindestanzahl an Trainingstupel pro Blatt für die Teilungsentscheidung vorgegeben und eine Beschneidung durch entweder eine Umwandlung von Knoten in Blätter oder eine Verschiebungen von Unterbäumen (Knotenanhhebung) erlaubt werden.

Weiterhin können verschiedene Implementierungsvarianten, Compileroptionen und Assembleroptimierungen evaluiert werden. Durch den Austausch des ISS lassen sich unterschiedliche Mikroprozessoren und der Einsatz zusätzlicher Rechenwerke oder Ausführungseinheiten in der Analyseumgebung berücksichtigen.

Eine Simulation erfolgt jeweils durch das Training eines Klassifikators und dem sich anschließenden Test des erstellten Modells. Die Aufteilung der zur Verfügung stehenden Daten ist auf 60 % Training-, 20 % Validierung- und 20 % Teststupel voreingestellt und kann frei angepasst werden. Weiterhin ist es möglich, für Training und Test zwei Datenreihen zu nutzen. Als Beispiel ist die Parametrisierung der Entwurfsraumexploration für die Laufgeschwindigkeitsbestimmung in Abschnitt 7.5.1 beschrieben.

Die Ausgabe der Analyseumgebung besteht unter anderem aus dem trainierten Vorhersagemodell des Klassifikators, Statistiken des Trainingsvorgangs (z.B. Dauer, Epochenanzahl und MSE im Verlauf) sowie der durchgeführten Klassifikation unter Nutzung der Teststupel (z.B. Klassifikationsgenauigkeit, Taktzyklen- und Energiebedarf), den Pareto-optimalen Konfigurationen und deren Visualisierung. Letztere stellt den Entwurfsraum mit den Ergebnissen aller durchgeführten Simulationen dar; die Pareto-optimalen Konfigurationen sind durch eine Markierung hervorgehoben. Auf der Ordinate ist die Klassifikationsgenauigkeit absteigend (das Optimum mit 100 % liegt im Nullpunkt) aufgetragen und auf der Abszisse aufsteigend die Taktzyklenanzahl. Das Optimierungsziel richtet sich gegen den Nullpunkt, welcher das bestmögliche Ergebnis hinsichtlich Klassifikationsgenauigkeit und Taktzyklenanzahl darstellt<sup>10</sup>. Die Simulationsergebnisse können entsprechend der einzelnen Konfigurationsparameter (z.B. Merkmalskombination und Klassifikatortyp) eingefärbt werden (siehe Abbildungen 7.2 und 7.3).

---

<sup>10</sup>Es kann zwar eine Genauigkeit von 100 % erreicht werden, jedoch keine Taktanzahl von null.

---

**Pseudocode 7.1** : Pseudocode des Ablaufs der Entwurfsraumexploration in der Analyseumgebung. (**Input**) beschreibt die Parametrisierung. Für jeden der  $n$  Konfigurationsparameter wird ein weiteres Array mit den zu simulierenden Ausprägungen übergeben.

---

**Input** : Konfigurationsparameter ( Sensoren, Aufzeichnungsfrequenzen, Fensterlängen, Merkmalsräume, Klassifikatorkonfigurationen ), Datenreihen, ...

**Output** : Konfigurations-IDs, Klassifikationsmodelle, Genauigkeiten, Taktzyklen, Energiebedarfsschätzungen, Pareto-optimale Konfigurationen, ...

Erzeuge Konfigurations-ID;  
 Lade Datenreihe und reduziere Tupelanzahl auf gemeinsame Mindestanzahl an Tupel pro Klasse;  
 Teile Datenreihe in Trainings- und Testtupel auf;  
**for** Konfigurationsparameter 1 **do**  
 | **for** Konfigurationsparameter 2 **do**  
 | | ... **for** Konfigurationsparameter  $n$  **do**  
 | | | Lade Trainingstupel;  
 | | | Trainiere Klassifikationsmodell;  
 | | | Übertrage Modell in Mikroprozessorcode und kompiliere;  
 | | | Lade Testtupel;  
 | | | Simuliere Konfiguration mit ISS;  
 | | | Erzeuge Ausgabe der Ergebnisse;  
 | | **end**  
 | **end**  
**end**

---

### 7.4.3.2 Technische Realisierung

Die Analyseumgebung ermöglicht die Parametrisierung und die Ausführung der einzelnen Verarbeitungsschritte der Entwurfsraumexploration. Sie ist in der quelloffenen Skriptsprache TCL<sup>11</sup> geschrieben und beinhaltet Funktionsaufrufe, die in den Programmiersprachen Matlab-Skriptsprache, C und Java realisiert sind.

Die beschriebenen Möglichkeiten der Parametrisierung können im Initialisierungsbereich der Analyseumgebung vorgenommen werden, in der auch die zu verwendende Datenreihe angegeben wird. Zunächst erfolgt eine Aufteilung der Sensorsignale in Trainings-, Validierungs- und Testdatenreihen. Falls eine ungleichmäßige Klassenverteilung der Tupel der Datenreihe vorliegt, wird die Anzahl an Tupel auf die ermittelte Mindestanzahl an Tupel pro Klasse beschnitten.

Anschließend werden die unterschiedlichen Konfigurationen entsprechend der Parametrisierung iterativ erstellt und simuliert (siehe Pseudocode 7.1). Für jede Simulation werden dazu die entsprechenden Merkmale berechnet. Die Merkmalsberechnung ist in für den Mikroprozessor angepassten C-Code implementiert und entstand unter anderem im Rahmen

---

<sup>11</sup>TCL: *Tool Command Language*, weiter Informationen siehe [www.tcl.tk/about](http://www.tcl.tk/about), letzter Zugriff 06.07.2015.

der Masterarbeiten von [184; 187]. Der Funktionsumfang der Signalverarbeitungsbibliothek ist so gewählt, dass eine Entwurfsraumexploration für die Laufgeschwindigkeitsbestimmung durchgeführt werden konnte. Die Implementierung der Funktionen ist in [184, Kap.5] beschrieben. Die Fensterlängen zur Merkmalsberechnung wurden dabei als Zweierpotenzen darstellbar gewählt, sodass Divisionen effizient als Schiebeoperationen durchgeführt werden können. Die Berechnungen sind als Festkommaarithmetik mit einer maximalen Wortbreite von 32 b realisiert.

Anschließend erfolgt das Training des Klassifikators für den erstellten Merkmalsraum. Für das MLP wird dazu eine Netzstruktur entsprechend des Merkmalsraums, der Anzahl verdeckter Neuronen und der Ausgabeklassen angelegt. Das Training der Netzkonfiguration erfolgt mittels eines Backpropagation-Algorithmus der FANN Bibliothek [116]. Während des Trainingsvorgangs wird der MSE auf den Validierungstupel überwacht. Der Abbruch erfolgt bei einem Anstieg des MSEs oder falls die vorgegebene Höchstzahl an Epochen erreicht ist. Aufgrund der zufälligen Initialisierung der Neuronengewichte besteht beim MLP das Risiko, dass das Training frühzeitig aufgrund eines lokalen Minimums beendet wird. Um dieses Risiko einzuschränken, wird der Trainingsvorgang dreimal wiederholt und die Netzkonfiguration ausgegeben, die den niedrigsten Validierungsfehler aufweist. Zur Erhöhung der Ausführungsgeschwindigkeit des MLPs wurde eine mit sechs Stützstellen diskrete Approximation einer sigmoiden Aktivierungsfunktion (siehe Abschnitt 4.2.6.2) gewählt; diese ist jedoch austauschbar. Im Anschluss an den Trainingsvorgang des Klassifikators werden die ermittelten Neuronengewichte in Festkommazahlen mit einer Wortbreite von 32 b konvertiert. Die Induktion des Entscheidungsbaums erfolgt durch Einbindung von Funktionen der WEKA-Bibliothek [57]. Im Anschluss erfolgt eine automatische Übersetzung des Entscheidungsbaums in C-Code. Die Ergebnisse werden in den Mikroprozessorcode eingefügt und dieser wird kompiliert.

Die Simulation der Klassifikation erfolgt anschließend auf den 20 % unabhängigen Teststupel unter Verwendung des ISS des hier betrachteten CoreVA-Mikroprozessors. Die Ausgabe der Analyseumgebung erfolgt in Form von Textdateien (Simulationsprotokoll, trainiertes Modell des Klassifikators und Statistiken) und als Grafikdateien in den Formaten EPS und PNG (Ergebnisse Entwurfsraum mit Pareto-optimalen Konfigurationen). Unter Verwendung der an der AG K&S entwickelten Umgebung zur Verteilung der Rechenlast [83] können die Simulationen auf mehreren Prozessorkernen und x86-Linux-Computern parallel erfolgen [184, Kap.6].

## 7.5 Evaluation der Gang- und Laufgeschwindigkeitsbestimmung

Im folgenden Abschnitt werden die Simulationsergebnisse der durchgeführten Entwurfsraumexploration vorgestellt und die Pareto-optimalen Konfigurationen bezüglich Klassifikationsgenauigkeit und Taktzyklenbedarf (Energiebedarf) aufgezeigt.

### 7.5.1 Parametrisierung

Der im Folgenden beschriebene Entwurfsraum wurde bereits vorab anhand der Ergebnisse aus Abschnitt 4.2 eingrenzt. Die betrachteten Konfigurationsparameter umfassen die Aufzeichnungsfrequenz, die Achsenanzahl des Beschleunigungssensors, die Merkmalskom-

bination, den Klassifikatortyp und dessen Parametrisierung. Für die Simulationen wurde eine konstante Fensterlänge von zwei Sekunden gewählt, um eine ausreichende Anzahl an Sensormesswerten pro Datenfenster für die Berechnung der Merkmale zu gewährleisten. Dies ist beispielsweise bei einer Verkürzung der Fensterlänge auf unter eine Sekunde in Verbindung mit einer niedrigen Aufzeichnungsfrequenz von 4 Hz nicht gegeben. Das Risiko, dass sich die Klassifikationsgenauigkeit aufgrund eines Mangels an zur Verfügung stehenden Sensormesswerten verändert, ist für diesen Fall größer als der Einfluss der Fensterlänge selbst.

Die für die Entwurfsraumexploration verwendete Testdatenreihe (V1.1) wurde mit einer Aufzeichnungsfrequenz von 150 Hz aufgezeichnet. Die Laufgeschwindigkeitsbestimmung kann jedoch auf Beschleunigungssignalen mit niedrigerer zeitlicher Auflösung durchgeführt werden (siehe Abschnitt 4.2.3). Im Rahmen der Entwurfsraumexploration wurden die Auswirkungen einer Reduzierung der Aufzeichnungsfrequenz auf bis zu 4 Hz simuliert (siehe Tabelle 7.1), indem die Anzahl an Beschleunigungsmessungen pro Zeit verringert wurde (engl. *Downsampling*).

Die vertikale Beschleunigungsachse enthält den Großteil der Laufgeschwindigkeitsinformationen (siehe Ergebnisse aus Kapitel 4.2). Um den Taktzyklenbedarf zu reduzieren, wurde anhand von zwei Kombinationen, bestehend aus Beschleunigungen entlang der drei orthogonalen Achsen und nur vertikaler Beschleunigungen, der Einfluss auf die Klassifikationsgenauigkeit geprüft.

Die Auswahl an Merkmalen beschränkte sich mit der Varianz, dem Spitze-Tal-Wert und dem quadratischen Mittelwert (RMS) auf die Zeitdomäne. Zunächst erfolgte ein Test der Merkmale einzeln ( $K_M = \{ 1, 2, 3 \}$ ), anschließend in Zweierkombinationen und abschließend zusammen.

In der Entwurfsraumexploration wurden die zwei Klassifikatortypen MLP und Entscheidungsbaum mit jeweils unterschiedlichen Konfigurationen miteinander verglichen. Dies ist insbesondere interessant, da das MLP auf der Datenreihe V1.1 und der Entscheidungsbaum auf V2 bessere Ergebnisse erzielen (siehe Abschnitt 4.2.5). Für das MLP wurde die Anzahl an Neuronen in der verdeckten Schicht zwischen 3 und 30 variiert. Während des Trainingsvorgangs wurde für den Entscheidungsbaum eine Beschneidung in Form einer Umwandlung von Knoten in Blätter und einer Verschiebungen von Unterbäumen zugelassen (Konfidenzschwellenwert 0,25). Für die Induktion wurde die Mindestanzahl an Trainingstupel pro Blatt für die Teilungsentscheidung variiert und keine Beschränkung auf Binärbäume vorgenommen.

Insgesamt umfasst die Entwurfsraumexploration 1008 Konfigurationen welche in der Tabelle 7.1 zusammengefasst sind.

Tabelle 7.1.: Übersicht über die 1008 Konfigurationen, die in der Entwurfsraumexploration für die Laufgeschwindigkeitsbestimmung simuliert wurden. Die Abkürzungen der Konfigurationsparameter des EB bedeuten: Beschneidung durch (U) Umwandlung von Knoten in Blätter oder (V) Verschiebungen von Unterbäumen, (-) markiert dabei jeweils die Negation, (T) Anzahl an Trainingstupel pro Blatt.

| Konfigurationsparameter | Wertebereich                                       | Kürzel                   | Sim. |
|-------------------------|--|--------------------------|------|
| Aufzeichnungsfreq. [Hz] | { 4, 9, 18, 37, 75, 150 }                          | $K_{f_s}$                | 6    |
| Achsen                  | $\{ a_V, \{ a_{AP}, a_{ML}, a_V \} \}$             | $K_A = \{ 1, 3 \}$       | 2    |
| Merkmalskombination     | $\{ Var, ST, RMS, \}$                              | $K_M = \{ 1, 2, 3 \}$    | 7    |
|                         | $\{ Var, ST \}, \{ Var, RMS \}, \{ RMS, ST \}, \}$ | $K_M = \{ 4, 5, 6 \}$    |      |
|                         | $\{ Var, ST, RMS \} \}$                            | $K_M = 7$                |      |
| <b>Klassifikator</b>    |  |                          | 12   |
| MLP Neuronenanzahl      | { 3, 5, 7, 10, 15, 20, 30 }                        | $K_N$                    |      |
| EB Konf.parameter       | $\{ U, T = 2, V \}$                                | $K_{EB} = 1$             |      |
|                         | $\{ -U, T = \{ 2, 4, 6 \}, V \}$                   | $K_{EB} = \{ 2, 3, 4 \}$ |      |
|                         | $\{ U, T = 2, -V \}$                               | $K_{EB} = 5$             |      |

Gesamt: 1008

### 7.5.2 Datenmaterial

Für die Entwurfsraumexploration der Laufgeschwindigkeitsbestimmung wurde die Datenreihe aus V1.1 genutzt, da diese mit 22 Probanden und jeweils Geschwindigkeiten von 3 km/h bis 9 km/h am umfangreichsten ist. Für jede Geschwindigkeitsstufe enthält die Datenreihe 27000 dreidimensionale Beschleunigungsvektoren pro Proband (siehe Anhang A.1.1 für weiterführende Informationen).

### 7.5.3 Ergebnisse

Die Simulationen der 1008 Konfigurationen mit der Analyseumgebung erfolgten unter Verwendung des ISS des CoreVA-Mikroprozessors. Die Datenreihe wurde dazu prozentual in 60 % Trainings-, 20 % Validierungs- und 20 % Testtupel aufgeteilt. Die Validierungstupel wurden nur für den Trainingsvorgang des MLPs benötigt. Parallelisiert auf 30 Prozesse, die verteilt auf 12 Computern ausgeführt wurden, dauerten die Simulationen 9 h 42 min<sup>12</sup>. Aufgrund der Möglichkeit, die Simulationen in diesem Zeitraum durchführen zu können, erfolgte keine zusätzliche Eingrenzung des Entwurfsraums.

Jede Konfiguration wurde dabei mit den Maßen Klassifikationsgenauigkeit und benötigter Taktzyklenanzahl bewertet. Die Schätzung des Energiebedarfs für die einmalige Ausführung des Klassifikationsalgorithmus erfolgte auf Grundlage der ermittelten Taktzyklenanzahl und des mittleren Energiebedarfs des CoreVA-ULPs [100]. In den sechs Abbildungen 7.2a bis 7.3b sind die Simulationsergebnisse aller 1008 Konfigurationen bezüglich Klassifikationsgenauig-

<sup>12</sup>Intel Xeons CPUs W3565 und W3670 (3,2 GHz) mit 12 GB bis 24 GB RAM, Ubuntu 10.04.02 LTS.

Tabelle 7.2.: Ausgewählte Pareto-optimale Konfigurationen der Entwurfsraumexploration für die Laufgeschwindigkeitsbestimmung. Betrachtet wurden die Konfigurationsparameter: Achsenanzahl ( $K_A$ ), Aufzeichnungsfrequenz ( $K_{f_s}$ ), Merkmalsraum ( $K_M$ ), Klassifikator ( $K_K$ ), Neuronenanzahl ( $K_N$ ) und Konfiguration des EB ( $K_{EB}$ ). Angegeben sind der Taktzyklenbedarf (gesamt und Klassifikatoranteil) und die Klassifikationsgenauigkeit  $\bar{R}$ .

| $P$ | $K_A$ | $K_{f_s}$<br>[Hz] | $K_M$ | $K_K$ | $K_N$ | $K_{EB}$ | Takte | Anteil $K_K$<br>[%] | $\bar{R}$<br>[%] |
|-----|-------|-------------------|-------|-------|-------|----------|-------|---------------------|------------------|
| 1   | 3     | 75                | 7     | MLP   | 10    | -        | 22422 | 23,8                | 93,92            |
| 2   | 3     | 75                | 7     | EB    | -     | 5        | 17152 | 0,3                 | 93,64            |
| 7   | 1     | 37                | 1     | MLP   | 3     | -        | 3815  | 50,6                | 93,01            |
| 8   | 1     | 18                | 5     | MLP   | 5     | -        | 3802  | 71,6                | 92,33            |
| 9   | 1     | 18                | 1     | MLP   | 3     | -        | 3020  | 64,2                | 92,22            |
| 10  | 1     | 18                | 1     | EB    | -     | 2        | 1117  | 3,2                 | 92,16            |
| 11  | 1     | 9                 | 1     | EB    | -     | 2        | 722   | 5,0                 | 90,28            |
| 15  | 1     | 4                 | 2     | EB    | -     | 2        | 204   | 17,6                | 84,66            |

keit und Taktzyklenanzahl dargestellt. Das Optimierungsziel, eine möglichst hohe Genauigkeit bei möglichst niedriger Taktzyklenanzahl zu erreichen, befindet sich im Koordinatenursprung, die Optimierungsrichtung ist durch Pfeile verdeutlicht. In jeder Abbildung ist ein Konfigurationsparameter (Aufzeichnungsfrequenz, Achsenanzahl, Merkmalsraum, Klassifikator und dessen Parametrisierung) nach möglicher Ausprägung unterschiedlich eingefärbt, um den Einfluss zu veranschaulichen. Für die Auswahl einer Konfiguration zwecks Portierung auf den Mikroprozessor sind jedoch nur die (eingekreisten) Pareto-optimale Konfigurationen relevant.

Die Klassifikationsgenauigkeit der 15 Pareto-optimale Konfigurationen ( $P$ ) reicht von 84,7% bis 93,9%<sup>13</sup>. Eine Ausführung des Klassifikationsalgorithmus benötigt dabei zwischen 204 und 22422 Takte. Zur besseren Übersicht ist in der Tabelle 7.2 nur eine Auswahl der 15 Pareto-optimale Konfigurationen gegeben, die vollständige Liste ist im Anhang in der Tabelle B.8 angegeben. Die folgende Ergebnisdarstellung konzentriert sich auf die Pareto-optimale Konfigurationen und es wird beschrieben, welche Auswirkungen die einzelnen Konfigurationsparameter haben. Dazu müssen jedoch stets die Ausprägungen der übrigen Konfigurationsparameter zusätzlich berücksichtigt werden, um sicherzustellen, dass diese nicht begrenzend Einfluss nehmen. Beispielsweise führt eine Erhöhung der Anzahl an verdeckten Neuronen nicht zu einer höheren Klassifikationsgenauigkeit, falls die Aufzeichnungsfrequenz der Signale zu stark reduziert wird.

Die Simulation der Reduzierung der Aufzeichnungsfrequenz der Beschleunigungssignale auf 4 Hz führt zu einem signifikanten Verlust an Laufgeschwindigkeitsinformationen, die Klassifika-

<sup>13</sup>Im Vergleich werden mit der in Matlab realisierten Laufgeschwindigkeitsbestimmung mit Gleitkommaarithmetik eine nur 1,5% höhere Klassifikationsgenauigkeit erreicht (siehe Abschnitt 4.2.5, Genauigkeit für  $M_{G2}$ ).

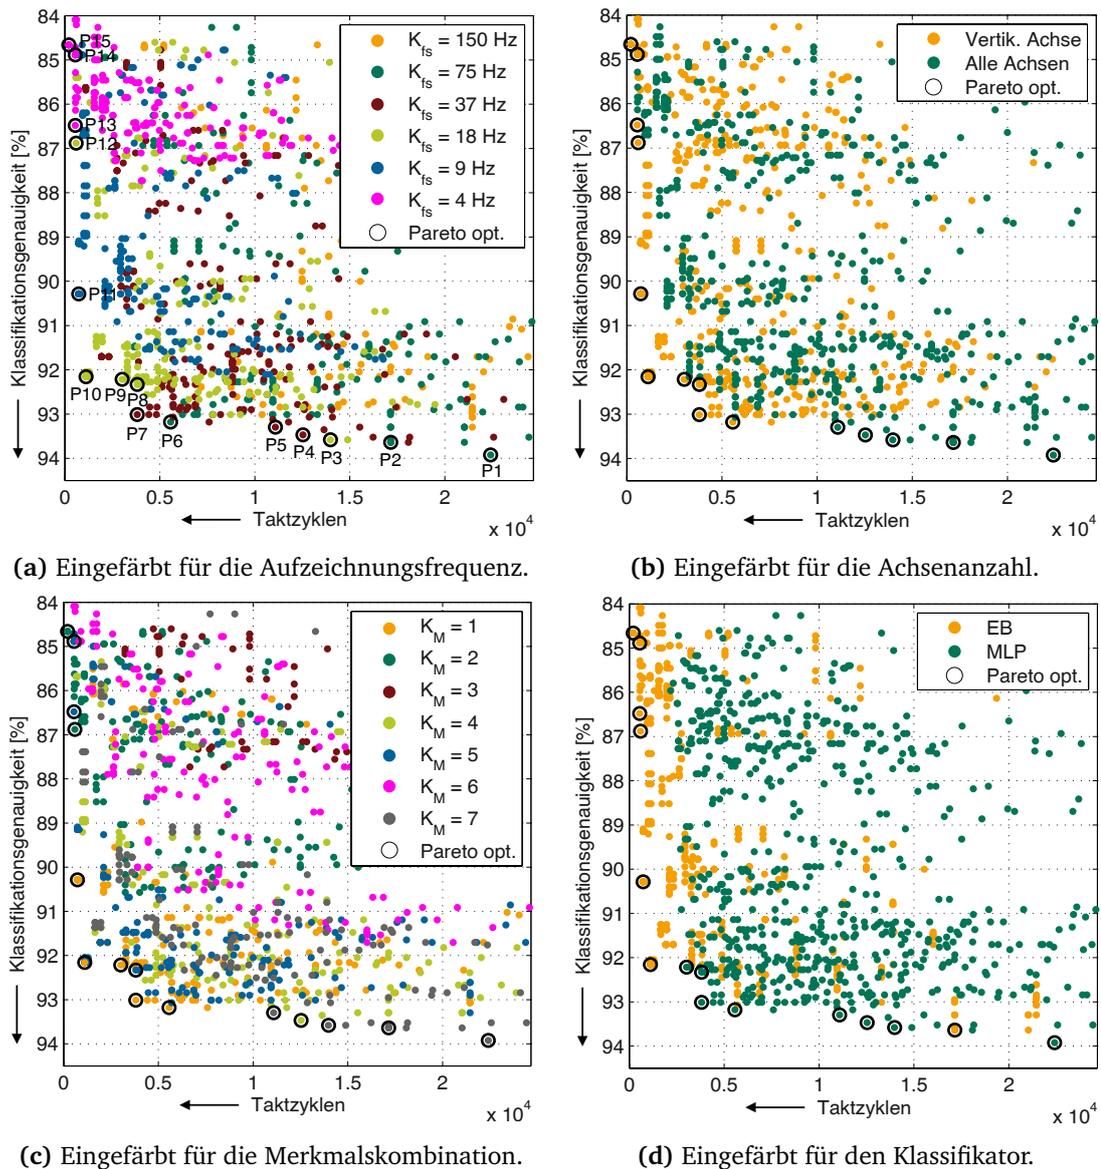
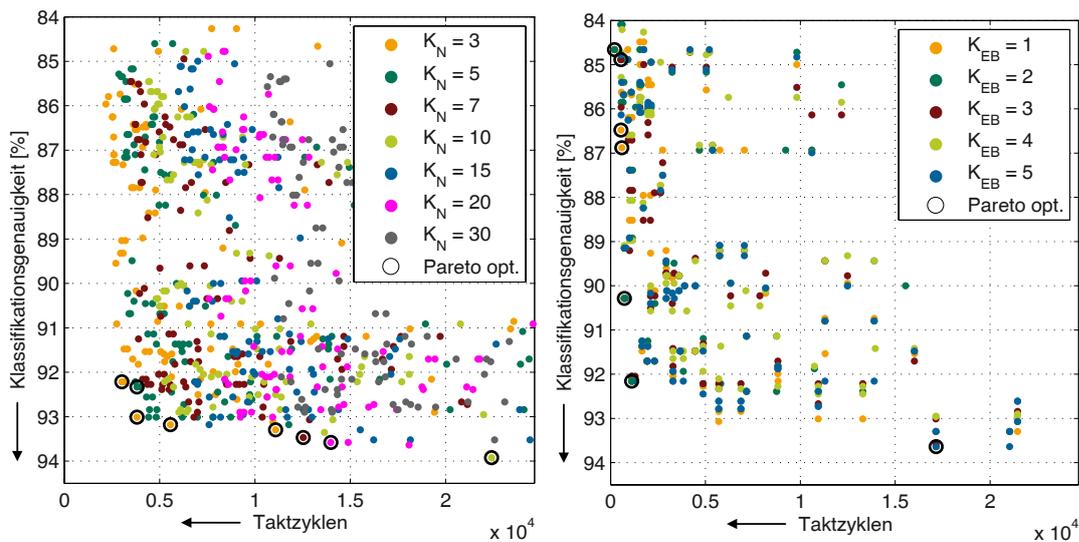


Abbildung 7.2.: Ergebnisse der 1008 Simulationen eingefärbt für die unterschiedlichen Konfigurationsparameter (siehe Tabelle 7.1). Die Ergebnisdarstellung ist auf die Bereiche der Pareto-optimalen Konfigurationen mit der niedrigsten und höchsten Genauigkeit sowie Taktzyklenanzahl begrenzt. Die Pfeile zeigen in Richtung Optimierungsziel.

tionsgenauigkeit sinkt als Folge auf unter 88 % (siehe Abbildung 7.2a). Dieser Zusammenhang deckt sich mit den Beobachtungen, dass Spitzenbeschleunigungen des Fersen-Auftreffens insbesondere bei höheren Laufgeschwindigkeiten nicht ausreichend erfasst werden können. Eine Aufzeichnungsfrequenz von 9 Hz ist für den Erhalt von Charakteristika des Schrittz-



(a) Ergebnisse eingefärbt für die Anzahl an verdeckten Neuronen. (b) Ergebnisse eingefärbt für die EB-Konfiguration.

Abbildung 7.3.: Ergebnisse der 1008 Simulationen eingefärbt für die Konfigurationsmöglichkeiten des MLPs und des EBs. Die Ergebnisse des jeweils anderen Klassifikators sind ausgeblendet.

klus im vertikalen Beschleunigungssignal, insbesondere für höhere Laufgeschwindigkeiten, weiterhin zu niedrig. In Kombination mit den Merkmalen in der Zeitdomäne reichen die Geschwindigkeitsinformationen jedoch bereits bei dieser niedrigen Aufzeichnungsfrequenz aus, um vier Geschwindigkeitsstufen mit bis zu etwa 92 % Genauigkeit zu unterscheiden. So wird mit der Pareto-optimalen Konfiguration *P11* auf Grundlage von ausschließlich des Varianz-Merkmal, berechnet aus dem vertikalen Beschleunigungssignal bei einer simulierten Aufzeichnungsfrequenz von 9 Hz, eine Genauigkeit von 90,3 % erreicht. Eine höhere Aufzeichnungsfrequenz von 18 Hz führt zu Genauigkeiten zwischen 91 % und 93,6 %; 18 Hz sind in fünf Pareto-optimalen Konfigurationen vertreten. Mit steigender Aufzeichnungsfrequenz (37 Hz) verbessert sich die Klassifikationsgenauigkeit tendenziell weiter, das Maximum wird bei 75 Hz erreicht (*P1*). Die Aufzeichnungsfrequenz kann daher mindestens um die Hälfte gegenüber der ursprünglichen Implementierung (Matlab) reduziert werden.

Die Betrachtung der Achsenanzahl teilt die Pareto-Front in zehn Konfigurationen, die auf ausschließlich vertikalen Beschleunigungen basieren, mit denen bis zu 93,2 % Genauigkeit (*P6*) erreicht werden und fünf Konfigurationen, die alle Beschleunigungsachsen verwenden, mit denen Genauigkeiten bis zu 93,9 % erzielt werden (siehe Abbildung 7.2b). Die vertikale Beschleunigungsachse enthält die entscheidenden Geschwindigkeitsinformationen in Form der Auf- und Abwärtsbewegung des Körpers; dies deckt sich mit den Ergebnissen aus Kapitel 4.2. In Anbetracht des nur geringen Zugewinns an Genauigkeit ist eine Reduktion auf nur vertikale Beschleunigungen eine sinnvolle Maßnahme, um den Taktzyklenbedarf für die Ausführung auf dem Mikroprozessor zu reduzieren (linearer Zusammenhang,  $\frac{2}{3}$  Ersparnis

für die Merkmalsberechnung).

Die drei Pareto-optimalen Konfigurationen mit der höchsten Genauigkeit basieren auf dem vollständigen Merkmalsraum ( $K_M = 7$ ), gefolgt von der Konfiguration ( $K_M = 4$ ) bestehend aus den beiden wichtigsten Merkmalen Varianz und Spitze-Tal-Wert (siehe Abbildung 7.2c). Das RMS-Merkmal ( $K_M = 3$ ) kann zwar in Kombination mit der Varianz ( $K_M = 5$ ) die Genauigkeit steigern ( $P = \{8, 10, 13, 14\}$ ), einzeln eingesetzt führt es jedoch zu keiner Pareto-optimalen Konfiguration. Mit dem Spitz-Tal-Wert ( $K_M = 2$ ) hingegen werden zwei Pareto-optimale Konfigurationen unterhalb von 87% erreicht. Eine Erklärung dafür kann die zusätzliche hohe intraindividuelle Variabilität in der Spitzenbeschleunigung korrespondierend zu dem Fersen-Auftreffen sein. Fünf Pareto-optimale Konfigurationen basieren auf dem Varianz-Merkmal ( $K_M = 1$ ) mit Genauigkeiten oberhalb von 92%. Die Eignung des Merkmals für die Geschwindigkeitsbestimmung deckt sich mit den Beobachtungen aus Kapitel 4.2 und der Literatur [12].

Die Wahl des Klassifikators teilt, ähnlich wie die Achsenanzahl, die Pareto-Front in sechs Pareto-optimale Konfigurationen, die auf Entscheidungsbäumen basieren und eine Genauigkeit von bis zu 92,2% erreichen sowie in acht Konfigurationen, die auf MLPs basieren und bis zu 93,9% erzielen (siehe Abbildung 7.2d). Die Konfiguration *P2* stellt diesbezüglich eine Ausnahme dar, wobei mit einem Entscheidungsbaum die zweitbeste Klassifikationsgenauigkeit von 93,6% erreicht wird. Die dazu benötigte Taktzyklenanzahl liegt auf einem ähnlichen Niveau wie bei MLPs mit vergleichbarer Genauigkeit. Im Allgemeinen erzielen vornehmlich MLP-basierte Konfigurationen hohe Genauigkeiten oberhalb von 93%. Für Genauigkeiten unterhalb von 92,2% bieten hingegen Entscheidungsbäume ein signifikant besseres Verhältnis bezüglich Genauigkeit und Taktzyklenbedarf. Der erhöhte Taktzyklenbedarf für MLPs wird beispielsweise an den Konfigurationen *P9* und *P10* deutlich, die sich nur bezüglich des Klassifikators unterscheiden. *P9* benötigt etwa das 2,7-fache an Taktzyklen, wobei 1939 Taktzyklen auf das MLP und nur 36 Taktzyklen auf den EB entfallen. Die Klassifikationsgenauigkeit der beiden Konfigurationen liegt mit 92,22% und 92,16% auf dem gleichen Niveau.

Um den Einfluss der Anzahl an Neuronen in der verdeckten Schicht auf die Genauigkeit und die Taktzyklenanzahl abschätzen zu können, wurden die übrigen Parameter festgehalten. Weiterhin wurden Konfigurationen aus den Ergebnissen der Entwurfsraumexploration ausgewählt, die auf dem vollständigen Merkmalsraum ( $K_M = 7$ ) und den drei Beschleunigungssignalen (Aufzeichnungsfrequenz 75 Hz) basieren, um sicherzustellen, dass diese Parameter keinen begrenzenden Einfluss aufweisen. Die Konfiguration mit der höchsten Genauigkeit (*P1*) besteht aus zehn Neuronen, jedoch werden bereits mit drei Neuronen 93% Genauigkeit erreicht. Die Genauigkeitszunahme durch zusätzliche Neuronen ist für die Laufgeschwindigkeitsbestimmung mit etwa 1% gering. Dies deckt sich mit den Beobachtungen aus Kapitel 4.2, wobei jedoch bereits mit drei Neuronen über 96% erreicht werden. Der Taktzyklenaufwand erhöht sich im Durchschnitt um  $\approx 420$  Taktzyklen pro Neuron (siehe auch Rechtsverschiebung auf der Taktzyklenachse mit steigender Neuronenanzahl, Abbildung 7.3a). Eine Reduzierung der Neuronen bietet damit ein hohes Einsparpotential an Taktzyklen für die Geschwindigkeitsbestimmung auf einem Mikroprozessor.

Die Pareto-optimale Konfiguration *P2* mit der höchsten Genauigkeit für einen Entscheidungsbaum besteht aus einem beschnittenen Binärbaum, bei dem Knoten in Blätter umge-

wandelt, jedoch keine Unterbäume verschoben wurden ( $K_{EB} = 5$ ). Bis auf die Konfiguration  $P14$  erfolgte die Induktion der übrigen Pareto-optimalen Konfigurationen mit einer Mindestanzahl von zwei Trainingstupel pro Blatt. Eine Erhöhung dieser Mindestanzahl führt zu keiner Verbesserung. Die Pareto-optimalen Konfigurationen ergeben keine für die Laufgeschwindigkeitsbestimmung zu bevorzugende Parametrisierung des Induktionsalgorithmus (siehe Abbildung 7.3b).

**Wiederholung der Entwurfsraumexploration** Aufgrund der zufälligen Initialisierung der Neuronengewichte des MLPs führt der Trainingsvorgang zu unterschiedlichen Netzkonfigurationen. Für jede Konfiguration wurden die MLPs jeweils dreimal trainiert, um ein Vorhersagemodell mit einem möglichst geringen MSE nahe des globalen Minimums auszuwählen (siehe Abschnitt 4.1.1.2). Dennoch kann die optimale Lösung nicht garantiert werden, daher wurde die Entwurfsraumexploration ein zweites Mal wiederholt, um zu überprüfen, ob die Grundaussagen der ersten Durchführung weiterhin gelten.

Das Ergebnis ist eine Menge von 16 Pareto-optimalen Konfigurationen, diese sind mit einem tiefgestellten  $W$  markiert (siehe Anhang Tabelle B.9). Die höchste Klassifikationsgenauigkeit von 93,9% wird mit einem Entscheidungsbaum erreicht ( $P1_W$ ). Ein MLP mit 10 Neuronen in der verdeckten Schicht erzielt 93,8% Genauigkeit. Im Vergleich zur ersten Ausführung beträgt die dazu nötige Aufzeichnungsfrequenz anstelle von 75 Hz nur 37 Hz.  $P1_W$  benötigt 11380 Taktzyklen mehr als  $P1$  und ist daher nicht für eine Portierung auf den Mikroprozessor eines Körpersensors vorzuziehen. Der hohe Taktzyklenbedarf entsteht durch die Merkmalsberechnung, die Beschleunigungssignale mit 150 Hz Aufzeichnungsfrequenz verarbeitet und anteilig 99,8% der Gesamtaktzyklenanzahl ausmacht. Beide Konfigurationen nutzen ebenfalls den vollständigen Merkmalsraum  $K_M = 7$ . Ausgenommen von  $P1_W$  zeigen die Ergebnisse ebenfalls, dass eine Aufzeichnungsfrequenz zwischen 18 Hz und 75 Hz ausreichend ist, wobei ab 37 Hz auch bei der Wiederholung bereits Klassifikationsgenauigkeiten oberhalb von 93% erreicht werden. Auch in der Wiederholung beruhen Konfigurationen höherer Genauigkeit, bis auf die Ausnahme von  $P1_W$ , auf MLPs.

**Auswahl für Mikroprozessorportierung** Auf Grundlage der Ergebnisse der Entwurfsraumexploration wird im Folgenden eine Konfiguration für die Portierung der Geschwindigkeitsbestimmung auf den CoreVA-Mikroprozessor vorgeschlagen. Insbesondere bei einem eingeschränkten Energiebudget ist eine Beschränkung auf die Nutzung von ausschließlich der vertikalen Achse des Beschleunigungssensors sinnvoll. Mediolaterale und anteriorposteriore Beschleunigungen enthalten zwar ebenfalls Geschwindigkeitsinformationen, weisen jedoch höhere interindividuelle Variationen auf (siehe auch Eignung zur Personenidentifikation). Die Merkmalsberechnung benötigt anteilig im Allgemeinen mehr Taktzyklen als der Klassifikator. Insofern stellt die so erzielte Reduzierung des Taktzyklenbedarfs der Merkmalsberechnung um  $\frac{2}{3}$  eine wichtige Optimierung des Ressourcenverbrauchs dar; diese Maßnahme beschränkt sich nicht auf den CoreVA-Mikroprozessor.

Für die betrachtete Datenreihe bietet die auf einem Entscheidungsbaum basierende Konfiguration  $P10$  einen guten Kompromiss zwischen Genauigkeit und Taktzyklenbedarf. Im Vergleich benötigt  $P9$  bei annähernd gleicher Genauigkeit (+0,06%) 1903 Taktzyklen mehr.

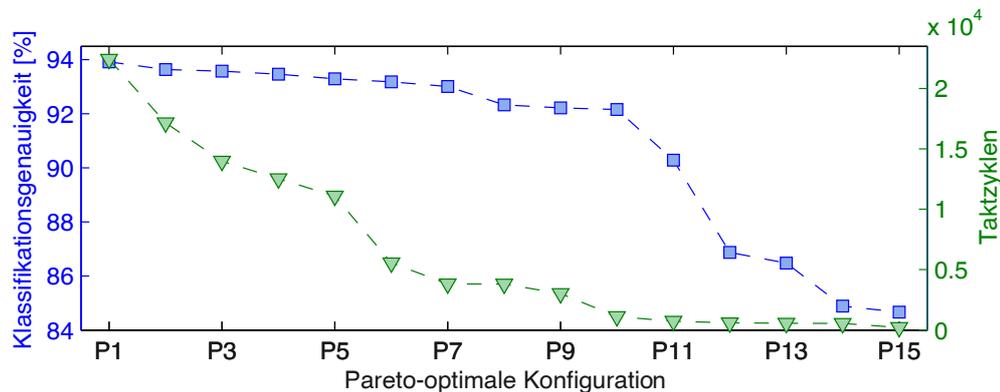


Abbildung 7.4.: Zusammenhang zwischen Klassifikationsgenauigkeit und benötigten Taktzyklen der Laufgeschwindigkeitsbestimmung (15 Pareto-optimale Konfigurationen, erste Entwurfsraumexploration).

Für die Konfiguration *P11* sind es zwar 395 Taktzyklen weniger, die Genauigkeit reduziert sich jedoch um 1,88 % (siehe Abbildung 7.4). Für eine Klassifikationsgenauigkeit von 92,2 % werden für die Konfiguration *P10* nur 1117 Taktzyklen benötigt, was einem Energiebedarf von 24,2 nJ pro Geschwindigkeitsklassifikation für den Prozessorkern des CoreVAs bei einer Taktfrequenz von 42,5 MHz entspricht. Für die Geschwindigkeitsbestimmung kann auch der CoreVA-ULP im Energieoptimum bei 133 kHz genutzt werden, falls sich Betriebssoftware und Signalerfassung zusätzlich in Echtzeit ausführen lassen. Der Energiebedarf lässt sich dadurch auf 11,1 nJ reduzieren. Der mittlere Energiebedarf für die beiden Prozessorkonfigurationen wurde aus [81; 100] entnommen.

Soll alternativ eine MLP-basierte Konfiguration genutzt werden, ist *P7* mit einer Genauigkeit von 93,01 % bei einem Bedarf von 3815 Taktzyklen zu empfehlen. Mit *P7* steigert sich die Genauigkeit gegenüber *P8* und *P9* ohne eine signifikante Zunahme des Taktzyklenbedarfs. *P6* hingegen verbessert die Genauigkeit nur geringfügig (+0,06 %), benötigt jedoch 1749 Taktzyklen mehr als *P7*. Für *P7* erhöht sich der Energiebedarf pro Geschwindigkeitsbestimmung auf 83 nJ (CoreVA) und 38 nJ (CoreVA-ULP).

Weiterführend wurde geprüft, ob bezüglich *P10* und *P7* eine Sensorsignalverarbeitung auf dem Mikroprozessor mit einer anschließenden drahtlosen Übertragung des Geschwindigkeitswerts einen niedrigeren Energiebedarf ergibt als die Übertragung der dazu nötigen Beschleunigungssignale (Rohdaten). Zuzüglich zu den 24,2 nJ für die Berechnung des Geschwindigkeitswerts (*P10*) fallen 1314 nJ für die drahtlose Kommunikation mittels eines ANT-Transceivers (73 nJ/b [121]) an, sodass sich ein Gesamtenergiebedarf von 1338 nJ ergibt. Der Berechnung sind 3 b für den Geschwindigkeitswert (Darstellung von acht Geschwindigkeitsstufen), 15 b Redundanz<sup>14</sup> für Störungen im Funkkanal bei einer Sendefrequenz von 1 Hz zu Grunde gelegt. Die Konfiguration *P10* basiert auf dem Merkmal Varianz, berechnet

<sup>14</sup>Alternativ als bidirektionale Kommunikation realisierbar.

Tabelle 7.3.: Gegenüberstellung des Energiebedarfs für die drahtlose Übertragung von Rohdaten ( $R$ ) und der ausgewerteten Geschwindigkeit ( $V$ ). Angegeben ist der Energiebedarf pro Geschwindigkeitsbestimmung für die Konfigurationen  $P10$  und  $P7$ , dem CoreVA und CoreVA-ULP sowie einem ANT- und IR-UWB-Transceiver.

|       | ANT (73 nJ/b) |        |      | IR-UWB (1,65 nJ/b) |        |      |            |
|-------|---------------|--------|------|--------------------|--------|------|------------|
|       | R [nJ]        | V [nJ] | R/V  | R [nJ]             | V [nJ] | R/V  |            |
| $P10$ | 15768         | 1338   | 11,8 | 356                | 54     | 6,6  | CoreVA     |
|       |               | 1325   | 11,9 |                    | 41     | 8,7  | CoreVA-ULP |
| $P7$  | 97236         | 1397   | 69,6 | 2198               | 112    | 19,6 | CoreVA     |
|       |               | 1352   | 71,9 |                    | 68     | 32,3 | CoreVA-ULP |

aus mit 18 Hz aufgezeichneten vertikalen Beschleunigungsmesswerten mit einer Wortbreite von jeweils 12 b. Im Vergleich werden für die drahtlose Kommunikation der Beschleunigungsmesswerte (ohne Redundanz), die für eine Geschwindigkeitsbestimmung benötigt werden (Zeitfenster von 1 Sekunde), 15768 nJ benötigt. Dies entspricht der zwölffachen Energiemenge gegenüber der Geschwindigkeitsbestimmung auf dem CoreVA-Mikroprozessor mit einer anschließenden drahtlosen Übertragung der Geschwindigkeit.

Bei Einsatz der Konfiguration  $P7$  steigt insbesondere der Energiebedarf für die drahtlose Übertragung auf 97236 nJ, da Beschleunigungssignale von allen drei Achsen mit einer Sendefrequenz von 37 Hz ( $P7$ ) verwendet werden (Faktor 70). Bei Einsatz eines IR-UWB-Transceivers mit einem sehr niedrigem Energiebedarf von 1,65 nJ/b [41] benötigt die drahtlose Kommunikation für  $P10$  das 7- bis 9-fache und für  $P7$  das 20- bis 32-fache (siehe Tabelle 7.3). Die Durchführung der Sensorsignalverarbeitung auf dem Mikroprozessor mit einer anschließenden drahtlosen Übertragung des Geschwindigkeitswerts ist daher aus energetischer Sicht für die hier betrachteten Konfigurationen sinnvoll.

**CoreVA-VLIW** Die bisherigen Ergebnisse basieren auf Simulationen mit dem CoreVA realisiert als Skalarprozessor. Eine Möglichkeit, die Energieeffizienz weiter zu verbessern, bietet die Nutzung von Parallelität der VLIW-Befehlsarchitektur. Die parallele Ausführung von Instruktionen ermöglicht es, abhängig von dem Mikroprozessorcode und dem Compiler, die Ausführungszeit zu verkürzen. Die VLIW-Slots benötigen jedoch, abhängig von deren Anzahl, zusätzliche Energie. Dieser Zusammenhang wurde für den CoreVA-VLIW mit ein bis zu vier VLIW-Slots am Beispiel der Laufgeschwindigkeitsbestimmung in einer weiteren Entwurfsraumexploration untersucht. Die Berechnung des Energiebedarfs erfolgte anhand der Taktzyklenanzahl und des durchschnittlichen Energieverbrauchs der jeweiligen CoreVA Konfiguration. Um die Simulationsdauer zu reduzieren, wurden die beschriebenen Ergebnisse der ersten Entwurfsraumexploration genutzt, um den Suchraum bezüglich der Konfigurationsparameter des Klassifikationsalgorithmus auf die 126 wichtigsten Konfigurationen einzuschränken (Konfigurationsbeschreibung siehe [180]).

Auf Grundlage der Datenreihe V1.1 erfolgte die Simulation von 504 Konfigurationen; dabei

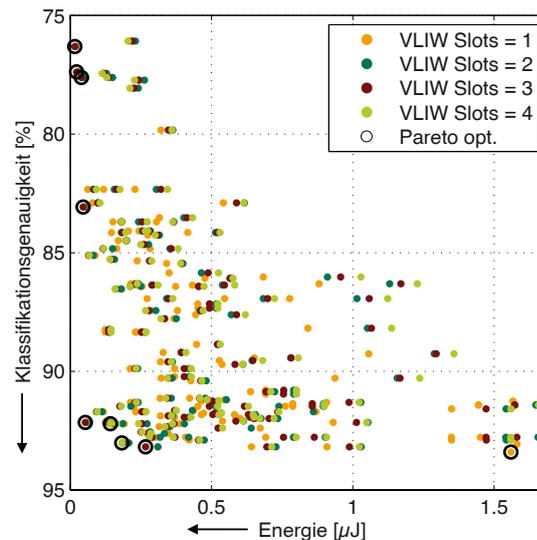


Abbildung 7.5.: Ergebnisse der 504 Simulationen der Entwurfsraumexploration eingefärbt für die unterschiedliche Anzahl an VLIW-Slots.

wurden neun Pareto-optimale Konfigurationen ermittelt. Für die höchste Klassifikationsgenauigkeit von 93,4% ergibt sich für den CoreVA als Skalarprozessor ein Energiebedarf von  $1,559 \mu\text{J}$  pro Geschwindigkeitsbestimmung. Die niedrigste Energie pro Klassifikation beträgt  $0,015 \mu\text{J}$  (drei VLIW-Slots) und führt zu einer Genauigkeit von 76,3%. Für die Merkmale Varianz, Spitze-Tal-Wert und RMS kann eine Beschleunigung von 60%, 100% und 130% für einen CoreVA mit zwei, drei und vier VLIW-Slots erreicht werden. Die Ausführung des Entscheidungsbaums kann nur um bis zu 10% und die des MLPs um 32%, 47% und 65% beschleunigt werden.

In der Pareto-Front sind sechs CoreVA-Konfigurationen mit drei VLIW-Slots, zwei mit vier VLIW-Slots und eine Konfiguration als Skalarprozessor vertreten (siehe Abbildung 7.5). Die Berechnung des verwendeten Spitze-Tal Merkmals profitiert nur geringfügig von der Parallelität der Befehlsarchitektur, sodass dadurch der CoreVA als Skalarprozessor eine Pareto-optimale Konfiguration darstellt. Ein CoreVA mit drei VLIW-Slots ist aufgrund des besseren Verhältnisses aus Fläche zu Energiebedarf gegenüber einer Konfiguration mit vier VLIW-Slots, die einen Flächenoverhead von 21% aufweist, vorzuziehen. Für eine weiterführende Darstellung der Ergebnisse wird an dieser Stelle auf [180] verwiesen.

## 7.6 Zusammenfassung und Ausblick

Eine Optimierung der Signalverarbeitung ist insbesondere auf eingebetteten Systemen mit begrenzten Berechnungskapazitäten und Energieressourcen wichtig, um eine Analyse von Sensormesswerten in Echtzeit sowie eine ausreichend lange Betriebszeit des Systems zu ermöglichen. Hierzu wurde eine Analyseumgebung mit dem Ziel realisiert, unter anderem Klassifikationsalgorithmen für die Verarbeitung von Sensormesswerten auch auf Mikroprozessoren verfügbar zu machen. Klassifikationsalgorithmen bestehen aus Funktionen

zur Merkmalsberechnung sowie der eigentlichen Klassifikation und sind im Allgemeinen in hohem Maße konfigurierbar. Die realisierte Analyseumgebung ermöglicht, automatisiert unterschiedliche Konfigurationsparameter zu simulieren und die Pareto-optimalen Konfigurationen zu ermitteln. Anhand der Bewertungsmaße Klassifikationsgenauigkeit und Taktzyklenanzahl (Energiebedarf) lassen sich aus den Ergebnissen geeignete Konfigurationen für das jeweilige Anwendungsszenario bestimmen. Möglich ist dabei die Untersuchung des Zusammenwirkens von Konfigurationsparametern wie unter anderem Sensortyp und -anzahl, Aufzeichnungsfrequenz, Merkmalskombination, Klassifikatortyp und dessen Parametrisierung. Die Klassifikation wird mittels eines ISS für einen Mikroprozessor simuliert. Untersuchungen auf der Hardwarearchitekturebene, wie die Nutzung funktionaler Einheiten, können ebenfalls durchgeführt werden. Die Simulationen erfolgen verteilt auf mehreren Prozessoren und Computern, um die Simulationsdauer zu reduzieren. Die Analyseumgebung kann flexibel erweitert werden. So sind Funktionen der Merkmalsberechnung und der Klassifikation sowie der ISS des betrachteten Mikroprozessors austauschbar.

Exemplarisch erfolgte die Durchführung einer Entwurfsraumexploration für die realisierte Laufgeschwindigkeitsbestimmung. Dazu wurden die notwendigen Funktionen zur Merkmalsberechnung und zwei Klassifikatoren (MLP und Entscheidungsbaum) mittels einer Fixpunktarithmetik mit 32 b Wortbreite implementiert. Die Ausführungszeit des MLPs wurde zusätzlich durch eine mit sechs Stützstellen linear approximierte Aktivierungsfunktion verbessert. Die Entwurfsraumexploration erfolgte auf der Datenreihe aus V1.1 und umfasst 1008 Simulationen, die 15 Pareto-optimale Konfigurationen ergeben. Die höchste Klassifikationsgenauigkeit von 93,9 % erreicht ein MLP mit 10 verdeckten Neuronen; die Konfiguration benötigt dazu 22422 Taktzyklen pro Klassifikation. Beide Klassifikatoren sind für das Anwendungsszenario Laufgeschwindigkeitsbestimmung geeignet. Im Allgemeinen erreichen jedoch MLP-basierte Konfigurationen eine höhere Genauigkeit. Unterhalb von 92,2 % basieren alle Pareto-optimalen Konfigurationen hingegen ausschließlich auf Entscheidungsbäumen, da MLPs mit ähnlicher Genauigkeit mehr Taktzyklen benötigen. Für das MLP beträgt der durchschnittliche Taktzyklenbedarf etwa 420 Taktzyklen pro zusätzlichem Neuron in der verdeckten Schicht. Bereits mit drei verdeckten Neuronen werden für die Datenreihe V1.1 eine Genauigkeit von 93 % erzielt, für das Maximum von 93,9 % sind 10 Neurone notwendig. Im Allgemeinen ist bei der Gang- / Laufgeschwindigkeitsbestimmung der Taktzyklenbedarf für die Merkmalsberechnung höher als für die Klassifikation. Insbesondere für auf Entscheidungsbäumen basierende Konfigurationen beträgt der Aufwand für den Klassifikator anteilig weniger als 20 %.

Die Pareto-optimale Konfiguration *P10*, basierend auf dem Merkmal Varianz und berechnet aus der mit 18 Hz abgespeicherten vertikalen Beschleunigung, bietet mit einem Entscheidungsbaum einen guten Kompromiss aus Genauigkeit und Taktzyklenbedarf im Hinblick auf die Ausführung auf dem Mikroprozessor. Für eine Geschwindigkeitsbestimmung mit 92,2 % Genauigkeit werden nur 24,2 nJ vom Prozessorkern des CoreVAs benötigt (11,1 nJ CoreVA-ULP). Für die Laufgeschwindigkeitsbestimmung wird damit für die Verarbeitung der Beschleunigungssignale auf dem Mikroprozessor mit einer anschließenden drahtlosen Kommunikation des Geschwindigkeitswerts weniger Energie benötigt als für die drahtlose Kommunikation der dazu nötigen Sensormesswerte (Faktor 12 für die Konfiguration *P10*).

Die Betrachtung basiert auf der Nutzung eines ANT-basierten Transceivers.

Eine differenzierte Angabe wie viel Speicher eine Konfiguration jeweils benötigt wird zukünftig mit einer Erweiterung des ISS möglich sein. Der Speicherbedarf einer Anwendung kann damit als zusätzliches Bewertungsmaß in die Entwurfsraumexploration aufgenommen werden. Weiterhin ist eine Ergänzung der Merkmalsberechnung um Funktionen für eine diskrete Wavelet- und Fouriertransformation von Bedeutung. Diese Merkmale werden bereits für die Laufgeschwindigkeitsbestimmung und die Personenidentifikation erfolgreich eingesetzt und finden in vielen Klassifikationsalgorithmen Anwendung [14]. Insbesondere eine CoreVA-Konfiguration mit mehreren VLIW-Slots kann eine Nutzung dieser von Seiten des Berechnungsaufwands aufwändigeren Merkmale auf einem Körpersensor ermöglichen. Im Bereich der Klassifikatoren ist eine Erweiterung um einen Naïve-Bayes Klassifikator sowie eine lineare Diskriminanzanalyse sinnvoll [46; 133].

## 8 Zusammenfassung und Ausblick

Körpersensoren bezeichnen am Körper angebrachte Sensorsysteme, die über eine integrierte Verarbeitungseinheit verfügen und eine benutzerzentrierte Überwachung von physiologischen und biokinematischen Parametern in der natürlichen Umgebung ermöglichen. Die Anwendungsmöglichkeiten sind dabei vielfältig und liegen im Breiten- und Leistungssport, dem Gesundheits- und Lifestylebereich, der Medizin und Rehabilitation.

Gegenstand der vorliegenden Arbeit ist die Weiterentwicklung eines Körpersensors, der mit Hilfe eines Brustgurts und eines computerbasierten Assistenten ohne Expertenwissen angelegt werden kann. Darauf aufbauend liegt der Schwerpunkt der Beiträge in der Entwicklung von Algorithmen, die aus den Sensorsignalen vielfältige physiologische und biokinematische Parameter ableiten, trotz auftretender Störungen, Bewegungsartefakten sowie intra- und interindividuellen Variabilitäten. Eine dahingehend robuste Parameterbestimmung bildet die Grundlage für Einsatzmöglichkeiten des Körpersensors im Alltag, der Leistungsdiagnostik, der Präventivmedizin und der Rehabilitation. Kenntnis über die Identität des Trägers ist weiterhin von Bedeutung, um interindividuellen Variabilitäten in den Signalverläufen durch eine individualisierte Algorithmuskonfiguration zu begegnen. Darüber hinaus sind persoen-spezifische Zusatzinformationen für die Datenauswertung wichtig. Realisiert wurde eine Identifikation des Trägers des Körpersensors anhand von Charakteristika extrahiert aus den erfassten Biosignalen. Die entwickelte Energieumsatzbestimmung ist ein Anwendungsbeispiel, das die Identität sowie die physiologischen und biokinematischen Parameter verwendet. Für die Akzeptanz eines Körpersensors sind seine Abmessungen und sein Gewicht entscheidende Kriterien. Der Energiebedarf nimmt dabei maßgeblich Einfluss, da er die Kapazität des Energiespeichers bestimmt. Zusätzlich zu der Auswahl von Komponenten mit niedrigem Energiebedarf ist eine Optimierung des Taktzylenaufwands der Sensorsignalverarbeitung von Bedeutung, um die Aktivzeiten des Mikroprozessors zu minimieren. Dazu wurde im Rahmen der vorliegenden Arbeit eine Analyseumgebung realisiert, die unterstützt, einen Kompromiss zwischen Genauigkeit der Sensorsignalverarbeitung und dem Taktzyklenaufwand zu finden.

Die wichtigsten Ergebnisse der einzelnen Kapitel sind im Folgenden zusammengefasst.

**Komponenten Körpersensoren** Das Kapitel 2 beschreibt typische Komponenten von Körpersensoren. Behandelt werden Sensoren, Mikrocontroller, Flash-Speicher, drahtlose Kommunikationsschnittstellen und Möglichkeiten der Energieversorgung. Weiterhin wird Bezug auf den Körpersensor BG-V4.2 der AG K&S genommen und die durchgeführte Erweiterung, Aktualisierung und Evaluierung von Hard- und Softwarekomponenten beschrieben.

Es erfolgte eine Erweiterung der bestehenden physiologischen Sensoren für die Erfassung eines Einkanal-EKGs und der Hauttemperatur um einen Atemsensor. Mittels eines piezoresistiven Kraftsensors werden dazu die durch die mechanische Atemtätigkeit bedingten Erweiterungen und Verengungen des Thoraxes erfasst. Integriert in einen Brustgurt befindet sich die Messposition hierzu seitlich am Thorax zwischen den senkrechten Orientierungslinien *linea medioclavicularis* und *linea axillaris anterior*. Für eine sichere mechanische Kraftübertragung wurde ein Gehäuse mit integriertem Druckstempel entwickelt. Die Bewertung des realisierten Atemsensors erfolgte durch einen Vergleich mit einem RIP-basierten Atemsensor und einem Ergospirometrysystem für niedrige bis hohe körperliche Belastungsstufen.

Der für die Erfassung biokinematischer Parameter genutzte Beschleunigungssensor wurde aktualisiert, da dessen Messbereich von bis zu  $\pm 6$  g nicht ausreichend für die Aufzeichnung von Spitzenbeschleunigungen des Fersen-Auftreffens für Laufgeschwindigkeiten ab 9 km/h ist. Der gewählte Beschleunigungssensor lässt sich dazu auf einen Bereich von bis zu  $\pm 12$  g einstellen. Für direkte Körperkontakte, wie im Handballsport, oder die Anbringung an den Extremitäten können bis zu  $\pm 24$  g gewählt werden. Die Aktualisierung erfolgte für BG-V4.2; das beanspruchte Volumen des Beschleunigungssensors reduzierte sich um den Faktor 3 und die Leistungsaufnahme um den Faktor 2.

Die drahtlose Kommunikation von Sensormesswerten und Parametern ermöglicht eine direkte Rückmeldung an den Nutzer, Trainer oder (Sport-) Mediziner. In einer zunächst statischen Versuchsanordnung mit einem Empfänger erfolgte dazu die Evaluation unterschiedlicher Konfigurationsparameter der Funkschnittstelle. Betrachtet wurde der auf dem BG-V4.2 eingesetzte nRF24L01-Transceiver von Nordic Semiconductors. Gegenstand waren Paketlängen von 5 B bis 35 B, Paketsendefrequenzen von 15 Hz bis 250 Hz und eine unterschiedliche Anzahl zeitgleich aktiver Sender von 5 bis 14. Nach einem initialen Wechsel der Trägerfrequenz von den voreingestellten hoch frequentierten 2,465 GHz (Kanäle 11 und 12 von WiFi-Routern) auf 2,482 GHz reduzierte sich die Paketverlustrate der Sender im Einzeltest auf  $\leq 0,38 \pm 0,083$  %. In Kombination mit zusätzlich aktiven Sendern wurde eine maximale Gesamtdatenrate von  $16,3 \pm 2,1$  kB/s am Empfänger ermittelt, dabei zeigte sich keine begrenzende Abhängigkeit zu einem der drei Konfigurationsparametern. Für eine kontinuierliche Übertragung von Sensormesswerten lassen sich somit beispielsweise fünf Sender mit jeweils 100 Hz Paketsendefrequenz und 30 B Paketlänge nutzen. Die Erweiterung der Tests um räumlich verteilte Sender und vier Empfänger zeigte einen positiven Einfluss der Mehrwegeausbreitung auf die Paketverlustrate sowie eine Reduzierung der Anzahl an aufeinanderfolgend verlorener Pakete. Die Evaluation in dynamischen Szenarien während des Laufens auf Laufbändern und des Badmintonspielens führte zu Paketverlusten zwischen 1,8 % und 9,7 %. Die Kombination der empfangenen Pakete von zwei Empfängern reduzierte für ein dynamisches Szenario, in welchem der Weg zwischen den Empfängern in alternierender Richtung abgesprochen wurde, die Paketverlustrate signifikant auf nur  $0,4 \pm 0,5$  %. Die empfangenen Daten lassen sich weiterführend mittels des entwickelten Visualisierungsprogramms *Signalmonitor* während der Datenerhebung darstellen, aufzeichnen und über RSB bereitstellen.

Für eine lückenlose Aufzeichnung von Sensormesswerten und Parametern mit hohen Datenraten, beispielsweise bedingt durch eine hohe Senderanzahl im Mannschaftssport, wurde zusätzlich ein 64 Mbit Flash-Speicher auf dem BG-V4.2 integriert. Dieser bietet weiterhin die Flexibilität, eine Aufzeichnung auch außerhalb der Funkreichweite durchzuführen. Spezifiziert und implementiert wurden zwei Speicherformate für unterschiedliche Anwendungs- und Laufzeitanforderungen. Eine Aufzeichnung mit 25 Hz bei Wortbreiten von bis zu 10 b ist über einen Zeitraum von 11 h 39 min möglich. Für den Erhalt eines höheren Detailgrads der Sensorsignalverläufe sind eine Aufzeichnungsfrequenz von 100 Hz und Wortbreiten von bis zu 16 b vorgesehen. Für diese Konfiguration wird eine Aufzeichnungsdauer von 1 h 48 min erreicht. Das Auslesen der Daten aus dem Flash-Speicher des Körpersensors sowie die weiterführende Analyse der Sensormesswerte und Parameter erfolgt mit dem dazu

---

entwickelten Computerprogramm *Aktivitätsmonitor*.

**Parametererkennung** Die Kapitel 3 und 4 behandeln die Bestimmung von physiologischen und biokinematischen Parametern; deren Anwendung und kombinierte Nutzung ist in Kapitel 6 beschrieben.

Die Bestimmung der Herzfrequenz und deren Variabilität beruht auf einer Segmentierung des EKGs in Herzschläge. Die Grundlage dazu bildet der QRS-Detektionsalgorithmus von J. Pan und W. J. Tompkins. Durchgeführt wurde eine Evaluation des QRS-Detektionsalgorithmus für den Einsatz mit dem EKG-Sensor des BG-V4.2 in Verbindung mit den textilen Elektroden eines Brustgurtes und unterschiedlichen Belastungsstufen auf einem Laufband. Die erreichte mittlere Sensitivität beträgt  $99,9 \pm 0,4\%$  für Gehen mit 3 km/h. Während des Laufens mit 9 km/h nehmen insbesondere Bewegungsartefakte zu, erzielt wird eine Sensitivität von  $97,9 \pm 2,7\%$ . Die mittlere Spezifität liegt für die betrachtete Datenreihe bei 100 %. Der realisierte Atemsensor erfasst die Erweiterungen und Verengungen des Thoraxes als Kraftänderungen. Für die Bestimmung der Atemfrequenz wurde ein Algorithmus für eine Atemzugdetektion entwickelt, der sich adaptiv an Frequenz- und Amplitudenänderungen anpasst. Die Evaluation der Atemfrequenzbestimmung erfolgte in einem Laufbandexperiment mit fünf Belastungsstufen zwischen 3 km/h und 11 km/h durch einen Vergleich mit den Ausgaben eines stationären Ergospirometrysystems. Die mittlere Abweichung zwischen den beiden Systemen beträgt  $-0,32 \pm 0,68$  Atemzüge pro Minute. Die Evaluation der Hauttemperaturerfassung während des Laufens wurde signifikant durch die auftretende Luftkühlung beeinflusst. Ein Anstieg der Körperkerntemperatur, bedingt durch eine körperliche Belastung, wird derzeit in den Messwerten nicht sichtbar. Für den Einsatz in der Leistungsdiagnostik sind daher alternative Messpositionen zu prüfen. Geeignete Einsatzmöglichkeiten werden jedoch im Bereich des Arbeitsschutzes gesehen, wo diese Problematik nicht besteht.

Für die Erfassung von biokinematischen Parametern lag der Schwerpunkt der vorliegenden Arbeit in der Entwicklung eines Algorithmus zur Bestimmung der Gang- und Laufgeschwindigkeit aus den Messwerten eines im Brustbereich platzierten Beschleunigungssensors. Dazu erfolgt eine Extraktion von Geschwindigkeitsinformationen aus den Schrittmustern der Beschleunigungssignale. Diese dienen als Eingabe eines Klassifikators, der die Zuordnung zum Geschwindigkeitswert vornimmt. Die Evaluation erfolgte sowohl auf Laufbändern als auch auf einer Laufbahn im Außenbereich für die vier Geschwindigkeiten 3, 5, 7 und 9 km/h. Der Vergleich mit den jeweiligen Referenzwerten ergibt eine Genauigkeit von 98,8 % und 97,3 %; die Angaben gelten für den RF-Klassifikator, der die höchste Genauigkeit erreicht. Mit einer Steigerung der Laufgeschwindigkeit auf 11 km/h nehmen die interindividuellen Variabilitäten zu, die mittlere Genauigkeit reduziert sich als Folge auf 97,8 %. Die vertikale Beschleunigungsachse und das Merkmal Varianz enthalten die meisten Geschwindigkeitsinformationen. Eine individuelle Optimierung des Vorhersagemodells, die interindividuelle Variabilitäten ausblendet, steigert die Genauigkeit auf sehr hohe 99,1 %. Die durchgeführte Portierung des Klassifikationsalgorithmus auf den Mikrocontroller MSP430FG4618 des BG-V4.2 benötigt pro Ausführung 52866 Takte, dies entspricht einem Energiebedarf von  $95,2 \mu\text{J}$ . Der größte Anteil entfällt auf die Berechnung der Varianz, des RMS- und des ST-Werts (42666 Takte). Der Speicheraufwand beträgt zusätzlich zur Betriebssoftware weniger als 1 kB. Die portierte

Geschwindigkeitsbestimmung erreicht eine mittlere Genauigkeit von 96,1%.

Ein weiterer in dieser Arbeit realisierter biokinematischer Parameter ist die Bestimmung des Oberkörperneigungswinkels auf Grundlage eines dreiaxialen Beschleunigungssensors. Dazu erfolgt zunächst eine Approximation der statischen Erdbeschleunigung. Aus deren anteilmäßiger Verteilung auf die drei orthogonalen Achsen wird mittels trigonometrischer Funktionen der seitliche Oberkörperneigungswinkel  $\phi$  (engl. *Roll*) und der vorwärts-rückwärts Neigungswinkel  $\theta$  (engl. *Pitch*) berechnet. Darüber hinaus erfolgte die Realisierung einer Schrittdetektion, die Beschleunigungssignale in Schrittsegmente aufteilt, beispielsweise für Anwendungen zur Ganganalyse. Die mittlere Sensitivität und Spezifität der Detektion beträgt für die vier Geschwindigkeiten zwischen 3 km/h und 9 km/h  $97,9 \pm 0,013\%$  und  $94,5 \pm 0,085\%$ . Außerdem erfolgte die Entwicklung eines Algorithmus zur Detektion der unterschiedlichen Alltagsaktivitäten Sitzen, Stehen, Liegen und Gehen sowie der sportlichen Übungen Liegestützen, Kniebeugen und der Bauchmuskelübung *Sit-up*. Genutzt wird dazu ein BG-V4.2 im Brustbereich, welches um ein zweites BG-V4.2 oberhalb des Handgelenks sowie ein Smartphone (Inertialsensorinformationen) in der Hosentasche erweitert werden kann. Die erreichte Genauigkeit der Aktivitätsdetektion beträgt 91,9%. Weiterhin wird gezeigt, wie sich universelle Aktivitätsmaße, die die drei orthogonalen Beschleunigungssignale zeitlich zusammenfassen, für Anwendungsszenarien nutzen lassen, in denen keine Klassifikation einzelner Aktivitäten möglich ist.

Die physiologischen und biokinematischen Parameter lassen sich beispielsweise im Kontext der Energieumsatzbestimmung des Menschen nutzen. Dazu wird zunächst ein Überblick zu in der Literatur beschriebenen Vorhersagemodellen gegeben, die jeweils einen der Parameter als Eingabegrößen nutzen. Weiterführend wird das in dieser Arbeit entwickelte Vorhersagemodell vorgestellt, welches die Herz- und Atemfrequenz sowie Informationen des Beschleunigungssensors kombiniert nutzt. Die Auswahl der Parameter erfolgt dabei adaptiv hinsichtlich detektierter Sensorsignalstörungen. Die Abweichung zu Referenzwerten, ermittelt mit einem Spirometriesystem für unterschiedliche Belastungsstufen auf einem Laufband, beträgt im Mittel  $3,3 \pm 8,3$  kJ/min. Wird die dazu nötige Angabe des Grundumsatzes nicht mittels der Regressionsgleichung von J. A. Harris und F. G. Benedict geschätzt, sondern individuell mittels des Spirometriesystems bestimmt, reduzieren sich die Abweichungen auf nur  $-0,05 \pm 4,8$  kJ/min. Darüber hinaus wird als Ausblick erläutert, wie sich das universelle Aktivitätsmaß und die Gang- / Laufgeschwindigkeitsbestimmung zur Unterstützung von Algorithmen externer Trackingverfahren nutzen lassen.

**Biosignalbasierte Personenidentifikation** Vorhersagemodelle zur Energieumsatzbestimmung, die Individualisierung von Konfigurationseinstellungen (z.B. Herzfrequenzbereiche zur Trainingssteuerung und Klassifikationsmodelle) sowie die Unterstützung externer Trackingverfahren benötigen die Identität des Trägers, um personenspezifische Zusatzinformationen abrufen zu können. Weiterhin ist die Annotation von Sensormesswerten und Parameter ein wiederkehrender manueller Prozess, der sich mittels einer Personenidentifikation automatisieren lässt. Kapitel 5 beschreibt das dazu realisierte Verfahren, welches interindividuelle Variabilitäten in den Verläufen der EKG- und Beschleunigungssignale nutzt, um auf den Träger des Körpersensors zu schließen. Mittels der Kombination beider Informationsquel-

---

len ist eine Identifikation auch außerhalb von Ruhephasen und während Störungen des EKG-Signalverlaufs durch Bewegungsartefakte möglich. Die Evaluierung der Identifikation während unterschiedlicher Belastungsstufen auf Laufbändern zeigt, dass eine Unterscheidung von 22 Probanden im Mittel mit einer Sensitivität von  $98,1 \pm 1,7\%$  bei einer Spezifität von  $99,9 \pm 0,1\%$  möglich ist. Die Identifikation von 14 Handballspielern ist im Mittel mit einer Sensitivität von  $91,4 \pm 4,4\%$  bei einer Spezifität von  $99,7 \pm 0,5\%$  möglich.

**Sensorsignalverarbeitung auf Mikroprozessoren** Genauigkeit, Taktzyklen-, Energie- und Speicherbedarf eines Algorithmus sind wesentliche Kriterien, die entsprechend der Anforderungsspezifikation einer Parameterbestimmung und den Komponenten eines Körpersensors (z.B. Mikroprozessor und Energiespeicher) abzugleichen sind. Kapitel 7 beschreibt eine dazu in dieser Arbeit realisierte Analyseumgebung, die es ermöglicht, eine Entwurfsraumexploration von Anwendungen zur Sensorsignalverarbeitung auf Mikroprozessoren durchzuführen, um die Pareto-optimalen Konfigurationen bezüglich Detektionsgenauigkeit und Taktzyklenbedarf (Energiebedarf) zu ermitteln. Durchgeführt wurde exemplarisch eine Entwurfsraumexploration der Gang- / Laufgeschwindigkeitsbestimmung, um geeignete Konfigurationen für die Portierung auf einen Mikroprozessor zu bestimmen. Auf Grundlage der Ergebnisse aus Kapitel 4.2 wurden dazu 1008 Konfigurationen für die Simulation ausgewählt. Als Zielplattform kam exemplarisch der CoreVA-Mikroprozessor der AG K&S zum Einsatz. Berücksichtigt wurden in den Simulationen sowohl Konfigurationsparameter des Klassifikationsalgorithmus in Form von der Sensoranzahl, der Aufzeichnungsfrequenz, des Merkmalsraums, des Klassifikortyps und dessen Konfiguration als auch Eigenschaften der Hardwarearchitektur des CoreVA-Mikroprozessors.

Für die höchste Genauigkeit von  $93,9\%$  sind eine Aufzeichnung der Signale aller drei Beschleunigungsachsen mit einer Frequenz von  $75\text{ Hz}$ , die Merkmale Varianz, ST-Wert und RMS sowie ein MLP mit 10 Neuronen notwendig. Ist eine Genauigkeit von  $92,2\%$  für das Anwendungsszenario ausreichend, kann durch die Nutzung der Pareto-optimalen Konfiguration P10 der Taktzyklenaufwand um den Faktor 20 reduziert werden. Die Konfiguration basiert auf der vertikalen Beschleunigungsachse, die die meisten Geschwindigkeitsinformationen enthält, einer auf  $18\text{ Hz}$  reduzierten Aufzeichnungsfrequenz und einem EB als Klassifikator. Der Prozessorkern des CoreVAs benötigt für die Bestimmung des Geschwindigkeitswerts  $24,2\text{ nJ}$ , für den CoreVA-ULP sind es  $11,1\text{ nJ}$ . Verfügt ein Körpersensor über den CoreVA als Mikroprozessor, reduziert sich der Energiebedarf um den Faktor 12, wenn die Verarbeitung der Beschleunigungssignale auf diesem erfolgt und anschließend nur der Geschwindigkeitswert anstelle des vertikalen Beschleunigungssignals über die Funkschnittstelle übertragen wird. Der Vergleich gilt für einen ANT-basierten Transceiver mit einem Energiebedarf von  $73\text{ nJ/b}$ . Bezüglich der Wahl des Klassifikators zeigt sich, dass die Pareto-optimalen Konfigurationen mit Genauigkeiten von  $\geq 92,2\%$  vornehmlich auf einem MLP basieren. Dahingegen bieten EB ein besseres Verhältnis aus Taktzyklenbedarf und Genauigkeit, sie sind in den Pareto-optimalen Konfiguration mit  $< 92,2\%$  Genauigkeit vertreten.

**Verwertbarkeit der Ergebnisse** Der Körpersensor BG-V4.2, die entwickelten Algorithmen zur Bestimmung der physiologischen und biokinematischen Parameter sowie die Software-



Abbildung 8.1.: Präsentation des Körpersensors BG-V4.2 auf der internationalen Fachmesse Orthopädie und Reha-Technik 2012 in Leipzig.

komponenten zur Analyse und Visualisierung der Ergebnisse fanden bereits, zusätzlich zur Forschung, vielfältigen Einsatz in acht universitären Abschlussarbeiten, in Lehrpraktika und als Demonstrator für die Öffentlichkeitsarbeit. Die Ergebnisse sind sichtbar in internationalen Publikationen (7 Erstautor- und 4 Koautorenschaften) und wurden im Rahmen von 6 Vorträgen auf Fachkonferenzen präsentiert.

In Kooperation mit der Orthopädietechnik Winkler aus Minden bot sich 2012 die Möglichkeit, den damals aktuellen Stand des BG-V4.2 auf der internationalen Fachmesse für Orthopädie und Reha-Technik in Leipzig zu präsentieren (siehe Abbildung 8.1). Darauf aufbauend wurde ein BMWi gefördertes Forschungs- und Entwicklungsprojekt (FuE-Projekt) zur Entwicklung eines ressourceneffizienten Körpersensors für die kontinuierliche Überwachung von Vitalfunktionen und kinematischen Parametern in der Rehabilitation und der Arbeitsmedizin erfolgreich beantragt (Laufzeit: 02/2013 bis 02/2014, Kennzeichen: KF2639307KM3). Für das Projekt konnten maßgeblich die Forschungsergebnisse der vorliegenden Arbeit genutzt werden. Im Rahmen des Folgeprojekts „Hochintegriertes Aktivitätsmonitoring mittels Multisensorik (HAM)“ findet darüber hinaus unter anderem der Anlegeassistent und die realisierte Energieumsatzschätzung Anwendung (Laufzeit: 01/2015 bis 12/2015, Kennzeichen: KF2639310KM4). Weiterhin fließen die Ergebnisse der vorliegenden Arbeit in das vom BMBF geförderte Verbundprojekt „Adaptives Lern- und Unterstützungssystem basierend auf Augmented Reality (Alubar)“ (Laufzeit 08/2013 bis 07/2016, Kennzeichen: 16SV6130)<sup>1</sup> und das Teilprojekt *Supportive Personal Coach* des Verbundprojekts „Vernetztes Wohnen - die mitdenkende Wohnung (KogniHome)“ (Laufzeit 08/2014 bis 07/2017)<sup>2</sup> ein.

---

<sup>1</sup>Internetpräsenz siehe: [www.alubar.de](http://www.alubar.de), letzter Zugriff 01.06.2015.

<sup>2</sup>Internetpräsenz siehe: [www.kognihome.de](http://www.kognihome.de), letzter Zugriff 01.06.2015.

---

**Ausblick** Die vorliegende Arbeit hat gezeigt, dass sich vielfältige physiologische und biokinematische Parameter mit einem Körpersensor im Brustbereich erfassen lassen. Für die dazu entwickelten Algorithmen erfolgten umfangreiche Evaluationen mit insgesamt mehr als 63 Probanden. Dennoch sind weiterführend zusätzliche Datenerhebungen mit größeren Probandenkollektiven sinnvoll, um verallgemeinernde Aussagen bezüglich der Robustheit der Parameterbestimmungen gegenüber intra- und interindividuellen Variabilitäten und unterschiedlichen Aufzeichnungsbedingungen sowie Anwendungsszenarien treffen zu können.

Die Kombination der unterschiedlichen physiologischen und biokinematischen Parameter bietet die Möglichkeit, zusätzliche Aussagen abzuleiten. Ein bereits realisiertes Beispiel ist die Energieumsatzbestimmung, die Informationen der Herz- und Atemfrequenz sowie der körperlichen Aktivität verbindet. Erste Ergebnisse der im Rahmen der vorliegenden Arbeit durchgeführten Betrachtungen zeigen, dass weiterführend die Erkennung der Erschöpfung einer Person durch eine ganzheitliche Analyse der Parameter realisiert werden kann. Dazu sind die physiologischen und biokinematischen Parameter im zeitlichen Verlauf gegenüberzustellen, um feststellen zu können, ob ein kardiovaskulärer Drift eintritt. Zusätzliche Informationsquellen bieten darüber hinaus den Vorteil, dass bei vorliegender Störung einer Quelle auf die davon unabhängigen ausgewichen werden kann; dies wird bereits im Rahmen der Energieumsatzbestimmung angewandt. Weiterführend können auf diese Weise Störungen der Atemfrequenzbestimmung bei einer nicht ausreichenden Kraftübertragung der Thoraxerweiterung und -verengung ausgeglichen werden, indem die Änderungsraten der ST-Werte der R-Zacken im EKG sowie die Variationen der Zeitabstände zwischen den RR-Zacken analysiert werden. Ein weiteres Beispiel sind körperliche Aktivitäten, die sich nicht ausreichend mittels des Beschleunigungssensors im Brustbereich erfassen lassen. Dies gilt unter anderem für Radfahren oder Langhantelübungen, die mit vorgebeugtem Oberkörper oder auf dem Rücken liegend durchgeführt werden. Dabei ist die Erfassung der Aktivität der Extremitäten zwar nicht mit dem Beschleunigungssensor möglich, dennoch spiegeln die physiologischen Parameter die körperliche Belastung wider.

Die realisierte Umgebung zur Analyse der Sensorsignalverarbeitung von Algorithmen zur Parameterbestimmung lässt sich weiterführend nutzen, um eine Entwurfsraumexploration für die Atemfrequenz- und Energieumsatzbestimmung sowie die Personenidentifikation durchzuführen. Darüber hinaus bietet die Analyseumgebung die Möglichkeit, hinsichtlich einer Modellierung der Energieaufnahme des Gesamtsystems Körpersensor erweitert zu werden. Zu berücksichtigen sind dazu die Energieaufnahme der Sensoren, der Schaltungen zur Vorverarbeitung und Analog-Digital-Wandlung, des Mikrocontrollers, des Flash-Speichers, der Kommunikationsschnittstellen sowie der Energieversorgung. Jede Komponente weist dabei unterschiedliche Betriebsmodi auf, die in Abhängigkeit von den Konfigurationsparametern des jeweiligen Algorithmus zur Sensormesswertverarbeitung stehen. Auf diese Weise lassen sich Konfigurationsentscheidungen bezüglich Detektionsgenauigkeit und Ressourcenbedarf entsprechend der Anforderungsspezifikation des jeweiligen Anwendungsszenarios treffen.

Der Einsatz von Körpersensoren in Form von Aktivitätstrackern oder als Bestandteil von *Smartwatches* ist ein hochaktuelles Themenfeld. Biochemische Sensoren, *Energy Harvesting* und textile Integration sind Beispiele für Herausforderungen und Entwicklungspotenziale zukünftiger Systeme. Die Erfassung von physiologischen und biokinematischen Parametern

durch Körpersensoren und Sensoren integriert in Einrichtungsgegenstände (z.B. Bettmatratze und Sitzmöbel) bietet die Möglichkeit, longitudinale Datenreihen außerhalb des Klinik- und Laborumfelds in der natürlichen Umgebung zu erheben. Die Erfassung der Daten von vielen Individuen und über lange Zeiträume bietet neue Einblicke und Unterstützungspotential für die Bereiche Prävention, Diagnose und Behandlung – sie geht jedoch mit hohen Anforderungen an den Datenschutz und die Privatsphäre einher.

---



# Abkürzungsverzeichnis

|        |  |
|--------|--|
| ADC    | Analog-Digital-Wandler (engl. <i>Analog Digital Converter</i> )      |
| AG K&S | Arbeitsgruppe Kognitronik & Sensorik                                 |
| AP     | Anteroposterior  |
| ASIC   | <i>Application Specific Integrated Circuit</i>                       |
| BG     | Brustgurtmodul   |
| BLE    | <i>Bluetooth Low Energy</i>  |
| BMBF   | Bundesministerium für Bildung und Forschung                          |
| BMR    | Grundumsatz (engl. <i>Basal Metabolic Rate</i> )                     |
| BMWi   | Bundesministerium für Wirtschaft und Energie                         |
| CRC    | <i>Cyclic Redundancy Check</i>                                       |
| DFT    | Diskrete Fourier-Transformation                                      |
| DWT    | Diskrete Wavelet-Transformation                                      |
| EB     | Entscheidungsbaum, teils ist tiefgestellt die Knotenanzahl angegeben |
| EDA    | Elektrodermale Aktivität   |
| EEG    | Elektroenzephalogramm  |
| EKG    | Elektrokardiogramm   |
| EMG    | Elektromyogramm  |
| ERR    | <i>Equal Error Rate</i>  |
| FANN   | <i>Fast Artificial Neural Network</i>                                |
| FFT    | <i>Fast Fourier-Transformation</i>                                   |
| GFSK   | <i>Gaussian Frequency-Shift Keying</i>                               |
| GPS    | Globales Positionsbestimmungssystem                                  |
| HF     | Herzfrequenz   |
| HFV    | Herzfrequenzvariabilität   |
| HMM    | <i>Hidden Markov Model</i>   |
| ILP    | <i>Instruction Level Parallelism</i>                                 |
| IMU    | <i>Inertial Measurement Unit</i>                                     |
| ISM    | <i>Industrial Scientific Medical (Band)</i>                          |
| ISS    | Instruktionsatzsimulator   |
| K-NN   | k-nächste-Nachbarn (Algorithmus)                                     |
| KNN    | Künstliches neuronales Netz  |
| KS     | Körpersensor   |

|        |   |
|--------|---|
| MARS   | <i><u>M</u>ultivariate <u>A</u>ddaptive <u>R</u>egression <u>S</u>plines</i>  |
| MEMS   | <i><u>M</u>ikro<u>e</u>lektromechanische <u>S</u>ysteme</i>   |
| MET    | Metabolisches Äquivalent (engl. <i><u>M</u>etabolic <u>E</u>quivalent of <u>T</u>ask</i> )  |
| ML     | <i><u>M</u>ediol<u>a</u>teral</i>   |
| MLP    | Mehrschichtiges Perzeptron (engl. <i><u>M</u>ultilayer <u>P</u>erceptron</i> ), teils ist tiefgestellt die Anzahl verdeckter Neuronen angegeben         |
| MSE    | <i><u>M</u>ean <u>S</u>quared <u>E</u>rror</i>  |
| O-QPSK | <i><u>O</u>ffset <u>Q</u>uadrature <u>P</u>hase-<u>S</u>hift <u>K</u>eying</i>  |
| PAEE   | Arbeits- / Leistungsumsatz (engl. <i><u>P</u>hysical <u>A</u>ctivity <u>R</u>elated <u>E</u>nergy <u>E</u>xpenditure</i> )                              |
| RAM    | <i><u>R</u>andom <u>A</u>ccess <u>M</u>emory</i>  |
| RF     | <i><u>R</u>andom <u>F</u>orest</i> , teils ist tiefgestellt die Anzahl an Entscheidungsbäume gefolgt von der Anzahl berücksichtigter Merkmale angegeben |
| RIP    | <i><u>R</u>espiratorische <u>i</u>nduktive <u>P</u>lethysmografie</i>   |
| RMS    | <i><u>R</u>oot <u>M</u>ean <u>S</u>quare</i>  |
| RSB    | <i><u>R</u>obotics <u>S</u>ervice <u>B</u>us</i>  |
| SCG    | <i><u>S</u>caled <u>C</u>onjugate <u>G</u>radient</i>   |
| SIG    | <i><u>S</u>pecial <u>I</u>nterest <u>G</u>roup (Bluetooth)</i>  |
| SoC    | <i><u>S</u>ystem-<u>o</u>n-<u>a</u>-<u>C</u>hip</i>   |
| SPA    | <i><u>S</u>ports <u>P</u>erformance <u>A</u>nalyzer</i>   |
| ST     | <i><u>S</u>pitze-<u>T</u>al (Wert)</i>  |
| SVM    | <i><u>S</u>upport <u>V</u>ector <u>M</u>achine</i>  |
| TDEE   | Täglicher Gesamtenergieumsatz (engl. <i><u>T</u>otal <u>D</u>aily <u>E</u>nergy <u>E</u>xpenditure</i> )  |
| TEF    | Nahrungsinduzierte Thermogenese (engl. <i><u>T</u>hermic <u>E</u>ffect of <u>F</u>ood</i> )   |
| V      | <i><u>V</u>ertikal</i>  |

# Symbolverzeichnis

|             |   |
|-------------|---|
| $f_s$       | Abtastfrequenz  |
| $a$         | Beschleunigungsmesswert, teils ist tiefgestellt die Sensorachse (AP, ML oder V) angegeben   |
| $\vec{a}$   | Beschleunigungsvektor, im Textfluss auch mit <b>a</b> bezeichnet  |
| $ \vec{a} $ | Länge des Beschleunigungsvektors $\vec{a}$  |
| $D$         | Dimensionalität des Merkmalsraums   |
| $g$         | Angabe der Beschleunigung als Lastvielfaches der Erdbeschleunigung $g$ mit $1g = 9,80665 \text{ m} \cdot \text{s}^{-2}$ (Normfallbeschleunigung)  |
| $v$         | Geschwindigkeit in km/h   |
| $f_c$       | Grenzfrequenz des Tief- oder Hochpassfilters  |
| $C$         | Klassifikatorausgabe  |
| $K_x$       | Konfigurationsparameter $x$ der Entwurfsraumexploration, $x$ ist in Tabelle 7.1 definiert   |
| $r$         | Korrelationskoeffizient   |
| $L$         | Anzahl an Messwerten in einem Zeitfenster (Merkmalsberechnung)  |
| $M_{Gi}$    | Kürzel des Merkmalsraums für die Geschwindigkeitsbestimmung mit der eindeutigen Nummer $i$  |
| $M_{Ii}$    | Kürzel des Merkmalsraums für die Personenidentifikation mit der eindeutigen Nummer $i$  |
| $N$         | Anzahl an Probanden   |
| $R$         | Referenzwert (z.B. Annotationswert der tatsächlichen Geschwindigkeit)   |
| $R_i$       | Sensitivität der Klasse $i$   |
| $\bar{R}$   | Arithmetisches Mittel der Sensitivitätswerte  |
| $S_i$       | Spezifität der Klasse $i$   |
| $\bar{S}$   | Arithmetisches Mittel der Spezifitätswerte  |
| $VO_2$      | Sauerstoffaufnahme  |
| $\sigma$    | Standardabweichung  |
| $T$         | Taktzyklen  |
| $V_{i,j}$   | Kürzel des Versuchs; $i$ bezeichnet das Szenario mit $i = 1$ für Laufband, $i = 2$ für Laufbahn und $i = 3$ für Mannschaftssport, $j$ ist eine eindeutige Nummer für die jeweils unterschiedlichen Versuchsdurchführungen |



# Literaturverzeichnis

- [1] J. Achten und A. Jeukendrup. „Heart Rate Monitoring: Applications and Limitations“. In: *Sports Medicine* 33.7 (2003), S. 517–538.
- [2] I. J. Acker. *Methoden der mehrstufigen Ablaufplanung in der Halbleiterindustrie*. Springer Fachmedien, 2011. ISBN: 9783834967312.
- [3] V. X. Afonso, W. J. Tompkins, T. Q. Nguyen und S. Luo. „ECG Beat Detection Using Filter Banks“. In: *Trans. on Biomedical Engineering* 46.2 (1999), S. 192–202. DOI: 10.1109/10.740882.
- [4] A. Ahmadi, D. Rowlands und D. James. „Development of Inertial and Novel Marker-Based Techniques and Analysis for Upper Arm Rotational Velocity Measurements in Tennis“. In: *Sports Engineering* 12 (2010), S. 179–188. DOI: 10.1007/s12283-010-0044-1.
- [5] H. J. Ailisto, M. Lindholm, J. Mantyjarvi, E. Vildjiounaite und S. M. Makela. „Identifying People From Gait Pattern With Accelerometers“. In: *Society of Photo-Optical Instrumentation Engineers*. 2005, S. 7–14. DOI: 10.1117/12.603331.
- [6] P. N. Ainslie, T. Reilly und K. R. Westerterp. „Estimating Human Energy Expenditure“. In: *Sports Medicine* 33.9 (2003), S. 683–698. DOI: 10.2165/00007256-200333090-00004.
- [7] B. E. Ainsworth, W. L. Haskell, M. C. Whitt, M. L. Irwin, A. M. Swartz u. a. „Compendium of Physical Activities: An Update of Activity Codes and MET Intensities“. In: *Medicine and Science in Sports and Exercise* 32.9 (2000), S498–S504.
- [8] I. Al Khatib, F. Poletti, D. Bertozzi, L. Benini, M. Bechara u. a. „A Multiprocessor System-On-Chip for Real-Time Biomedical Monitoring and Analysis: Architectural Design Space Exploration“. In: *Proc. of the 43rd annual Design Automation Conf. ACM*. 2006, S. 125–130.
- [9] A. Alomainy, Y. Hao und D. M. Davenport. „Parametric Study of Wearable Antennas with Varying Distances from the Body and Different On-Body Positions“. In: *Seminar on Antennas and Propagation for Body-Centric Wireless Communications*. IET, Apr. 2007, S. 84–89.
- [10] M. Amin Karami und D. J. Inman. „Powering Pacemakers from Heartbeat Vibrations Using Linear and Nonlinear Energy Harvesters“. In: *Applied Physics Letters* 100.4 (2012). DOI: 10.1063/1.3679102.
- [11] K. Aminian, B. Najafi, C. Büla, P-F. Leyvraz und P. Robert. „Spatio-Temporal Parameters of Gait Measured by an Ambulatory System Using Miniature Gyroscopes“. In: *Journal of Biomechanics* 35.5 (2002), S. 689–699.
- [12] K. Aminian, P. Robert, E. Jequier und Y. Schutz. „Estimation of Speed and Incline of Walking Using Neural Network“. In: *IEEE Trans. on Instrumentation and Measurement* 44.3 (1995), S. 743–746. DOI: 10.1109/19.387322.

- [13] T. Aoyagi, M. Kim, J. Takada, K. Hamaguchi und K. Ryuji. „Numerical Simulations for Dynamic WBAN Propagation Channel during Various Human Movements“. In: *5th Int. Symp. on Medical Information and Communication Technology*. 2011, S. 65–69.
- [14] A. Avci, S. Bosch, M. Marin-Perianu, R. Marin-Perianu und P. Havinga. „Activity Recognition Using Inertial Sensing for Healthcare, Wellbeing and Sports Applications: A Survey“. In: *Proc. of the 23th Int. Conf. on Architecture of Computing Systems*. Berlin: VDE Verlag, Feb. 2010, S. 167–176.
- [15] W. Ballhaus, B. Song, F.-A. Meyer, J.-P. Ohrtmann und C. Dressel. *Media Trend Outlook Wearables: Die tragbare Zukunft kommt näher*. Whitepaper. PricewaterhouseCoopers AG, März 2015.
- [16] L. Bao und S. Intille. „Activity Recognition from User-Annotated Acceleration Data“. In: *Pervasive Computing*. Hrsg. von A. Ferscha und F. Mattern. Bd. 3001. Lecture Notes in Computer Science. Springer Berlin / Heidelberg, 2004, S. 1–17.
- [17] P. Barralon, N. Vuillerme und N. Noury. „Walk Detection With a Kinematic Sensor: Frequency and Wavelet Comparison“. In: *Proc. 28th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*. 2006, S. 1711–1714. DOI: 10.1109/IEMBS.2006.260770.
- [18] M. H. Beale, M. T. Hagan und H. B. Demuth. *Neural Network Toolbox 7*. The MathWorks, Inc. 3 Apple Hill Drive, Natick, MA 01760-2098, 2010.
- [19] K.-P. Bethge. „Nicht-invasive Elektrokardiographie“. In: *Herzschrittmachertherapie + Elektrophysiologie* 19.3 (2008), S. 87–88. DOI: 10.1007/s00399-008-0019-0.
- [20] L. Bianchi, D. Angelini und F. Lacquaniti. „Individual Characteristics of Human Walking Mechanics“. In: *Pflügers Archiv European Journal of Physiology* 436 (1998), S. 343–356. DOI: 10.1007/s004240050642.
- [21] N. Bidargaddi, A. Sarela, L. Klingbeil und M. Karunanithi. „Detecting Walking Activity in Cardiac Rehabilitation by Using Accelerometer“. In: *Proc. 3rd Int. Conf. on Intelligent Sensors, Sensor Networks and Information*. 2007, S. 555–560. DOI: 10.1109/ISSNIP.2007.4496903.
- [22] L. Biel, O. Pettersson, L. Philipson und P. Wide. „ECG Analysis: A New Approach in Human Identification“. In: *IEEE Trans. on Instrumentation and Measurement* 50.3 (2001), S. 808–812. DOI: 10.1109/19.930458.
- [23] L. Bierl. *The MSP430 Hardware Multiplier - Functions and Applications*. Techn. Ber. Texas Instruments, 1999. URL: <http://www.ti.com/lit/an/slaa042/slaa042.pdf>.
- [24] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2006. ISBN: 0387310738.
- [25] A. Bolz und W. Urbaszek. *Technik in der Kardiologie: Eine interdisziplinäre Darstellung für Ingenieure und Mediziner*. Springer Berlin Heidelberg, 2002. ISBN: 9783540424789.
- [26] N. A. Borghese, L. Bianchi und F. Lacquaniti. „Kinematic Determinants of Human Locomotion.“ In: *The Journal of Physiology* 494.Pt 3 (1996), S. 863–879.

- [27] J. Boyle, N. Bidargaddi, A. Sarela und M. Karunanithi. „Automatic Detection of Respiration Rate From Ambulatory Single-Lead ECG“. In: *IEEE Trans. on Information Technology in Biomedicine* 13.6 (2009), S. 890–896. DOI: 10.1109/TITB.2009.2031239.
- [28] L. Breiman. „Random forests“. In: *Machine learning* 45.1 (Okt. 2001), S. 5–32. DOI: 10.1023/A:1010933404324.
- [29] P. Brinckmann, W. Frobin, G. Leivseth und B. Drerup. *Orthopädische Biomechanik*. Bd. 5. Wissenschaftliche Schriften der WWU Münster 2. Monsenstein und Vannerdat OHG Münster, 2012, S. 499. ISBN: 978-3-8405-0059-6.
- [30] B. Búsze, F. Bouwens, M. Konijnenburg, M. De Nil, M. Ashouei u. a. „Ultra Low Power Programmable Biomedical SoC for on-body ECG and EEG Processing“. In: *IEEE Asian Conf. on Solid State Circuits*. 2010, S. 1–4. DOI: 10.1109/ASSCC.2010.5716625.
- [31] B. Calhoun, J. Lach, J. Stankovic, D. Wentzloff, K. Whitehouse u. a. „Body Sensor Networks: A Holistic Approach from Silicon to Users“. In: *Proc. of the IEEE* 1.99 (2012), S. 1–16.
- [32] R. Caruana, N. Karampatziakis und A. Yessenalina. „An Empirical Evaluation of Supervised Learning in High Dimensions“. In: *Proc. of the 25th Int. Conf. on Machine Learning*. Helsinki, Finland: ACM, 2008, S. 96–103. DOI: 10.1145/1390156.1390169.
- [33] A. D. C. Chan, M. M. Hamdy, A. Badre und V. Badee. „Wavelet Distance Measure for Person Identification Using Electrocardiograms“. In: *IEEE Trans. on Instrumentation and Measurement* 57.2 (2008), S. 248–253. DOI: 10.1109/TIM.2007.909996.
- [34] K. Y. Chen und M. Sun. „Improving Energy Expenditure Estimation by Using a Triaxial Accelerometer“. In: *Journal of Applied Physiology* 83.6 (1997), S. 2112–2122. ISSN: 8750-7587.
- [35] M. Chen, S. Gonzalez, A. Vasilakos, H. Cao und V. C. Leung. „Body Area Networks: A Survey“. In: *Mobile Networks and Applications* 16.2 (2011), S. 171–193. DOI: 10.1007/s11036-010-0260-8.
- [36] J. Choi, B. Ahmed und R. Gutierrez-Osuna. „Development and Evaluation of an Ambulatory Stress Monitor Based on Wearable Sensors“. In: *IEEE Trans. on Information Technology in Biomedicine* 16.2 (März 2012), S. 279–286. DOI: 10.1109/TITB.2011.2169804.
- [37] P. Christ. „Messung von Bewegung und körperlichem Stress mit einem mobilen EKG-System“. Diplomarbeit. Universität Heidelberg / Hochschule Heilbronn, 2009.
- [38] A. Corporation. *8-bit AVR Microcontroller with 4/8/16/32K Bytes In-System Programmable Flash*. San Jose, USA, 2009.
- [39] N. Cotton. „A Neural Network Implementation on Embedded Systems“. Dissertation. Auburn University, 2010.
- [40] J. W. Crenshaw. *Integer Square Roots*. Letzter Zugriff 26.09.2012. Feb. 1998. URL: <http://www.embedded.com/electronics-blogs/programmer-s-toolbox/4219659/Integer-Square-Roots>.

- [41] M. Crepaldi, C. Li, K. Dronson, J. Fernandes und P. Kinget. „An Ultra-Low-Power Interference-Robust IR-UWB Transceiver Chipset Using Self-Synchronizing OOK Modulation“. In: *IEEE Int. Solid-State Circuits Conf. Digest of Technical Papers*. IEEE, Feb. 2010, S. 226–227. DOI: 10.1109/ISSCC.2010.5433960.
- [42] K. M. Culhane, M. O’Connor, D. Lyons und G. M. Lyons. „Accelerometers in Rehabilitation Medicine for Older Adults“. In: *Age and Ageing* 34.6 (2005), S. 556–560. DOI: 10.1093/ageing/afi192.
- [43] A. Czabke, S. Marsch und T. Lueth. „Accelerometer Based Real-Time Activity Analysis on a Microcontroller“. In: *5th Int. Conf. on Pervasive Computing Technologies for Healthcare*. Mai 2011, S. 40–46.
- [44] J. M. Daly, S. B. Heymsfield, C. A. Head, L. P. Harvey, D. W. Nixon u. a. „Human Energy Requirements: Overestimation by Widely Used Prediction Equation.“ In: *The American Journal of Clinical Nutrition* 42.6 (1985), S. 1170–4.
- [45] G. Dissanayake, S. Sukkarieh, E. Nebot und H. Durrant-Whyte. „The Aiding of a Low-Cost Strapdown Inertial Measurement Unit Using Vehicle Model Constraints for Land Vehicle Applications“. In: *IEEE Trans. on Robotics and Automation* 17.5 (2001), S. 731–747. DOI: 10.1109/70.964672.
- [46] J. Dougherty, R. Kohavi und M. Sahami. „Supervised and Unsupervised Discretization of Continuous Features“. In: *Proc. of the 12th Int. Conf. on Machine Learning*. Morgan Kaufmann, 1995, S. 194–202.
- [47] J. Dunfied, M. Tarbouchi und G. Labonte. „Neural Network Based Control of a Four Rotor Helicopter“. In: *IEEE Int. Conf. on Industrial Technology*. Bd. 3. Dez. 2004, S. 1543–1548. DOI: 10.1109/ICIT.2004.1490796.
- [48] J. Fisher, P. Faraboschi und C. Young. *Embedded Computing: A VLIW Approach to Architecture, Compilers and Tools*. Morgan Kaufmann, 2005, S. 712. ISBN: 9781558607668.
- [49] J. Fraden. *Handbook of Modern Sensors: Physics, Designs, and Applications*. Springer New York, 2003, S. 590. ISBN: 9780387007502.
- [50] Freescale Semiconductor, Inc. *Kinetis KL25 Sub-Family*. Rev 4 03/2014.
- [51] K.-I. Funahashi. „On the Approximate Realization of Continuous Mappings by Neural Networks“. In: *Neural Networks* 2.3 (1989), S. 183 –192. DOI: 10.1016/0893-6080(89)90003-8.
- [52] D. Gafurov, K. Helkala und T. Søndrol. „Biometric Gait Authentication Using Accelerometer Sensor“. In: *Journal of Computers* 1.7 (2006), S. 51–59.
- [53] M. Gekle. *Physiologie*. Thieme, 2010. ISBN: 9783131449818.
- [54] G. von Graevenitz. *Erfolgskriterien und Absatzchancen biometrischer Identifikationsverfahren*. Management Wissen aktuell 4. LIT Verlag Münster, 2006. ISBN: 9783825898601.
- [55] L. S. Green, R. L. Lux, C. W. Haws, R. R. Williams, S. C. Hunt und M. J. Burgess. „Effects of Age, Sex, and Body Habitus on QRS and ST-T Potential Maps of 1100 Normal Subjects“. In: *Circulation* 71.2 (1985), S. 244–253.

- [56] M. Haid. *Verbesserung der referenzlosen inertialen Objektverfolgung zur Low-cost Indoor-Navigation durch Anwendung der Kalman-Filterung*. Fraunhofer-IRB-Verlag, 2004, S. 182. ISBN: 9783816767046.
- [57] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann und I. H. Witten. „The WEKA Data Mining Software: An Update“. In: *SIGKDD Explorations* 11.1 (2009), S. 10–18.
- [58] P. Hamilton. *Open Source ECG Analysis Software Documentation*. Techn. Ber. E.P. Limited, 2002.
- [59] P. Hamilton. „Open Source ECG analysis“. In: *Computers in Cardiology, 2002*. Sep. 2002, S. 101–104. DOI: 10.1109/CIC.2002.1166717.
- [60] J. Han und M. Kamber. *Data Mining: Concepts and Techniques*. The Morgan Kaufmann Series in Data Management Systems. Elsevier, 2006. ISBN: 9781558609013.
- [61] J. A. Harris und F. G. Benedict. „A Biometric Study of Human Basal Metabolism“. In: *Proc. of the National Academy of Sciences of the United States of America* 4.12 (1918), S. 370.
- [62] C. Haubelt und J. Teich. *Digitale Hardware / Software-Systeme: Spezifikation und Verifikation*. eXamen.press. Springer Berlin Heidelberg, 2010, S. 601. DOI: 10.1007/978-3-642-05356-6.
- [63] Z. He und W. Zhang. „Estimation of Walking Speed Using Accelerometer and Artificial Neural Networks“. In: *Computer Science for Environmental Engineering and EcoInformatics*. Hrsg. von Y. Yu, Z. Yu und J. Zhao. Bd. 159. Communications in Computer and Information Science. Springer Berlin Heidelberg, 2011, S. 42–47. DOI: 10.1007/978-3-642-22691-5\_8.
- [64] E. A. Heinz, K. S. Kunze, M. Gruber, D. Bannach und P. Lukowicz. „Using Wearable Sensors for Real-Time Recognition Tasks in Games of Martial Arts - An Initial Experiment“. In: *Proc. IEEE Symp. Computational Intelligence and Games*. 2006, S. 98–102. DOI: 10.1109/CIG.2006.311687.
- [65] M. Hesse. „Entwicklung eines inertialen Navigationssystems für Miniroboter“. Studienarbeit. Fachgruppe Schaltungstechnik, Universität Paderborn, Apr. 2010.
- [66] A. P. Hills, N. Mokhtar und N. M. Byrne. „Assessment of Physical Activity and Energy Expenditure: An Overview of Objective Measures“. In: *Frontiers in Nutrition* 1.5 (2014). DOI: 10.3389/fnut.2014.00005.
- [67] N. Hjortskov, D. Rissén, A. Blangsted, N. Fallentin, U. Lundberg und K. Søggaard. „The Effect of Mental Stress on Heart Rate Variability and Blood Pressure During Computer Work“. In: *European Journal of Applied Physiology* 92.1-2 (2004), S. 84–89. DOI: 10.1007/s00421-004-1055-z.
- [68] T. K. Ho. „Random Decision Forests“. In: *Proc. of the 3rd Int. Conf. on Document Analysis and Recognition*. Bd. 1. Aug. 1995, S. 278–282. DOI: 10.1109/ICDAR.1995.598994.
- [69] Honeywell. *Magnetic Sensor Products*. Techn. Ber. 12001 State Highway 55, Plymouth, MN 55441: Solid State Electronics Center (Honeywell).

- [70] T. Hörmann. „Experimentelle Leistungsanalyse des BG-V4 Sensorknotens“. Bachelorarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Sep. 2012.
- [71] K. Hottenrott, O. Hoos und H. Esperer. „Herzfrequenzvariabilität und Sport“. In: *Herz Kardiovaskuläre Erkrankungen* 31.6 (2006), S. 544–552. DOI: 10.1007/s00059-006-2855-1.
- [72] J.-S. Hu, K.-C. Sun und C.-Y. Cheng. „A Kinematic Human-Walking Model for the Normal-Gait-Speed Estimation Using Tri-Axial Acceleration Signals at Waist Location“. In: *IEEE Trans. on Biomedical Engineering* 60.8 (2013), S. 2271–2279. DOI: 10.1109/TBME.2013.2252345.
- [73] R. Huch und C. Bauer. *Mensch, Körper, Krankheit: Anatomie, Physiologie, Krankheitsbilder; Lehrbuch und Atlas für die Berufe im Gesundheitswesen*. 4. Aufl. Urban & Fischer, 2003. ISBN: 9783437267901.
- [74] D. Innovations. *SpeedMax White Paper*. Techn. Ber. Dynastream Innovations Inc., 2005.
- [75] T. Instruments. *MSP430 Optimizing C/C++ Compiler v4.1 - User's Guide*. Mai 2012.
- [76] T. Instruments. *MSP430MSP430 Mixed Signal Microcontroller*. März 2011.
- [77] D. A. James. „The Application of Inertial Sensors in Elite Sports Monitoring“. In: *The Engineering of Sport 6*. Hrsg. von E. F. Moritz und S. Haake. Springer New York, 2006, S. 289–294. ISBN: 978-0-387-45951-6.
- [78] A. Jimenez, F. Seco, J. Prieto und J. Guevara. „Indoor Pedestrian Navigation Using an INS/EKF Framework for Yaw Drift Reduction and a Foot-Mounted IMU“. In: *7th Workshop on Positioning Navigation and Communication*. 2010, S. 135–143. DOI: 10.1109/WPNC.2010.5649300.
- [79] E. Jovanov, A. Milenkovic, C. Otto und P. de Groen. „A Wireless Body Area Network of Intelligent Motion Sensors for Computer Assisted Physical Rehabilitation“. In: *Journal of NeuroEngineering and Rehabilitation* 2.1 (2005), S. 6. DOI: 10.1186/1743-0003-2-6.
- [80] Y. Jung und B. Cha. „Gesture Recognition Based on Motion Inertial Sensors for Ubiquitous Interactive Game Contents“. In: *IETE Technical Review* 27.2 (2010), S. 158–166. DOI: 10.4103/0256-4602.60168.
- [81] T. Jungeblut. „Entwurfsraumexploration ressourceneffizienter VLIW-Prozessoren“. Diss. Universität Bielefeld, 2011.
- [82] T. Jungeblut, R. Dreesen, M. Pormann, U. Rückert und U. Hachmann. „Design Space Exploration for Resource Efficient VLIW-Processors“. In: University Booth of the Design, Automation and Test in Europe (DATE) Conf. 2008.
- [83] T. Jungeblut, S. Lütke-meier, G. Sievers, M. Pormann und U. Rückert. „A Modular Design Flow for Very Large Design Space Explorations“. In: *Proc. of the CDNLive! EMEA*. 2010.

- [84] T. Jungeblut, G. Sievers, M. Porrman und U. Rückert. „Design Space Exploration for Memory Subsystems of VLIW Architectures“. In: *IEEE 5th Int. Conf. on Networking, Architecture, and Storage*. IEEE, Juli 2010, S. 377–385. DOI: 10.1109/NAS.2010.14.
- [85] L. R. Keytel, J. H. Goedecke, T. D. Noakes, H. Hiiloskorpi, R. Laukkanen u. a. „Prediction of Energy Expenditure from Heart Rate Monitoring During Submaximal Exercise“. In: *Journal of Sports Sciences* 23.3 (2005), S. 289–297. DOI: 10.1080/02640410470001730089.
- [86] D. Kim und H. Kim. „Estimation of Activity Energy Expenditure Based on Activity Classification Using Multi-Site Triaxial Accelerometry“. In: *Electronics Letters* 44.4 (2008), S. 266–267. DOI: 10.1049/el:20082139.
- [87] S. Knezevic, R. Stojanovic, J. Kovacevic und D. Karadaglic. „Wavelet Based Processing of Physiological Signals for Purposes of Embedded Computing“. In: *Mediterranean Conf. on Embedded Computing*. IEEE, 2012, S. 42–45.
- [88] B.-U. Kohler, C. Hennig und R. Orglmeister. „The Principles of Software QRS Detection“. In: *IEEE Engineering in Medicine and Biology Magazine* 21.1 (Jan. 2002), S. 42–57. DOI: 10.1109/51.993193.
- [89] R. Kramme. *Medizintechnik: Verfahren - Systeme - Informationsverarbeitung*. 4., vollst. überarb. Aufl. Springer-Verlag Berlin Heidelberg, 2011. ISBN: 9783642161872.
- [90] K. Kroschel, G. Rigoll und B. Schuller. *Statistische Informationstechnik: Signal - und Mustererkennung, Parameter- und Signalschätzung*. Springer, 2011. DOI: 10.1007/978-3-642-15954-1.
- [91] Q. Ladetto. „On Foot Navigation: Continuous Step Calibration Using Both Complementary Recursive Prediction and Adaptive Kalman Filtering“. In: *ION GPS* (2000), S. 1735–1740.
- [92] B. Latré, B. Braem, I. Moerman, C. Blondia und P. Demeester. „A Survey on Wireless Body Area Networks“. In: *Wireless Networks* 17 (2011), S. 1–18. DOI: 10.1007/s11276-010-0252-4.
- [93] J. Lázaro, E. Gil, R. Bailón, A. Mincholé und P. Laguna. „Deriving Respiration From Photoplethysmographic Pulse Width“. In: *Medical & Biological Engineering & Computing* 51.1-2 (2013), S. 233–242. DOI: 10.1007/s11517-012-0954-0.
- [94] Y. Lee, Y. Kim, D. Yoon, D. Blaauw und D. Sylvester. „Circuit and System Design Guidelines for Ultra-Low Power Sensor Nodes“. In: *Proc. of the 49th Annual Design Automation Conf. DAC '12*. San Francisco, California: ACM, 2012, S. 1037–1042. DOI: 10.1145/2228360.2228548.
- [95] B. Lo, L. Atallah, O. Aziz, M. ElHew, A. Darzi und G. Yang. „Real-time Pervasive Monitoring for Postoperative Care“. In: *4th Int. Workshop on Wearable and Implantable Body Sensor Networks*. Springer Berlin Heidelberg, 2007, S. 122–127.

- [96] K. Lorincz und M. Welsh. „MoteTrack: A Robust, Decentralized Approach to RF-Based Location Tracking“. In: *Location- and Context-Awareness*. Hrsg. von T. Strang und C. Linnhoff-Popien. Bd. 3479. Lecture Notes in Computer Science. Springer Berlin Heidelberg, 2005, S. 63–82. DOI: 10.1007/11426646\_7.
- [97] N. H. Lovell, N. Wang, E. Ambikairajah und B. G. Celler. „Accelerometry Based Classification of Walking Patterns Using Time-Frequency Analysis“. In: *Proc. 29th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*. 2007, S. 4899–4902. DOI: 10.1109/IEMBS.2007.4353438.
- [98] O. Ltd. *MSP430-4619LCD Development Board - Users Manual*. Plovdiv, Bulgaria, Juni 2011.
- [99] Lütke-meier. „Ressourceneffiziente Digitalschaltungen für den Subschwellebetrieb“. Diss. Universität Paderborn, 2013.
- [100] S. Lütke-meier, T. Jungeblut, H. Berge, S. Aunet, M. Porrmann und U. Rückert. „A 65 nm 32 b Subthreshold Processor With 9T Multi-Vt SRAM and Adaptive Supply Voltage Control“. In: *IEEE Journal of Solid-State Circuits* 48.1 (Jan. 2013), S. 8–19. DOI: 10.1109/JSSC.2012.2220671.
- [101] M. Macknet, P. Kimball-Jones, R. Applegate, R. Martin und M. Allard. „Accuracy of a Novel Bioacoustic Sensor in Adult Postoperative Patients“. In: *Anesthesiology* 107 (2007), A83.
- [102] A. Mannini und A. M. Sabatini. „Machine Learning Methods for Classifying Human Physical Activity from On-Body Accelerometers“. In: *Sensors* 10.2 (2010), S. 1154–1175. DOI: 10.3390/s100201154.
- [103] J. Mäntyjärvi, M. Lindholm, E. Vildjiounaite, S.-M. Mäkelä und H. A. Ailisto. „Identifying Users of Portable Devices from Gait Pattern with Accelerometers“. In: *IEEE Int. Conf. on Acoustics, Speech, and Signal Processing*. Bd. 2. März 2005, S. ii/973–ii/976. DOI: 10.1109/ICASSP.2005.1415569.
- [104] E. Martin. „Solving Training Issues in the Application of the Wavelet Transform to Precisely Analyze Human Body Acceleration Signals“. In: *Proc. IEEE Int. Conf. on Bioinformatics and Biomedicine*. 2010, S. 427–432. DOI: 10.1109/BIBM.2010.5706604.
- [105] P. Marwedel und L. Wehmeyer. *Eingebettete Systeme*. Springer London, Limited, 2007. ISBN: 9783540340492.
- [106] U. Maurer, A. Smailagic, D. Siewiorek und M. Deisher. „Activity Recognition and Monitoring Using Multiple Sensors on Different Body Positions“. In: *Int. Workshop on Wearable and Implantable Body Sensor Networks*. Apr. 2006, 4 pp. –116. DOI: 10.1109/BSN.2006.6.
- [107] D. McIlwraith und G. Z. Yang. „Body Sensor Networks for Sport, Wellbeing and Health“. In: *Sensor Networks*. Hrsg. von G. Ferrari. Signals and Communication Technology. Springer Berlin Heidelberg, 2009, S. 349–381. ISBN: 978-3-642-01341-6.

- [108] S. Moafipoor. *GPS Augmentation: Personal Navigation Supported by the Human Locomotion Model*. Techn. Ber. Letzter Zugriff: 01.08.2011. GPS World, 2007. URL: <http://www.gpsworld.com/tech-talk-blog/gps-augmentation-personal-navigation-supported-human-locomotion-model-11319>.
- [109] M. F. Møller. „A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning“. In: *Neural Networks* 6.4 (1993), S. 525–533. DOI: DOI:10.1016/S0893-6080(05)80056-5.
- [110] E. Monier. „Vision Based Tracking in Team Sports“. Diss. University Paderborn, 2011.
- [111] G. B. Moody, R. G. Mark, M. A. Bump, J. S. Weinstein, A. D. Berman u. a. „Clinical Validation of the ECG-Derived Respiration (EDR) Technique“. In: *Group* 1.3 (1986).
- [112] Y. Mrabet. *Körpererebenen des Menschen*. Letzter Zugriff 20.02.2014. Juli 2008. URL: [https://commons.wikimedia.org/wiki/File:Human\\_anatomy\\_Koerperebenen.svg](https://commons.wikimedia.org/wiki/File:Human_anatomy_Koerperebenen.svg).
- [113] M. Müller. „Dynamic Time Warping“. In: *Information Retrieval for Music and Motion*. Springer Berlin Heidelberg, 2007, S. 69–84. DOI: 10.1007/978-3-540-74048-3\_4.
- [114] M. P. Murray, A. B. Drought und R. C. Kory. „Walking Patterns of Normal Men“. In: *The Journal of Bone & Joint Surgery* 46.2 (1964), S. 335–360.
- [115] M. Myrtek, D. Weber, G. Brügger und W. Müller. „Occupational Stress and Strain of Female Students: Results of Physiological, Behavioral, and Psychological Monitoring“. In: *Biological Psychology* 42.3 (1996), S. 379–391. DOI: 10.1016/0301-0511(95)05168-6.
- [116] S. Nissen. *Implementation of a Fast Artificial Neural Network Library (FANN)*. Techn. Ber. University of Copenhagen, 2003.
- [117] M. S. Nixon, T. Tan und R. Chellappa. *Human Identification Based on Gait*. Bd. 4. Int. Series on Biometrics. Springer US, 2006, S. 187. DOI: 10.1007/978-0-387-29488-9.
- [118] Nordic Semiconductors ASA. *nRF24L01 Single Chip 2.4GHz Transceiver - Product Specification*. Oslo, Norway, Juli 2007.
- [119] J. Pan und W. J. Tompkins. „A Real-Time QRS Detection Algorithm“. In: *IEEE Trans. on Biomedical Engineering* 3 (1985), S. 230–236.
- [120] A. Panagiota, S. Layal und H. Stefan. „Assessment of Human Gait Speed and Energy Expenditure Using a Single Triaxial Accelerometer“. In: *9th Int. Conf. on Wearable and Implantable Body Sensor Networks*. Mai 2012, S. 184–188. DOI: 10.1109/BSN.2012.7.
- [121] M. Patel und J. Wang. „Applications, Challenges, and Prospective in Emerging Body Area Networking Technologies“. In: *IEEE Wireless Communications* 17.1 (2010), S. 80–88.
- [122] J. P. Paul. „Force Actions Transmitted by Joints in the Human Body“. In: *Proc. of the Royal Society of London. Series B. Biological Sciences* 192.1107 (1976), S. 163–172. DOI: 10.1098/rspb.1976.0004.

- [123] P. Pavan, R. Bez, P. Olivo und E. Zaroni. „Flash Memory Cells-An Overview“. In: *Proc. of the IEEE* 85.8 (1997), S. 1248–1271.
- [124] A. Pedotti. „A Study of Motor Coordination and Neuromuscular Activities in Human Locomotion“. In: *Biological Cybernetics* 26 (1977), S. 53–62. DOI: 10.1007/BF00363992.
- [125] D. Puccinelli und M. Haenggi. „Wireless Sensor Networks: Applications and Challenges of Ubiquitous Sensing“. In: *IEEE Circuits and Systems Magazine* 5.3 (2005), S. 19–31. DOI: 10.1109/MCAS.2005.1507522.
- [126] R. Quinlan. *C4.5: Programs for Machine Learning*. San Mateo, CA: Morgan Kaufmann Publishers, 1993.
- [127] M. Raju. *Energy Harvesting ULP Meets Energy Harvesting: A Game-Changing Combination for Design Engineers*. Techn. Ber. Texas Instruments, 2008.
- [128] C. M. A. van Ravenswaaij-Arts, L. A. A. Kollee, J. C. W. Hopman, G. B. A. Stoeltinga und H. P. van Geijn. „Heart Rate Variability“. In: *Annals of Internal Medicine* 118.6 (1993), S. 436–447. DOI: 10.7326/0003-4819-118-6-199303150-00008.
- [129] M. Raya und L. Sison. „Adaptive Noise Cancelling of Motion Artifact in Stress ECG Signals Using Accelerometer“. In: *Engineering in Medicine and Biology*. Bd. 2. 2002, S. 1756–1757. DOI: 10.1109/IEMBS.2002.1106637.
- [130] P. Refaeilzadeh, L. Tang und H. Liu. „Cross-Validation“. In: *Encyclopedia of Database Systems*. Hrsg. von L. Liu und M. T. Özsu. Springer US, 2009, S. 532–538. DOI: 10.1007/978-0-387-39940-9\_565.
- [131] T. Reilly und G. A. Brooks. „Exercise and the Circadian Variation in Body Temperature Measures“. In: *Int. Journal of Sports Medicine* 7.06 (1986), S. 358–362. DOI: 10.1055/s-2008-1025792.
- [132] F. Rincon, J. Recas, N. Khaled und D. Atienza. „Development and Evaluation of Multilead Wavelet-Based ECG Delineation Algorithms for Embedded Wireless Sensor Nodes“. In: *IEEE Trans. on Information Technology in Biomedicine* 15.6 (2011), S. 854–863. DOI: 10.1109/TITB.2011.2163943.
- [133] M. Ring, U. Jensen, P. Kugler und B. Eskofier. „Software-Based Performance and Complexity Analysis for the Design of Embedded Classification Systems“. In: *21st Int. Conf. on Pattern Recognition*. 2012, S. 2266–2269.
- [134] L. Rong, Z. Jianzhong, L. Ming und H. Xiangfeng. „A Wearable Acceleration Sensor System for Gait Recognition“. In: *2nd IEEE Conf. on Industrial Electronics and Applications*. 2007, S. 2654–2659.
- [135] F. Rosenblatt. *The Perceptron, a Perceiving and Recognizing Automaton (Project PARA)*. Cornell Aeronautical Laboratory, 1957.
- [136] A. Rütten, K. Abu-Omar, T. Lampert und T. Ziese. *Körperliche Aktivität*. Reihe Gesundheitsberichterstattung des Bundes 26. Robert Koch Institut (Statistisches Bundesamt), Juli 2005.

- [137] STMicroelectronics. *LIS331HH - MEMS Digital Output Motion Sensor Ultra Low-Power High Full-Scale 3-Axes Nano Accelerometer*. Okt. 2009.
- [138] STMicroelectronics. *LIS3LV02DL - MEMS Inertial Sensor 3-Axis -  $\pm 2g/\pm 6g$  Digital Output Low Voltage Linear Accelerometer*. Jan. 2008.
- [139] W. Sämann. „Charakteristische Merkmale und Auswirkungen ungünstiger Körperhaltungen“. In: *Schriftenreihe Arbeitswissenschaft und Praxis*. Bd. 17. Beuth Köln, 1970.
- [140] W. G. Scanlon und N. E. Evans. „Numerical Analysis of Bodyworn UHF Antenna Systems“. In: *Electronics Communication Engineering Journal* 13.2 (2001), S. 53–64. DOI: 10.1049/ecej:20010203.
- [141] G. A. Selkirk, T. M. McLellan und J. Wong. „Active Versus Passive Cooling During Work in Warm Environments While Wearing Firefighting Protective Clothing“. In: *Journal of Occupational and Environmental Hygiene* 1.8 (2004), S. 521–531. DOI: 10.1080/15459620490475216.
- [142] T. W. Shen, W. J. Tompkins und Y. H. Hu. „One-Lead ECG for Identity Verification“. In: *Proc. of the 2nd IEEE Int. Joint Conf. on Engineering in Medicine and Biology Society*. Bd. 1. IEEE. 2002, S. 62–63.
- [143] B. P. Simon und C. Eswaran. „An ECG Classifier Designed Using Modified Decision Based Neural Networks“. In: *Computers and Biomedical Research* 30.4 (1997), S. 257–272.
- [144] M. Simoons und P. Hugenholtz. „Gradual Changes of ECG Waveform During and After Exercise in Normal Subjects“. In: *Circulation* 52.4 (1975), S. 570–577.
- [145] T. Simunic, L. Benini, G. De Micheli und M. Hans. „Source Code Optimization and Profiling of Energy Consumption in Embedded Systems“. In: *Proc. of the 13th Int. Symp. on System Synthesis*. 2000, S. 193–198. DOI: 10.1109/ISSS.2000.874049.
- [146] Y. Song, S. Shin, S. Kim, D. Lee und K. H. Lee. „Speed Estimation From a Tri-axial Accelerometer Using Neural Networks“. In: *Proc. 29th Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society*. 2007, S. 3224–3227. DOI: 10.1109/IEMBS.2007.4353016.
- [147] Spansion. *S25FLO64K: 64-Mbit CMOS 3.0 Volt Flash Memory with 80-MHz SPI (Serial Peripheral Interface) Multi I/O Bus*. Juli 2011.
- [148] M. Štajdohar und J. Demšar. „Visualization and Analysis of the Space of Prediction Models“. Diss. University of Ljubljana, 2012.
- [149] J. Staudenmayer, D. Pober, S. Crouter, D. Bassett und P. Freedson. „An Artificial Neural Network to Estimate Physical Activity Energy Expenditure and Identify Physical Activity Type from an Accelerometer“. In: *Journal of Applied Physiology* 107.4 (2009), S. 1300–1307. DOI: 10.1152/jappphysiol.00465.2009.

- [150] J. Taelman, S. Vandeput, A. Spaepen und S. Huffel. „Influence of Mental Stress on Heart Rate and Heart Rate Variability“. In: *4th European Conf. of the Int. Federation for Medical and Biological Engineering*. Hrsg. von J. Sloten, P. Verdonck, M. Nyssen und J. Haueisen. Bd. 22. IFMBE Proc. Springer Berlin Heidelberg, 2009, S. 1366–1369. DOI: 10.1007/978-3-540-89208-3\_324.
- [151] Tekscan, Inc. *Data sheet: FlexiForce A201*. Rev N 9.30.13. Boston, MA 02127, USA, 2013. URL: [www.tekscan.com/flexible-force-sensors](http://www.tekscan.com/flexible-force-sensors).
- [152] W. J. Tompkins. *Biomedical Digital Signal Processing: C-Language Examples and Laboratory Experiments for the IBM PC*. Prentice Hall, 1993.
- [153] H. Vathsangam, A. Emken, D. Spruijt-Metz und G. Sukhatme. „Toward Free-Living Walking Speed Estimation Using Gaussian Process-Based Regression with On-Body Accelerometers and Gyroscopes“. In: *4th Int. Conf. on Pervasive Computing Technologies for Healthcare*. IEEE, 2010, S. 1–8. DOI: 10.4108/ICST.PERVASIVEHEALTH2010.8786.
- [154] C. Vidaurre, T. H. Sander und A. Schlögl. „BioSig: The Free and Open Source Software Library for Biomedical Signal Processing“. In: *Computational Intelligence and Neuroscience 2011* (2011), S. 12.
- [155] R. Vullers, R. Schaijk, H. Visser, J. Penders und C. Hoof. „Energy Harvesting for Autonomous Wireless Sensor Networks“. In: *Solid-State Circuits Magazine, IEEE* 2.2 (2010), S. 29–38. DOI: 10.1109/MSSC.2010.936667.
- [156] T. Vuorela, V. P. Seppä, J. Vanhala und J. Hyttinen. „Wireless Measurement System for Bioimpedance and ECG“. In: *13th Int. Conf. on Electrical Bioimpedance and the 8th Conf. on Electrical Impedance Tomography*. Hrsg. von R. Magjarevic, H. Scharfetter und R. Merwa. Bd. 17. IFMBE Proc. Springer Berlin Heidelberg, 2007, S. 248–251. DOI: 10.1007/978-3-540-73841-1\_66.
- [157] C. Walravens und W. Dehaene. „Design of a Low-Energy Data Processing Architecture for WSN Nodes“. In: *Proc. of the Conf. on Design, Automation and Test in Europe*. Dresden, Germany: IEEE Computer Society, 2012, S. 570–573. ISBN: 978-3-9810801-8-6.
- [158] A. Weder. „An Energy Model of the Ultra-Low-Power Transceiver nRF24L01 for Wireless Body Sensor Networks“. In: *Proc. 2nd Int. Conf. on Computational Intelligence, Communication Systems and Networks*. 2010, S. 118–123. DOI: 10.1109/CICSyN.2010.24.
- [159] J. Weineck. *Sportbiologie*. Spitta, 2004. ISBN: 9783934211834.
- [160] P. G. Weyand, D. B. Sternlight, M. J. Bellizzi und S. Wright. „Faster Top Running Speeds are Achieved with Greater Ground Forces Not More Rapid Leg Movements.“ In: *Journal of Applied Physiology* 89.5 (2000), S. 1991–1999.
- [161] G. Whyte und S. Sharma. *Practical ECG for Exercise Science and Sports Medicine*. Human Kinetics, 2010. ISBN: 9780736081948.

- 
- [162] B. Wigger. *Grundzüge der Finanzwissenschaft*. Springer London, Limited, 2007. ISBN: 9783540304357.
- [163] P. Wilhelm. „IT-gestützte Leistungsmessung im Sport : System und Anwendung“. Diss. Universität Bielefeld, 2011.
- [164] R. Wolthuis, V. Froelicher, A. Hopkirk, J. Fischer und N. Keiser. „Normal Electrocardiographic Waveform Characteristics During Treadmill Exercise Testing“. In: *Circulation* 60.5 (1979), S. 1028–1035.
- [165] World Health Organization, Food and Agriculture Organization of the United Nations, United Nations University. *Human Energy Requirements Report of a Joint FAO/WHO/UNU Expert Consultation*. Food und Agriculture Organization of the United Nations, 2004. ISBN: 9251052123.
- [166] S. Yang und Q. Li. „Inertial Sensor-Based Methods in Walking Speed Estimation: A Systematic Review“. In: *Sensors* 12.5 (2012), S. 6102–6116. DOI: 10.3390/s120506102.
- [167] R. Yates. *Fixed-Point Arithmetic: An Introduction*. Forschungsbericht. Digital Signal Labs. Juni 2009. URL: <http://www.digitalsignallabs.com/fp.pdf>.
- [168] I. F. Zakeri, A. L. Adolph, M. R. Puyau, F. A. Vohra und N. F. Butte. „Multivariate Adaptive Regression Splines Models for the Prediction of Energy Expenditure in Children and Adolescents“. In: *Journal of Applied Physiology* 108.1 (2010), S. 128–136. DOI: 10.1152/jappphysiol.00729.2009.
- [169] K. Zhang, P. Werner, M. Sun, F. X. Pi-Sunyer und C. N. Boozer. „Measurement of Human Daily Physical Activity“. In: *Obesity Research* 11.1 (2003), S. 33–40. DOI: 10.1038/oby.2003.7.



## Eigene Veröffentlichungen

- [170] P. Christ, J. Mielebacher, M. Haag und U. Rückert. „Detection of Body Movement and Measurement of Physiological Stress with a Mobile Chest Module in Obesity Prevention“. In: *Proc. of the 10th Australasian Conf. on Mathematics and Computers in Sport*. Hrsg. von A. Bedford und M. Ovens. Juli 2010, S. 67–74. ISBN: 9780957862357.
- [171] P. Christ, B. Neuwinger, F. Werner und U. Rückert. „Performance Analysis of the nRF24L01 Ultra-Low-Power Transceiver in a Multi-Transmitter and Multi-Receiver Scenario“. In: *Proc. of the 10th IEEE Int. Conf. on SENSORS*. IEEE, Okt. 2011, S. 1205–1208. DOI: 10.1109/ICSENS.2011.6127100.
- [172] P. Christ und U. Rückert. „Ein ressourceneffizienter Körpersensor zur Erfassung physiologischer und kinematischer Parameter“. In: *Informations- und Kommunikationstechnologien in der angewandten Trainingswissenschaft - Abstracts zur 15. Frühjahrsschule des IAT*. Apr. 2013, S. 6–7.
- [173] P. Christ, G. Sievers, J. Einhaus, T. Jungeblut, M. Porrmann und U. Rückert. „Pareto-optimal Signal Processing on Low-Power Microprocessors“. In: *Proc. of the 12th IEEE Int. Conf. on SENSORS*. Nov. 2013, S. 1843–1846. DOI: 10.1109/ICSENS.2013.6688593.
- [174] P. Christ, F. Werner, U. Rückert und J. Mielebacher. „An Approach for Determining Linear Velocities of Athletes from Acceleration Measurements Using a Neural Network“. In: *Proc. of the 6th IASTED Int. Conf. on Biomechanics*. Hrsg. von B. M. M. Hamza. ACTA Press. Nov. 2011, S. 105–112. DOI: 10.2316/P.2011.751-009.
- [175] P. Christ, F. Werner, U. Rückert und J. Mielebacher. „Athlete Identification Using Acceleration and Electrocardiographic Measurements Recorded with a Wireless Body Sensor“. In: *Proc. of the 6th Int. Conf. on Bio-Inspired Systems and Signal Processing, Int. Joint Conf. on Biomedical Engineering Systems and Technologies*. Hrsg. von S. Alvarez, J. Solé-Casals, A. Fred und H. Gamboa. SciTePress, Feb. 2013, S. 11–19.
- [176] P. Christ und U. Rückert. „Identification of Athletes During Walking and Jogging Based on Gait and Electrocardiographic Patterns“. In: *Biomedical Engineering Systems and Technologies*. Hrsg. von M. Fernández-Chimeno, P. L. Fernandes, S. Alvarez, D. Stacey, J. Solé-Casals u. a. Bd. 452. Communications in Computer and Information Science. Springer Berlin Heidelberg, Nov. 2014, S. 240–257. DOI: 10.1007/978-3-662-44485-6\_17.
- [177] S. Hein, J. Mielebacher, P. Christ und M. Haag. „Preventing Physical Inactivity Using a Mobile Chest Module“. In: *NCT-Congress Heidelberg on Exercise, Energy Balance and Cancer*. Heidelberg, Germany, Nov. 2010.
- [178] M. Hesse, P. Christ, T. Hörmann und U. Rückert. „A Respiration Sensor for a Chest-Strap Based Wireless Body Sensor“. In: *Proc. of the 13th IEEE Int. Conf. on SENSORS*. IEEE, Nov. 2014, S. 490–493. DOI: 10.1109/ICSENS.2014.6985042.

- [179] T. Hörmann, P. Christ, M. Hesse und U. Rückert. „Robust Estimation of Physical Activity by Adaptively Fusing Multiple Parameters“. In: *Body Sensor Networks*. IEEE, Juni 2015. ISBN: 978-1-4673-7201-5.
- [180] G. Sievers, P. Christ, J. Einhaus, T. Jungeblut, M. Pormann und U. Rückert. „Design-Space Exploration of the Configurable 32bit VLIW Processor CoreVA for Signal Processing Applications“. In: *Proc. of the 31st IEEE Int. Conf. NORCHIP*. IEEE, Nov. 2013, S. 1–4. DOI: 10.1109/NORCHIP.2013.6702002.

## Betreute Arbeiten

- [181] M. Adams. „Entwicklung und Evaluierung eines BLE Multitransmitterszenarios für ein Vitalparametermonitoring“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Jan. 2015.
- [182] M. Adams. „Ressourceneffiziente Signalverarbeitung auf einem mobilen Körpersensor“. Bachelorarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Sep. 2012.
- [183] N. Dehio, C. Menßen und C. Wall. „Intelligent Systems Project: Vital, Real-Time Activity Classification“. In: *Proc. of the ISY Workshop*. Hrsg. von T. Hermann, F. Lier und E. Riedenklau. Projektarbeit. 2013, S. 53–59.
- [184] J. Einhaus. „Entwurfsumgebung zur ressourceneffizienten Mustererkennung auf dem CoreVA-Prozessor“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Juni 2013.
- [185] T. Hörmann. „Realisierung eines multidimensionalen Aktivitätsmaßes mit Hilfe eines Körpersensors“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Sep. 2014.
- [186] S. Kulathunga. „Wireless Configuration and Data-Access of an Embedded Sensor Node“. Masterarbeit. Universität Paderborn, März 2013.
- [187] F. Lehmke. „Erkennung von Laufgeschwindigkeiten auf einem eingebetteten Sensor-knoten“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Sep. 2012.
- [188] C. Menßen. „Multifaktorielle online Stresserkennung mit einem mobilen Endgerät“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Okt. 2014.
- [189] J. Ruhe. „Classification of Tooth-Brushing Patterns under Real World Conditions Using Inertial Sensors“. Masterarbeit. Arbeitsgruppe Kognitronik und Sensorik, Universität Bielefeld, Nov. 2012.



# A Datenmaterial

Im Folgenden werden die durchgeführten Versuche und das erhobene Datenmaterial beschrieben. Die Versuchsnummern V1.x bezeichnen Versuche, die verschiedene Gang- und Laufgeschwindigkeiten auf Laubändern im Innenbereich umfassten. Der Versuch V2 erweiterte die Betrachtung auf den Außenbereich und wurde auf einer 400 m Laufbahn durchgeführt. V3 bezeichnet die Aufzeichnung eines Trainingsspiels einer Handballmannschaft in einer Sporthalle. Die Nummerierung der Probanden P erfolgte pro Versuch, die Versuchsnummer wird zur Unterscheidbarkeit tiefgestellt oder im Kontext angegeben. Die Namensgebung ermöglicht auf diese Weise auch eine Unterscheidung von Probanden, die an mehreren Versuchen teilgenommen haben und deren Probandeneigenschaften (Alter, Gewicht oder Trainingszustand) sich verändert haben.

Die Probanden wurden mündlich und schriftlich über den jeweiligen Versuch informiert und unterzeichneten jeweils eine Einverständniserklärung. Mit einem Probandenbogen wurden zusätzlich Eigenschaften für die Datenanalyse erhoben.

## A.1 Verschiedene Geschwindigkeiten Laufband V1

### A.1.1 Hauptversuch Laufband V1.1 mit 22 Probanden

|                     |   |
|---------------------|---|
| Versuchsnummer:     | V1.1  |
| Versuchsablauf:     | 2 x { 3, 5, 7, 9, 11 km/h } für jeweils 2 min   |
| Probanden:          | 15 Männer, 7 Frauen   |
| Körpersensor:       | BG-V4.1<br>Einstellungen: Aufzeichnungsfrequenz 150 Hz, Messbereich Beschleunigungssensor $\pm 6$ g |
| Zusätzliche Geräte: | Woodway Lamellenlaufbänder  |
| Datum:              | 23.03.2011 bis 26.05.2011 (4 Aufzeichnungstermine)  |
| Ort:                | Fitness- und Gesundheitszentrum, Universität Bielefeld  |

An dem Versuch nahmen 22 gesunde Probanden mit unterschiedlichen Lauferfahrungen teil (siehe Probandeneigenschaften Tabelle A.1). Vier der Probanden stufen sich als erfahrene Läufer mit mehr als drei Stunden Lauftraining pro Woche ein, fünf der Probanden wiesen keine Lauferfahrung auf und einige betrieben andere Ausdauersportarten. Der Versuch wurde im Fitness- und Gesundheitszentrum der Universität Bielefeld auf drei Lamellenlaufbändern des Herstellers Woodway durchgeführt. Nach einer Aufwärmphase absolvierten die Probanden ohne Steigung die Geschwindigkeiten 3, 5, 7, 9 und (11) km/h korrespondierend zu langsamem, normalem und schnellem Gehen als auch Laufen. Jede Geschwindigkeit wurde für 2 min konstant gehalten, bevor die Probanden sie selbständig um 2 km/h erhöhten. Diese Prozedur wurde ein zweites Mal wiederholt, um Variationen in den Schrittmustern zu erfassen. Die Obergrenze der Geschwindigkeit wählten die Probanden selbst, 16 Probanden absolvierten bis zu 9 km/h, die übrigen fünf bis zu 11 km/h. Es wurde den Probanden keine Vorgabe bezüglich

Tabelle A.1.: Überblick Probandeneigenschaften V1.1 (22 Probanden).

|                    | Mittelwert $\pm\sigma$ | Wertebereich |
|--------------------|------------------------|--------------|
| Alter (a)          | 26,6 $\pm$ 4,0         | 18 – 33      |
| Größe (cm)         | 179,8 $\pm$ 9,6        | 160 – 198    |
| Gewicht (kg)       | 76,7 $\pm$ 11,1        | 58 – 108     |
| Laufen/Woche (h)   | 3,5 $\pm$ 3,9          | 0 – 18       |
| Ausdauer/Woche (h) | 1,8 $\pm$ 3,0          | 0 – 14       |

des Laufstils gemacht, um natürliche Bedingungen zu erhalten. Einige Probanden wechselten während 7 km/h zwischen Gehen und Laufen; teils wurden die Handläufe genutzt.

Für die Aufzeichnung kam der Körpersensor BG-V4.1 zum Einsatz, den sich die Probanden selbst über einen Brustgurt anlegten. Erfasst wurde ein Einkanal-EKG sowie die Beschleunigungen im Oberkörperbereich (Sternum) entlang der drei orthogonalen Achsen (ML, AP, V). Beschleunigungen wurden mit einem Messbereich von  $\pm 6$  g erfasst. Die Aufzeichnungsfrequenz für die Beschleunigungssignale und das EKG betragen 150 Hz bei einer Wortbreite von 12 b. Die Messwerte wurden drahtlos an einen Empfänger zwecks Speicherung übertragen.

Die Annotation der Daten mit der Probanden-ID und der eingestellten Geschwindigkeit erfolgte manuell im Nachhinein. In den Übergangsbereichen der Geschwindigkeitsanpassung wurden jeweils 30 s entfernt, sodass die Datenreihe pro Geschwindigkeitsklasse und Proband 27000 Beschleunigungsvektoren und EKG-Messpunkte umfasst.

**Anmerkung** Im Rahmen der Evaluation der Laufgeschwindigkeit (siehe Abschnitt 4.2) konnten zunächst die Daten von zwei Probanden nicht verwendet werden, da die Aufzeichnungen fehlerhafte Datenpakete enthielten. Die Ursache dafür war eine falsche Nummerierung der Datenpakete, ausgelöst durch eine nicht ausreichende Absicherung (CRC-Prüfsumme) des Kommunikationskanals seitens des nRF24L01-Transceivers gegenüber „Bitkippern“ (siehe auch Abschnitt 2.5.2). Die fehlerhaften Datenpakete wurden ausgeschlossen und die Nummerierung manuell korrigiert, sodass die Daten für die weitere Evaluation genutzt werden konnten. Die Betriebssoftware des Körpersensors wurde um eine zusätzliche CRC-Prüfsumme, gebildet über das Datenpaket, erweitert.

**A.1.2 Versuch Laufband V1.2 mit 9 Probanden und jeweils 2 Aufzeichnungen**

|                     |   |
|---------------------|---|
| Versuchsnummer:     | V1.2  |
| Versuchsablauf:     | 2 x { 3, 5, 7, 9, 11 km/h } für jeweils 2 min   |
| Probanden:          | 9 Männer  |
| Körpersensor:       | BG-V4.2<br>Einstellungen: Aufzeichnungsfrequenz 75 Hz, Messbereich Beschleunigungssensor $\pm 12$ g |
| Zusätzliche Geräte: | Woodway Lamellenlaufbänder  |
| Datum:              | 16.07.2012, V1.2(1)<br>18.07.2012, V1.2(2)  |
| Ort:                | Fitness- und Gesundheitszentrum, Universität Bielefeld  |

Es wurde der Versuchsablauf von V1.1 mit neun männlichen Probanden (Eigenschaften siehe Tabelle A.2) wiederholt, wobei jeder Proband den Versuch zweimal mit einem zeitlichen Abstand von einer Woche durchführte (V1.2(1) und V1.2(2)). Alle Probanden absolvierten pro Versuchstag zweimal die fünf Geschwindigkeiten 3, 5, 7, 9 und 11 km/h.

Die Aufzeichnung von EKG- und Beschleunigungssignalen erfolgte in den internen Flash-Speicher des BG-V4.2 mit einer Frequenz von 75 Hz. Der Messbereich des Beschleunigungssensors betrug dabei  $\pm 12$  g. Die Annotation der Signale und die Entfernung von Übergangsbereichen während Geschwindigkeitsanpassungen erfolgten manuell im Anschluss an die Aufzeichnung. Die Datenreihe V1.2(1) umfasst für  $P5_{V1.2}$  bei der ersten Absolvierung der Geschwindigkeit 3 km/h nur etwa 5000 Tupel, da nach einem Abriss der Sicherungsschnur das Laufband neu gestartet werden musste. Bei V1.2(2) liegt das Minimum für  $P1_{V1.2}$  bei 3 km/h aufgrund eines verzögerten Starts bei etwa 6000 Tupel. Für die übrigen Geschwindigkeitsklassen und Probanden stehen mehr als 8000 Tupel (pro Durchgang) zur Verfügung. Eine Gleichverteilung der Datentupel zwischen den Geschwindigkeitsklassen und Probanden ist für das Training und die Evaluation von Klassifikationsalgorithmen von Bedeutung. Die beiden Datenreihen wurden dazu auf die jeweilige Mindestanzahl an Tupel reduziert (10000 Tupel / Klasse und 12000 Tupel / Klasse)<sup>1</sup>.

Tabelle A.2.: Überblick Probandeneigenschaften V1.2.

|              | Mittelwert $\pm \sigma$ | Wertebereich |
|--------------|-------------------------|--------------|
| Alter [a]    | 27,8 $\pm$ 2,8          | 24-34        |
| Größe [cm]   | 183 $\pm$ 4,9           | 172-189      |
| Gewicht [kg] | 78,3 $\pm$ 4,7          | 68-85        |

<sup>1</sup>Die Ermittlung der Genauigkeit der Online-Geschwindigkeitsbestimmung (Portierung auf das BG-V4.2) erfolgte hingegen auf den ungekürzten Datenreihen der einzelnen Probanden.

### A.1.3 Versuch Ergospirometrie V1.3 mit 5 Probanden

---

|                     |  |
|---------------------|--|
| Versuchsnummer:     | V1.3   |
| Versuchsablauf:     | 3 min Ruhe, 1 x { 3, 5, 7, 9, 11, 5 km/h } für jeweils 3 min, 3 min Ruhe   |
| Probanden:          | 4 Männer, 1 Frau   |
| Körpersensor:       | BG-V4.2 um Atemsensor erweitert<br>Einstellungen: Aufzeichnungsfrequenz 100 Hz, Messbereich Beschleunigungssensor $\pm 12$ g |
| Zusätzliche Geräte: | CORTEX Metalyzer, Woodway Lamellenlaufband   |
| Datum:              | 23.05.2013   |
| Ort:                | Labor Sportmedizin, Universität Bielefeld  |

---

Ziel des Versuchs war die Evaluation der realisierten Atemfrequenzbestimmung für den Körpersensor BG-V4.2. Dazu wurde eine Ergospirometrie mit fünf Probanden im Labor der Sportmedizin der Universität Bielefeld durchgeführt, um eine Referenz für Atemfrequenz und Atemzugvolumen zu erhalten. Die Probanden absolvierten einen Stufentest, der Ruhe sowie leichte bis hohe körperliche Beanspruchungen abdeckte. Zunächst wurden drei Minuten in Ruhe erfasst. Anschließend erfolgte eine Erhöhung der Geschwindigkeit, startend bei 3 km/h, alle drei Minuten um 2 km/h bis auf 11 km/h. Es folgten drei Minuten Gehen bei 5 km/h und eine dreiminütige Erholungsphase (Gesamtdauer 24 min).

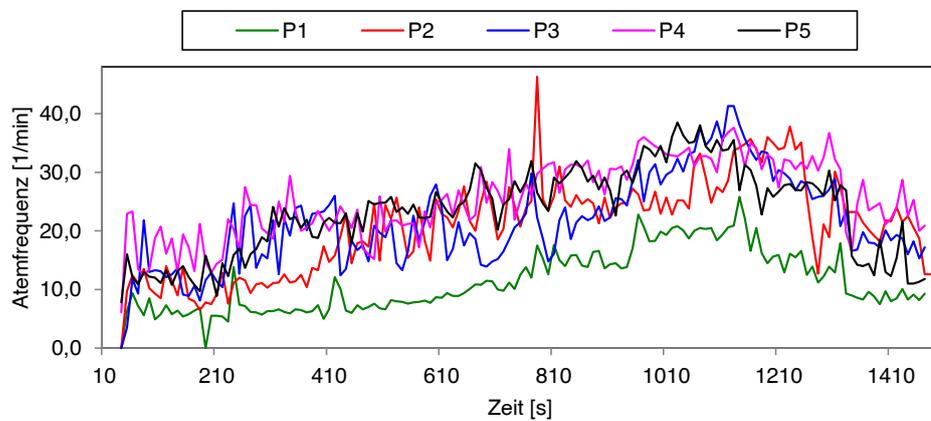
Die Probanden legten das BG-V4.2, angebracht auf einem Brustgurt, an. Die Platzierung des Atemsensors erfolgte dabei seitlich am Thorax zwischen den senkrechten Orientierungslinien *linea medioclavicularis* und *linea axillaris anterior*. Während des Versuchs wurden das EKG, die Oberkörperbeschleunigungen, die Temperatur und der Kraftwert des Atemsensors mit einer Wortbreite von 12 b und einer Frequenz von 100 Hz in den Flash-Speicher aufgezeichnet.

Das Ergospirometriesystem *Metalyzer* der Firma Cortex Biophysik GmbH diente bezüglich des Atemsensors als Referenzsystem. Während der Aufzeichnung trugen die Probanden dazu eine Atemmaske, deren Größe sie selbst vorab auswählten. Die Aufzeichnung der Parameter Atemfrequenz, Atemminutenvolumen, Sauerstoffaufnahme und Kohlendioxidabgabe erfolgte kabelgebunden mit einer Frequenz von 0,1 Hz. Für die Datenaufbereitung wurde die Software *MetaSoft* (Version 3.7) genutzt. Vor Versuchsbeginn wurde die empfohlene Aufwärmphase des Ergospirometriesystems von 30 min eingehalten und eine Kalibrierung des Systems bezüglich Luftdruck, Volumen und Gas durchgeführt. Die zeitliche Synchronisation der Daten von Körpersensor und Ergospirometriesystem erfolgte manuell. Die Abbildung A.1 zeigt die mittels des Ergospirometriesystems gemessene Atemfrequenz und das Atemminutenvolumen im zeitlichen Verlauf für die fünf Probanden.

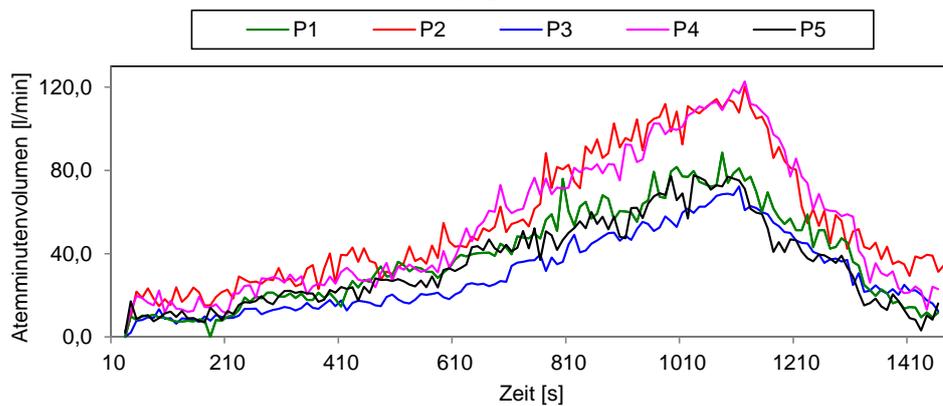
Mit dem Probandenprotokoll wurden zusätzlich der Brustumfang und die Längeneinstellung des Brustgurts erfasst, um den Anpressdruck des Atemsensors bewerten zu können. Weitere erhobene Probandeneigenschaften für die Analyse der Ergospirometrieergebnisse und die Berechnung des Energieumsatzes sind ebenfalls in der Tabelle A.3 aufgeführt.

Tabelle A.3.: Probandenprotokoll V1.4.

| P | Geschlecht | Brustum-<br>fang [cm] | Gurt-<br>länge [cm] | Alter<br>[a] | Größe<br>[cm] | Gewicht<br>[kg] | Sport /<br>Woche [h] |
|---|------------|-----------------------|---------------------|--------------|---------------|-----------------|----------------------|
| 1 | m          | 88                    | –                   | 25           | 179           | 69              | 2                    |
| 2 | m          | 95                    | 81                  | 23           | 190           | 83              | 6                    |
| 3 | w          | 75                    | 66,5                | 23           | 172           | 56              | 4-6                  |
| 4 | m          | 96                    | 78                  | 31           | 188           | 90              | 4                    |
| 5 | m          | 91                    | 82                  | 28           | 184           | 75              | 4                    |



(a) Atemzüge pro Minute.



(b) Atemminutenvolumen.

Abbildung A.1.: Ausgaben des Ergospirometriesystems für die fünf Probanden (P). Die höchste Belastungsstufe mit 11 km/h endete bei 1080 s.

## A.2 Verschiedene Geschwindigkeiten Laufbahn V2

---

|                     |   |
|---------------------|---|
| Versuchsnummer:     | V2  |
| Versuchsablauf:     | 2 x { 3, 5, 7, 9 km/h } für jeweils 400 m   |
| Probanden:          | V2(1): 11 Männer, 2 Frauen<br>V2(2): 9 Männer, 1 Frau (P4, P6 und P13 fehlten)                      |
| Körpersensor:       | BG-V4.2<br>Einstellungen: Aufzeichnungsfrequenz 100 Hz, Messbereich Beschleunigungssensor $\pm 6$ g |
| Zusätzliche Geräte: | Garmin CX405, 2 Stoppuhren  |
| Datum:              | 08.08.2012, V2(1)<br>15.08.2012, V2(2)  |
| Ort:                | Aschenbahn mit Schotterbett, Universität Bielefeld  |

---



Abbildung A.2.: Laufbahn mit eingezeichneten GPS-basierten Trajektorien der Läufergruppen.

Ziel des Versuchs war die Aufzeichnung von Schrittmustern bei Gang- und Laufgeschwindigkeiten im Außenbereich auf einer Laufbahn (Aschenbahn, siehe Abbildung A.2). Für jeden Probanden wurden dazu zwei Datenreihen in einem zeitlichen Abstand von einer Woche erfasst. An der ersten Aufzeichnung V2(1) nahmen 13 Probanden teil (Probandeneigenschaften siehe Tabelle A.4); zehn von ihnen (P4, P6 und P13 konnten nicht teilnehmen) wiederholten den Versuch in der nächsten Woche V2(2). Die Probanden absolvierten einen Stufentest mit Geschwindigkeiten von 3 km/h bis 11 km/h korrespondierend zu langsamem, normalem und schnellem Gehen und Laufen. Um zusätzlich die Rundenzeit manuell mit einer Stoppuhr erfassen zu können, wurde jeweils eine Runde zurückgelegt. Die Geschwindigkeitserhöhung um 2 km/h bis zur selbstgewählten Höchstgeschwindigkeit erfolgte jeweils zu Rundenanfang.

Tabelle A.4.: Überblick Probandeneigenschaften V2 (13 Probanden).

|              | Mittelwert $\pm \sigma$ | Wertebereich |
|--------------|-------------------------|--------------|
| Alter (a)    | 26,6 $\pm$ 3,5          | 23-34        |
| Größe (cm)   | 181,8 $\pm$ 9,4         | 163-197      |
| Gewicht (kg) | 80,5 $\pm$ 9,2          | 60-90        |

Die Probanden organisierten sich in Gruppen mit drei bis fünf Läufern, die jeweils von einem Läufer angeführt wurden, der die Geschwindigkeit mit Hilfe einer Garmin 405CX Laufuhr kontrollierte. Die Laufuhr berechnet die Geschwindigkeit anhand von GPS-Informationen; die Genauigkeit der Geschwindigkeitsangaben schwankte jedoch mit der Empfangsqualität der GPS-Signale. Zusätzlich erfolgte daher eine manuelle Zeiterfassung an zwei Messpunkten mittels Stoppuhr.

Die Aufzeichnung des EKGs und der Oberkörperbeschleunigungen erfolgte mit dem Körpersensor BG-V4.2. Den Probanden wurde zu Versuchsanfang erklärt, wie dieser mittels des Brustgurts anzulegen ist (Anfeuchten der EKG-Textilelektroden, Positionierung und Anpressdruck). Die Aufzeichnungsfrequenz betrug 100 Hz und die Wortbreite 12 b.

Alle Probanden liefen eine vollständige Runde für Geschwindigkeiten bis einschließlich 9 km/h. Bei V2(1) absolvierte nur die zweite Läufergruppe eine vollständige Runde mit 11 km/h; die erste Gruppe lief 200 m und die dritte Gruppe 300 m. Bei der Wiederholung V2(2) liefen die erste und die dritte Gruppe eine vollständige Runde mit 11 km/h und die zweite Gruppe 300 m. Die Annotation der Datenreihen mit den Geschwindigkeiten und den Probandennummern sowie die Entfernung der Übergänge zwischen den Geschwindigkeiten erfolgte manuell. Für die vier Geschwindigkeitsklassen wurde im Anschluss das gemeinsame Minimum an Datentupel, getrennt für die beiden Datenreihen, bestimmt. Es erfolgte eine Reduktion der Tupelanzahl, um eine Gleichverteilung zwischen den Geschwindigkeitsklassen der jeweiligen Datenreihe zu erzielen. Für V2(1) sind dies 15800 Tupel pro Geschwindigkeitsklasse und für V2(2) 15600.

### A.3 Handballtrainingsspiel V3 des Soester TV

---

|                     |  |
|---------------------|--|
| Versuchsnummer:     | V3   |
| Versuchsablauf:     | Trainingsspiel   |
| Probanden:          | 14 Männer  |
| Körpersensor:       | BG-V4.2<br>Einstellungen: Aufzeichnungsfrequenz 150 Hz, Messbereich Beschleunigungssensor: Brust $\pm 12$ g, Extremitäten $\pm 24$ g |
| Zusätzliche Geräte: | SPA (Videotracking), XIO Technologies x-IMU (Inertialsensor)   |
| Datum:              | 15.11.2011   |
| Ort:                | Sporthalle Schulzentrum, Paradieser Weg 92, 59494 Soest  |

---

Aufgezeichnet wurde ein Trainingsspiel mit 14 Handballspielern der Herrenmannschaft (Oberliga) des Soester Turnvereins (TV), die Probandeneigenschaften sind in der Tabelle A.5 zusammengefasst. Gespielt wurden zweimal etwa 20 min mit einer Erholungspause von 5 min. Das Trainingsspiel endete unentschieden mit 14 zu 14 Toren. Ziel war die Erfassung der körperlichen Aktivität und der Herz-Kreislaufbelastung mit dem Körpersensor BG-V4.2 und zusätzlich der Lauftrajektorien mit dem videobasierten Trackingverfahren des SPAs [163].

Um den Bewegungsablauf möglichst detailliert erfassen zu können, trugen die Handballspieler einen Körpersensor am Sprungbein (oberhalb des Fußgelenks), am Wurfarm (oberhalb des Handgelenks) und im Brustbereich (siehe Abbildung A.3). Für die Anbringung an den Extremitäten wurden Schweißbänder genutzt, in die jeweils ein Einschub für das BG-V4.2 eingenäht worden war. Auf eine einheitliche Achsenorientierung der Beschleunigungssensoren wurde beim Anlegen geachtet. Zum Einsatz kamen insgesamt 42 BG-V4.2. Die Messbereiche der Beschleunigungssensoren an den Extremitäten wurden auf  $\pm 24$  g eingestellt, im Brustbereich waren es  $\pm 12$  g. Die Aufzeichnung der EKG- und Beschleunigungssignale erfolgte mit einer Frequenz von 150 Hz in den internen Flash-Speicher. Der Handballspieler P8 trug zusätzlich eine x-IMU, um Informationen von Gyroskopen und Magnetometern erfassen zu können<sup>2</sup>. Die Videoaufzeichnung erfolgte über zwei an der Hallendecke installierte Gigabit-Ethernet Kameras mit Fischaugenobjektiven (Messaufbau und Aufzeichnungsauflösung siehe [163, S.58f]). Die Bestimmung der Lauftrajektorien der Handballspieler erfolgte im Nachhinein mit dem Trackingverfahren des SPA. Darüber hinaus kamen sechs Empfänger am Spielfeldrand zum Einsatz (jeweils einer hinter den Toren und zwei pro Längsseite), um die drahtlose Kommunikation von Sensormesswerten und Parametern mit dem nRF24L01-Transceiver in einer Sporthalle bewerten zu können.

Während der Aufzeichnung kam es aufgrund von Körperkontakten teils dazu, dass sich die Druckknöpfe zwischen Brustgurt und Körpersensor lösten. Für zwei Handballspieler (P2 und P12) betraf dies nur einen der beiden Druckknöpfe, sodass dies zunächst nicht auffiel. Während dieser Zeit konnte jedoch das EKG nicht erfasst werden; es erfolgte eine entsprechende

---

<sup>2</sup>x-IMU der britischen Firma XIO Technologies (<http://www.x-io.co.uk>, letzter Zugriff 08.01.2014).

Tabelle A.5.: Überblick Probandeneigenschaften V3.

|                             | Mittelwert $\pm \sigma$ | Wertebereich |
|-----------------------------|-------------------------|--------------|
| Alter (a)                   | 22.2 $\pm$ 5.8          | 16-36        |
| Größe (cm)                  | 187.8 $\pm$ 8.1         | 170-200      |
| Gewicht (kg)                | 84.8 $\pm$ 10.0         | 64-102       |
| Wurfarm (rechts / links)    | 13 rechts / 1 links     |              |
| Sprungbein (rechts / links) | 1 rechts / 13 links     |              |

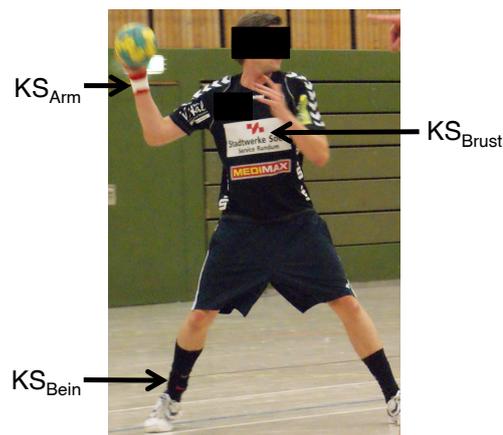


Abbildung A.3.: Handballspieler mit angelegten Körpersensoren (KS).

Annotation der nicht verwertbaren Signalabschnitte. Nach Ausschluss dieser Abschnitte stehen 192868 Tupel für  $P_2$  und 279799 Tupel für  $P_{12}$  zur Verfügung. Um eine Gleichverteilung der Tupelanzahl zwischen den übrigen zwölf Handballspielern zu erreichen, erfolgte eine Reduktion auf das gemeinsame Minimum von 341473 Tupel (inklusive Spielunterbrechungen).

Für die zeitliche Synchronisation der Daten der 42 BG-V4.2 mit denen des SPAs erfolgte zunächst die Bestimmung der real erzielten Aufzeichnungsfrequenz der einzelnen BG-V4.2. Das arithmetische Mittel betrug  $149,62 \pm 0,017$  Hz, das Minimum lag bei 149,56 Hz und das Maximum bei 149,66 Hz; als Korrekturmaßnahme erfolgte eine Interpolation auf eine Frequenz von 150 Hz. Anschließend wurde der Startzeitpunkt des Trainingsspiels anhand des zu Anfang gemeinsam von den Handballspielern ausgeübten Klopfsignals auf die Körpersensoren (Brustbereich) in den Beschleunigungsmesswerten und Videobildern identifiziert. Die weitere zeitliche Synchronisation zwischen den Sensormesswerten der 42 BG-V4.2 und den einzelnen Videobildern erfolgte anhand von Zeitstempeln.



## B Erweiterte Ergebnisdarstellung

### B.1 Gang- und Laufgeschwindigkeitsbestimmung

#### B.1.1 Ergebnisse Laufband V1.1

Tabelle B.1.: *Mittlere Sensitivität und Spezifität (mit Standardabweichung und Bereich) der Laufgeschwindigkeitsbestimmung für die Datenreihe aus V1.1. Die Ergebnisse wurden mit einer zehnfachen stratifizierten Kreuzvalidierung für den Merkmalsraum  $M_{G4}$  und drei Klassifikatoren ermittelt. Ergebnisse für Geschwindigkeiten von a) 3 km/h bis 9 km/h mit 20 Probanden und b) 3 km/h bis 11 km/h mit 15 Probanden.*

|    | Klassifikator      | $\bar{R} \pm \sigma$ [Min.–Max.] [%] | $\bar{S} \pm \sigma$ [Min.–Max.] [%] |
|----|--------------------|--------------------------------------|--------------------------------------|
| a) | MLP <sub>12</sub>  | 98,4 ± 0,6 [97,7 – 98,9]             | 99,5 ± 0,2 [99,2 – 99,7]             |
|    | EB <sub>117</sub>  | 97,8 ± 0,6 [97,1 – 98,4]             | 99,3 ± 0,2 [99,2 – 99,5]             |
|    | RF <sub>20,4</sub> | <b>98,8 ± 0,5 [98,2 – 99,4]</b>      | <b>99,6 ± 0,1 [99,4 – 99,7]</b>      |
| b) | MLP <sub>13</sub>  | 95,6 ± 3,7 [90,6 – 98,8]             | 98,9 ± 1,0 [97,7 – 99,7]             |
|    | EB <sub>263</sub>  | 95,3 ± 4,8 [89,1 – 99,2]             | 98,8 ± 1,2 [97,5 – 99,8]             |
|    | RF <sub>20,4</sub> | <b>97,8 ± 2,1 [95,3 – 99,4]</b>      | <b>99,4 ± 0,6 [98,6 – 99,9]</b>      |

### B.1.2 Ergebnisse Laufbahn V2

Tabelle B.2.: Klassifikationsergebnisse der Geschwindigkeitsbestimmung für die Datenreihe aus V2 basierend auf dem Merkmalsraum  $M_{G4}$  und drei Klassifikatoren. Das Training erfolgte auf der ersten Datenreihe und die Evaluation auf der zweiten eine Woche später. Es wurde dabei auf eine Gleichverteilung der Tupelanzahl zwischen den Geschwindigkeitsklassen geachtet (780 Tupel / Klasse).  $v_R$  bezeichnet die Referenz und  $v_K$  die Klassifikatorausgabe.

(a) MLP

| $v_R \backslash v_K$ | 3 km/h     | 5 km/h     | 7 km/h     | 9 km/h     |
|----------------------|------------|------------|------------|------------|
| 3 km/h               | <b>767</b> | 12         | 1          | 0          |
| 5 km/h               | 14         | <b>735</b> | 31         | 0          |
| 7 km/h               | 0          | 69         | <b>711</b> | 0          |
| 9 km/h               | 0          | 0          | 1          | <b>779</b> |

(b) EB

| $v_R \backslash v_K$ | 3 km/h     | 5 km/h     | 7 km/h     | 9 km/h     |
|----------------------|------------|------------|------------|------------|
| 3 km/h               | <b>737</b> | 43         | 0          | 0          |
| 5 km/h               | 0          | <b>766</b> | 14         | 0          |
| 7 km/h               | 0          | 26         | <b>740</b> | 14         |
| 9 km/h               | 0          | 0          | 1          | <b>779</b> |

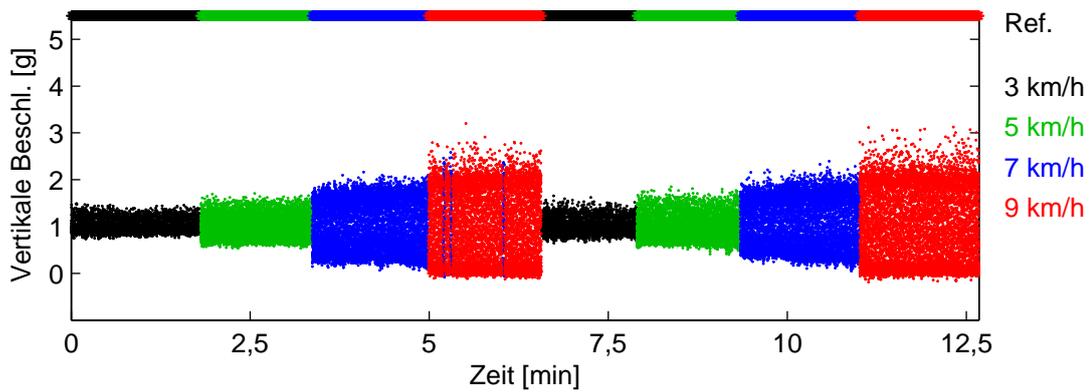
(c) RF

| $v_R \backslash v_K$ | 3 km/h     | 5 km/h     | 7 km/h     | 9 km/h     |
|----------------------|------------|------------|------------|------------|
| 3 km/h               | <b>748</b> | 32         | 0          | 0          |
| 5 km/h               | 3          | <b>759</b> | 18         | 0          |
| 7 km/h               | 0          | 27         | <b>752</b> | 1          |
| 9 km/h               | 0          | 0          | 2          | <b>778</b> |

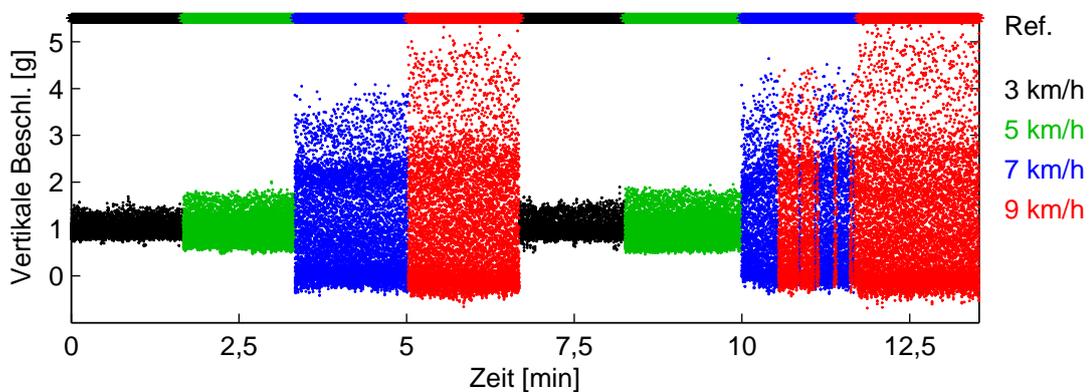
**B.1.3 Ergebnisse Laufband V1.2**

Tabelle B.4.: Gesamtgenauigkeit in [%] der auf den Körpersensor BG-V4.2 portierten Geschwindigkeitsbestimmung für neun Probanden und vier Geschwindigkeitsstufen (Datenreihe V1.2(2)).

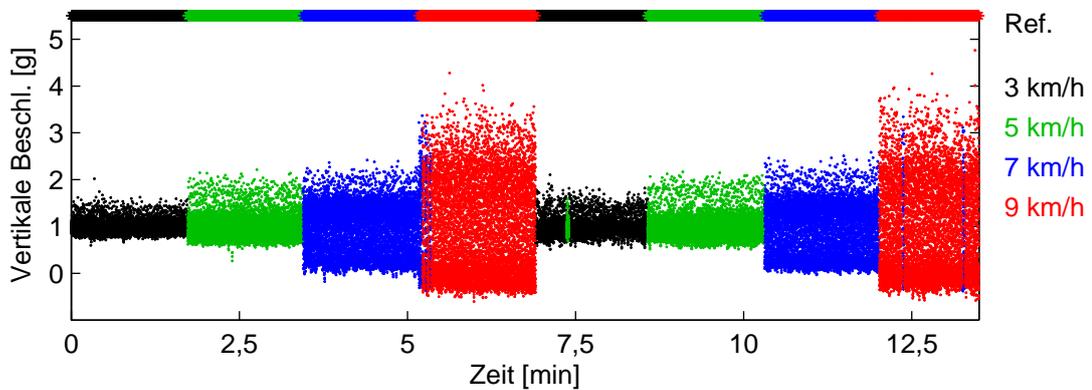
|    | 3 km/h | 5 km/h | 7 km/h | 9 km/h |
|----|--------|--------|--------|--------|
| P1 | 100    | 100    | 100    | 96,9   |
| P2 | 100    | 100    | 73,2   | 97,5   |
| P3 | 98,4   | 99,5   | 100    | 100    |
| P4 | 100    | 100    | 85,4   | 88,0   |
| P5 | 100    | 100    | 80,5   | 100    |
| P6 | 99,0   | 100    | 100    | 94,3   |
| P7 | 100    | 100    | 100    | 90,5   |
| P8 | 100    | 100    | 79,7   | 98,9   |
| P9 | 97,3   | 93,8   | 93,3   | 93,8   |



(a) Proband  $P1_{V1,2}$  mit einer Klassifikationsgenauigkeit von 99,2%.

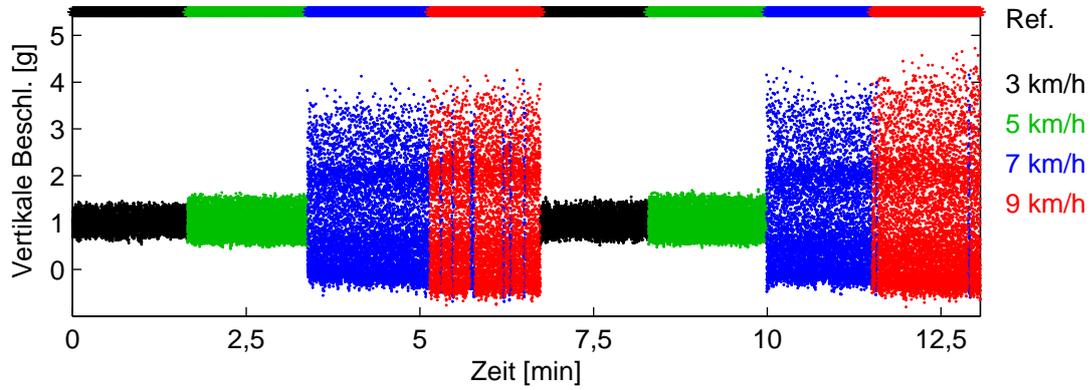


(b) Proband  $P5_{V1,2}$  mit einer Klassifikationsgenauigkeit von 95,1%.

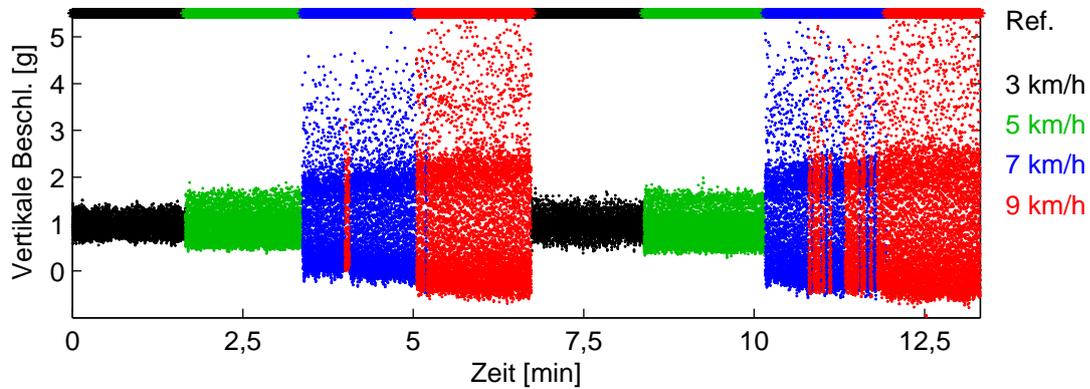


(c) Proband  $P6_{V1,2}$  mit einer Klassifikationsgenauigkeit von 98,4%.

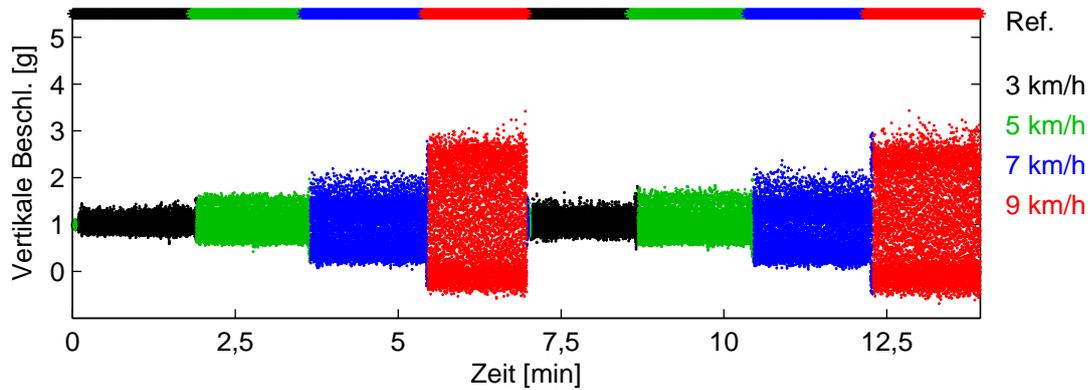
Abbildung B.1.: Vertikales Beschleunigungssignal eingefärbt für die Ergebnisse der Online-Geschwindigkeitsbestimmung auf dem MSP430xG461x des BG-V4.2. Als Referenz ist oberhalb die auf dem Laufband tatsächlich eingestellte Geschwindigkeit abgebildet.



(a) Proband  $P7_{V1,2}$  mit einer Klassifikationsgenauigkeit von 97,7%.



(b) Proband  $P8_{V1,2}$  mit einer Klassifikationsgenauigkeit von 94,5%.



(c) Proband  $P9_{V1,2}$  mit einer Klassifikationsgenauigkeit von 94,5%.

Abbildung B.2.: Fortsetzung der Ergebnisdarstellung der Online-Geschwindigkeitsbestimmung. Fehlklassifikationen treten vor allem bei 7 km/h auf.

## B.2 Personenidentifikation

### B.2.1 Ergebnisse Laufband V1.2

Tabelle B.5.: Konfusionsmatrizen mit den Klassifikationsergebnissen für die Identifikation der neun Probanden  $P$  auf Grundlage des Merkmalsraums  $M_{I8}$  und des  $RF_{100,10}$  Klassifikators.  $P_R$  bezeichnet die Klassenreferenz (Annotation) und  $P_K$  die Klassifikatorausgabe.

(a) Training auf der Datenreihe aus V1.2(1) und Evaluation auf V1.2(2),  $\bar{R} = 90,7\%$ .

| $P_R \backslash P_K$ | P1         | P2         | P3         | P4         | P5         | P6         | P7         | P8         | P9         |
|----------------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| P1                   | <b>148</b> | 6          | 1          | 0          | 0          | 28         | 1          | 13         | 2          |
| P2                   | 0          | <b>194</b> | 0          | 0          | 0          | 4          | 0          | 0          | 0          |
| P3                   | 0          | 0          | <b>194</b> | 0          | 0          | 1          | 0          | 1          | 3          |
| P4                   | 10         | 4          | 0          | <b>154</b> | 1          | 29         | 0          | 0          | 0          |
| P5                   | 1          | 0          | 0          | 2          | <b>192</b> | 2          | 0          | 1          | 0          |
| P6                   | 0          | 2          | 4          | 0          | 1          | <b>190</b> | 0          | 1          | 1          |
| P7                   | 0          | 0          | 1          | 0          | 0          | 0          | <b>193</b> | 4          | 0          |
| P8                   | 2          | 0          | 0          | 0          | 0          | 0          | 0          | <b>197</b> | 0          |
| P9                   | 0          | 24         | 1          | 0          | 0          | 8          | 1          | 6          | <b>158</b> |

(b) Training auf der Datenreihe aus V1.2(2) und Evaluation auf V1.2(1),  $\bar{R} = 93,8\%$ .

| $P_R \backslash P_K$ | P1         | P2         | P3         | P4         | P5         | P6         | P7         | P8         | P9         |
|----------------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| P1                   | <b>148</b> | 0          | 0          | 15         | 0          | 0          | 0          | 2          | 0          |
| P2                   | 0          | <b>162</b> | 0          | 0          | 0          | 0          | 1          | 0          | 2          |
| P3                   | 0          | 0          | <b>143</b> | 0          | 1          | 8          | 12         | 1          | 0          |
| P4                   | 0          | 1          | 0          | <b>165</b> | 0          | 0          | 0          | 0          | 0          |
| P5                   | 0          | 0          | 0          | 14         | <b>138</b> | 8          | 2          | 3          | 0          |
| P6                   | 0          | 0          | 0          | 3          | 0          | <b>162</b> | 0          | 0          | 0          |
| P7                   | 0          | 0          | 0          | 2          | 0          | 0          | <b>163</b> | 0          | 0          |
| P8                   | 3          | 0          | 1          | 0          | 0          | 3          | 1          | <b>157</b> | 0          |
| P9                   | 0          | 0          | 3          | 0          | 0          | 6          | 0          | 0          | <b>156</b> |

## B.2.2 Ergebnisse Handballtrainingsspiel V3

Tabelle B.7.: Konfusionsmatrix mit den Klassifikationsergebnissen für die Identifikation der 14 Handballspieler  $P$  auf Grundlage des Merkmalsraums  $M_{I8}$  und des  $RF_{100,70}$  Klassifikators.  $P_R$  bezeichnet die Klassenreferenz (Annotation) und  $P_K$  die Klassifikatorausgabe. Die Datenreihen von  $P2$  und  $P12$  umfassen weniger Tupel (siehe Abschnitt A.3).

| $P_R \backslash P_K$ | $P1$       | $P2$       | $P3$       | $P4$       | $P5$       | $P6$       | $P7$       | $P8$       | $P9$       | $P10$      | $P11$      | $P12$      | $P13$      | $P14$      |
|----------------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|------------|
| $P1$                 | <b>543</b> | 1          | 0          | 0          | 2          | 0          | 12         | 0          | 0          | 1          | 1          | 5          | 0          | 3          |
| $P2$                 | 4          | <b>295</b> | 0          | 2          | 1          | 0          | 9          | 0          | 0          | 0          | 0          | 2          | 0          | 7          |
| $P3$                 | 1          | 0          | <b>514</b> | 0          | 21         | 0          | 1          | 0          | 2          | 9          | 1          | 3          | 11         | 4          |
| $P4$                 | 2          | 0          | 0          | <b>489</b> | 0          | 0          | 33         | 0          | 0          | 0          | 0          | 36         | 0          | 8          |
| $P5$                 | 21         | 0          | 13         | 0          | <b>474</b> | 1          | 2          | 0          | 1          | 19         | 20         | 4          | 10         | 3          |
| $P6$                 | 3          | 0          | 0          | 0          | 3          | <b>533</b> | 0          | 0          | 5          | 5          | 9          | 9          | 0          | 0          |
| $P7$                 | 20         | 1          | 0          | 3          | 1          | 0          | <b>519</b> | 0          | 0          | 0          | 0          | 9          | 0          | 15         |
| $P8$                 | 0          | 0          | 0          | 0          | 0          | 0          | 0          | <b>567</b> | 0          | 0          | 0          | 0          | 0          | 0          |
| $P9$                 | 11         | 0          | 0          | 0          | 0          | 30         | 0          | 0          | <b>525</b> | 2          | 0          | 0          | 0          | 0          |
| $P10$                | 3          | 0          | 7          | 0          | 33         | 6          | 0          | 0          | 11         | <b>496</b> | 4          | 0          | 7          | 1          |
| $P11$                | 12         | 0          | 0          | 0          | 4          | 25         | 0          | 0          | 2          | 0          | <b>523</b> | 0          | 1          | 0          |
| $P12$                | 2          | 2          | 0          | 1          | 0          | 0          | 28         | 0          | 0          | 0          | 0          | <b>414</b> | 3          | 15         |
| $P13$                | 1          | 0          | 5          | 0          | 32         | 0          | 1          | 0          | 0          | 13         | 14         | 2          | <b>499</b> | 1          |
| $P14$                | 3          | 0          | 0          | 0          | 1          | 0          | 4          | 0          | 0          | 0          | 0          | 10         | 0          | <b>549</b> |

### B.3 Pareto-optimale Konfigurationen Gang- und Laufgeschwindigkeitsbestimmung

Tabelle B.8.: Liste der 15 Pareto-optimalen Konfigurationen der Entwurfsraumexploration der Gang- und Laufgeschwindigkeitsbestimmung, die die folgenden Konfigurationsparameter umfasste: Achsenanzahl ( $K_A$ ), Aufzeichnungsfrequenz ( $K_{f_s}$ ), Merkmalsraum ( $K_M$ ), Klassifikator ( $K_K$ ), Neuronenanzahl ( $K_N$ ) und Konfiguration des EB ( $K_{EB}$ ). Weitere Informationen zu den Konfigurationen befinden sich in Tabelle 7.1. Angegeben sind der Taktzyklenaufwand (gesamt und Klassifikatoranteil) und die Klassifikationsgenauigkeit  $\bar{R}$ .

| $P$ | $K_A$ | $K_{f_s}$<br>[Hz] | $K_M$ | $K_K$ | $K_N$ | $K_{EB}$ | Takte | Anteil $K_K$<br>[%] | $\bar{R}$<br>[%] |
|-----|-------|-------------------|-------|-------|-------|----------|-------|---------------------|------------------|
| 1   | 3     | 75                | 7     | MLP   | 10    | -        | 22422 | 23,8                | 93,92            |
| 2   | 3     | 75                | 7     | EB    | -     | 5        | 17152 | 0,3                 | 93,64            |
| 3   | 3     | 18                | 7     | MLP   | 20    | -        | 13976 | 65,5                | 93,58            |
| 4   | 3     | 37                | 4     | MLP   | 7     | -        | 12535 | 30,0                | 93,47            |
| 5   | 3     | 37                | 7     | MLP   | 3     | -        | 11092 | 20,9                | 93,30            |
| 6   | 1     | 75                | 1     | MLP   | 3     | -        | 5564  | 34,7                | 93,18            |
| 7   | 1     | 37                | 1     | MLP   | 3     | -        | 3815  | 50,6                | 93,01            |
| 8   | 1     | 18                | 5     | MLP   | 5     | -        | 3802  | 71,6                | 92,33            |
| 9   | 1     | 18                | 1     | MLP   | 3     | -        | 3020  | 64,2                | 92,22            |
| 10  | 1     | 18                | 1     | EB    | -     | 2        | 1117  | 3,2                 | 92,16            |
| 11  | 1     | 9                 | 1     | EB    | -     | 2        | 722   | 5,0                 | 90,28            |
| 12  | 1     | 18                | 2     | EB    | -     | 1        | 592   | 6,8                 | 86,88            |
| 13  | 1     | 4                 | 5     | EB    | -     | 1        | 554   | 10,6                | 86,48            |
| 14  | 1     | 4                 | 5     | EB    | -     | 3        | 540   | 8,3                 | 84,89            |
| 15  | 1     | 4                 | 2     | EB    | -     | 2        | 204   | 17,6                | 84,66            |

Tabelle B.9.: Liste der 16 Pareto-optimalen Konfigurationen der Wiederholung der Entwurfsraumexploration. Aufgrund der zufälligen Initialisierung des MLPs entstehen für die Trainingsvorgänge unterschiedliche Vorhersagemodelle, sodass es zu Variationen in der Klassifikationsgenauigkeit und der benötigten Taktzyklenanzahl kommt. Dies führt zu anderen Pareto-optimalen Konfigurationen.

| $P_W$ | $K_A$ | $K_{f_s}$<br>[Hz] | $K_M$ | $K_K$ | $K_N$ | $K_{EB}$ | Takte | Anteil $K_K$<br>[%] | $\bar{R}$<br>[%] |
|-------|-------|-------------------|-------|-------|-------|----------|-------|---------------------|------------------|
| 1     | 3     | 150               | 7     | EB    | -     | 2        | 33802 | 0,2                 | 93,86            |
| 2     | 3     | 37                | 7     | MLP   | 10    | -        | 14092 | 37,8                | 93,81            |
| 3     | 3     | 37                | 4     | MLP   | 5     | -        | 11687 | 25,0                | 93,47            |
| 4     | 3     | 37                | 7     | MLP   | 3     | -        | 11097 | 21,0                | 93,30            |
| 5     | 1     | 37                | 1     | MLP   | 7     | -        | 5088  | 63,0                | 93,18            |
| 6     | 1     | 37                | 1     | MLP   | 5     | -        | 4502  | 58,2                | 93,13            |
| 7     | 1     | 37                | 1     | MLP   | 3     | -        | 3814  | 50,6                | 93,01            |
| 8     | 1     | 18                | 5     | MLP   | 5     | -        | 3795  | 71,5                | 92,39            |
| 9     | 1     | 18                | 4     | MLP   | 3     | -        | 3653  | 55,9                | 92,33            |
| 10    | 1     | 18                | 1     | MLP   | 3     | -        | 3020  | 64,2                | 92,22            |
| 11    | 1     | 18                | 1     | EB    | -     | 2        | 1117  | 3,2                 | 92,16            |
| 12    | 1     | 9                 | 1     | EB    | -     | 2        | 722   | 5,0                 | 90,28            |
| 13    | 1     | 18                | 2     | EB    | -     | 1        | 592   | 6,8                 | 86,88            |
| 14    | 1     | 4                 | 5     | EB    | -     | 1        | 554   | 10,6                | 86,48            |
| 15    | 1     | 4                 | 5     | EB    | -     | 3        | 540   | 8,3                 | 84,89            |
| 16    | 1     | 4                 | 2     | EB    | -     | 2        | 204   | 17,6                | 84,66            |



# C Algorithmen

## C.1 Entscheidungsbaum Gang- Laufgeschwindigkeitsbestimmung

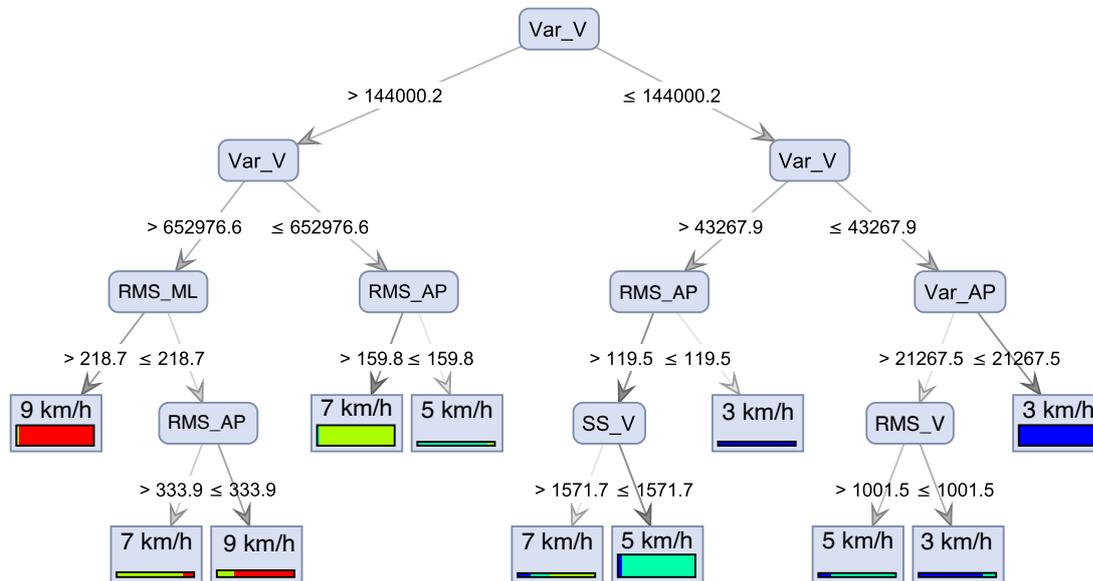


Abbildung C.1.: Darstellung des auf dem BG-V4.2 zusätzlich realisierten Entscheidungsbaums zur Gang- und Laufgeschwindigkeitsbestimmung. Basierend auf den Merkmalen der Zeitdomäne ( $M_{G2}$ ) wird eine Genauigkeit von 94,8% für Geschwindigkeiten zwischen 3 km/h und 9 km/h (4 Ausgabeklassen) erreicht. Im Gegensatz zum KNN reduziert sich die Genauigkeit, auch bei einer Vergrößerung der Baumtiefe auf 15 Ebenen, auf 85,0% für die zusätzliche fünfte Ausgabeklasse.



# Abbildungsverzeichnis

|      |  |    |
|------|--|----|
| 1.1  | Umsatzentwicklung für den Verkauf von <i>Wearables</i> in Europa (Quelle: IHS Technology, PwC Analysis, Abbildung aus [15, S.20]). . . . .   | 6  |
| 1.2  | Beispiele für Körpersensoren mit unterschiedlichen Anwendungsszenarien. . . . .  | 7  |
| 2.1  | Fotoaufnahme der bestückten Platine des BG-V4.2. . . . .   | 19 |
| 2.2  | Technisches Blockschaltbild des BG-V4.2. . . . .   | 19 |
| 2.3  | Empfänger mit integriertem nRF24L01-Transceiver und einer +9 dBi-Antenne. . . . .  | 20 |
| 2.4  | Paketaufbau für die drahtlose Kommunikation zwischen BG-V4.2 und dem Empfänger. . . . .  | 21 |
| 2.5  | Signalmonitor zur Online-Darstellung von Sensormesswerten und Parametern. . . . .  | 21 |
| 2.6  | Aktivitätsmonitor zur Offline-Analyse von Sensormesswerten und Parameter. . . . .  | 23 |
| 2.7  | Körperebenen des Menschen. . . . .   | 24 |
| 2.8  | Die Erregungsausbreitung im Herzen. . . . .  | 26 |
| 2.9  | Nomenklatur des Elektrokardiogramms (Abbildung aus [89, S.114]). . . . .   | 27 |
| 2.10 | Positionierung von EKG-Elektroden für Extremitäten- und Brustwandableitungen (Abbildung aus [89, S.118-119]). . . . .  | 28 |
| 2.11 | Leistungsspektren (normalisiert) von QRS-Komplex, P- und T-Welle, Elektromyogramm-Rauschen und Bewegungsartefakten gemittelt über 150 Herzschläge (Abbildung aus [152, S.237]). . . . .              | 29 |
| 2.12 | EKGs von drei Probanden (P) aufgezeichnet mit dem EKG-Sensor von BG-V4.x während des Gehens und Laufens auf Laufbändern. . . . .   | 31 |
| 2.13 | Atemkurven aufgezeichnet mit dem piezoresistiven Kraftsensor nach Verstärkung und Tiefpassfilterung (Butterworth 5. Ordnung, $f_c = 0,6$ Hz). . . . .  | 34 |
| 2.14 | Konstruktion und Integration des Atemsensors in den Brustgurt von BG-V4.2 (Größenangaben in Millimetern). Innenseite des Brustgurts nach außen gedreht für Sichtbarkeit des Atemsensors (e). . . . . | 35 |
| 2.15 | Gegenüberstellung der Atemkurven aufgezeichnet mit dem BG-V4.2 und einem kommerziellen RIP-basierten Atemsensor. . . . .   | 36 |
| 2.16 | Messanordnung 1: Statisches Funkszenario mit bis zu 14 aktiven um einen Empfänger in einem Kreis angeordneten BG-V4.1. . . . .   | 46 |
| 2.17 | Paketverlustrate im zeitlichen Verlauf von 16 Uhr nachmittags bis 9 Uhr morgens eines Senders im Einzeltest (Trägerfrequenz 2,465 GHz). . . . .  | 47 |
| 2.18 | Mittlere Paketverlustrate von 14 Sendern im Einzeltest in Abhängigkeit von der Paketlänge und der Paketsendefrequenz (Trägerfrequenz 2,482 GHz). . . . .   | 47 |
| 2.19 | Mittlere Paketverlustrate für 5 bis 14 zeitgleich aktive Sender in Abhängigkeit von der Paketlänge und der Paketsendefrequenz. . . . .   | 48 |
| 2.20 | Paketverlustraten für drei Messanordnungen mit Sendern (S) verteilt in einem Testraum und vier Empfängern (E) in den Ecken. . . . .  | 49 |
| 2.21 | Balkendiagramme mit der prozentualen Verteilung der Anzahl aufeinanderfolgend verlorener Pakete für vier Messanordnungen. . . . .  | 51 |
| 2.22 | Paketverlustraten in drei dynamischen Funkszenarien. . . . .   | 54 |

|      |  |     |
|------|--|-----|
| 2.23 | Leistungsaufnahme (anteilig) der Komponenten von Sensorknoten für drei Anwendungsszenarien (Abbildung aus [94]). . . . .   | 56  |
| 2.24 | Leistungsaufnahme der Komponenten des BG-V4.2 während der Speicherung und Übertragung von Sensormesswerten. . . . .  | 57  |
| 3.1  | Verarbeitungsschritte des QRS-Detektionsalgorithmus in der Implementierung von P. Hamilton. . . . .  | 63  |
| 3.2  | Atemkurve nach Analog-Digital Wandlung und digitaler Tiefpassfilterung. Die Atemzugdetektion erfolgt mit einer Spitzenerkennung, die sich an Änderungen der Frequenz und des ST-Werts anpasst. . . . . | 67  |
| 3.3  | Proband während der Ergospirometrie. Erfassung der Thoraxerweiterung und -verengung mit dem Atemsensor des BG-V4.2. . . . .  | 68  |
| 3.4  | Gegenüberstellung der Atemfrequenzbestimmung des BG-V4.2 mit den Referenzwerten des Ergospirometriesystems (Datenreihe V1.3). . . . .  | 69  |
| 3.5  | Darstellung der Differenzwerte zwischen den Atemfrequenzen ermittelt mit dem Ergospirometriesystem und dem BG-V4.2 als <i>Box-Whisker-Plots</i> . . . . .  | 70  |
| 4.1  | Zweischichtiges Perzeptron mit einer Feed-Forward-Netzstruktur. . . . .  | 75  |
| 4.2  | Mittlerer quadratischer Fehler während des Trainings eines MLPs. . . . .   | 76  |
| 4.3  | Phasen des Schrittzyklus des menschlichen Gangs (a) und der Belastungsverlauf während der Standphase am Hüftgelenk für verschiedene Ganggeschwindigkeiten (b). . . . .                                 | 88  |
| 4.4  | Vertikales Beschleunigungssignal eines Probanden eingefärbt für fünf Geschwindigkeiten zwischen 3 und 11 km/h. . . . .   | 89  |
| 4.5  | Gegenüberstellung des vertikalen Beschleunigungssignals von drei Probanden (P1 bis P3) für Geschwindigkeiten von 3 bis 11 km/h. . . . .  | 90  |
| 4.6  | Schrittmuster im vertikalen Beschleunigungssignal während des Gehens und Laufens. Gezeigt sind Aufzeichnungsmöglichkeiten mit verschiedenen Frequenzen und Wortbreiten. . . . .                        | 92  |
| 4.7  | Unterscheidung von Gehen und Laufen anhand von Spitze-Tal-Werten berechnet aus Beschleunigungsmessungen mittels einer linearen Trennfunktion einer SVM. . . . .  | 95  |
| 4.8  | Visualisierung von Merkmalen berechnet aus den dreiaxialen Beschleunigungssignalen von 16 Probanden (V1.1), eingefärbt nach der eingestellten Laufbandgeschwindigkeit (3 bis 11 km/h). . . . .         | 96  |
| 4.9  | Diskrete Wavelet Transformation (DWT) des vertikalen Beschleunigungssignals für Geschwindigkeiten von 3 bis 11 km/h. . . . .   | 97  |
| 4.10 | Klassifikationsgenauigkeit und MSE der Geschwindigkeitsbestimmung in Abhängigkeit von der Neuronenanzahl auf Grundlage von $M_{G4}$ . . . . .  | 101 |
| 4.11 | Probandenspezifische Klassifikationsgenauigkeit auf Grundlage von für jeden Probanden individuell angepassten Neuronengewichten und Biaswerten. . .  | 103 |
| 4.12 | Vertikales Beschleunigungssignal mit unterschiedlicher Färbung für die mit dem BG-V4.2 bestimmte Geschwindigkeitsklasse (Klassifikatorausgabe). . .  | 114 |

---

|      |  |     |
|------|--|-----|
| 4.13 | Herzfrequenz, ML- und V-Beschleunigungen aufgezeichnet mit dem BGV-4.2 während des Gehens und einer Stadtbahnfahrt. . . . .  | 121 |
| 4.14 | Dynamischer Beschleunigungsanteil und Herzfrequenz eines Probanden im zeitlichen Verlauf aufgezeichnet mit einem BG-V4.2 während eines Langhantelprogramms ( <i>BODYPUMP</i> ). . . . .  | 122 |
| 4.15 | Daten des Handballspielers P7 während eines Trainingsspiels und der Halbzeitpause (V3). Herzfrequenzverlauf und Aktivität aufgezeichnet mit drei BG-V4.2 (Sternum, Handgelenk und Fußgelenk). . . . .                            | 123 |
| 5.1  | Überlagerung von 100 aufeinanderfolgenden Schrittsegmenten zur Darstellung der probandenspezifischen Muster im Signalverlauf. . . . .  | 133 |
| 5.2  | Überlagerte Darstellung von Herzschlagsegmenten von sechs Probanden. . .   | 135 |
| 5.3  | Darstellung der Ergebnisse der Vorverarbeitung der EKG- und Beschleunigungssignale. . . . .  | 138 |
| 5.4  | Überlagerte Darstellung von 20 Herzschlagsegmenten von sechs Probanden. .  | 140 |
| 5.5  | Die Amplitudenspektren von EKG- und Beschleunigungssignalen dreier Probanden im Vergleich für Gehen (3 km/h) und Laufen (9 km/h). . . . .  | 143 |
| 5.6  | Visualisierung der Merkmale (Zeitdomäne) berechnet aus Beschleunigungssignalen. . . . .  | 145 |
| 5.7  | Klassenspezifische Sensitivität und Spezifität der Identifikation der 22 Probanden. . . . .  | 149 |
| 5.8  | Klassenspezifische Sensitivität und Spezifität der Identifikation der neun Probanden auf Grundlage der beiden Datenreihen aus V1.2. . . . .  | 151 |
| 5.9  | Gegenüberstellung der mittleren Sensitivität der Identifikation von 14 Handballspielern und der benötigten Trainingszeit des RF-Klassifikators in Abhängigkeit von der Anzahl eingesetzter Merkmale pro Entscheidungsbaum. . . . | 154 |
| 5.10 | Klassenspezifische Sensitivität und Spezifität der Identifikation der 14 Handballspieler. . . . .  | 154 |
| 7.1  | Blockdiagramm des CoreVA-ULP Mikroprozessors mit einer sechsstufigen Pipeline und Fotoaufnahme des SoC mit zwei CoreVA-ULP Prozessorkernen. . . .  | 171 |
| 7.2  | Ergebnisse der 1008 Simulationen eingefärbt für die unterschiedlichen Konfigurationsparameter. . . . .   | 182 |
| 7.3  | Ergebnisse der 1008 Simulationen eingefärbt für die Konfigurationsmöglichkeiten des MLPs und des EBs. . . . .  | 183 |
| 7.4  | Zusammenhang zwischen Klassifikationsgenauigkeit und benötigten Taktzyklen der Laufgeschwindigkeitsbestimmung. . . . .   | 186 |
| 7.5  | Ergebnisse der 504 Simulationen der Entwurfsraumexploration eingefärbt für die unterschiedliche Anzahl an VLIW-Slots. . . . .  | 188 |
| 8.1  | Präsentation des Körpersensors BG-V4.2 auf der internationalen Fachmesse Orthopädie und Reha-Technik 2012 in Leipzig. . . . .  | 196 |
| A.1  | Ausgaben des Ergospirometriesystems für die fünf Probanden (P). . . . .  | 227 |

|     |  |     |
|-----|--|-----|
| A.2 | Laufbahn mit eingezeichneten GPS-basierten Trajektorien der Läufergruppen.   | 228 |
| A.3 | Handballspieler mit angelegten Körpersensoren (KS).  | 231 |
| B.1 | Vertikales Beschleunigungssignal eingefärbt für die Ergebnisse der Online-Geschwindigkeitsbestimmung.                    | 236 |
| B.2 | Vertikales Beschleunigungssignal eingefärbt nach den Ergebnissen der Online-Geschwindigkeitsbestimmung (Fortsetzung).    | 237 |
| C.1 | Darstellung des auf dem BG-V4.2 zusätzlich realisierten Entscheidungsbaums zur Gang- und Laufgeschwindigkeitsbestimmung. | 243 |

# Tabellenverzeichnis

|     |  |     |
|-----|--|-----|
| 2.1 | Überblick Stand der Technik von Beschleunigungssensoren. . . . .   | 38  |
| 2.2 | Gegenüberstellung des MSP430xG461x und der Kinetis KL25 Sub-Family. . .  | 41  |
| 2.3 | Vier bei Körpersensoren in dem 2,4 GHz ISM-Frequenzband verbreitete Funk-<br>technologien (Tabelle gekürzt aus [121]). . . . .   | 44  |
| 2.4 | Leistungsaufnahme und Betriebsdauer ermittelt mit dem Messboard BGM für<br>drei Anwendungsszenarien. . . . .   | 58  |
| 2.5 | Überblick über Eigenschaften von Primär- und Sekundärelementen. . . . .  | 59  |
| 2.6 | Abschätzung von <i>Energy Harvesting</i> -Möglichkeiten nach [127]. . . . .  | 61  |
| 3.1 | Taktaufwand und Energiebedarf des QRS-Detektionsalgorithmus für die Aus-<br>führung auf dem MSP430FG4618. . . . .  | 65  |
| 4.1 | Klassifikationsgenauigkeiten für die unterschiedlichen Merkmale einzeln und<br>kombiniert auf Grundlage der Datenreihe V1.1 mit Geschwindigkeiten von 3<br>bis 9 km/h und dem MLP-Klassifikator. . . . . | 100 |
| 4.2 | Konfusionsmatrizen mit den Klassifikationsergebnissen der Geschwindigkeits-<br>bestimmung für die Datenreihe V1.1 auf Grundlage von $M_{G4}$ und dem MLP-<br>Klassifikator. . . . .                      | 102 |
| 4.4 | Ergebnisse der Geschwindigkeitsbestimmung (3 bis 11 km/h) für eine zehnfache<br>Kreuzvalidierung basierend auf der Datenreihe V1.1. . . . .  | 104 |
| 4.5 | Ergebnisse der Geschwindigkeitsbestimmung für die Datenreihe (V2) auf<br>Grundlage von $M_{G4}$ für drei Klassifikatoren. . . . .  | 105 |
| 4.7 | Taktzyklenaufwand der Merkmalsberechnung und des MLPs für verschiedene<br>Optionen des MSP430-Compilers. . . . .   | 110 |
| 4.8 | Klassifikationsgenauigkeit in [%] in Abhängigkeit von der Geschwindigkeits-<br>stufe. Im Mittel ergibt sich eine Gesamtgenauigkeit von 96,1 %. . . . .   | 113 |
| 4.9 | Gegenüberstellung der Ergebnisse von Verfahren zur Geschwindigkeitsbestim-<br>mung in der Literatur mit denen für V1.1, V1.2 und V2. . . . .   | 116 |
| 5.1 | Ergebnisse der Evaluation der einzelnen Merkmale für die Identifikation unter<br>Verwendung des MLP-Klassifikators. . . . .  | 150 |
| 5.2 | Vergleich mit Ergebnissen von Gang- und EKG-basierten Identifikationsmetho-<br>den in der Literatur. . . . .   | 153 |
| 5.3 | Ergebnisse der Identifikation der 14 Handballspieler für verschiedene Merk-<br>malsräume basierend auf dem $RF_{100,70}$ -Klassifikator. . . . .   | 155 |
| 6.1 | MARS-Modell zur Vorhersage des PARs. . . . .   | 163 |
| 7.1 | Übersicht über die in der Entwurfsraumexploration simulierten Konfiguratio-<br>nen der Laufgeschwindigkeitsbestimmung. . . . .   | 180 |
| 7.2 | Ausgewählte Pareto-optimale Konfigurationen der Entwurfsraumexploration<br>für die Laufgeschwindigkeitsbestimmung. . . . .   | 181 |

|     |   |     |
|-----|---|-----|
| 7.3 | Gegenüberstellung des Energiebedarfs für die drahtlose Übertragung von Rohdaten und der ausgewerteten Geschwindigkeit. . . . .  | 187 |
| A.1 | Überblick Probandeneigenschaften V1.1. . . . .  | 224 |
| A.2 | Überblick Probandeneigenschaften V1.2. . . . .  | 225 |
| A.3 | Probandenprotokoll V1.4. . . . .  | 227 |
| A.4 | Überblick Probandeneigenschaften V2. . . . .  | 229 |
| A.5 | Überblick Probandeneigenschaften V3. . . . .  | 231 |
| B.1 | Mittlere Sensitivität und Spezifität (mit Standardabweichung und Bereich) der Laufgeschwindigkeitsbestimmung für die Datenreihe aus V1.1. . . . .                         | 233 |
| B.2 | Klassifikationsergebnisse der Geschwindigkeitsbestimmung für die Datenreihe aus V2 für drei Klassifikatoren. . . . .  | 234 |
| B.4 | Gesamtgenauigkeit der auf den Körpersensor BG-V4.2 portierten Geschwindigkeitsbestimmung für neun Probanden und vier Geschwindigkeitsstufen (Datenreihe V1.2(2)). . . . . | 235 |
| B.5 | Konfusionsmatrizen mit den Klassifikationsergebnissen für die Identifikation der neun Probanden aus V1.2. . . . .   | 238 |
| B.7 | Konfusionsmatrix mit den Klassifikationsergebnissen der Identifikation der 14 Handballspieler aus V3. . . . .   | 239 |
| B.8 | Liste der 15 Pareto-optimalen Konfigurationen der Entwurfsraumexploration der Gang- und Laufgeschwindigkeitsbestimmung. . . . .   | 240 |
| B.9 | Liste der 16 Pareto-optimalen Konfigurationen der Wiederholung der Entwurfsraumexploration. . . . .   | 241 |