

# **Mustererkennung beim Gehen und Rennen unter verschiedenen Randbedingungen**

Zur Erlangung des akademischen Grades eines  
Doktors der Philosophie

(Dr.phil.)

von der Fakultät für Geistes- und Sozialwissenschaften  
des  
Karlsruher Instituts für Technologie (KIT)

angenommene

DISSERTATION

von

M.A. Andreas Fischer  
(geb. in Frankfurt/Main)

Dekan: Prof. Dr. phil. Andreas Böhn

1. Gutachter: Jun.-Prof. Dr. rer. nat. Thorsten Stein

2. Gutachter: Prof. Dr. Wolfgang Potthast

Tag der mündlichen Prüfung: 29.11.2016



Dieses Werk ist lizenziert unter einer Creative Commons Namensnennung -  
Weitergabe unter gleichen Bedingungen 4.0 International Lizenz (CC BY-SA 4.0):  
<https://creativecommons.org/licenses/by-sa/4.0/deed.de>

# Inhaltsverzeichnis

1	Einleitung .....	1
1.1	Problemstellung.....	1
1.2	Aufbau der Arbeit.....	8
2	Theoretische Grundlagen.....	12
2.1	Klassen menschlicher Bewegung.....	12
2.2	Zentrale Mustergeneratoren zur Erzeugung von Lokomotionsbewegungen	13
2.3	Muster menschlicher Lokomotionsbewegungen.....	17
2.3.1	Gehen .....	19
2.3.2	Rennen .....	32
2.4	Verfahren der Mustererkennung.....	33
2.4.1	Künstliche Neuronale Netze.....	35
2.4.2	Support Vector Machines.....	55
2.4.3	Markov Modelle.....	66
2.5	Synthese der Befunde und Zielstellung der Arbeit.....	74
3	Studie 1: Personenerkennung mit Hidden Markov Modellen .....	77
3.1	Einleitung.....	77
3.2	Methodik.....	79
3.3	Ergebnisse .....	83
3.4	Diskussion .....	87
4	Studie 2: Vergleich der Klassifikationsleistung von Künstlichen Neuronalen Netzen, Support Vector Machines und Hidden Markov Modellen bei der Personenerkennung .....	89
4.1	Einleitung.....	89
4.2	Methodik.....	91
4.3	Ergebnisse .....	95
4.4	Diskussion .....	98

5	Studie 3: Erkennung von Breiten- und Leistungssportlern auf Basis kinematischer Parameter beim Rennen auf dem Laufband.....	99
5.1	Einleitung.....	99
5.2	Methodik.....	101
5.3	Ergebnisse .....	105
5.4	Diskussion .....	113
6	Studie 4: Erkennung von unterschiedlichen Untergründen mit Hidden Markov Modellen.....	117
6.1	Einleitung.....	117
6.2	Methodik.....	121
6.3	Ergebnisse .....	124
6.4	Diskussion .....	130
7	Zusammenfassung und Ausblick .....	134
8	Literaturverzeichnis .....	142
	Anhang A.....	162
	Framework zur Datenaufbereitung und -analyse.....	162
	Anhang B.....	166
	Fragebogen Studie 2 - körperlich sportliche Aktivität .....	166
	Anhang C.....	167
	Fragebogen Studie 3 - körperlich sportliche Aktivität .....	167



# 1 Einleitung

## 1.1 Problemstellung

Bewegung ist, gerade im Hinblick auf die Diskussionen der Folgen einer überalternden Gesellschaft und einer Jugend, die auf Grund immer länger werdender Sitz- und Stehzeiten, zunehmend gesundheitliche Defizite aufzuweisen scheint (Bös, 2009; Opper, Worth, Wagner & Bös, 2007), im allgemeinen Fokus. Erklärungen, wie die Winston Churchills, der an seinem 90. Geburtstag auf die Frage, wie er sein hohes Alter erreicht habe, lapidar antwortete: „No Sports“, sind mittlerweile auf wissenschaftlicher Basis hinreichend widerlegt. Kohl et al. konnten 2012 in einer Studie zeigen, dass Mangel an Bewegung die vierthäufigste Todesursache weltweit ist und, dass erst in den vergangenen Jahren Strukturen etabliert werden konnten, die der wissenschaftlichen Evidenz über die Folgen des Bewegungsmangels Rechnung tragen. Politiker sehen sich hierzulande mit immer weiter steigenden Kosten für das Gesundheitswesen konfrontiert, die 2006 noch 10,6 % des Bruttoinlandprodukts (Bip) ausmachten (245 Mrd. Euro). Im Jahr 2013 stiegen die Ausgaben bereits auf 314,9 Mrd. Euro (11,2 % Bip; Statistisches Bundesamt). In der Zeit von 2010 – 2013 stiegen die durchschnittlichen inflationsbereinigten Gesundheitsausgaben pro Kopf in Deutschland sogar schneller als im Durchschnitt der OECD. Vor dem Hintergrund einer vielfach berichteten kausalen Verknüpfung von körperlicher Aktivität und seelischer und körperlicher Gesundheit (Centers for Disease Control and Prevention, 1996; Robert Koch Institut, 2005) wurden in den letzten Jahrzehnten in Deutschland Quer- und Längsschnittstudien zur körperlichen Aktivität von Erwachsenen und Jugendlichen durchgeführt (Bellach, 1999; Bös, 2009; Krug et al., 2013). Zwar zeigen diese Studien, dass ein Anstieg der körperlichen Aktivität bei Erwachsenen zwischen 18 und 79 Jahren über die vergangenen 10 Jahre zu verzeichnen ist (Bellach, 1999; Robert Koch Institut, 2005), jedoch gibt es zugleich mehr Menschen, die an Adipositas leiden. Auch bei Kindern und Jugendlichen ist eine ähnliche Entwicklung zu verzeichnen, die neben genetischen und sozioökonomischen Faktoren auf Fehlernährung und Bewegungsmangel zurückzuführen ist (Graf, Dordel, Koch & Predel, 2006, S. 220-221).

Einhergehend mit der ökonomischen Bedeutung des Themas Bewegung stieg über die vergangenen Jahrzehnte auch das wissenschaftliche Interesse. Neben der Betrachtung, welche Auswirkung ein Mangel an Bewegung auf den Gesundheitszustand des Menschen hat und auf Basis welcher Mechanismen die Aufrechterhaltung einer lebenslangen körperlichen Aktivität begünstigt werden kann, hat sich in der Sportwissenschaft die Teildisziplin der Bewegungswissenschaften etabliert. Sie setzt sich neben der Analyse der beobachtbaren Produkte von Bewegung mit der Frage auseinander, welche internen Mechanismen der beobachtbaren Bewegung zugrunde liegen (Roth & Willimczik, 1999). Trotz des starken Fokus auf diesen Wissenschaftsbereich sind die Umstände, wie es Menschen im Detail möglich ist sich zu bewegen und welche Informationen in den Mustern einer Bewegung enthalten sind, bislang noch nicht vollständig verstanden (Mombaur, 2015; Troje, 2002; Troje, Westhoff & Lavrov, 2005). Regeln zu kennen und formulieren zu können, nach denen beispielsweise automatische Bewegungen auf Ebene des Spinalmarks oder komplexe Willkürbewegungen auf supraspinaler Ebene generiert werden, scheint auf den ersten Blick nicht von großer Bedeutung, da wir im Verlauf der Ontogenese, scheinbar von selbst, eine Vielzahl motorischer Fertigkeiten erlernen. Fertigkeiten, wie zum Beispiel das Gehen und Rennen, wenden wir dann ein Leben lang automatisiert an (Roth & Roth, 2009). Betrachtet man aber die Entwicklung der erlernten Muster über das Lebensalter, so fällt auf, dass sich Bewegungsabläufe über die Zeit verändern. Bedingt durch individuelle Alterungsprozesse der physiologischen Strukturen unseres Körpers, wie auch durch Krankheit oder Gewalteinwirkung verursachte Veränderungen am Muskel-Skelett System und/oder Zentralnervensystem, findet eine teilweise unbewusste Adaptation der Bewegungsabläufe im Sinne einer Selbstregulation statt (Fukuchi & Duarte, 2008; Fukuchi, Eskofier, Duarte & Ferber, 2011; Winter, Patla, Frank & Walt, 1990). Dem Gesetz der Homöostase folgend (Bernard, 1885), ist unser Körper als ein lernfähiges System zu sehen, das bestrebt ist, selbst definierte Ziele trotz einer Störung des Gesamtsystems, durch regulative Einflussnahme auf Teilsysteme des Organismus zu erreichen. In diesem Sinne finden bei einer Störung des Gesamtsystems interne Adaptationsvorgänge statt (Chamary, 2016). Sie dienen z.B. dem Aufrechterhalten der Fähigkeit zur Lokomotion, die eine wichtige Klasse der menschlichen Bewegung darstellt und Grundlage vieler alltäglicher und sportlicher Handlungen ist. In vielen Fällen bilden die Vermeidung von Schmerzen bei der Bewegungsausführung und/oder die Entlastung von geschädigten Strukturen des

Muskel-Skelett Systems die Basis für die Art und Weise, in der eine Adaptation der Bewegungsmuster erfolgt. Die Veränderungen finden oft vom Individuum unbemerkt statt und können bereits mittelfristig durch Überlastung anderer Strukturen im Sinne einer Kompensation zu Schädigungen führen (Astefian, Deluzio, Caldwell & Dunbar, 2008; Mündermann, Dyrby & Andriacchi, 2005). Ebenso kann die Entlastung von geschädigten Strukturen zu weiteren degenerativen Veränderungen führen und ein Voranschreiten der pathologischen Prozesse begünstigen (Christian et al., 2016; Jansen, Fenwick, Doht, Frey & Meffert, 2013; Lynn, Reid & Costigan, 2007). In diesem Kontext wird klar, dass ein fundamentales Wissen über Regelung und Steuerung der menschlichen Motorik im Zuge sowohl rehabilitativer als auch präventiver Maßnahmen von großer Bedeutung ist. Aber auch im Hinblick einer Steigerung sportlicher Leistungsfähigkeit durch eine Optimierung von Trainingsprozessen scheint Wissen über motorische Prozesse von großer Bedeutung.

Über das gesundheits-, bewegungs- und sportwissenschaftliche Interesse an der Untersuchung menschlicher Bewegungen hinaus, hat sich in den letzten Jahren auch die internationale Robotikforschung im Kontext der Entwicklung humanoider Serviceroboter dem Forschungsgegenstand menschlicher Bewegungen gewidmet (Hirose & Ogawa, 2007; Miller, Buffinton, Bieryla & Pratt, 2016; Takenaka, 2006). Serviceroboter sollen in den Alltag des Menschen integriert werden und dort vielschichtige Aufgaben übernehmen (Asfour et al., 2006; Robins, Dautenhahn, Boekhorst & Billard, 2005). Zur Steigerung der Akzeptanz beim Menschen und zur Prävention von Kollisionen zwischen Mensch und Maschine wird ein menschenähnliches Aussehen der Maschinen angestrebt, aber auch die Fähigkeit des Roboters, sich wie sein menschliches Gegenüber zu bewegen. Gerade die menschlichen Formen der Lokomotion, die in einem ständigen dynamischen Gleichgewicht des Systems Mensch erfolgen, bereiten große Probleme. Trotz zahlreicher Studien zum Thema, herrscht nach wie vor ein großes Forschungsdefizit diesbezüglich (Collins, Ruina, Tedrake & Wisse, 2005; Firmani & Park, 2013; Vukobratovic & Borovac, 2004).

Da von zahlreichen Autoren die menschliche Lokomotion als wichtige Klasse der menschlichen Bewegung herausgestellt wird (Inman, 1966, 1966; Kramers-de Quervain, Stüssi E. & Stacoff A., 2008; Mombaur, 2015; Troje et al., 2005), scheint es sinnvoll, bei der Betrachtung menschlicher Bewegungsmuster den Fokus auf eben

diese Klasse zu legen. „Das Gehen stellt die wichtigste alltägliche Form der Fortbewegung dar. Demgegenüber ist das Rennen in vielen sportlichen Situationen von zentraler Bedeutung“ (Kramers-de Quervain et al., 2008, S. 35). Beide Formen der Lokomotion sind ausgesprochen reproduzierbar und verhalten sich unter physiologischen Bedingungen bei allen gesunden Menschen nach demselben Grundmuster, das weitgehend im Unterbewusstsein abläuft. (Inman, Ralston & Todd, 1981; Kadaba et al., 1989; Rose & Gamble, 2006). Dennoch unterscheiden sich die Muster einzelner Individuen und enthalten eine Vielzahl an Informationen, die Rückschlüsse auf Geschlecht, Stimmung u.a. zulassen und zur Identifikation der Person genutzt werden können (Inman, 1966; Little & Boyd, 1998; Murray, Drought & Kory, 1964; Troje, 2002). Art und Anzahl der Informationen konnten bislang nicht beschrieben werden (Inman, 1966; Troje et al., 2005).

Die instrumentelle Ganganalyse stellt ein gut entwickeltes Instrument der Biomechanik dar, um menschliche Geh- und Rennmuster zu untersuchen (Cimolin & Galli, 2014; Kramers-de Quervain et al., 2008; Simon, 2004). Die heute angewandten Verfahren gehen im Wesentlichen auf die Arbeiten von Winter (1984), Kirtley, Whittle und Jefferson (1985) und Perry (1992) zurück. Dabei werden im Rahmen der instrumentierten Ganganalyse in der Regel unterschiedliche biomechanische Messmethoden in Kombination angewendet, um eine möglichst umfassende Beschreibung der menschlichen Geh- und Rennbewegung zu erreichen (Cimolin & Galli, 2014). Unabhängig von den eingesetzten Methoden zur Analyse des Ganges zeigen sich natürliche Variabilitäten bei wiederholten Messungen der gleichen Parameter (Jordan & Newell, 2008). Variationen in der Bewegungsausführung sind auf veränderte Aufgabenanforderungen in der Handlungssituationen (Abbildung 1) zurückzuführen, die sich aus der Relation von Aufgabe, Umwelt und Person ergeben (Shumway-Cook & Woollacott, 2012).

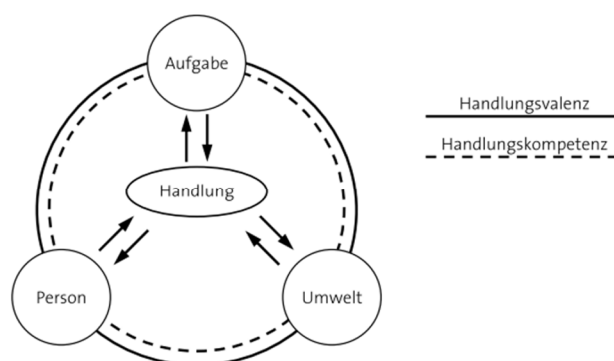


Abbildung 1. Grundkomponenten der Handlungssituation (Gabler, Nitsch & Singer, 2001, S. 95).

Die Bewertung der Handlungssituation findet über einen Abgleich der Handlungsvalenz und der individuellen Handlungskompetenz in der Situation statt. Die Handlungsvalenz als Aufforderungsstruktur einer Handlungssituation setzt sich dabei aus der Motivation der Person, dem intrinsischen Reiz der Aufgabe und dem extrinsischen Handlungsreiz zusammen. Die Handlungskompetenz stellt demgegenüber die subjektiv beurteilte Effizienz dar, mit der die Aufgabe unter Berücksichtigung der persönlichen Fähigkeiten unter den gegebenen Bedingungen bewältigt werden kann. Die Abwägung der situationsspezifischen Komponenten Valenz und Kompetenz mündet in der Einschätzung eines Handlungsspielraumes, der sich im Kontext einer Bewegungshandlung in der Variation von Bewegungshandlungen manifestiert. Vor diesem Hintergrund unterliegen sowohl Alltagsbewegungen wie auch sportliche Bewegungen einer Person ständigen Regelungsprozessen, die durch Kommunikation mit Mitspielern, Interaktion mit Geräten und/oder Mit-/Gegenspielern, Adaptationsvorgängen, spontanen Entscheidungen (Umwelt) sowie der sportlichen Aufgabe (z.B. Rennen, Springen, Werfen) beeinflusst werden (Gabler et al., 2001; Perl, 2008). Darüber hinaus scheinen personeninterne Faktoren wie neurophysiologisch bedingtes Rauschen im Rahmen von intern ablaufenden Informationsverarbeitungsprozessen eine exakte Bewegungsreproduktion zu verhindern (Bernštejn, 1967; Faisal, Selen & Wolpert, 2008).

Betrachtet man menschliche Lokomotionsbewegungen mit den zuvor beschriebenen Eigenschaften als Untersuchungsgegenstand, so stellt sich das bewegte Objekt Mensch als ein Mehrkörpersystem dar, welches sich aus einzelnen Segmenten zusammensetzt. Die Gesamtbewegung des Menschen resultiert dabei aus

Bewegungen der Segmente zueinander und unterliegt den komplexen Wechselwirkungsprozessen aller Teilsegmente. Der klassische Ansatz der Modellierung von Bewegungen prognostiziert mittels deterministischer Algorithmen auf Basis von Mittelwerten einer Population externe, sowie interne Kräfte und Gelenkmomente (Langenderfer, Hughes & Carpenter, 2005) für die Teilsegmente und das Gesamtsystem. Im Hinblick auf die Simulation einer Gehbewegung oder die Generierung von Bewegungsmustern z.B. für künstliche Beine eines Roboters, zeigen diese Modelle den Vorteil, dass sie einerseits schnell und effizient Zielgrößen berechnen können und andererseits zu optimalen Ergebnissen im Modellkontext führen (Blickhan, 1989; Clever, Harant, Koch, Mombaur & Endres, 2016). Im Gegensatz zum Menschen reproduzieren Systeme, die auf Basis deterministischer Modelle geregelt werden, Bewegungsmuster exakt. Deterministische Modelle verstehen sich in diesem Kontext als Modelle, die auf der Basis von diskreten Werten manifester Variablen den aktuellen Systemzustand bestimmen. Vor dem Hintergrund unterschiedlicher Modellansätze für das Erlernen von Bewegung (Schaal, 1999) erfolgt eine Regelung des Systems mittels vollständig definierter Differential-Gleichungen. Gegenüber den einfachen Spring-Mass Modellen zum Hüpfen und Rennen von Blickhan (1989) und McMahon und Cheng (1990) erlauben Erweiterungen des SPLIT Modells (Spring Loaded Inverted Pendulum) auch die Behandlung von Störungen des Systems während der Lokomotion (Maus et al., 2015). Allen deterministischen Modellansätzen gemein ist, dass gleiche Ausgangssituationen in Form gleicher diskreter Ausgangswerte der manifester Variablen, die Reproduktion der immer gleichen Bewegung zur Folge haben (Schöllhorn, 1999). Dies steht im Konflikt zur Annahme, dass Menschen nicht in der Lage sind Bewegungen exakt zu reproduzieren (Faisal et al., 2008).

Zur Quantifizierung der vielschichtigen Zusammenhänge menschlicher Lokomotionsbewegungen und insbesondere individueller Bewegungsmuster eignen sich konventionell definierte Modelle, die Bewegung mittels präziser vollständig determinierter mathematischer Algorithmen Bewegung beschreiben, demnach nur bedingt (Perl, 2008).

Im Gegensatz hierzu stehen mathematische Modelle, die auf der Basis von strukturellen Grundregeln Lösungsräume definieren und Wahrscheinlichkeiten für die Zuordnung der Muster in der beobachteten Bewegungssequenz zu den Lösungsräumen berechnen. Sie scheinen, abhängig vom Untersuchungsziel, für die

Modellierung menschlicher Bewegungen allgemein und von Lokomotionsbewegungen im Speziellen besser geeignet (Perl, 2006). Die bekanntesten Vertreter der von Perl (2008) als unkonventionell beschriebenen Modelle sind die Genetischen Algorithmen, Fuzzy Logic und Neuronale Netze (Bartlett, 2006; Ng et al., 2011; Sudha & Bhavani, 2012). Vor allem aus dem Bereich der Spracherkennung bekannt sind auch Markov Modelle und Ketten (Rabiner, 1989). Schöllhorn und Perl (2002) argumentieren, dass sich aufgrund der zuvor beschriebenen Eigenschaften menschlicher (Lokomotions-) Bewegungen unkonventionelle musterbildende und mustererkennende Modelltypen besonders gut für die Modellierung menschlicher Bewegungen eignen (Bartlett, 2006; Horst et al., 2015; Perl, 2008; Perl & Dauscher, 2006; Schöllhorn, 2004).

Zusammenfassend kann deterministischen Modellansätzen die besondere Eignung zur Abbildung von generalisierten Bewegungsmustern auf der Basis großer Population zugesprochen werden. Diese können einerseits für die Generierung oder Simulation von Bewegungen für z.B. Roboter eingesetzt werden und können andererseits zum Grundverständnis der mechanischen Regelung natürlicher Bewegungen unter deterministischen Gesichtspunkten beitragen (Maus et al., 2015; Mombaur, 2015). Dies gilt insbesondere für Systeme, bei denen ein deterministischer Zusammenhang zwischen Ursache und Wirkung beobachtet werden kann (Schöllhorn, 2004). Der Faktor der Individualität bleibt hierbei unberücksichtigt (Schöllhorn, 1999). Im Gegensatz hierzu eignen sich Methoden mit unkonventionellen Modellierungsparadigmen, die, unter Berücksichtigung der genetisch determinierten natürlichen Variabilität einerseits und der Wechselwirkung von Handlungsvalenz, Handlungskompetenz und Spielraum der Bewegungshandlung andererseits, menschliche Bewegung modellieren, zur Abbildung von individuellen Bewegungsmustern (Schöllhorn, 2004, S. 876) im Kontext biologischer Prozesse. Dies prädestiniert stochastische Modellansätze, neben ihrer hohen Generalisierungsfähigkeit, für die Klassifizierung von Mustern und die Analyse von individuellen Bewegungsmustern. Ergänzend dazu ermöglichen sie die Synthese von Bewegungsmustern, auf der Basis natürlich inspirierter Regeln, unter Einbezug einer natürlichen Variabilität.

Aus den aufgearbeiteten Befunden lässt sich die allgemeine Problemstellung der vorliegenden Arbeit ableiten:

1. Im Mittelpunkt des Forschungsinteresses stehen menschliche Geh- und Rennbewegungen unter verschiedenen Randbedingungen, als eine im

Alltag und Sport wichtige Klasse menschlicher Bewegungen. Demnach sind aus der Fachliteratur sinnvolle Modifikationen für die Handlungssituation des menschlichen Gehens und Rennens, die sich aus der Interaktion von Aufgabe, Person und Umwelt ergeben, abzuleiten.

2. Die menschlichen Geh- und Rennbewegungen unter verschiedenen Randbedingungen sind mit Hilfe einer instrumentierten Ganganalyse präzise zu vermessen. Hierfür sind, in Abhängigkeit der zuvor identifizierten verschiedenen Randbedingungen, unterschiedliche Messplätze zu entwickeln, die eine präzise Erfassung der Geh- und Rennbewegungen sicherstellen.
3. Auf der Grundlage der aufgezeichneten Geh- und Rennbewegungen werden verschiedene unkonventionelle musterbildende und mustererkennende Modelltypen dahingehend überprüft, ob sie dazu in der Lage sind, menschliche Geh- und Rennbewegungen unter verschiedenen Randbedingungen abzubilden. Demnach wird die Arbeit einen Beitrag für ein tiefgreifendes Verständnis leisten, welcher unkonventionelle Modelltyp sich am besten zur Analyse menschlicher Geh- und Rennbewegungen unter verschiedenen Randbedingungen eignet.

## **1.2 Aufbau der Arbeit**

Die vorliegende Arbeit gliedert sich in einen theoretischen und einen experimentellen Teil, sowie eine abschließende Zusammenfassung der Befunde und deren kritische Betrachtung auch im Kontext eines Ausblicks zur Motivation weiterer Forschungsvorhaben.

Im theoretischen Teil wird in Kapitel 2.1 zunächst ein Überblick über die Klassen gegeben, in die sich menschliche Bewegungen einteilen lassen. Kapitel 2.2 erschließt mit den zentralen Mustergeneratoren einen aktuellen Ansatz der Motorikforschung zur Erklärung der Steuerung unbewusst ablaufender zyklischer Bewegungshandlungen im Allgemeinen und menschlicher Lokotionsbewegungen im Speziellen. Kapitel 2.3 stellt aktuelle Verfahren zur Analyse ebendieser Bewegungsmuster beim Gehen und Rennen sowie deren historische Entwicklung vor. Im Folgenden werden die gängigen Funktionsparameter der Ganganalyse sowie deren Normwertbereiche für das Gehen



und Rennen erläutert. Im Kontext der Analyse von Mustern menschlicher Lokomotionsbewegungen werden in Kapitel 2.4 jene probabilistischen Verfahren erläutert, die sich auf Basis der aktuellen Literatur als geeignet herausstellen lassen. Kapitel 2.5 fasst abschließend die Ergebnisse der theoretischen Betrachtung zusammen und motiviert die wissenschaftliche Rechtfertigung dieser Arbeit mit der Formulierung offener Forschungsfragen.

Den experimentellen Teil bilden vier einzelne Studien (Kapitel 3-6), die dem Sinn entsprechend aufeinander aufbauen und deren Erkenntnisse jeweils in den nachfolgenden Studien Beachtung finden. Jede Studie widmet sich Fragestellungen, die sich aus der Analyse der aktuellen Literatur und den hieraus resultierenden Forschungsdefiziten ergeben haben.

Studie 1: *Personenerkennung mit Hidden Markov Modellen* kann in diesem Zusammenhang im weitesten Sinne als Machbarkeits-/Vorstudie betrachtet werden. Hidden-Markov Modelle werden in der Untersuchung von Lokomotionsbewegungen im Kontext von Sport und Alltag nur vereinzelt angewendet und zum Zeitpunkt der ersten Studie lagen keine Erkenntnisse vor, inwieweit sich die Modelle dafür eignen menschliche Bewegungsmuster des Gehens und Rennens zu klassifizieren bzw. abzubilden. Die Tatsache, dass dieser Modellansatz in der Vergangenheit vor allem Anwendung in der Erkennung von Sprache und zur Identifikation von biologischen Sequenzen in der Genforschung gefunden hat, und somit zur Klassifizierung von Mustern, die natürlichen Gesetzmäßigkeiten folgen, eingesetzt wurde, legte nahe, dass ein Transfer der Methode zur Bearbeitung von Fragestellungen im Kontext der Zielstellung dieser Arbeit möglich ist. Auf Basis der Erkennungsleistung als Kriterium für die Abbildungsgüte der kinematischen Muster soll gezeigt werden, dass mit HMMs die Muster menschlicher Lokomotion modelliert werden können.

Studie 2: *Vergleich der Klassifikationsleistung von Künstlichen Neuronalen Netzen, Support Vector Machines und Hidden Markov Modellen bei der Personenerkennung* stellt die gängigen Methoden, die zur Klassifizierung von Bewegungsmustern beim Gehen und Rennen unter Berücksichtigung der natürlichen Variabilität Anwendung finden, und Hidden Markov Modelle einander gegenüber. Auf Grundlage einer Ganganalyse unter Laborbedingungen sollten die Erkennungsleistungen der Modelle

überprüft und miteinander verglichen werden. Im Sinne der Nachvollziehbarkeit der Ergebnisse wurden frei zugängliche Programme/Toolboxen zur Konstruktion der Modell-Topologien für alle Methoden verwendet. Ziel dieser Studie war es, jenes Modell zu identifizieren, das sich für die Abbildung von Geh- und Rennbewegungen am besten eignet. Zu diesem Zweck wurden die unterschiedlichen Modelle, die auf der Grundlage der in der Literatur beschriebenen Eignung zur Klassifikation von Geh- und Rennmustern ausgewählt wurden, mit Hidden-Markov Modellen verglichen.

*Studie 3: Erkennung von Breiten- und Leistungssportlern auf Basis kinematischer Parameter beim Rennen auf dem Laufband* stellt die Bewegungsmuster von Personen mit unterschiedlicher Spezialisierung im Hinblick auf Geh- und Rennbewegungen einander gegenüber. Im Gegensatz zu den vorangegangenen Studien, bei denen die Diskriminierung interindividueller Muster im Vordergrund stand, wurden in Studie 3 Hidden Markov Modelle trainiert, die den Grad der Spezialisierung von Hobbyläufern und Leistungssportlern abbildeten. Zeigen Muster einer Person geringe Variabilitäten bei der wiederholten Bewegungsausführung, so weisen die Bewegungsfolgen unterschiedlicher Personen heterogene Muster auf. Studie 3 soll zeigen, inwieweit sich die Bewegungsmuster von Leistungssportlern beim Gehen und Rennen, trotz der Heterogenität der Muster innerhalb der Gruppe der Leistungssportler, von den Bewegungsmustern von Hobbyläufern mit einem geeigneten Klassifikator trennen lassen.

*Studie 4: Erkennung von unterschiedlichen Untergründen mit Hidden-Markov Modellen* untersucht Bewegungsmuster von Personen beim Gehen unter realitätsnahen Bedingungen. Wird beim Gehen auf dem Laufband durch den sich bewegenden Untergrund eine Zwangsbedingung geschaffen, die Änderungen in der Dynamik und Kinematik des Läufers induzieren, ermöglicht das nichtstationäre Gehen über eine definierte Strecke eine Bewegungsfolge unter freien Randbedingungen. Durch das Aufbringen verschiedener Untergründe sollten wiederum Musteränderungen provoziert werden, die eine Diskriminierung der Bodenbeschaffenheit auf Basis der Bewegungsmuster beim Gehen und Rennen ermöglichen. Die Änderung der Analysemethodik für den Gang in dieser Studie stellt eine Annäherung an klinische Bedingungen dar. Mit dieser Studie soll gezeigt werden, dass ein Transfer der Methode von der laufbandgestützten Analyse hin zur nichtstationären Ganganalyse

möglich ist. Ergänzend hierzu wurde durch den Einsatz von unterschiedlichen Untergründen getestet, inwieweit Änderungen der kinematischen Muster durch realitätsnahe Randbedingungen diskriminiert werden können.

Abschließend werden in Kapitel 7 die Ergebnisse aller Studien zusammengefasst und im Kontext der Zielstellung der Arbeit nochmals kritisch diskutiert.

## 2 Theoretische Grundlagen

### 2.1 Klassen menschlicher Bewegung

Menschen erlernen im Laufe ihres Lebens eine Vielzahl motorischer Fertigkeiten. Der Ausführung dieser Fertigkeiten liegen verschiedene Steuerungs- und Regelungsvorgänge zugrunde. Die motorische Kontrolle kann dabei grundsätzlich willkürlich oder unwillkürlich erfolgen. Diesem Grundverständnis motorischer Kontrollprozesse folgend, können drei Klassen menschlicher Bewegungen unterschieden werden (Ghez & Krakauer, 2000; Konczak, 2003).

- **Reflexe** entziehen sich weitgehend der willkürlichen Kontrolle des Menschen und stellen die schnellstmöglichen stereotypen motorischen Reaktionen des Organismus auf bestimmte Reize dar. Sie können sowohl als angeborene Reaktionen (unbedingt) eine Anpassung in der biologischen Entwicklung einer Art an deren Lebensbedingungen darstellen, als auch ontogenetisch erlernte Reaktionen (unbedingt, konditioniert) repräsentieren. Zu ihnen gehören u.a. der Patellarsehnenreflex (Eigenreflex), der Lidschlussreflex (Fremdreflex) und der Saugreflex (frühkindlicher Reflex) (Klinke, Silbernagl & Bauer, 2003).
- **Automatische Bewegungen** sind durch eine zyklische Bewegungsfolge gekennzeichnet. Beim Gehen und Rennen (u.a.) werden rhythmusbildende Bereiche in Rückenmark und Hirnstamm aktiviert, die über efferente Nervenbahnen Bewegungsmuster automatisch (unwillkürlich) generieren. Automatische Bewegungen sind durch eine geringe Variabilität in den zyklischen Bewegungsfolgen gekennzeichnet und somit individuell stabil reproduzierbar (Konczak, 2003).
- Unter **Willkürbewegungen** sind jene Bewegungen zusammengefasst, die zielgerichtet, geplant und kontrolliert erfolgen. Zu ihnen gehören Alltagsbewegungen wie das Zeigen oder die Manipulation von Objekten und alle sportlichen Techniken. Hoherlernte willkürliche Bewegungen bekommen mit der Zeit eine automatische Qualität, was zu einer effizienteren Nutzung kognitiver und energetischer Ressourcen führt. Trotz der übungsbedingten Automatisierung werden die Bewegungen willkürlich ausgeführt (Konczak, 2003).

Im Mittelpunkt der vorliegenden Arbeit stehen, wie im einleitenden Kapitel beschrieben, menschliche Lokomotionsbewegungen, die der Klasse automatischer Bewegungen zuzuordnen sind. Zyklische Bewegungen werden einem aktuellen Ansatz der Motorikforschung nach durch sogenannte zentrale Mustergeneratoren erzeugt. Das Vorhandensein solcher musterbildender Netzwerke konnte in der Vergangenheit sowohl bei wirbellosen Tieren (Miller & Sigvardt, 2000; Selverston, 2010) als auch bei Wirbeltieren (Orlovskij, Deliagina & Grillner, 1999) nachgewiesen werden. Neben Schwimm- und Flugbewegungen existieren auch Erklärungsansätze für die Lokomotion von Vertebraten, die im folgenden Kapitel erläutert werden.

## **2.2 Zentrale Mustergeneratoren zur Erzeugung von Lokomotionsbewegungen**

Die menschliche Lokomotionsbewegung wird einer Klasse von Bewegungen zugeordnet, die unbewusst automatisch ablaufen. Zu dieser Klasse zählen unter anderem das Kauen, Schwimmen, Atmen und Rennen. Einige der Bewegungsmuster sind prädispositioniert und können bereits direkt nach der Geburt erzeugt werden. Andere werden abhängig von der individuellen Entwicklung eines Lebewesens erlernt. Sie sind gekennzeichnet durch sich zyklisch wiederholende Bewegungsfolgen, die durch eine alternierende Aktivität von agonistisch und antagonistisch arbeitender Muskulatur geprägt sind. In Studien konnte an unterschiedlichen Tieren gezeigt werden, dass solche stereotypen Bewegungsfolgen nicht der Kontrolle des Gehirns oder höherer Zentren unterliegen, sondern durch Strukturen im Rückenmark erzeugt werden (Brown, 1914; Orlovskij et al., 1999; Shik & Orlovskij, 1976). Brown entwickelte hierzu das *Half Center Modell* (Halbzentrumsorganisation, alternierende Zentren), das aus einem einfachen neuronalen Netz mit zwei D-Neuronen (drive-Neuronen), zwei Interneuronen und zwei Motoneuronen besteht, die jeweils einen Flexor und einen Extensor aktivieren (Abbildung 2 a). Jeweils ein D-Neuron sorgt für die stete Erregung eines Halbzentrums (Interneuron & Motoneuron). Die Interneuronen sind suppressiv miteinander verknüpft und unterdrücken bei eigener Aktivität die Erregung des anderen Interneurons. Die inhibitorische Wirkung lässt mit der Zeit nach und führt somit zur Aktivierung des anderen Interneurons, welches wiederum inhibitorisch die Erregung des ersten Interneurons unterdrückt. Bei der Aktivierung des Netzes (chemisch oder elektrisch) durch eine höhere Ebene wird somit, durch die

alternierende Erregung der Motoneurone von Flexor und Extensor, ein oszillierendes Bewegungsmuster erzeugt. Brown konnte, ebenso wie Sherrington (Breathnach, 2004) zeigen, dass Säugetiere, deren nervöse Verbindung zum Gehirn auf der Höhe des Halses durchtrennt wurde, in der Lage waren oszillierende Bewegungsmuster, ähnlich derer beim Laufen, auszuführen. Cohen, Rossignol und Grillner (1988) brachten den Nachweis, dass es sich bei den unwillkürlichen Aktionen, die nach Deafferenzierung zu beobachten sind, um Lokomotionsbewegungen handelt. Sie konnten damit beweisen, dass die zyklischen Lokomotionsbewegungen bei Tieren (Grillner, 2003; Selverston, 2005) durch neuronale Netzwerke, die heute häufig als zentrale Mustergeneratoren (ZMGs, Central Pattern Generators, CPGs) bezeichnet und im Rückenmark erzeugt werden. Betrachtet man jedoch die Komplexität der Geh- und Rennbewegungen und die Fähigkeit des Menschen, die Bewegungsmuster sowohl kurzfristig als auch mittel- und langfristig zu adaptieren, scheint offensichtlich, dass das Modell von Brown eine starke Vereinfachung darstellt.

Kling und Székely (1968) entwickelten daraufhin ein Closed Loop Modell, bei dem die suppressiv wirkenden Interneurone in einer geschlossenen Schleife miteinander verknüpft sind (Abbildung 2 b). Ansammlungen von Motoneuronen werden nacheinander durch ihre Interneurone aktiviert bzw. gehemmt und erlauben im Gegensatz zum Half-Center Modell eine differenziertere Aktivierung von Flexoren und Extensoren. Orlovskij et al. (1999, zitiert nach Grillner, 2006) konnten das Zentrum zur Kontrolle der CPGs für Lokomotionsbewegung im Mittelhirn der Katze (Formatio reticularis) lokalisieren. Es steuert den Zeitpunkt der Aktivierung ebenso wie das Aktivitätslevel, welches bei Lokomotionsbewegungen die Geschwindigkeit der Bewegungsausführung reguliert (Shik & Orlovskij, 1976). Zeigen sensorische Rückmeldungen der Gliedmaßen, dass ein CPG ein Bewegungsmuster erzeugt, welches im Konflikt mit der z.B. durch ein Laufband induzierten Bewegung steht, wird vermutlich durch das Muster selbst ein neuer CPG aktiviert (Schmidt & Lee, 2005)(Abbildung 3).

Im Gegensatz zu den vorangegangenen Ansätzen, die auf Basis inhibitorischer Eigenschaften von Interneuronen rhythmische Muster erzeugen, beruht die Erzeugung von Mustern beim Pacemaker Modell (Schrittmacher) auf den Diffusionseigenschaften der Zellmembran von Schrittmacherzellen (Abbildung 2 c). Eine durch  $\text{Ca}^{2+}$  ausgelöste langsame Depolarisation der Zellmembran der Schrittmacherzelle führt in diesem

Modell zu einer sich wiederholenden Impulsentladung, deren Dauer durch  $\text{Ca}^{2+}$ -sensitive  $\text{K}^+$ -Kanäle reguliert wird (Shepherd, 1993).





Abbildung 2. Unterschiedliche Netzstrukturen für CPGs: a) Half Center Model; b) Closed Loop Model; c) Pacemaker Model (verändert nach Grillner, 1996).

Zahlreiche Modellansätze zur Erklärung der Struktur von neuronalen Netzwerken zur mehr oder weniger autonomen Erzeugung von Mustern, in erster Linie für die Lokomotion, wurden seither entwickelt. Tresch, Saltiel und Bizzi (1999), sowie Bizzi, Cheung, d'Avella, Saltiel und Tresch (2008) entwickelten das Synergy Model und McCrea und Rybak (2008) ein Modell basierend auf einem zweistufigen CPG. Beide Arbeiten wurden durch das Modell von Perret und Cabelguen (1980) inspiriert. Sie fanden heraus, dass Fortbewegungsmuster in eine Extensions-, eine Flexions- und zwei Transitionsphasen unterteilt werden können, während derer über sensorische Informationen der Gliedmaßen eine Regulierung des Bewegungsmusters erfolgt. Auf Basis ihrer Ergebnisse schlussfolgerten sie, dass die Aktivität eines CPGs durch ein einfaches initiales Signalmuster zu einer Adaptation der Bewegungsmuster in der Peripherie führt (z.B. schnelleres Gehen, rückwärts Gehen). Hausdorff, Peng, Ladin, Wei und Goldberger (1995) fanden heraus, dass beim Gehen über einen Zeitraum von neun Minuten Änderungen in den Mustern der Gangzyklen entstehen, die sich jeweils in Abhängigkeit zu den Mustern der vorangegangenen Gangzyklen entwickeln. Basierend auf der Annahme, dass die Intervalle der Gangzyklen einer sequentiellen Ordnung unterliegen entwickelten sie das Modell für ein CPG, mit dem die Entwicklung der Intervalle über die Zeit abgebildet werden konnten.

Allen angeführten Studien gemein ist die Annahme, dass vorwiegend autonom arbeitende Mustergeneratoren eine, von höheren Ebenen weitgehend unabhängige, Aktivierung und Koordination der Gliedmaßen bei rhythmischen Bewegungsfolgen im Allgemeinen und bei Lokomotionsbewegungen im Speziellen gewährleisten (Abbildung 3).



*Abbildung 3.* Schematische Darstellung eines zentralen Mustergenerators für das Gehen mit Eingangsvariablen anderer Oszillatoren, Sensoren und höherer Zentren, sowie der Flexoren und Extensoren (Schmidt & Lee, 2005, S. 171).

Guertin (2012) sieht auf Grund der zahlreichen übereinstimmenden Ergebnisse unterschiedlicher Studien die Existenz von Mustergeneratoren als erwiesen.

Zwar beschreibt Pearson (1993), dass die durch CPGs erzeugten Lokomotionsformen bei allen Wirbeltieren vergleichbar sind, betrachtet man jedoch die Geh- und Rennmuster beim Menschen, scheinen diese eine Sonderstellung einzunehmen. Auf Grund der Komplexität der Muster und einer asynchronen Aktivierung der Beuger und Strecker der unteren Extremität, die unter anderem von Forssberg und Hirschfeld (1988) berichtet wurde, scheinen beim Menschen die neuronalen Strukturen der zentralen Mustergeneratoren anders organisiert als bei anderen Wirbeltieren (Guertin, 2012). Im Gegensatz zu den Untersuchungen an sowohl wirbellosen Tieren als auch an Wirbeltieren, besteht beim Menschen nicht die Möglichkeit durch eine operative Isolierung der neuronalen Netzwerke im Rückenmark, die Existenz der musterbildenden Zentren herzuleiten bzw. ihre Aktivierungsmechanismen vollständig zu untersuchen. Der endgültige Nachweis, dass zentrale Mustergeneratoren auch beim Menschen für die Bewegungssteuerung beim Gehen verantwortlich sind, ist demnach unter ethischen Gesichtspunkten nicht zu führen. Auf der anderen Seite gibt es aber auch keine Evidenz, dass zentrale Mustergeneratoren beim Menschen nicht oder in einer gänzlich anderen Form existieren würden. Die Ergebnisse von Fung, Stewart



und Barbeau (1990), die zeigen konnten, dass Lokomotionsbewegungen beim Training mit Paraplegikern auf dem Laufband vermutlich vornehmlich auf die Ansteuerung der Muskulatur durch Reflexbögen zurückzuführen sind, stehen dazu nicht im Widerspruch.

### **2.3 Muster menschlicher Lokomotionsbewegungen**

Nachdem im letzten Kapitel zentrale Mustergeneratoren als ein aktuelles Modell zur Erzeugung menschlicher Lokomotionsbewegungen vorgestellt und kritisch diskutiert wurden, stehen in diesem Kapitel mit den Mustern menschlicher Lokomotionsbewegungen die äußerlich sichtbaren und messbaren Produkte zentraler Mustergeneratoren im Mittelpunkt.

Historisch gesehen gibt es unterschiedliche Mutmaßungen, wann und warum sich der Mensch von einer quadropedalen Art der Fortbewegung hin zum bipedalen Gang entwickelt hat. 1974 wurde in Äthiopien Lucy, ein weibliches Teilskelett der Gattung *Australopithecus afarensis* entdeckt. Der Aufbau des Beckens und des Oberschenkels weisen darauf hin, dass Lucy und ihre Zeitgenossen aufrecht gehen konnten. Ebenfalls 1974 wurden in der gleichen Region Beinknochen und Kniegelenk eines Hominiden gefunden, der vor über drei Millionen Jahren lebte (Breuer, 2004) und ebenfalls aufrecht gehen konnte. Die bipedale Lokomotion ermöglichte die Verbreitung über Afrika hinaus nach Asien und Europa. Die Entwicklung zum aufrechten Gang erfolgte von einer waagerechten Position der Wirbelsäule über eine Schräglage zur senkrechten Haltung. Parallel zur Aufrichtung wurde der gesamte Körperbau angepasst, wobei sich der Massenschwerpunkt des Schädels immer weiter an die Okzipitalöffnung des Schädels annäherte (Abbildung 4).




Abbildung 4. Schädel und Nackenmuskeln: (a) Gorilla, (b) Australopithecus, (c) Homo erectus und (d) Homo sapiens (Facchini, 1991, S. 65).

Die Last des Kopfes wurde dadurch lotrecht über der Wirbelsäule ausgerichtet, was zu einer Minimierung der Drehmomente, die an der Verbindungsstelle Kopf – Rumpf wirken, führte und somit eine Optimierung des Kraftaufwands zum Tragen des Kopfes darstellt. Zur vollständigen Aufrichtung wurde im Laufe der Zeit außerdem das Becken erweitert und nach vorne rotiert, sowie die Wirbelsäule aufgerichtet (Abbildung 5). Über die unterschiedlichen Entwicklungsstadien hinweg setzte sich die Bipedie gegenüber anderen Mischformen durch, da sie, laut Facchini (1991), die meisten Vorteile brachte. Unter anderem ist der ungehinderte Blick über die Steppe zu nennen sowie das Freiwerden der Arme zum Jagen und Verteidigen. Ebenso konnten die Arme und Hände für Gesten genutzt werden (Arbib, 2012) und bildeten somit neue Grundlagen der Kommunikation. Neuere Studien hingegen vertreten die Theorie, dass der aufrechte Gang eine Folge von Anpassungen an die Fortbewegung auf flexiblen Ästen in Bäumen ist (Thorpe, Holder & Crompton, 2007).




Abbildung 5. Entwicklung des Aufrechten Ganges in der menschlichen Evolution (ohne Quelle GNU-Lizenz).

Die Veränderung der Lokomotion im Laufe der Evolution des Menschen fand und findet im Kontext einer Adaptation an veränderte Umweltbedingungen und Anforderungsprofile statt. Bereits Darwin (2006) beschrieb in seinem Buch *On the Origin of Species* im Jahr 1859 die Zusammenhänge der Evolution und die fortwährende Weiterentwicklung aller Spezies. „Auch gegenwärtig verändert sich der Mensch im Sinne einer Adaptation an die aktuellen Lebensumstände. Größenwachstum, Bewegungsarmut und Gewichtszunahme sind nur einige Beispiele“ (Götz-Neumann, 2016, S. 20) und werden sich auch in Zukunft auf eine Veränderung unseres Gangbildes auswirken. Normdaten zu einem „normalen Gang“ müssen demzufolge nicht nur in Bezug auf die Heterogenität der beschriebenen Gruppe, sondern auch im evolutionären Zusammenhang immer wieder auf ihre Gültigkeit hin geprüft werden. Im Folgenden werden mit dem Gehen (Kapitel 2.2.1) und Rennen (Kapitel 2.2.2) die vom Menschen am häufigsten verwendeten Arten der Lokomotion beschrieben.

### 2.3.1 Gehen

Gehen ist eine zyklische Bewegung, bei der in sich wiederholenden Bewegungssequenzen der Gliedmaßen der Körper vorwärts bewegt wird, während gleichzeitig die Stabilität durch eine Standphase gewährleistet ist (Perry & Burnfield, 2010). „Innerhalb der Standphase gibt es einen ständigen Wechsel zwischen einfach und doppelt unterstützten Phasen“ (Götz-Neumann, 2016, S. 31). Mit der instrumentierten Ganganalyse werden die mechanischen Umstände des Gehens quantitativ beschrieben (Cappozzo, 1984).

#### 2.3.1.1 Entwicklung der instrumentierten Ganganalyse

Die ersten Analysen von Bewegungen unter wissenschaftlichen Gesichtspunkten gehen zurück auf Alfonso Borelli, ein Schüler Galileo Galileis, der 1680 in seinem Buch *De motu animalium* die Lokomotion von Tieren und, wie in Abbildung 6 zu sehen, die Rolle der Muskulatur für die Bewegung quantitativ beschreibt.




Abbildung 6. Berechnungen Borellis zur Mechanik menschlicher Bewegungen im Arbeitsumfeld (Borelli & Maquet, 1989)

Er verfolgte den Ansatz, Lebewesen als Maschinen zu sehen und Bewegungen unter rein mechanischen Gesichtspunkten zu erklären (Borelli & Maquet, 1989). Er kann als Urheber der Biodynamik und Biokinematik der Bewegung und somit als Begründer der Biomechanik angesehen werden (Medved, 2001). Braune und Fischer (Braune & Fischer, 1987) erforschten zwischen 1895 und 1905 im Auftrag des preußischen Kriegsministeriums die Auswirkungen des Marschgepäcks auf den Gang der Infanteristen. Gasentladungsröhren wurden an den Körperteilen des Probanden befestigt und mittels Chronofotografie (Abbildung 7) beim Gehen mit und ohne Gepäck aufgezeichnet.



Abbildung 7. Chronofotografie eines sprintenden Athleten von E. Muybridge (<http://nucius.org>).



Mit dieser Technik konnten sie Gelenkmittelpunkte bestimmen und die Verläufe im zweidimensionalen Koordinatensystem visualisieren. Ihre Ergebnisse konnten keine Auswirkung des Zusatzgewichts auf die Kinematik beim Gehen nachweisen.

Lange in der westlichen Welt ignoriert wurde Alexandrowitsch Nikolai Bernstein (1896 – 1966). Er arbeitete von 1922 – 1925 am Zentralinstitut für Arbeit im Labor für Biomechanik und anschließend am Moskauer Staatlichen Institut für experimentelle Psychologie. Er befasste sich intensiv mit Untersuchungen zu Bewegungen beim Musizieren und beim Arbeiten. Bei der Analyse des Hammerschlags konnte er zeigen, dass bei einer hohen Variabilität der Bewegung von Körper und Arm die Bewegung des Hammers dennoch invariant ist. Er sah darin den Beweis für eine Steuerungsfunktion des zentralen Nervensystems. Für die Untersuchung der Lokomotion entwickelte er ein Verfahren zur räumlichen Bewegungsregistrierung.




Abb. 1. Das Kymozyklographion, links = zur Aufnahme bereit, rechts = mit geöffnetem Film-Adapter. Buchstabendeutung: *Ob* = Obturator, *S* = Sirenenring, *MS* = Mattscheibe. *K* = Kasette, *Ad* = Film-Adapter, *Sch* = Schlüssel, *D* = Schiebetür der Kasette, *R<sub>1</sub>*, *R<sub>2</sub>* = Verbindungsräder, *Sg* = Schneckengang, *F* = Rollfilm, *Em* = Elektromagnet, *BW* = biegsame Welle.

Abbildung 8. Technische Beschreibung des Kymozyklographion (Bernštejn, 1927, S. 784).

Mit der Zyklographie (Abbildung 8) entwickelte er ein Verfahren, mit dem er die Segmentschwerpunkte der Gliedmaßen *in vivo* bestimmen konnte und so die Biomechanik von Bewegungen (Lokomotion) und deren Entwicklung untersuchen konnte. Er entfernte sich von den Mensch-Maschine-Analogismen und gilt heute als der Begründer der modernen Bewegungswissenschaft (Bernštejn, Pickenhain &

Schnabel, 1988; Latash, 2001). Bernstein wurde 1950 auf Grund von kritischen Äußerungen zu den Theorien von Iwan Petrowitsch Pawlow entlassen und trat nach kurzer Schaffenspause offiziell in den Ruhestand (1956). Ein Großteil seines theoretischen Werkes entstand in den Jahren danach, in denen er das Konzept einer Physiologie und Biologie der Aktivität verfolgte, in der die Integration von bewegungswissenschaftlichen, neurophysiologischen, biokybernetischen und philosophischen Ansätzen im Mittelpunkt stand (Bernštejn et al., 1988; Hotz, 2001). Durch die späte Übersetzung der Werke von Bernstein wurden seine wissenschaftlichen Erkenntnisse erst spät im westlichen Raum zugänglich sind, aber auch heute noch aktuell und finden z.B. Anwendung in der Robotik (Manoonpong, Geng, Kulvicius, Porr & Wörgötter, 2007).

Die Bewegungsanalyse hat sich in den vergangenen drei Jahrzehnten rasant weiterentwickelt und wird mit diversen Methoden realisiert. Infrarotsysteme mit reflektierenden Markern, Systeme mit unterschiedlichen aktiven Markern (z.B. Licht, elektromagnetischen Sensoren), Systeme mit Videokameras zur Markerverfolgung, video-basierte Systeme zum Tracken der Körperhülle und Beschleunigungssensor-basierte Systeme repräsentieren unterschiedlich komplexe Messmethoden, die zu mehr oder weniger exakten Ergebnissen führen (Banzer & Vogt, 2005; Kramers-de Quervain et al., 2008). Die Verfahren zur Analyse der kinematischen, dynamischen, elektromyografischen und physiologischen Kenngrößen gehen im Wesentlichen zurück auf die Arbeiten von Winter (1984), Whittle (2008) und Perry und Burnfield (2010). Sie definieren in ihren Arbeiten Funktionsparameter, mit denen Normwerte für das Gehen in Abhängigkeit von Alter und Geschlecht beschrieben und im folgenden Kapitel expliziert werden. Da über alle Studien dieser Arbeit hinweg ausschließlich kinematische Funktionsparameter für die Klassifikation von Bewegungsmustern verwendet werden, beschränkt sich die Darstellung der Normwerte auf ebendiese Merkmale.

### 2.3.1.2 Der „normale“ Gang

Der Gangzyklus (gait cycle, stride, GZ) wird definiert durch zwei aufeinanderfolgende initiale Kontakte desselben Beines mit dem Boden (Götz-Neumann, 2016). Da ein Zyklus zahlreiche Ereignisse beinhaltet, die es zu beschreiben gilt, gibt es unterschiedliche Ansätze der Bewegungssegmentierung, die sich in der Feinheit der Bewegungsauflösung unterscheiden. Die einfachste Methode unterteilt den Gangzyklus nach den aufeinanderfolgenden reziproken Bodenkontakten der Füße (Perry & Burnfield, 2010) wie in Abbildung 9 zu sehen.




Abbildung 9. Einteilung des Gangzyklus des rechten Beines nach Bodenkontakten (Perry & Burnfield).

Obwohl jeder beliebige Zeitpunkt als Beginn eines Gangzyklus gewählt werden könnte, da es sich um eine sich fortwährend wiederholende zyklische Bewegung handelt, bietet sich der initiale Kontakt eines Fußes mit dem Boden an (Medved, 2001; Perry & Burnfield, 2010; Whittle, 2008; Winter, 1984). Zum einen kann die Festlegung des Zeitpunktes auch mit einfachen analytischen Methoden gewährleistet werden, zum anderen stellt diese Vorgehensweise den Standard in der Ganganalyse dar und ermöglicht eine Vergleichbarkeit der Ergebnisse unterschiedlicher Studien (Banzer & Vogt, 2005; Cappozzo, 1984; Kramers-de Quervain et al., 2008). In der Regel wird der Kontakt zum Boden durch die Ferse eingeleitet. Bedingt durch pathologische Mechanismen gibt es Personen, die mit dem Ballen den Boden zuerst berühren. Aus diesem Grund spricht man allgemeingültig vom initialen Bodenkontakt des Fußes (Perry & Burnfield, 2010). Ein Schritt (step) beschreibt den Zeitraum vom initialen Kontakt eines Fußes bis zum initialen Kontakt des kontralateralen Fußes. Jeder Schritt kann in eine Phase unterteilt werden, in der der Fuß Kontakt zum Boden hat (Standphase / stance) und eine Phase, in der der Fuß in Fortbewegungsrichtung durch die Luft schwingt (Schwungphase / swing, Abbildung 10).




Abbildung 10. Stand- und Schwungphase eines Schrittes (Perry & Burnfield, 2010).

Bezieht man das kontralaterale Bein mit ein, ergibt sich für die Standphase eine weitere Unterteilung in drei Abschnitte (Abbildung 11). Eine initiale, doppelt unterstützte Standphase, bei der beide Beine Bodenkontakt halten, eine einfach unterstützte Standphase, bei der das kontralaterale Bein in der Schwungphase ist und eine terminal doppelt unterstützte Standphase.




Abbildung 11. Einfach und doppelte unterstützte Phasen eines Schrittes (Perry & Burnfield, 2010).

Die Schwungphasen des einen Beines repräsentieren jeweils die einfach unterstützte Standphase des kontralateralen Beins. Perry und Burnfield verweisen darauf, dass die Bezeichnung der doppelten Unterstützung im Hinblick auf die Dynamik irreführend ist, da eine gleichmäßige Lastverteilung auf beide Beine während dieser Periode nur kurzzeitig stattfindet. Die Standphase beträgt ca. 60 % des gesamten Gangzyklus, wovon 40 % einfach und jeweils 10 % initial und terminal doppelt unterstützt sind. Auf die Schwungphase entfallen ca. 40 % (Andriacchi, Ogle & Galante, 1977; Kirtley et al., 1985; Perry & Burnfield, 2010; Whittle, 2008). Tabelle 1 stellt die unterschiedlichen Verteilungen der Stand- und Schwungphasen in prozentualen Anteilen des Gangzyklus ausgewählter Autoren vergleichend gegenüber.



**Tabelle 1.** Prozentuale Verteilung der Stand- und Schwungphasen beim Gehen bei unterschiedlichen Autoren im Überblick.

<b>Autor</b>	<b>Initial doppelunterstützte Standphase [% GZ]</b>	<b>Terminal doppelt unterstützte Standphase [%GZ]</b>	<b>Einfach unterstützte Stand- / Schwungphase [%GZ]</b>
Murray et al. (1964)	11	11	39
Kramers de-Quervain (2008)	12	12	38
Whittle (2008)	10	10	40
Richards (2008)	10	10	40
Perry (2010)	10	10	40
Novacheck (1998)		24	38
Hollman, McDade und Petersen (2011)		26,3 – 30,3	37.1 – 35,2

Mit steigender Gehgeschwindigkeit verschieben sich die Anteile zugunsten einer längeren Schwungphase um 0,3 % bei  $0,1 \text{ ms}^{-1}$  Geschwindigkeitszunahme (Hebenstreit et al., 2015) und einer Verkürzung der Standphase bis unter 50 % des Gangzyklus. In diesem Bereich findet die Transition vom Gang zum Lauf statt. Es gibt keine Phasen mehr, bei denen beide Beine den Boden berühren (Novacheck, 1998). Sowohl die einfach als auch die doppelt unterstützten Standphasen werden kürzer (Borghese, Bianchi & Lacquaniti, 1996; Novacheck, 1998). Durch einen Anstieg der Kadenz (Schritte pro Minute) sinkt jedoch die absolute Dauer des Gangzyklus.

Die einfache Segmentierung nach Bodenkontakten ermöglicht die Bestimmung der ganganalytischen Basisparameter (zeitlich-räumliche Parameter; Tabelle 2). Zahlreiche Normwerte hierzu wurden über die letzten Jahrzehnte publiziert (Hebenstreit et al., 2015; Hollman et al., 2011; Kadaba et al., 1989; Kirtley et al., 1985; Kramers-de Quervain et al., 2008; Novacheck, 1998; Perry & Burnfield, 2010; Whittle, 2008; Winter, 1984).

**Tabelle 2.** Normwerte räumlich-zeitlicher Parameter beim Gehen (Kramers-de Quervain et al., 2008).

<b>Parameter</b>	<b>Einheit</b>	<b>Frauen</b>	<b>Männer</b>
Geschwindigkeit	m/s	1,2	1,5
Kadenz	1/min	105	130
Gangzykluslänge	m	1,3	1,5
Schrittlänge	m	0,65	0,75
Fußwinkel	°	7	6
Spurbreite	m	0,08	0,11

Betrachtet man den Gang im Hinblick auf die Aufgaben, die im Verlauf eines Gangzyklus erfüllt werden, ergibt sich nach Perry und Burnfield (2010) eine Segmentierung nach Teilaufgaben (Tasks), die durch Funktionsphasen erfüllt werden (Abbildung 12).

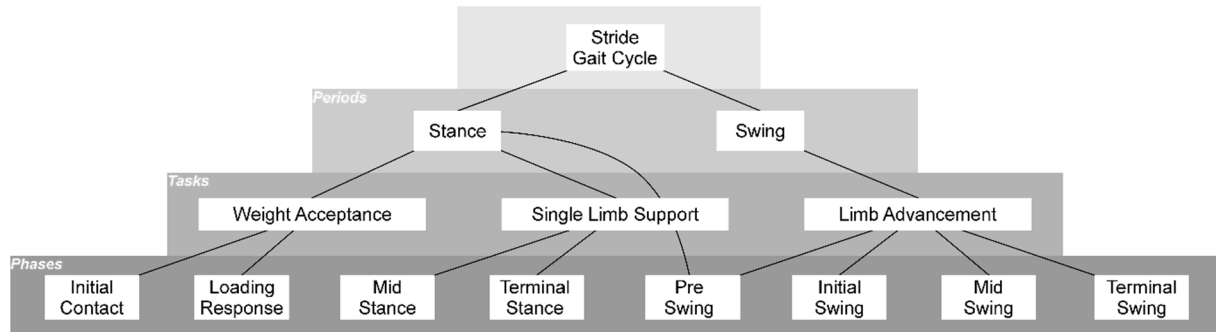


Abbildung 12. Unterteilung des Gangzyklus (verändert nach Perry & Burnfield, 2010, S. 10).

Im Folgenden werden die Normwerte der Gelenkwinkel der unteren Extremität anhand der acht Phasen nach Perry und Burnfield (2010) dargestellt.

## Task 1: Gewichtsübernahme (Weight Acceptance)

### Phase 1: Initial Contact

Mit der ersten Phase „Initial Contact“ ist das Teilziel der Positionierung der Gliedmaße verbunden, um über den Fersenhebel (heel rocker) die Standphase einzuleiten. Diese Phase macht bis zu 2 % des Ganzyklus aus. In Abbildung 13 sind typische Winkelverläufe der Gelenke der unteren Extremitäten dargestellt sowie die Phase des „Initial Contact“ grau hinterlegt.

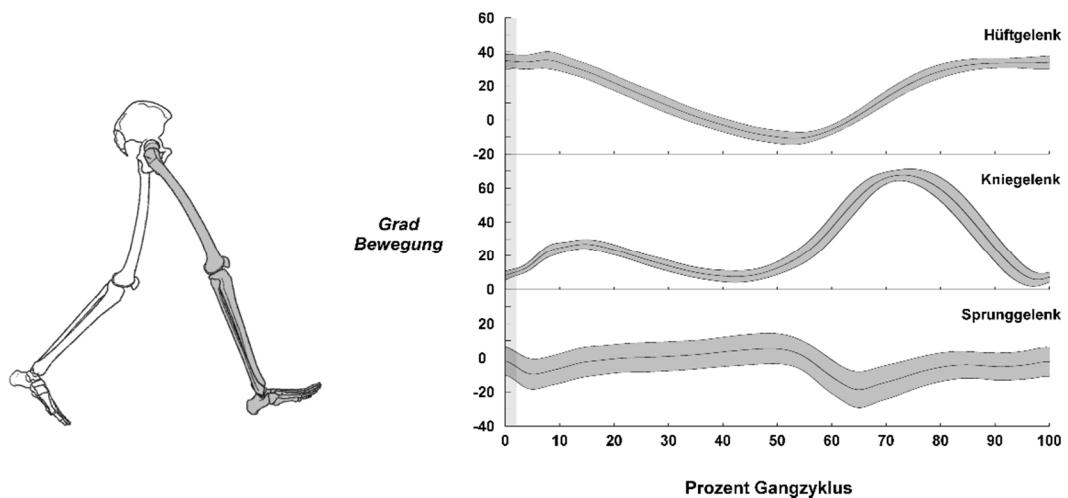


Abbildung 13. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Initial Contact“ (grau unterlegt; Hüftgelenk: 30° Flexion; Kniegelenk: 5° Flexion; Oberes Sprunggelenk: Neutral / 3-5° Plantarflexion).

### Phase 2: Loading response

Dies ist die initial doppelte unterstützte Phase, die durch den ersten Bodenkontakt eingeleitet wird und bis zum Abheben des kontralateralen Fußes andauert (0 % – 10% GZ). Die Phase dient der Stoßdämpfung, sowie der Gewichtsübernahme und der Aufrechterhaltung der Vorwärtsbewegung. In Abbildung 14 sind typische Winkelverläufe der Gelenke der unteren Extremitäten dargestellt sowie die Phase der „Loading response“ grau hinterlegt.

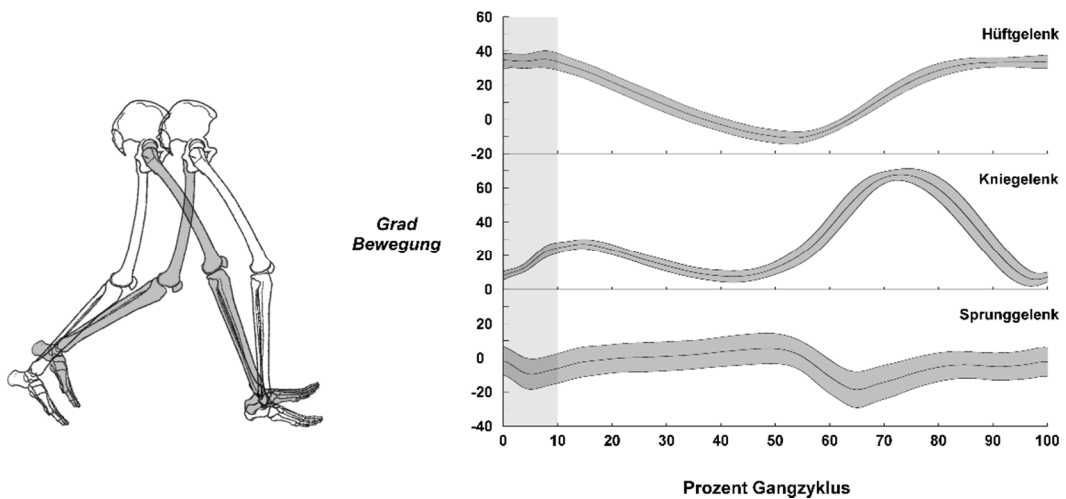


Abbildung 14. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Loading Response“ (grau unterlegt; Hüftgelenk: 30° Flexion; Kniegelenk: 20° Flexion; Oberes Sprunggelenk: 7° Plantarflexion).

## Task 2: Einfache Unterstützung (Single Limb Support)

### Phase 3: Mid Stance

Während der dritten Phase des GZ wird der Körper vom Bodenkontakt des kontralateralen Fußes fortbewegt, bis sich das Gewicht des Oberkörpers über dem Vorfuß des Standbeines befindet. Dies geschieht während der ersten Hälfte der einfach unterstützten Standphase (10 % – 30% GZ). Oberkörper und Gliedmaße werden während dieser Zeit stabilisiert.

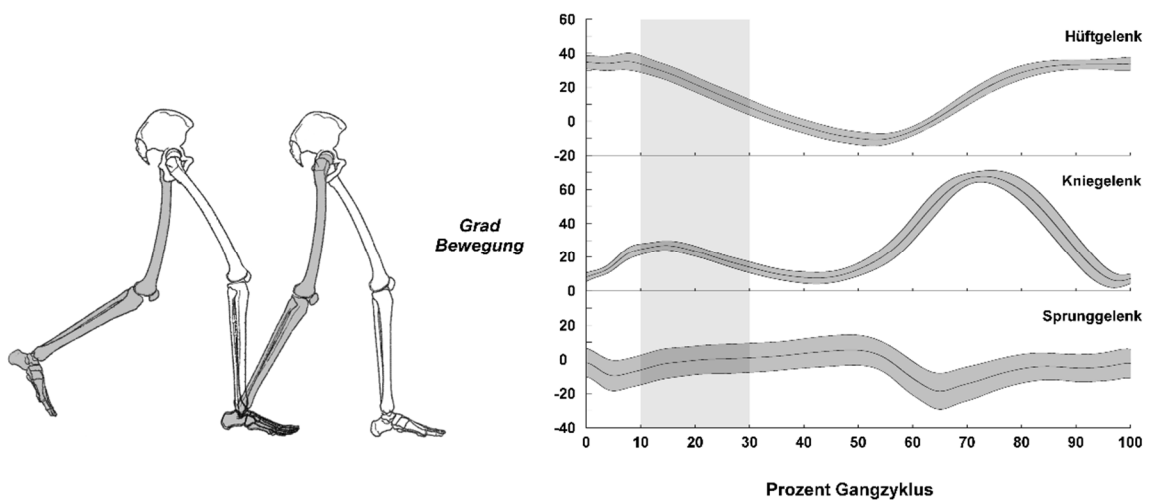


Abbildung 15. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Mid Stance“ (grau unterlegt; Hüftgelenk: 5° Flexion; Kniegelenk: 15° Flexion; Oberes Sprunggelenk: 5° Dorsiflexion).

#### Phase 4: Terminal Stance

Der „Terminal Stance“ (Abbildung 16) beginnt mit der Abhebung der Ferse des Standbeines und endet mit dem Fersenaufsatz des kontralateralen Fußes. Die einbeinige Standphase wird mit Fersenaufsatz beendet. Das Gewicht des Oberkörpers wird während dieser Phase (30 % – 50% GZ) über den Vorfuß des Standbeines hinweg bewegt.

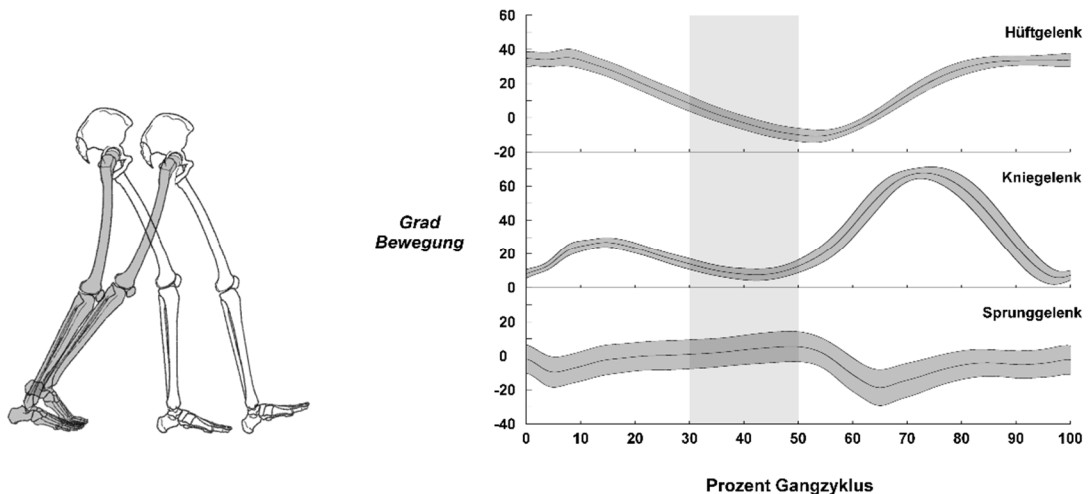


Abbildung 16. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Terminal Stance“ (grau unterlegt; Hüftgelenk: 15° Flexion; Kniegelenk: 10° Flexion; Oberes Sprunggelenk: 8° Dorsiflexion).

#### Phase 5: Pre-Swing

Die Phase des „Pre-Swing“ (Abbildung 17) repräsentiert die zweite doppeltunterstützte Standphase. Sie wird durch den initialen Fersenkontakt des kontralateralen Beines eingeleitet und dauert bis zum Abheben des ipsilateralen Fußes. Während dieser Phase (50 % – 60% GZ) wird das Körpergewicht auf das kontralaterale Bein übertragen und das ipsilaterale Bein auf die Schwungphase vorbereitet.




Abbildung 17. Gelenkwinkel der Gelenke der unteren Extremitäten während der Phase des „Pre Swing“ (grau unterlegt; Hüftgelenk: 10° Flexion; Kniegelenk: 35° Flexion; Oberes Sprunggelenk: 15° Plantarflexion).

### Task 3: Fortbewegung des Schwungbeins

#### Phase 6: Initial Swing

Während der Phase des „Initial Swing“ (Abbildung 18) wird der Fuß des ipsilateralen Beines vom Boden gelöst und nach vorne bewegt, bis auf Höhe des kontralateralen Fußes. Die Phase repräsentiert ca.  $\frac{1}{3}$  der gesamten Schwungphase (60 % – 73% GZ).




Abbildung 18. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Initial Swing“ (grau unterlegt; Hüftgelenk: 20° Flexion; Kniegelenk: 70° Flexion; Oberes Sprunggelenk: 9° Plantarflexion).

### Phase 7: Mid Swing

Während des zweiten Teilabschnitts der Schwungphase (73 % – 87 % GZ) wird das Schwungbein nach vorne vor den Körper geführt, bis die Tibia senkrecht zur Unterstützungsfläche steht (Abbildung 19).

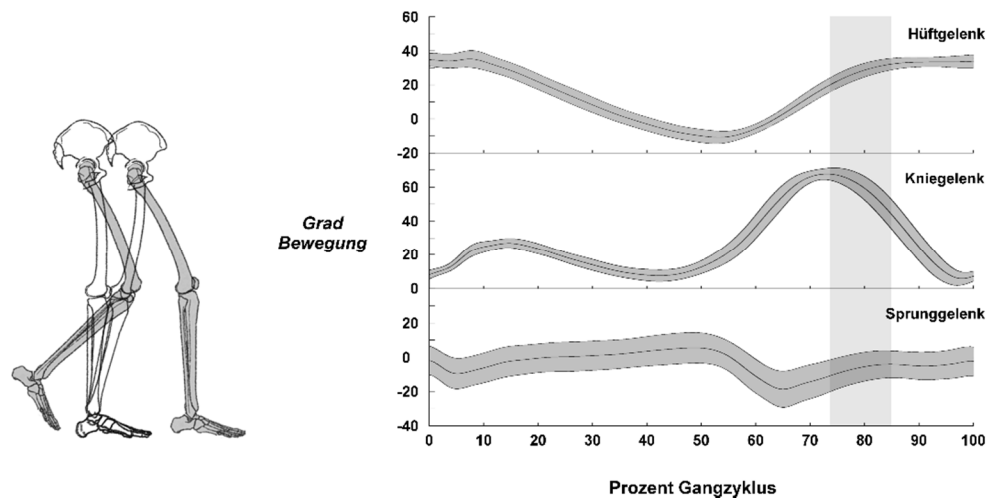


Abbildung 19. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Mid Swing“ (grau unterlegt; Hüftgelenk: 30° Flexion; Kniegelenk: 30° Flexion; Oberes Sprunggelenk: neutral).

### Phase 8: Terminal Swing

Mit dem „Terminal Swing“ endet die Vorwärtsbewegung des Schwungbeines und die Tibia wird bis vor den Oberschenkel geführt (Abbildung 20). Die Phase endet mit dem Kontakt der Ferse des ipsilateralen Beines (87 % – 100 % GZ).

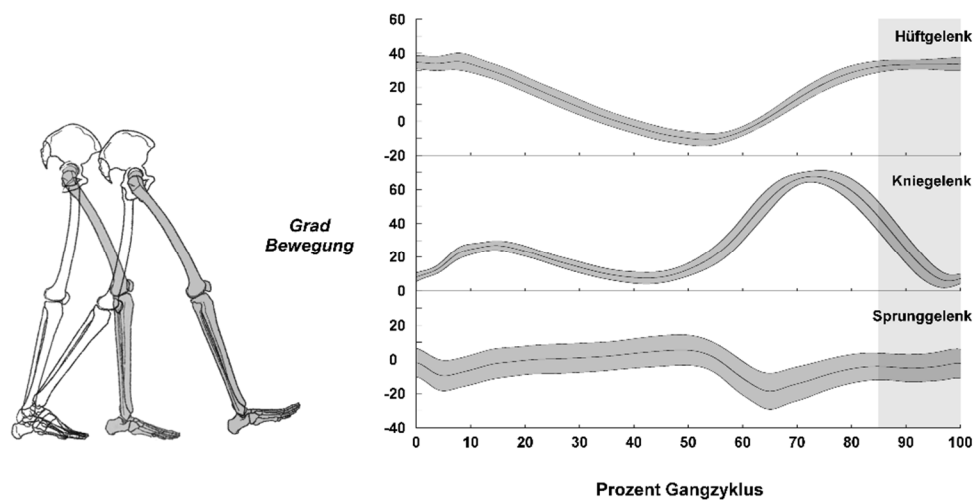


Abbildung 20. Gelenkwinkel der Gelenke der unteren Extremitäten in der Sagittalebene während der Phase des „Terminal Swing“ (grau unterlegt; Hüftgelenk: 35° Flexion; Kniegelenk: 35° Flexion; Oberes Sprunggelenk: neutral).

### 2.3.2 Rennen

Rennen wird gegenüber dem Gehen auf Basis der Bodenkontakte abgegrenzt. Mit zunehmender Ganggeschwindigkeit werden die doppelt unterstützten Phasen des Gangzyklus kürzer (Abbildung 21). Sie weichen Phasen, in denen beide Beine keinen Bodenkontakt mehr haben und eine Flugphase entsteht (Murray et al., 1964).




Abbildung 21. Stand- und Schwungphasen beim Gehen ( $1,2 \text{ ms}^{-1}$ ) und Rennen ( $3,2 \text{ ms}^{-1}$ ) (Novacheck, 1998).

Der Bodenkontakt wird bei den meisten Personen weiterhin initial über die Ferse hergestellt. Ein initialer Kontakt über den Ballen ist aber im Gegensatz zum Gehen nicht mehr als pathologisch zu beurteilen. Die prozentuale Verteilung von Standphase und Flugphase liegt bei einer Laufgeschwindigkeit von  $3,2 \text{ ms}^{-1}$  vergleichbar mit der beim Gehen bei 39 % : 61 % (Novacheck, 1998) und bei einer Geschwindigkeit von  $5 \text{ ms}^{-1}$  bei 30 % : 70 % (Kramers-de Quervain et al., 2008).

Tabelle 3. Normwerte räumlich-zeitlicher Parameter beim Rennen mit unterschiedlichen Geschwindigkeiten (Hamill, Knutzen & Derrick, 2015).

Parameter	Einheit	2 m/s	5 m/s
Kadenz	1/min	$155,14 \pm 8,51$	$184,46 \pm 11,47$
Schrittlänge	m	$0,89 \pm 0,19$	$0,91 \pm 0,10$
Bodenkontaktzeit	s	$0,33 \pm 0,05$	$0,20 \pm 0,02$
Flugzeit	s	$0,05 \pm 0,04$	$0,12 \pm 0,01^*$

Im Vergleich zum Gehen wird beim Rennen auf Grund der Flugphase der Körperschwerpunkt deutlich stärker vertikal ausgelenkt. Findet man beim Gehen die größte



Auslenkung in der Mitte der Stützphase, verschiebt sich die maximale Auslenkung beim Rennen in die Mitte der Flugphase.

Mit Steigerung der Geschwindigkeit werden die Schrittfrequenz sowie die Schrittlänge erhöht (Tabelle 3). Schrittlänge und Schrittfrequenz ändern sich linear mit der Geschwindigkeit (Williams, 1985). Dabei wählt jeder Läufer ein für sich optimales Verhältnis zwischen Schrittlänge und -frequenz, bei welchem der Energieverbrauch minimalisiert wird (Cavanagh & Kram, 1989). „Es ist daher sehr wahrscheinlich, dass jeder Läufer bei jeder beliebigen Laufgeschwindigkeit eine eigene, individuell optimierte Schrittfrequenz aufweist“ (Kramers-de Quervain et al., 2008, S. 37).

## **2.4 Verfahren der Mustererkennung**

Die biomechanische Analyse der Geh- und Rennbewegung mit den Methoden der Kinemetrie, Dynamometrie und Elektromyografie, ergänzt durch Kenngrößen zu den anthropometrischen Merkmalen der Testpersonen, liefert eine Vielzahl an Funktionsparametern, die Informationen zur Person und der ausgeführten Bewegung enthalten. Die Analyse der Muster, die Funktionsparameter bilden, kann Abweichungen zu Referenzmustern sowohl quantifizierbar als auch visualisierbar machen und Rückschlüsse auf die Mechanismen zulassen, die zur Veränderung der Muster beitragen. Das Wissen über diese Mechanismen lässt sich in der Sportwissenschaft beispielsweise zum Zweck der Taktikanalyse, der Trainingssteuerung, der Überwachung von Trainingsprozessen, der Technikkontrolle u.a. einsetzen (Baca, 2008; Perl, 2008; Schöllhorn & Perl, 2002).

Im historischen Verlauf wurden viele unterschiedliche Ansätze auf Basis mathematischer Algorithmen zur Analyse von Mustern entwickelt, welche bedeutend zum Erkenntnisgewinn in der Bewegungswissenschaft beigetragen haben. Über die vergangenen Jahre wurde die vieldimensionale Modellierung von Zusammenhängen kinematischer und dynamischer Bewegungsmuster bei sportlichen Bewegungen mit Methoden mit unkonventionellen Modellparadigmen erfolgreich realisiert (Perl, 2007; Schöllhorn et al., 2002). In erster Linie wurden Künstliche Neuronale Netze (KNN) eingesetzt, welche dazu genutzt wurden Muster zu analysieren, die im Hinblick auf Zeit und Raum dynamischen Änderungen unterliegen und durch Lernfähigkeit, assoziative

Fähigkeiten, selbstorganisierende Fehlertoleranz etc. determiniert sind. KNNs modellieren unter Berücksichtigung der Vorgeschichte des biologischen Systems vergangene und zukünftige Zustände. Für die Erkennung von Mustern beim Menschen wurden in erster Linie Self-Organizing Maps (Kohonen Maps) verwendet. Sie nutzen ein unüberwachtes Lernverfahren, bei dem das richtige Ergebnis für das entsprechende Eingangsmuster nicht bekannt ist. Es wird genutzt, um auf einem mehrdimensionalen Merkmalsraum eine Reduktion durchzuführen und niedrigerdimensionale Ergebnisse zu liefern (Knieling, 2007; Schöllhorn & Perl, 2002). Schöllhorn und Perl (2002) erzielten mit dieser Methode bei der Identifizierung von Laufmustern eine Erkennungsrate von 87 %. Insbesondere im Hinblick auf die Unterscheidung individueller menschlicher Bewegungsmuster während sportlicher Bewegungen, scheinen optimierte Modellansätze zur Mustererkennung menschliche Bewegungen besser abbilden zu können und zu genaueren Ergebnissen als herkömmliche Neuronale Netze zu führen (Wang, She, Nahavandi & Kouzani, 2010). Die Analyse der aktuellen Literatur zur Mustererkennung hat gezeigt, dass neben Künstlichen Neuronalen Netzen auch Support Vector Machines zur Modellierung natürlicher Daten verstärkt Anwendung finden. Sowohl KNNs, als auch SVMs scheinen insbesondere für die Abbildung zeitlich räumlicher Parameter vom Gehen und Rennen geeignet und lassen bessere Klassifikationsergebnisse als herkömmliche Verfahren, die deterministische Modellansätze verfolgen, erwarten. Sowohl Ng et al. (2011) und Sudha und Bhavani (2012), die klassische Verfahren (lineare Diskriminanzanalyse; LDA) zur Klassifizierung einem fuzzy k-nearest neighbour Modell und einer Support Vector Machine gegenüberstellten, als auch Pradhan et al. (2015), die klassische Verfahren mit KNNs und Support Vector Machines verglichen, konnten zeigen, dass die unkonventionellen Methoden zur Mustererkennung beim Gehen und Rennen zuverlässig bessere Ergebnisse bei der Klassifikation liefern. Ein weiterer Modellansatz zur Mustererkennung stellen Hidden Markov Modelle dar, die bereits erfolgreich für die Klassifikation im Kontext menschlicher Bewegungen im Allgemeinen (Yamato, Ohya & Ishii, 1992) und Lokomotionsbewegungen im Speziellen (Cheng, Ho & Huang, 2008; Mannini & Sabatini, 2012b) Verwendung gefunden haben.

#### 2.4.1 Künstliche Neuronale Netze

Künstliche neuronale Netze (KNNs) sind ursprünglich in Funktion und Arbeitsweise an den Aufbau des menschlichen Gehirns angelehnt. 1943 veröffentlichten McCulloch und Pitts den Beitrag *A logical calculus of the ideas immanent in nervous activity*, der ein Modell eines biologischen Neurons beschrieb. Seither wurden unzählige Neuronale Netze erforscht, die auf Basis der künstlichen Neurone, die untereinander „vernetzt“ wurden, als vereinfachte Nachbildung der Nervenzellen und ihrer Synapsen verstanden werden können. „Die spezifischen, z.T. sehr heterogenen Netztypen [...] lassen sich nur schwer in einer bündigen Definition zusammenfassen“ (Rey & Wender, 2008, S. 15). Die Anwendungsfelder von KNNs lassen sich mittlerweile in zwei große Bereiche einteilen: In der Erforschung menschlicher Verhaltensweisen und der Funktionsweise des Gehirns werden Netze modelliert, die zum Verständnis der komplexen Zusammenhänge der biologischen Informationsverarbeitung beitragen sollen. In vielen anderen Wissenschaftsgebieten werden KNNs dazu verwendet komplexe Zusammenhänge zu modellieren und tragen so zur Lösung konkreter Anwendungsprobleme bei. Alle Netzwerktypen haben aber weiterhin die biologisch geprägte Grundidee gemein, die sie von anderen Ansätzen abgrenzt.

### 2.4.1.1 Grundlage Künstlicher Neuronaler Netze

#### Neurone/Units

Künstliche Neuronale Netze bestehen aus einer variablen Anzahl von künstlichen Neuronen, die untereinander vernetzt sind. „Diese Neuronen werden auch als Units, Einheiten oder Knoten bezeichnet“ (Rey & Wender, 2008, S. 17). Das Netzwerk dient zur Informationsverarbeitung in verschiedenen Ebenen und unterscheidet drei unterschiedliche Typen von Ebenen. Einfache Netztypen bestehen aus einer Eingabe-Ebene (Input Layer) und einer Ausgabe-Ebene (Output Layer). Die meisten Netze zur Lösung komplexerer Aufgaben verfügen außerdem, wie in Abbildung 22 dargestellt, über eine versteckte Ebene (Hidden Layer).




Abbildung 22. : Struktur eines Künstlichen Neuronalen Netzes mit Eingabe-, versteckter- und Ausgabe-Ebene.

Die jeweils übereinander geordneten Units bilden eine gemeinsame Ebene (Layer). Units sind durch Links (Kanten) miteinander verbunden, die durch eine Gewichtung den Einfluss der Neurone aufeinander regeln. Positive Gewichte führen zu einer Erregung des verbundenen Neurons, negative Gewichte haben eine hemmende Auswirkung und eine neutrale Wichtung unterbindet den Einfluss auf die andere Unit. Lernt ein Neuronales Netz durch ein Training, werden die Gewichte der Verbindungen in Abhängigkeit von Regeln (Lernregeln) geändert (Hebb, 1949).

#### Input

Der Input beschreibt den Einfluss, den ein Neuron auf ein anderes hat. Er wird im Wesentlichen davon beeinflusst, wie hoch das Aktivitätslevel und damit (in den meisten Fällen) der Output des sendenden Neurons ist und wie stark der Link zwischen den beiden Neuronen gewichtet ist. Die Werte von Link und Output sind in der Regel

multiplikativ miteinander verknüpft und der Einfluss auf ein Neuron kann entsprechend berechnet werden (Rojas, 1996). Der Gesamtinput über ein Layer wird als Netinput (Nettoinput) bezeichnet. Die Berechnung des Netinputs erfolgt über die Propagierungsfunktion. Die einfachste und am häufigsten verwendete Form der Propagierungsfunktion bildet die Summe über alle Inputs eines Layers.

$$netinput_i = \sum_j input_{ij} = \sum_j a_j \cdot w_{ij}$$

Dabei gilt:

- i = empfangende Unit
- j = sendende Unit
- $a_j$  = Ausgabe der sendenden Unit
- $w_{ij}$  = Gewicht zwischen der empfangenden und der sendenden Unit

(Rey & Wender, 2008, S. 21)

In dieser Formaldarstellung kennzeichnet laut Konvention die erste Indexstelle immer die empfangende Unit und die zweite Indexstelle die sendende Unit.

### *Aktivität und Output*

Die Aktivität eines Neurons wird über den Input und die Aktivierungsfunktion des Neurons bestimmt. In der Regel wird eine Aktivierungsfunktion für alle Neurone eines Layers, bzw. für alle Neurone eines Netzes verwendet. Zahlreiche unterschiedliche Aktivierungsfunktionen können unterschieden werden.

Die *binäre Aktivierungsfunktion* (Abbildung 23 a) unterscheidet in Abhängigkeit des Inputs einen Output zwischen 0 (manchmal auch -1) und 1. Sie findet in erster Linie bei der Klassifikation von Mustern Anwendung.

Die *lineare Aktivierungsfunktion* (Abbildung 23 b) beschreibt einen linearen Zusammenhang zwischen Input und Output eines Neurons. Diese Funktion findet vorwiegend als adaptiver linearer Filter Anwendung.

Die *sigmoide Aktivierungsfunktion* (Abbildung 23 c) verhält sich ähnlich der Binärfunktion. Im Betrag stark negative Inputs führen bei einer *logistischen Funktion* zu einem Output nahe null, bei *Tangens Hyperbolicus Funktionen* zu einem Output

nahe -1. Stark positive Inputwerte führen bei beiden Funktionen zu einem Output nahe 1. Die Steigung der Funktion ist im mittleren Wertebereich ähnlich der einer Linearfunktion. Im Gegensatz zur binären Funktion ist die sigmoide Funktion an jeder Stelle differenzierbar. Sigmoide Aktivierungsfunktionen werden in erster Linie bei Rückkopplungsnetzen (Backpropagation-Netzen) verwendet (Rojas, 1996).




Abbildung 23. :Binäre (a), lineare (b) und Sigmoide (Tangens Hyperbolicus) Aktivierungsfunktion (Rojas, 1996).

Der Output ( $o_i$ ) eines Neurons wird vom Aktivierungslevel ( $a_i$ ) und einer Ausgabe-funktion bestimmt. Die Ausgabefunktion entspricht in der Regel der Identitätsfunktion.

$$o_i = a_i$$

Häufig wird aus diesem Grund in der Literatur und bei Computerprogrammen nicht zwischen dem Aktivierungslevel und dem Output unterschieden (Rey & Wender, 2008, S. 28).

### *Training und Test*

Während des Trainings lernt das KNN auf der Basis von Lerndaten. Lernregeln, die im Verlauf noch exemplarisch vorgestellt werden, bestimmen die Art und Weise wie die Gewichte der Links zwischen den Neuronen modifiziert werden. Während der Testphase wird das angelernte Wissen des Netzes überprüft. Wird dies mit Daten aus der Menge der Lerndaten gemacht, kann überprüft werden, ob die Trainingsphase erfolgreich und Wissen über das Lernmaterial generiert wurde. Werden zum Test neue Daten verwendet, kann geprüft werden, ob das Netz über eine Generalisierungsfähigkeit verfügt und das Wissen zur Klassifizierung unbekannter Daten verwendet werden kann (Bishop, 2010).

### *Lernregeln*

Grundlage für das Lernen der KNNs während der Trainingsphase sind die Lernregeln. Analog zum Mensch, bei dem Änderungen in den Anforderungen seiner Umwelt nach dem Gesetz der Homöostase zu einer Anpassung führen, steuern die Lernregeln die Reaktion eines Netzes auf das Training. Ein Netz kann sich dabei in allen beschriebenen Komponenten verändern. „Theoretisch könnte ein Neuronales Netz also lernen, indem es

- neue Verbindungen entwickelt,
- vorhandene Verbindungen löscht,
- Verbindungsgewichte verändert,
- Schwellenwerte von Neuronen ändert
- eine oder mehrere der drei Neuronenfunktionen ([...]Aktivierungs-, Propagierungs- und Ausgabefunktion) abwandelt,
- neue Neurone entwickelt
- oder aber vorhandene Neurone löscht (und damit natürlich Verbindungen)“

(Kriesel, 2007, S. 53)

Betrachtet man vereinfacht das Lernen ausschließlich als eine Änderung der Gewichte der Verbindung zwischen Neuronen, so wird die Modifikation einer Verbindung derart erfolgen, dass eine neutrale Verbindung zwischen zwei Neuronen über das Training ein Gewicht erhält. Analog dazu kann einer gewichteten Verbindung durch eine permanente Neutralisierung der Einfluss auf ein anderes Neuron „entzogen“ werden, was einer Löschung der Verbindung gleichkommt. Ebenso kann der Schwellenwert über die Gewichtung einer Verbindung reguliert werden. Die gängigsten Formen von Änderung an einem Netz durch Training lassen sich demnach durch Änderung der Gewichte vollziehen. „Die Möglichkeiten, Neurone zu entwickeln oder zu löschen, liefern während des Trainings eines Neuronalen Netzes nicht nur gut eingestellte Gewichte, sondern optimieren auch noch die Netztopologie – sie gewinnen daher immer mehr an Interesse und werden oft mit evolutionären Verfahren realisiert (Kriesel, 2007, S. 54).“ Die Veränderung der Propagierungs-, Aktivierungs- und Ausgabefunktionen werden in der Praxis selten eingesetzt, da eine Implementierung nur sehr schwierig umzusetzen ist.

In der Fachliteratur (Bishop, 2010; Rey & Wender, 2008; Rojas, 1996) werden mit der Hebbischen Lernregel (überwachtes Lernen), der Delta-Regel (überwachtes Lernen),

der Backpropagation Lernregel (überwachtes Lernen) sowie dem Kompetitiven Lernen (unbewachtes Lernen) vier Arten des Lernens unterschieden, die im Folgenden kurz vorgestellt werden.

Die *Hebbsche Lernregeln* (überwachtes Lernen) ist die älteste und eine der einfachsten Lernregeln. Sie funktioniert ausschließlich bei Netzen, in denen keine versteckten Ebenen vorkommen.

Wenn ein Axon der Zelle A [...] Zelle B erregt und wiederholt und dauerhaft zur Erzeugung von Aktionspotentialen in Zelle B beiträgt, so resultiert dies in Wachstumsprozessen oder metabolischen Veränderungen in einer oder in beiden Zellen, die bewirken, dass die Effizienz von Zelle A in Bezug auf die Erzeugung eines Aktionspotentials in B größer wird (Hebb 1949, S. 62; Übersetzung nach Kandel et al., 1995, S. 700, zitiert nach Rey & Wender 2008, S. 38-39).

oder

Wenn Zelle j eine Eingabe von Zelle i erhält und beide gleichzeitig stark aktiviert sind, dann erhöhe das Gewicht  $w_{i,j}$  (d. h. verstärke die Verbindung von Zelle i zu Zelle j).

$$\Delta w_{ij} = \epsilon \cdot a_i \cdot a_j$$

Dabei gilt:

- $\Delta w_{ij}$  = Veränderung des Gewichts zwischen den Einheiten i und j
- $\epsilon$  = vorher festgelegter, positiver Lernparameter (meist kleiner 1)
- $a_i$  = Aktivitätslevel bzw. Ausgabe der empfangenen Unit i
- $a_j$  = Aktivitätslevel bzw. Ausgabe der sendenden Unit j

(Rey & Wender, 2008)

Die *Delta-Regel* (überwachtes Lernen) vergleicht den tatsächlichen Aktivitätslevel einer Output Unit mit dem eigentlich gewünschten Ergebnis. Der Vergleich der Units wird über den Delta-Wert repräsentiert.

$$\delta = a_i(\text{gewünscht}) - a_i(\text{beobachtet})$$



Ist ein Neuron zu schwach aktiviert ( $\delta > 0$ ), so wird das Gewicht der Verbindung von Input- zu Output Unit erhöht, ist es zu stark aktiviert ( $\delta < 0$ ), wird das Gewicht verringert, bis das gewünschte Aktivitätslevel erreicht ist.

$$\Delta w_{ij} = \epsilon \cdot \delta_i \cdot a_j$$

Dabei gilt:

- $\Delta w_{ij}$  = Veränderung des Gewichts zwischen den Einheiten i und j
- $\epsilon$  = vorher festgelegter, positiver Lernparameter (meist kleiner 1)
- $\delta_i$  = Delta-Wert der (Output-) Unit i
- $a_j$  = Aktivitätslevel bzw. Ausgabe der sendenden (Input-) Unit j

(Rey & Wender, 2008)

Das *Backpropagation Verfahren* (überwachtes Lernen), oder auch Verfahren zur Fehlerrückführung ermöglicht im Gegensatz zur Hebbischen Regel die Änderung der Gewichte der Links zu den Hidden Units und stellt eine Erweiterung der Delta-Regel dar. Da die Aktivitätslevel der Hidden Units, die zu einer richtigen Klassifizierung führen zunächst nicht bekannt sind, kann für Neuronen dieser Schicht kein Abgleich zwischen tatsächlichem und gewolltem Aktivitätslevel stattfinden. Die Änderungen an den Gewichten werden deshalb in drei Phasen aufgeteilt.

#### 1. Forward-Pass

Während des Forward-Pass wird das KNN in der Trainings- und Testphase den Trainingsdaten ausgesetzt. Der Output aller Hidden Layer und des Output Layer wird mit Propagierungs-, Aktivierungs- und Ausgabefunktion bestimmt.

#### 2. Fehlerbestimmung

Der Fehler aller Output Units wird entsprechend der Delta-Regel bestimmt. Sind die Fehler größer als die vorab bestimmte Fehlertoleranz, folgt die Anpassung der Gewichte über den Backward-Pass.

#### 3. Backward-Pass

Während des Backward-Pass werden die für die Output Units berechneten Fehlerterme rückwärts durch das KNN geschickt. Für jeden Hidden Layer erfolgt über das Gradientenabstiegsverfahren (Rojas, 1996) eine Anpassung der Gewichte für alle Units eines Layers. Die einzelnen Ebenen werden nacheinander angepasst, bis der Input Layer erreicht ist. Dieses

Verfahren wird so lange wiederholt, bis entweder die Fehlertoleranz für die Output Units unterschritten wird, oder eine vorab festgelegte Anzahl von Zyklen überschritten wird (Rey & Wender, 2008, S. 57).

Im Gegensatz zu den vorgestellten Lernverfahren, die über den Abgleich eines Fehlerterms der Ausgabe-Unit mit dem gewünschten Ergebnis in einem überwachten Vorgang die Gewichte modifizieren, stellt das *kompetitive Lernen* (Wettbewerbslernen, competitive Learning) ein unbewachtes Verfahren dar. Auf Basis der Ähnlichkeiten der Trainingsdaten wird eine Klassifizierung durch das KNN durchgeführt (Kohonen, 1990; Kriesel, 2007). In der Regel verfügen KNNs, die nach den Regeln des Wettbewerbslernens trainiert werden, über keine versteckten Ebenen und verwenden eine Abwandlung der Delta-Regel zur Modifizierung der Gewichte. Das Training kann in drei Phasen unterteilt werden:

1. Erregung

Wie bei allen angesprochenen Verfahren werden zunächst Trainingsdaten präsentiert und die Aktivierung der Output-Neurone über die Propagierungs-, Aktivierungs- und Ausgabeformeln berechnet.

2. Wettbewerb

Die Output-Neurone treten miteinander in einen Wettbewerb. Das Neuron mit dem größten Netinput gewinnt.

3. Modifizierung der Gewichte

Im Gegensatz zur Delta-Regel wird nun ausschließlich eine Modifizierung aller Gewichte der Links zum Gewinner-Neuron vorgenommen. Die Anpassung der Gewichte geschieht in der Art, dass der Output dem Input ähnlicher gemacht wird.

$$\Delta w_{ij} = \epsilon \cdot (a_j - w_{ij})$$

Dabei gilt:

- $\Delta w_{ij}$  = Veränderung des Gewichts zwischen den Einheiten i und j
- $\epsilon$  = vorher festgelegter, positiver Lernparameter (meist kleiner 1)
- $a_j$  = Aktivitätslevel bzw. Ausgabe der sendenden (Input-) Unit j
- $w_{ij}$  = Gewicht zwischen der empfangenden und der sendenden Unit

### 2.4.1.2 Frameworks KNN

Es würde den Rahmen der vorliegenden Arbeit sprengen einen Überblick über alle gängigen Netztypen zu geben, so werden hier zwei ausgewählte Frameworks zur Erstellung von Künstlichen Neuronale Netzen vorgestellt, die für die Arbeit relevant sind. Einen sehr guten Überblick zu unterschiedlichen Netztypen gibt Kriesel (2007) in seinem Skript.

#### DyCoN

Das Framework DyCoN stellt eine Erweiterung der Self Organizing Maps von Kohonen (1982) dar. Self Organizing Maps (Self Organizing Feature Maps, SOMs) zählen zu den Netzen mit einem unbewachten Lernverfahren. Abbildung 24 zeigt, wie ein höherdimensionaler Eingaberaum kartiert wird, indem jedem Eingabevektor ein Neuron der Ausgabeschicht (SOM-Neuron) in einem niedriger dimensional Raum zugeordnet wird. Es findet ein Clustering der Eingabevektoren statt.




Abbildung 24. : Dimensionsreduktion Künstlicher Neuronale Netzwerke (Schölkopf & Smola, 2002).

SOMs verfügen über einen Input- und einen Output-Layer. Dabei hat jedes Neuron des Input-Layers eine Verbindung zu jedem Neuron der Ausgabebene. Das Lernverfahren ist eine Erweiterung des *kompetitiven Lernens*. Vor Beginn des Trainings werden die Gewichte der Verbindungen zwischen den Neuronen der Layer zufällig initialisiert. Dem Netz werden Trainingsdaten präsentiert, mit denen die Aktivitäten der Ausgabe-Neuronen berechnet werden. Analog zum kompetitiven Lernen wird das Neuron, das die höchste Aktivität aufweist, als Gewinner ausgewählt. Dies ist grundsätzlich das Neuron, welches die größte Ähnlichkeit zum Inputvektor aufweist. Wie beim competitive learning werden die Gewichte der Verbindungen zum Inputvektor in der Art verändert, dass die Ähnlichkeit zwischen Input und Output

verstärkt wird und, wie in Abbildung 25 zu erkennen, die Entfernungen der Neurone modifiziert werden.




Abbildung 25. : Modifikation einer SOM durch Training (Perl, 2002, S. 256).

Die Stärke der Veränderung wird über die Lernrate vorab definiert. Zusätzlich werden die Gewichte der Verbindung zu den Neuronen in der Nachbarschaft weniger stark in der gleichen Art modifiziert (Nachbarschaftsfunktion). Abhängig von den Startparametern kann auch die Lernrate in der Art modifiziert werden, dass mit zunehmender Anzahl von Trainingsdaten der Einfluss auf die Netzanpassung abnimmt, was zu einer Stabilisierung des Netzes über die Anzahl der Trainingsvektoren führt. Dieser Prozess wird so lange wiederholt, bis eine vorab definierte Anzahl an Trainingszyklen durchlaufen wurde. (Bishop, 2010; Rey & Wender, 2008)

Bei Versuchen Ballwechseltypen im Volleyball mit der Hilfe von Kohonen Feature Maps zu klassifizieren, konnten Lames und Perl (1999) zwei zentrale Probleme der SOMs identifizieren:

#### Mengenproblem

Mit der Zahl der zu lernenden Muster und mit dem Grad der notwendigen Unterscheidbarkeit von Mustern, wächst die Zahl der notwendigen Lernschritte erheblich: Bereits bei nur ca. 20 unterscheidbaren Typen taktischer Verhaltensprozesse in einem Spiel werden Netze mit etwa 20×20 Neuronen benötigt, die ihrerseits mindestens 5000 Lernschritte brauchen, wofür mindestens 5000 verschiedene beobachtete Spielprozesse notwendig sind. Pro Spiel können im Mittel aber je nach Spieltyp nur zwischen 500 und 1000 Spielprozesse beobachtet werden. Mit anderen Worten: Konventionelle

KFMs müssen mit Daten aus mehreren Spielen trainiert werden und sind daher im Normalfall nicht in der Lage, spielspezifische taktische Verhaltensstrukturen zu lernen. (Perl, 2002, S. 255)

#### Dynamikproblem

Es ist praktisch kaum möglich, ein einmal trainiertes konventionelles KFM weiter zu trainieren. Die Konsequenz ist, dass solche Netze Muster, die einmal gelernt wurden, nicht ergänzen, überlagern oder vorübergehend auch wieder vergessen könnten. Sie sind daher auch nicht in der Lage, die Änderungen technischer oder taktischer Muster mitzulernen. Da aber gerade solche Adaptationen im technischen und taktischen Bereich i.d.R. Ziel entsprechender Trainingsprogramme sind, kann z.B. die Wirkung von Trainingsprogrammen mit Hilfe konventioneller KFM nicht oder nur sehr schlecht analysiert werden. (Perl, 2002, S. 255)

Die Autoren schlossen daraus, dass es mit KFMs zwar möglich ist einzelne Spielsituation zu klassifizieren und in beobachtete Strukturen eines Spiels einzuordnen, nicht aber den Spielverlauf mit darin enthaltenen zeitabhängigen Lernvorgängen korrekt abzubilden. Sie führten dies auf die extern festgelegten Parameter zurück, die das Lernverhalten einer SOM regeln (siehe Kapitel Self Organizing Maps) und dazu führen, dass von einer SOM erlerntes Wissen über neue Trainingsreize, die andere Muster enthalten, verloren gehen kann. Perl entwickelte zur dynamischen Steuerung von Kohonen Feature Maps das Leistungspotential-Metamodell *LeiPot* (oder *PerPot* für Performance Potential) (Mester & Perl, 2000). Hierbei wird jedem Neuron ein eigenes *LeiPot* vorangestellt. Das *LeiPot* verringert den Einfluss von neuen Trainingsreizen auf bereits vorhandene Strukturen und „konserviert“ dadurch bereits erlerntes Wissen. In Abbildung 26 ist das veränderte Lernverhalten einer SOM durch die Anwendung des Leistungspotential-Metamodells im Vergleich zu klassischem Lernverhalten dargestellt.

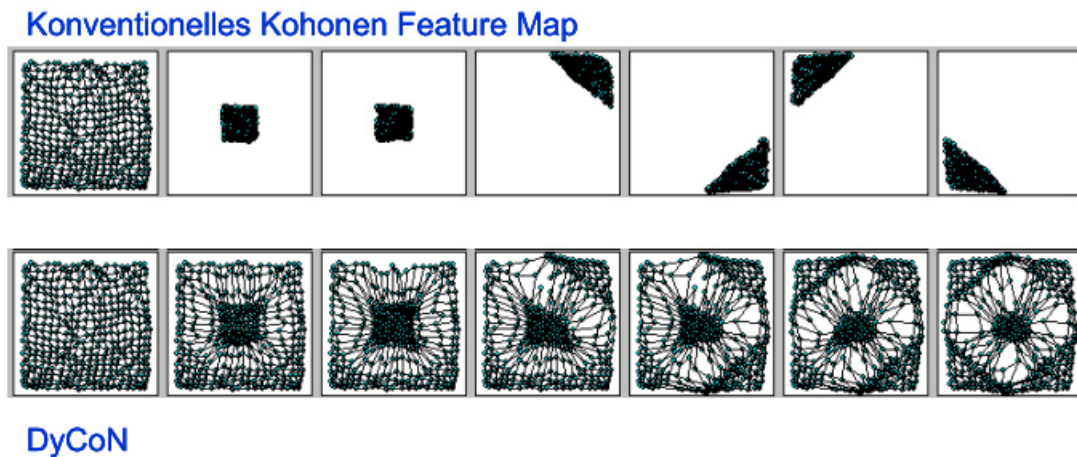


Abbildung 26. : Vergleich des Lernverhaltens von SOMs mit und ohne LeiPot (Perl, 2002, S. 258).

Negativer Effekt der reduzierten Wirkung der Trainingsreize ist, dass eine deutlich längere Zeit für die Erlernung einer Grundstruktur in Kauf genommen werden muss. Neue Muster können dann mit vergleichsweise geringem Lernaufwand zur vorhandene Grundstruktur hinzugelert werden (300 – 500 Trainingsschritte) (Perl, 2002, S. 255-256).

Wie [...] versucht wurde, deutlich zu machen, ist DYCON in der Lage, die spezifische Fähigkeit von Kohonen Feature Maps – d.h. die variable Clusteranalyse mit Selbsterkennung der Auffälligkeiten ohne Vorgabe der auffälligen oder erwarteten Kategorien – um die Fähigkeiten des kontinuierlichen (Weiter-) Lernens mit geringen Datenumfängen, des konkurrierenden Lernens mit atrophischer Reduktion und des Über-Lernens mit Löschung bei zu hoher Lernintensität zu ergänzen (Perl, 2002, S. 265).

### FANN

Die Software-Bibliothek FANN (Fast Artificial Neural Network) ist eine kostenlose quelloffene Bibliothek zur Erstellung von mehrschichtigen Künstlichen Neuronalen Netzen. Das Framework ist in C programmiert und stellt unterschiedliche Netztypen und Lernalgorithmen zur Verfügung. Ursprünglich wurde die Bibliothek für die Bildverarbeitung von Robotern im Kontext einer Studienarbeit von Nissen (2003) entwickelt. Historisch bedingt ist die Bibliothek im Hinblick auf die Geschwindigkeit insbesondere während der Klassifizierung optimiert. Die bereitgestellten Netztypen und Lernregeln sind besonders geeignet für das Klassifizieren von Mustern. Um

dennoch ein breites Anwendungsfeld zu gewährleisten, kann die Topologie der Netze vielfältig modifiziert werden. Die Bibliothek verfügt über Netze mit klassischer Topologie, bei denen alle Neurone einer Schicht mit Neuronen der nächsten Schicht verbunden sind (vollvernetzt). Ebenso werden Topologien zur Auswahl gestellt, bei denen nur eine Teilvernetzung gegeben ist oder Neurone über Schichten hinweg vernetzt sein können. Die Netze können mit versteckten Ebenen versehen werden. Die Bibliothek verfügt über sechs Aktivierungsfunktionen:

- lineare Aktivierungsfunktion (Kapitel 2.4.1.1)
- binäre Aktivierungsfunktion (Kapitel 2.4.1.1)
- Sigmoidfunktion (Kapitel 2.4.1.1)
- Gaußfunktion (Bishop, 2010)
- Elliot Sigmoidfunktion (Nissen, 2003)
- Sinus und Cosinus Aktivierungsfunktion (Bishop, 2010)

Da die Bibliothek von Beginn an darauf ausgelegt war auch Hidden Layers zu unterstützen, wurde der Backpropagation-Algorithmus (Kapitel 2.4.1.1) implementiert. Der Algorithmus kann so eingestellt werden, dass eine Anpassung der Gewichte entweder nach jedem Trainingsdatensatz oder aber nach einem kompletten Training mit mehreren Datensätzen erfolgt. In späteren Versionen (aktuell 2.2.0) wurden weitere Lernalgorithmen, die Erweiterungen bzw. Modifikationen der Backpropagation Regel darstellen, in die Bibliothek aufgenommen.

- Resilient Backpropagation
- Quick Propagation
- Simulated annealing resilient propagation

Das Training kann klassisch auf einem Netz erfolgen, dessen Topologie durch den Benutzer vorab festgelegt wurde. Die Modifikation des Netzes erfolgt dann in der in Kapitel 2.4.1.1 beschriebenen Weise. Vom Benutzer kann auch ein quasi leeres Netz erstellt werden, in welchem die Anzahl der Neuronen in der Input- und Output-Ebene definiert werden. Durch ein sogenanntes kaskadierendes Training werden dem Netz Hidden Layers mit entsprechenden Neuronen und Verbindungen hinzugefügt. Die Topologie des Netzes soll so bestmöglich lösungsorientiert angepasst werden.

### 2.4.1.3 Anwendungen Künstlicher Neuronaler Netze im Kontext von Sport- und Alltagsbewegungen

Die Einsatzmöglichkeiten der Modellierung mit Künstlichen Neuronalen Netzen erstreckt sich über nahezu alle Wissenschaftsbereiche im Sport. Mit der Wiederentdeckung der KNNs nach dem sogenannten „neural Winter“ Mitte der achtziger Jahre, befördert durch die Arbeiten von McClelland und Rumelhart (1986) zu mehrschichtigen Netztopologien und Teuvo Kohonen zu unterschiedlichen Netztypen der Kohonen-Netze (Kohonen, 1982, 1990), nahm auch die Anwendung dieser Methoden in der Sportwissenschaft zu (Fuchs & Lames, 1990; Schlicht, 1988; Schöllhorn, 1993; Schöllhorn, Jäger & Janssen D., 2008).

Mester und Perl adaptierten auf der Basis von Self Organizing Maps bestehende Netztopologien an die Anforderungen sportwissenschaftlicher Fragestellungen (Mester & Perl, 2000). Mester und Perl (2000) analysierten mit dem Framework DyCoN u.a. spielerpezifische Prozesse beim Squash, indem durch um LeiPots erweiterte SOMs mit 1000 – 2000 generierten Positionsfolgen trainiert wurden. Auf Grund des Einsatzes der LeiPots wurde durch das erneute Training auf ein bereits bestehendes Muster das Verlernen bereits vorhandenen Wissens vermieden. Einerseits konnte dadurch die Lernzeit für neue Muster reduziert werden, andererseits wurde gerade bei Taktikanalysen über den Spielzeitverlauf eine zeitliche Auflösung von Änderungen der Taktik eines Spielers nachvollziehbar. Auf die vorstrukturierten Netze konnte eine spielerpezifische Positionsfolge durch das Training mit 300 – 500 Datensätzen aufgeprägt werden. Abbildung 27 zeigt das Spielmuster eines Spielers A im Vergleich zu unterschiedlichen Gegnern im Halbfinale und Finale eines internationalen Squashturniers.

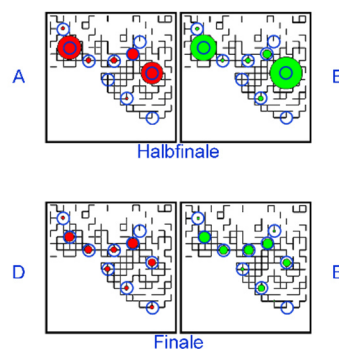


Abbildung 27. Positionsfolgen eines Spielers (B) im Vergleich über zwei Spiele mit unterschiedlichen Gegnern (A & D) modelliert mit DyCoN. (Perl, 2002, S. 261).



Aus den sich für beide Spiele ergebenden unterschiedlichen Spielmustern schlussfolgerte der Autor, dass sich die Grundmuster der Positionsfolgen zwischen allen Spielern kaum unterschieden. Jedoch die Häufigkeit der Positionsfolgen wurde durch das Entstehen einer Spielrhythmik zwischen zwei Spieler geprägt und hing weniger von der Dominanz eines Spielers ab (Perl, 2002). Auf Basis der durch das KNN gewonnenen Erkenntnisse schlägt Perl einen Einsatz DyCoNs für die Strukturanalyse und Überwachung von Prozessen, sowie die Optimierung von Trainingsprozessen vor. Zwischenzeitlich wurden die Ansätze von Perl weiterentwickelt und haben in der Steuerung und Optimierung von Belastungsprofilen im Radsport (Perl, 2009), in der Optimierung von Trainingsprozessen im Schwimmsport (Pfeiffer, Hohmann & Fuhrmann, 2012), der Analyse von Prozessmustern z.B. in der Ganganalyse und der Technikanalyse (Perl, 2008, S. 297; Schmidt, 2012) zum Erkenntnisgewinn beigetragen.

Frühe Arbeiten zur Verwendung von KNNs in der klinischen Biomechanik gab es 1993 von Holzreiter und Kohle. Sie verwendeten ein Feed-Forward Netz mit einem Hidden Layer und sigmoider Aktivierungsfunktion. Die Modifikation der Gewichte erfolgte mit dem Backpropagation Algorithmus (McClelland & Rumelhart, 1986). Sie nutzten das KNN für einen Mustervergleich der vertikalen Bodenreaktionskraft und klassifizierten hierüber gesunden und pathologischen Gang unterschiedlicher Genese (Kalkaneusfrakturen, Prothesen u.a.) bei 225 Testpersonen (94 gesunde und 131 kranke Personen). Insgesamt standen 8173 Gangzyklen für die Analyse zur Verfügung. Wie in Abbildung 28 zu sehen, fanden die Autoren eine maximale Generalisierungsfähigkeit des Netzes bei einem Training mit 80 % der zur Verfügung stehenden Daten.




Abbildung 28. Abhängigkeit der Generalisierungsfähigkeit von der Menge der Trainingsdaten. Die Ordinate zeigt den Quotienten der richtigen Gruppenzuordnung im Test Set. (Holzreiter & Kohle, 1993, S. 648).

Mit ihrer Methode konnten bis zu 95 % der neuen Datensätze richtig klassifiziert werden. Bezüglich der Abbildungsqualität des Netzes stellten sie fest, dass identisch ablaufende Trainingsiterationen aufgrund der initial zufällig gewählten Gewichte der Neuronenverbindungen, inhomogen erfolgreich verlaufen (Holzreiter & Kohle, 1993).

Gioftsos und Grieve (1995) verglichen in ihrer Arbeit Künstliche Neuronale Netze mit der linearen Diskriminanzanalyse zur Klassifikation von Pathologien beim Gehen und Gehgeschwindigkeiten in der Ganganalyse. Bei 20 Testpersonen (10 Frauen, 10 Männer) wurden bei sieben Gehgeschwindigkeiten, die nach der Formel

$$Faktor_{1-7} \cdot Körpergröße \cdot s^{-1}$$

berechnet wurden, unter drei Bedingungen (normales Gehen, Gehen mit 3,5 kg Masse am rechten Knöchel, Gehen mit fixiertem Kniegelenk rechts) die Schrittzeiten für das rechte und das linke Bein, sowie die Dauer der Doppelschrittzyklen aufgezeichnet. Rekursive Netze mit einem Hidden-Layer wurden mit Daten von fünf Frauen und fünf Männern trainiert. Unterschiedliche Topologien wurden für die Erkennung der Gehgeschwindigkeit bei gegebener Bedingung (drei Ebenen, drei Input-Units, neun Hidden-Units, sieben Output-Units), Erkennung der Bedingung bei gegebener Geschwindigkeit (drei Ebenen, vier Input-Units, neun Hidden-Units, drei Output-Units) und der Erkennung der Bedingung über alle Geschwindigkeiten (drei Ebenen, 21 Input-Units, neun Hidden-Units, drei Output-Units) verwendet. Die Topologie wurde aus unterschiedlich konstruierten Netzen auf Basis der besten Klassifikationsrate ausgewählt. Die Ergebnisse der Studie ließen keinen eindeutigen Schluss bezüglich der besseren Eignung einer Methode für das untersuchte Problem zu. Die Anzahl der erfolgreichen Klassifizierungen für Trainingsdaten mit KNNs zeigten bessere Werte als bei der Diskriminanzanalyse. Die Autoren schlussfolgerten jedoch, dass die Anzahl der zum Training zur Verfügung gestandenen Datensätze zu gering war, wodurch das Netz durch ein Übertraining eine geringe Generalisierungsfähigkeit aufwies. Testdaten konnten deshalb mit den KNNs nur geringfügig besser erkannt werden als mit der Diskriminanzanalyse (Gioftsos & Grieve, 1995). Gioftsos und Grieve sahen in den Ergebnisse aber eine Bestätigung der Annahme, dass sich KNNs sowohl auf Grund ihrer gegenüber einer Diskriminanzanalyse höheren Performanz, als auch der mit der Diskriminanzanalyse vergleichbaren Klassifizierungsrate, für die Unterscheidung von

Bewegungsmustern im klinischen Alltag eignen. Dies sollte in weiteren Studien mit entsprechend höherer Anzahl an Probanden gezeigt werden.

Schöllhorn, Nigg, Stefanyshyn und Liu (2002) untersuchten bei 13 Frauen mittleren Alters (40,3 Jahre  $\pm$  8,3 Jahre) die kinematischen und kinetischen Muster beim Gehen mit Absatzschuhen unterschiedlicher Höhe (14, 37, 54 und 85 mm). Alle Frauen waren an das Tragen hoher Schuhe gewöhnt. Für alle Testpersonen wurden für jede Kondition mindestens zwei Versuche, die in die Auswertung mit einbezogen wurden, mit einer kontrollierten Gehgeschwindigkeit (Lichtschranken) von  $1,4 \text{ ms}^{-1}$  mit einem Motion Analysis System mit vier Kameras und einer Kistler Kraftmessplatte aufgezeichnet. Insgesamt wurden 149 Versuche über alle Konditionen analysiert. Für den Zeitverlauf jeder Variable wurden sechs diskrete Werte berechnet (Schöllhorn et al., 2002, S. 181). Alle Variablen wurden, über eine Kondition hinweg zusammengefasst, über einen 21-dimensionalen Vektor repräsentiert. Einzelne Matrizen des Vektors wurden durch Summation zusammengefasst und als ganzheitliches Maß für die Ähnlichkeit genutzt (time discrete data set). Zusätzlich wurden SOMs mit einem 3D-Output-Layer trainiert. Die Output-Layer wurden Clusteranalysen unterzogen, die die Abstandsmatrix im Hinblick auf 1. Reihenfolge der Ähnlichkeiten der Versuche untereinander; 2. Gruppierung über die Zeitreihen der Kinematik, der Gelenkmomente und der Bodenreaktionskraft; 3. Gruppierung über die Variablen in der Sagittal- und Frontalebene (Schöllhorn et al., 2002, S. 183), sowie 4. Gruppierung über die Absatzhöhen und Kombinationen der Absatzhöhen (time continuous data set). Beide Verfahren konnten, wenn sie jeweils über die Versuche mit einer Absatzhöhe angewendet wurden, persönliche Gangmuster mit annähernd 100 % klassifizieren. Beim Ansatz mit diskreten Daten gab es, bezüglich der Erkennungswahrscheinlichkeit, nur geringe Unterschiede zwischen der Klassifizierung über alle Variablen hinweg zur Klassifizierung mit der Variablen, die die Minima aller Variablen enthielt. Eine Abnahme der Klassifizierung wurde festgestellt, wenn die Anzahl der Parameter reduziert wurde und/oder die Anzahl der Konditionen (Absatzhöhe) vergrößert wurde. Für den Ansatz mit kontinuierlichen Daten konnte die beste Klassifikationsrate erreicht werden, wenn alle Variablen verwendet wurden oder wenn die Variablen über die frontale Ebene (Schöllhorn et al., 2002, S. 182) präsentiert wurden. Über beide Methoden erreichten die Autoren eine Klassifikationsrate der Probanden von 93,1 % – 100 % für jede der Bedingungen Absatzhöhe. Auf Grund der Ergebnisse

sehen es die Autoren als erwiesen, dass die Muster beim Gehen stark individuell geprägt sind. Bereits die Kinematik der unteren Extremitäten scheint für die Erkennung von Personen auf Basis der Muster beim Gehen hinreichend. Inwieweit die Parameter koordinative Muster oder anthropometrische Verhältnisse des Beines, oder eine Kombination aus beiden, die Information der Individualität enthielten, konnten die Autoren nicht bestimmen und regen weitere Untersuchungen dazu an. Zusammenfassend stellten die Autoren fest, dass sich die Klassifikation über den kontinuierlichen Ansatz als zuverlässiger herausstellte, da mit diesem Ansatz Muster über alle Absatzhöhen bis einschließlich 54 mm mit einer Rate von annähernd 100 % zugeordnet werden konnten. Eine ähnlich gute Erkennungsrate war mit dem diskreten Ansatz nur über jeweils eine Absatzhöhe möglich (Schöllhorn et al., 2002).

Zu vergleichbaren Ergebnissen kamen Janssen et al. (2008), die Emotionen auf Basis kinematischer und kinetischer Daten beim Gehen klassifizierten. Sie untersuchten in zwei Studien die Erkennung von Personen und die Klassifizierung von Emotionen (normal, glücklich, traurig, ärgerlich) über kinematische und kinetische Daten. In Studie 1 wurden die kinetischen Daten von 22 Personen analysiert. Die Emotionen wurden von den Probanden auf Ansage simuliert. Die zeitnormalisierten Daten jedes Probanden wurden über die Differenz zum Mittelwert über alle Probanden individualisiert. Zur Klassifizierung der Personen wurden Multi Layer Perceptrons (McClelland & Rumelhart, 1986) mit einer Dimension von  $200 \times 111 \times 22$  Neuronen verwendet. Für die Erkennung der Emotion wurden diskrete und kontinuierliche Daten mit einer Self Organizing Map (Output-Ebene mit  $5 \times 3$  Neuronen) gruppiert. Die Ergebnisse zeigten wie bei Schöllhorn et al. (2002), dass mit kontinuierlichen Daten die Muster mit einer höheren Wahrscheinlichkeit zugeordnet werden konnten. Die Zuordnung des emotionalen Zustandes konnte über die diskreten Daten mit 80,8 % richtig erfolgen. Bei der Klassifizierung über die kontinuierlichen Daten konnte die Rate auf 83,7 % erhöht werden. Die Erkennungsrate der Personen lag bei 95,3 %. In Studie 2 wurden die kinematischen und kinetischen Daten von 16 Personen beim Gehen mit beruhigender (80 Schläge pro Minute / bpm) und erregender (130 bpm) Musik erfasst. Zur Erfassung der Kinematik wurden die Probanden mit zwei orthogonal zueinander ausgerichteten Videokameras mit einer Frequenz von 25 Hz gefilmt. Die Winkel und Winkelgeschwindigkeiten von Arm, Hüfte, Knie und Sprunggelenk wurden

in drei Dimensionen berechnet. Für jeden Probanden wurden Daten von drei Doppelschrittzyklen pro Kondition (Musik) aufgezeichnet. Die Videodaten wurden manuell digitalisiert. Die Erkennungsrate der Personen über die kinetischen Daten mit dem MLP betrug 99,3 %. Die Erkennungsrate über die kinematischen Daten war mit 96,9 % etwas höher. Der Erregungszustand ausgelöst durch anregende oder beruhigende Musik konnte auf Basis der kinetischen Daten intra-individuell mit 77,8 % im Durchschnitt über alle Probanden (N=38) zugeordnet werden. Eine Klassifizierung über die kinematischen Daten erfolgte intra-individuell mit 73,0 %. Die Erkennung der Person auf Basis der kinetischen Daten aus beiden Experimenten erfolgte mit 98,5 %. Eine Zuordnung des Erregungszustands war inter-individuell nicht möglich, was die Autoren auf die Dominanz des individuellen Gangmusters zurückführten.

Lamb, Mündermann, Bartlett und Robins (2011) verglichen in einer Studie die Auswirkungen von Fußorthesen auf die koordinativen Muster beim Rennen ( $4,0 \pm 0,2 \text{ ms}^{-1}$ ) mit Self Organizing Maps. Die kinematischen und kinetischen Daten von zwanzig Probanden wurden in neun Testungen über drei Wochen bei eingeschränkter und unterstützter Beweglichkeit des Sprunggelenks mit einem Infrarot Kamerasystem mit sieben Kameras (Motion Analysis; Frequenz: 240 Hz) und einer Kraftmessplatte (Kistler; Frequenz: 2400 Hz) aufgezeichnet. Die Autoren fanden für alle Probanden Änderungen in den koordinativen Mustern zwischen den Konditionen. Bei den meisten Testpersonen zeigten sich ähnliche systematische Änderungen der Muster, die auf Basis einer U-Matrix (unified distance matrix) qualitativ miteinander verglichen wurden und exemplarisch an einem Probanden aufgezeigt wurden. Die Autoren waren in der Lage, mit einer neuen Methode der Visualisierung, die komplexen Änderungen der hochdimensionalen kinematischen Muster im niedrig dimensionalen Raum übersichtlich darzustellen und Änderungen, die mit herkömmlichen Methoden nicht ersichtlich waren, aufzuzeigen. Im Hinblick auf die kinetischen Muster konnten jedoch keine Änderungen festgestellt werden.

Pradhan et al. (2015) untersuchten Patienten mit phobischem Schwankschwindel (N=30), zerebellärer Ataxie (N=30), progressive supranukleäre Blickparese (N=30), bilateraler Vestibulopathie (N=30) und gesunde Personen (N=30) beim Gehen über einen instrumentierten Bodenbelag der Firma GAITRite® (Frequenz: 120Hz). Die Probanden wurden zufällig auf zwei Gruppen aufgeteilt, deren Daten für das Training,

bzw. die Klassifikation mit einem k-nearest Neighbour Modell (kNNM, Coomans & Massart, 1982), einem Bayes Klassifikator (Domingos & Pazzani, 1997), einem KNN (Bishop, 2010) und einer Support Vector Machine (Schölkopf & Smola, 2002) verwendet wurden. Die Probanden gingen für die Datenaquise eine Strecke von 6,7 m bei einer frei gewählten Geschwindigkeit, einer langsamen Geschwindigkeit und der schnellstmöglichen Geschwindigkeit, bei einer frei gewählten Geschwindigkeit mit geschlossenen Augen, mit nach hinten geneigtem Kopf, sowie dem Ausführen von Dual-Task Aufgaben. Für das Training der Modelle wurden Trainingsvektoren mit 136 diskreten Werten für 75 Probanden erstellt. Die Validierung der Erkennungsleistung der Modelle erfolgte über die Vektoren der verbleibenden 75 Probanden.

Die Validierung der Modelle erfolgte mittels zehnfacher Kreuzvalidierung über die Parameter Sensitivität ( $\text{Sensitivity} = (\text{true positives} / (\text{true positives} + \text{false negatives})) * 100$ ) und Spezifität ( $\text{Specificity} = (\text{true negatives} / (\text{true negatives} + \text{false positives})) * 100$ ) (Pradhan et al., 2015, S. 416).

*Tabelle 4.* Ergebnisse der zehnfachen Kreuzvalidierung zur Klassifizierungsleistung (Pradhan et al., 2015, S. 419).

<b>Klassifikator</b>	<b>ANN</b>	<b>SVM</b>	<b>kNNM</b>	<b>NB</b>
<b>Sensitivität</b>	90.9 ± 1.4	92.3 ± 1.7	72.8 ± 4.9	79.7 ± 10.9
<b>Spezifität</b>	96.1 ± 2.5	97 ± 1.9	92.3 ± 6.5	93.8 ± 2.8

Bei der Klassifikation des Krankheitsbildes zeigten das KNN und die Support Vector Machine die besten Ergebnisse (Tabelle 4). Die Autoren schlussfolgerten, dass in Übereinstimmung mit früheren Befunden, KNNs und Support Vector Machines im Gegensatz zu den anderen geprüften Modellen dafür geeignet sind, Daten von Patienten mit Gangstörungen zuverlässig zu klassifizieren, da sie besonders für die Verwendung mit räumlich-zeitlichen Parametern geeignet scheinen (Pradhan et al., 2015).

#### *2.4.1.4 Kritische Würdigung Künstlicher Neuronaler Netze*

Künstliche Neuronale Netze zur Modellierung von Lokotionsbewegungen lassen sich in Bezug auf Kapitel 2.4.1.1 in zwei Klassen unterteilen. Modelle, bei denen deterministische Modellstrukturen zum Einsatz gebracht werden, setzen vorhandenes Wissen über die Strukturen der beobachteten Bewegung und die Systemdynamik voraus. Sie verfolgen einen theoriegeleiteten Ansatz und eignen sich in erster Linie

zur Überprüfung bestehender Annahmen durch die Klassifizierung unbekannter Datensätze. Datengeleitete Modellansätze stehen hierzu im Gegensatz und setzen wenig bis kein Wissen über die Strukturen innerhalb von Daten voraus. Durch „weiche“ Strukturen (Soft Computing), die oftmals biologisch inspiriert stochastische Einflussgrößen berücksichtigen, werden Modelle auf Basis von Daten generiert, die Rückschlüsse auf den Zusammenhang von Eingangsvektoren und Klassifikationsergebnissen zulassen (Lamb & Bartlett, 2013). Dieser Ansatz scheint im Hinblick auf das Generieren von Wissen über die multidimensionalen Zusammenhänge beim Gehen und Rennen auf der Basis kinematischer, aber auch kinetischer und elektromyografischer Daten, geeignet. Über alle in Kapitel 2.4.1.3 beschriebenen Studien hinweg zeigt sich, dass KNNs insbesondere für ein Übertraining empfindlich sind und die Anzahl der Trainingsiterationen starken Einfluss auf das Ergebnis der Klassifikation unbekannter Daten hat. Durch die Fähigkeit der unterschiedlichen Netztypen, hochdimensionale Daten in niedrigdimensionale Räume zu transferieren, zeigen KNNs eine hohe Performanz. Der aufgezeigte Forschungsstand verdeutlicht, dass zahlreiche Studien die Eignung von KNNs für die Abbildung menschlicher Bewegungen im Allgemeinen und von Lokomotionsbewegungen im Speziellen nachweisen konnten. Dies gilt insbesondere für die datengeleiteten Ansätze im Kontext der Modellierung systemdynamischer Zusammenhänge, die nach wie vor weitgehend unbekannt sind (Mombaur, 2015).

## 2.4.2 Support Vector Machines

### 2.4.2.1 Grundlagen Support Vector Machines

Support Vector Machines sind mathematische Verfahren zur Klassifikation und zur Erkennung von Mustern. Als sogenannter Large Margin Classifier sind sie bestrebt zwischen zwei Datenmengen eine Trennung zu vollziehen, die größtmöglichen Abstand zu beiden Datenmengen hat. Durch dieses Verfahren der Klassifikation vermeidet die Support Vector Machine (SVM) im Gegensatz zu herkömmlichen KNNs bereits systemisch eine Überanpassung und erhält eine große Generalisierungsfähigkeit im Hinblick auf die Klassifikation von neuen, nicht beim Training verwendeten Daten (Abbildung 29, Schölkopf & Smola, 2002).




Abbildung 29. Unterbestimmte (a), überbestimmte (b) und richtig bestimmte (c) Trennebene eines Klassifikators.

### Lineare Trennung

Zahlreiche Klassifikatoren trennen Daten, die linear separierbar sind mit sogenannten Hyperebenen, die über einen Stützvektor und, entsprechend der Anzahl der Dimensionen der Daten ( $\eta$ ), über  $\eta - 1$  Richtungsvektoren verfügen. Im zweidimensionalen Raum stellt eine Gerade eine Hyperebene dar und im dreidimensionalen Raum werden Datenmengen durch eine Ebene getrennt. Da es jeweils unendliche viele Möglichkeiten gibt eine Hyperebene zu definieren, kommt es bei zahlreichen Klassifikatoren zu dem Phänomen, dass die Trainingsdaten zwar eindeutig getrennt werden können, die Auswahl der Hyperebene aber zu einer eingeschränkten Generalisierungsfähigkeit führt. Bei der Beurteilung neuer Daten kann es somit zu einer falschen Klassifizierung kommen. Die SVM nutzt zur Optimierung der Hyperebene Stützvektoren (Support Vectors), die einen maximalen Abstand der Trennebene zu den Trainingsdaten gewährleisten (Abbildung 30).




Abbildung 30. Beliebige Klassifikation von Trainingsdaten (a), falsche Klassifikation mit beliebig gewählter Hyperebene (b) und erfolgreiche Klassifikation durch Hyperebene mit Stützvektoren (c).



Die SVMs finden durch dieses Verfahren für linear trennbare Daten eine optimale Trennebene, die von beiden Datenmengen den gleichen Abstand hat. Die Definition der Hyperebene erfolgt über die Trainingsmuster, die den geringsten Abstand zur Trennlinie haben. „Damit verlieren zusätzliche Muster, die irgendwo in der Ferne von der Grenzfläche hinzugefügt werden, ihren Einfluss auf die Lösung“ (Heinert, 2010, S. 181). Es kann aber auch bei grundsätzlich linear trennbaren Daten auf Grund von z.B. Messfehlern dazu kommen, dass sich diese für die SVM als nicht linear trennbar darstellen. Für diesen Fall verfügt die SVM über eine Schlupfvariable, die eine Fehlklassifizierung von Trainingsdaten bis zu einem zu definierenden Grad toleriert. Dieses Verfahren dient dazu eine Überbestimmung zu vermeiden und eine möglichst hohe Generalisierungsfähigkeit der SVM zu gewährleisten (Bishop, 2010).

### *Nicht lineare Trennung*

Die lineare Trennbarkeit von Trainingsdaten stellt in der Regel einen Sonderfall dar. Bereits einfache Probleme lassen sich häufig nur nichtlinear lösen. Das bekannteste Beispiel stellt das XOR-Problem dar (Abbildung 31). Den zweidimensionalen Wertepaaren (0,0) und (1,1) wird ein Ausgabewert von 0 und den Wertepaaren (0,1) und (1,0) ein Ausgabewert von 1 zugewiesen. Diese sollen in einem zweidimensionalen kartesischen System linear voneinander getrennt werden.




Abbildung 31. Das XOR-Problem in der Ebene – nicht lösbar (XOR=OR but NOT AND).

Diese Aufgabe ist auf Grund der Anordnung der Datenpaare in der Ebene nicht lösbar. Um die Daten doch linear voneinander separieren zu können, müssen die Daten in einem mindestens dreidimensionalen Raum erneut angeordnet werden (Abbildung 32). Der ursprüngliche Zustandsraum wird demnach verlassen und mit Hilfe von Funktionsparametern werden die Daten in einen höherdimensionalen Raum transferiert, in dem eine lineare Trennung erfolgen kann.




Abbildung 32. Das XOR-Problem im dreidimensionalen Raum - lösbar.

Durch Rücktransformation in den ursprünglichen Zustandsraum stellt sich die lineare Hyperebene gegebenenfalls nicht linear dar, bzw. kann sogar nicht zusammenhängende Hyperflächen bilden, die die Trainingsdaten mit den gleichen Eigenschaften trennen wie bei der zuvor beschriebenen linearen Trennung (Abbildung 33).




Abbildung 33. Das XOR-Problem mit Hyperebene nach der Transformation in den höherdimensionalen Raum.

Diese Methode basiert auf dem sogenannten Kernel-Trick (Schölkopf & Smola, 2002). Kernel-Funktionen beschreiben den höherdimensionalen Raum. Der Feature Space, der Raum, in dem die Hyperebene linear trennt, bleibt unbekannt. Die Kernel-Funktion gibt lediglich eine geometrische Interpretation der Hyperebene zurück. Eine wirkliche Transformation, die, abhängig von der Dimensionalität des Feature Space, sehr rechenintensiv und zeitaufwendig sein kann, entfällt. „Der Satz von Mercer besagt vereinfacht, dass eine Hyperebene im Raum höherer Ordnung einen Repräsentanten im ursprünglichen Datenraum besitzt: nämlich eine stetige, symmetrische, positiv definite Kernel-Funktion  $K(x, x')$ “ (Heinert, 2010, S. 180; Mercer, 1909).

### *Kernel-Funktion*

Eine Erläuterung der einzelnen Kernel-Funktionen würde den Rahmen dieser Arbeit sprengen. Die Kernel-Funktionen stellen die Vorschrift dar, nach der die Transformation in einen höherdimensionalen Raum vollzogen wird. Für die Support Vector Machines handelt es sich hierbei in der Regel um die *lineare Kernel-Funktion*, die *polynomiale Kernel-Funktion* oder um den *Radial Basis Function Kernel* (RBF/gaußsche Kernel-Funktion). Eine ausführliche Beschreibung der Kernel-Funktionen findet sich in *Kernel methods in computational biology* (Schölkopf, Vert & Tsuda, 2004).

#### *2.4.2.2 Anwendungen von SVMs im Kontext von Sport- und Alltagsbewegungen*

Support Vector Machines werden noch nicht lange für die Analyse von Bewegungen verwendet. In den vergangenen 8-10 Jahren hat sich das Verfahren etabliert und wird von verschiedenen Gruppen für die Mustererkennung eingesetzt. Einige Studien (Lu & Zhang, 2007; Lu, Zong, Xing & Bao, 2014; Yoo, Hwang & Nixon, 2005) untersuchen die Erkennung von Personen auf der Basis von Merkmalen, die direkt aus Videobildern extrahiert werden (Schrittlänge, Schritthöhe, Körpergröße u.a.). Die Ergebnisse dieser Untersuchungen stehen nicht in direktem Zusammenhang mit der Zielstellung dieser Arbeit, da dort die wissenschaftliche Herausforderung eher in der stabilen Extraktion der Merkmale aus unterschiedlichen Blickwinkeln zu sehen ist, als in der Klassifikation der Personen. Die SVM dient im Kontext dieser Arbeiten als Methode zur Validierung der Extraktionsverfahren und nicht als Modell zur Abbildung menschlicher Bewegungsmuster, wie sie im Hinblick auf die Zielstellung dieser Arbeit untersucht werden. Aus diesem Grund werden diese Studien bei der Analyse des aktuellen Forschungsstands nicht aufgeführt.

Begg, Palaniswami und Owen (2005) klassifizierten auf Basis des minimalen Bodenabstands des Fußes während der Schwungphase (Minimum Foot Clearance / MFC) mit unterschiedlichen SVMs (linearer, polynomialer und RBF Kernel) den Gang von 30 jungen ( $28,4 \pm 6,4$  Jahre;  $171 \pm 12$  cm Körpergröße) und 28 älteren Personen ( $69,2 \pm 5,1$  Jahre;  $165 \pm 8$  cm Körpergröße). Die Probanden liefen bei selbstgewählter Geschwindigkeit für ca. 20 Minuten auf einem Laufband, während der Verlauf von zwei Zehenmarkern in der Sagittalebene mit einer Videokamera (Frequenz: 50Hz)

aufgezeichnet wurde. Aus den MFCs jedes Probanden wurden 24 Merkmale zur Beschreibung der statistischen Merkmale der MFCs extrahiert und für das Training und die Erkennung mit den SVMs verwendet. Zusätzlich wurde ein KNN trainiert. Entsprechend der Anzahl der Merkmale verfügte das KNN über 24 Input-Neuronen, einen Hidden-Layer und einen Output-Layer mit zwei Neuronen. Die SVM mit linearem Kernel zeigte mit einer Klassifikationsrate von 83,3 % ( $\pm 2,9$ ) die besten Ergebnisse. Ähnlich gute Ergebnisse zeigten sich auch mit RBF Kernel mit einer Klassifikationsrate von 81,7 % ( $\pm 2,9$ ). Im Gegensatz dazu zeigte die SVM mit polynomialen Kernel ( $61,4 \pm 28,4$ ) und das KNN ( $75 \pm 5$ ) deutlich schlechtere Erkennungsraten (Begg et al., 2005).

Die Autoren sahen auf Grund Ihrer Untersuchungsergebnisse einen großen Zusammenhang zwischen den Erkennungsraten und den gewählten Merkmalen, die zum Training und zum Test verwendet werden. Vergleichbar zu anderen Studien empfehlen sie die Verwendung einer geringen Anzahl von Merkmalen, die eine gute Trennung der Klassen zulassen. Zusätzliche Merkmale, die eine unschärfere Separation der Klassen zulassen, führen ihres Erachtens nach zu einer Abnahme der Güte des Modells.

Wu und Wang (2008) haben auf Basis einer Hauptkomponentenanalyse und unterschiedlicher SVMs ebenfalls den Gang von jüngeren und älteren Menschen klassifiziert. Die Bodenreaktionskräfte von 30 jungen gesunden Männern ( $27,5 \pm 5,3$  Jahre;  $172 \pm 5,4$  cm Körpergröße) und 30 älteren gesunden Männern ( $62,4 \pm 4,3$  Jahre;  $169 \pm 4,8$  cm Körpergröße) wurden mit einer Kraftmessplatte (Frequenz: 400 Hz) aufgezeichnet. Die Kraftdaten wurden über das Gewicht der Probanden und die Dauer der Standphase normiert. Mittels Hauptkomponentenanalyse (PCA) wurde eine Dimensionsreduktion im Sinne einer verbesserten Klassifikationsleistung vorgenommen. Die extrahierten Merkmale aller Probanden wurden jeweils zur Hälfte für das Training und für die Evaluation der Erkennungsleistung verwendet. Zur Absicherung der Ergebnisse kam ein Kreuzvalidierungsverfahren zum Einsatz. Die maximale Erkennungswahrscheinlichkeit für die getesteten SVMs lag auf Basis der mit der PCA extrahierten Merkmale bei 90 %. Die Autoren erreichten im Vergleich dazu auf den gleichen Daten mit einem Künstlichen Neuronalen Netz (Backpropagation) eine Klassifizierungsrate von nur 80 %. Im Gegensatz zur Studie von Begg et al. (2005) wurde die höchste Erkennungsrate mit polynomialen und RBF Kernel erreicht.

Wu und Krishnan (2010) untersuchten 16 gesunde (2 Männer, 14 Frauen;  $39,3 \pm 18,5$  Jahre) und 15 an Parkinson erkrankte Personen (10 Männer, 5 Frauen;  $66,8 \pm 10,9$  Jahre) beim Gehen. Die Daten wurden aus einer öffentlich zugänglichen Datenbank entnommen (PhysioBank Archive: [www.physionet.org](http://www.physionet.org)). Die Probanden gingen mit instrumentierten Schuhe (acht Kraftsensoren pro Schuh) jeweils für eine Dauer von fünf Minuten mit einer selbstgewählten Geschwindigkeit. Für die Klassifizierung der Muster wurden eine lineare Diskriminanzanalyse, sowie eine SVM verwendet. Für die Analyse der Variabilität der Muster beim Gehen wurden die Messdaten nach der von Hausdorff et al. (1997) vorgeschlagenen Methode vorverarbeitet. SVMs mit least square Kernel (Cortes & Vapnik, 1995), polynomialer Kernel-Funktionen und RBF Kernel-Funktion wurden mit den Merkmalsvektoren der Funktionsparameter  $\sigma_\tau$  und  $STC_\tau$  (Hausdorff et al., 1997) trainiert. Für die polynomiale Kernel-Funktion ergaben sich die besten Klassifikationsergebnisse von 90,32 %, die mittels leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) abgesichert wurden. Demgegenüber konnten mit der Diskriminanzanalyse lediglich 67,74 % der Merkmalsvektoren richtig klassifiziert werden. Die Autoren führten die unterschiedlichen Erkennungsleistungen darauf zurück, dass die Hyperebene der SVM eine bessere Trennung der Daten gewährleistete.

Janssen et al. (2011) klassifizierten mit Support Vector Machines und Künstlichen Neuronalen Netzen (SOMs) den Ermüdungszustand, sowie die Personen beim Gehen. Bei neun jungen Männern ( $25,9 \pm 3,14$  Jahre) wurden die Bodenreaktionskräfte beim Gehen mit einer selbstgewählten Geschwindigkeit aufgezeichnet. Die Probanden absolvierten sechs Versuche auf einer sieben Meter langen Teststrecke. Danach wurde eine komplette Ermüdung der Mm. Gastrocnemii und der Mm. Soleii herbeigeführt. Direkt nach der kompletten Ermüdung absolvierten die Probanden weitere sechs Versuche auf der Teststrecke. Nach einer dreiminütigen Pause ohne erneute Ermüdung wurden sechs weitere Versuche aufgezeichnet. Die Auswirkung der Ermüdung auf die Gangmuster wurde auf Basis ausgewählter diskreter Parameter (Giakas & Baltzopoulos, 1997) sichergestellt (Janssen et al., 2011, S. 969). Für die Klassifizierung der Personen und des Ermüdungszustands wurde eine nicht lineare SVM mit einem RBF-Kernel verwendet. Die Klassifizierung erfolgte über die Daten aus jeweils einem Versuch. Alle anderen Daten wurden für das Training der SVM

verwendet. Die Ergebnisse wurden mittels Kreuzvalidierung über alle Versuche abgesichert (162 Gangmuster). Für die Datenverarbeitung wurden zwei unterschiedliche Zugänge verwendet. Für eine SVM wurden die Zeitreihen aller Gangzyklen verwendet. Für die zweite SVM wurde für jeden Probanden ein repräsentativer Gangzyklus über die Mittelwertbildung aller Gangzyklen berechnet (signal approach). Als Eingangsvektor für die SVM wurde die Differenz zwischen repräsentativem Gangzyklus und Testgangzyklus gebildet (deviations approach). Die Klassifizierung der Personen konnte über die Zeitreihen (ohne Ermüdung) mit einer Wahrscheinlichkeit von 100 % erfolgen und über den deviations approach zeigte sich eine Klassifikationsrate von 65,7 %. Im Gegensatz hierzu steht die Klassifikation der Ermüdung, die über den signal approach eine Erkennungswahrscheinlichkeit von 96,3 % und über den deviations approach von 98,1 % erreichte (Janssen et al., 2011). Zusätzlich zur beschriebenen Klassifizierung verwendeten die Autoren Self Organizing Maps, um den Zustand der Ermüdung zu visualisieren. Sie stellten fest, dass sich die individuellen Muster der Probanden unter Ermüdung zeitweise so stark änderten, dass eine Abnahme der Erkennungsrate auf Grund sich überlappender Muster resultierte. Die Autoren schlussfolgerten, dass in Abhängigkeit der Vorverarbeitung der Rohdaten bereits viele konditionsspezifische Information der Daten verloren gehen (Janssen et al., 2011).


Fukuchi et al. (2011) verwendeten SVMs mit linearer, polynomialer und RBF Kernel-Funktionen zur Klassifikation des Gangs jüngerer und älterer Menschen auf Basis kinematischer Daten. 17 jüngere ( $31 \pm 6$  Jahre) und 17 ältere ( $69 \pm 2$  Jahre) Männer, die alle sportlich aktiv waren, wurden beim Rennen mit  $3,1 \text{ ms}^{-1}$  mit vier Videokameras (Frequenz: 120 Hz) gefilmt. Die Mittelwerte über fünf Versuche des rechten Knies und die Rückfußwinkel des rechten Beines wurden für die Berechnung von 31 Merkmalen für jeden Probanden verwendet. Die SVM mit linearer Kernel-Funktion zeigte mit 91 % die besten Klassifizierungsraten über alle 31 Merkmale. Mittels Forward Feature Selection Approach (Guyon & Elisseeff, 2003) konnte die beste Klassifizierung mit linearem Kernel bei sechs Merkmalen mit einer Wahrscheinlichkeit von 100 % erreicht werden. Ab einer Anzahl von 18 Merkmalen nahm die Erkennungswahrscheinlichkeit der SVM ab. 88,2 % der Erkennungswahrscheinlichkeit konnten mittels Forward Feature Selection über zwei Merkmale erklärt werden (Range of Motion of Kneeflexion, Kneeabduction Angle at Initial Contact), die offensichtlich die größte individuelle

Informationsdichte beinhalteten. Die Autoren schlussfolgerten, dass die Auswahl der Merkmale im Hinblick auf das Klassifikationsziel sorgfältig ausgewählt werden müssen, da Merkmale mit einer geringen Informationsdichte im Hinblick auf das Ziel der Klassifizierung zu einer Abnahme der Erkennungswahrscheinlichkeit führten (Fukuchi et al., 2011).

Horst et al. (2015) untersuchten die Gangmuster von 128 gesunden jungen Personen ( $23,8 \pm 9,1$  Jahre) beim Barfußgehen über eine Strecke von zehn Metern mittels Kraftmessplatte (Frequenz: 1000 Hz). Die Daten von jeweils einem Schrittzklus wurden über zehn Versuche aufgezeichnet, über die Masse des Probanden und die Zeit normalisiert. Die Kraft-Zeitverläufe wurden auf ein globales Minimum von 0 und ein globales Maximum von 1 skaliert. Die Daten aller Probanden wurden in einem Inputvektor ( $1280 \times 600$ ) zusammengefasst. Die Daten wurden einer linearen multi-klassen SVM (einer-gegen-alle Algorithmus) präsentiert. Die Autoren konnte 99,6 % aller Schrittzklen den richtigen Personen zuordnen. Die Ergebnisse wurden mittels leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) abgesichert. Die Autoren schlussfolgerten, dass die individuellen Muster beim Gehen selbst über eine große Anzahl von Mustern hinweg differenziert werden können. Dies unterstreicht den Autoren zufolge die Tatsache, dass in kinetischen Mustern des Gehens große Mengen an individuellen Informationen vorliegen. Horst et al. (2015) empfehlen, dass gerade in der Diagnostik und Therapie die Individualität der Muster berücksichtigt werden müssen.

Christian et al. (2016) untersuchten den Gang von sieben Männer ( $37 \pm 7$  Jahre;  $179 \pm 8$  cm Körpergröße;  $78 \pm 6$  kg Körpergewicht) mit akuter Läsion des vorderen Kreuzbandes (Versuchsgruppe) und sieben Männer ( $36 \pm 5$  Jahre;  $181 \pm 6$  cm Körpergröße;  $80 \pm 8$  kg Körpergewicht) ohne akute Beeinträchtigung des Gehvermögens. Die gesunden Probanden wurden über das Alter und den Body Mass Index (BMI) der Kontrollgruppe zugeordnet. Für die Datenerfassung wurden alle Probanden mit 14 reflektierenden Markern versehen und über eine Strecke von zehn Metern beim Gehen mit einer selbst gewählten Geschwindigkeit mit acht Infrarotkameras (Frequenz: 250 Hz) aufgezeichnet. Die Versuchsgruppe absolvierte jeweils morgens, vor einer physiotherapeutischen Maßnahme (Manuelle khalifa Therapie), und eine

Stunde nach der Intervention eine Ganganalyse. Die Datenerhebung der Kontrollgruppe fand einmalig statt. Die erfassten Daten wurden in Schrittzyklen segmentiert, geglättet (6Hz lowpass Filter) und über die Zeit normalisiert (101 Datenpunkte je Schrittzklus). Aus den vorverarbeiteten Daten wurde ein Datenvektor mit 4242 Dimensionen erstellt, der mittels PCA auf die Hauptkomponenten (PC) reduziert wurde. Diese wurden für das Training einer linearen SVM zur Klassifikation der beiden Gruppen verwendet. Die Klassifikationsleistung der SVM wurden mittels recursive feature elimination (Guyon & Elisseeff, 2006) über die Minimierung des Fehlers der Kreuzvalidierung optimiert. Die Erkennungsleistung der SVM wurde mittels leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) bestimmt. Für das Training der SVM wurden auf Basis der beschriebenen Methode zwei PCs ausgewählt, die zusammen 55,1 % der Varianz erklärten (47.5 % PC1; 7.6 % PC4). Auf Grund der Gewichtung dieser PCs durch die SVM konnten 46,6 % der Erkennungsleistung durch PC1 und 53,4 % der Erkennungsleistung durch PC4 erklärt werden. Die Ergebnisse der Klassifikation vor der therapeutischen Intervention zeigten eine Erkennungsrate von 100 % in Bezug auf die Gruppen. Wie in Abbildung 34 zu sehen, wurden nach der Intervention vier Probanden (57 %) mit Kreuzbandläsion als gesund klassifiziert.



*Abbildung 34.* Gangmuster im PC Merkmalsraum aufgespannt durch PC1 und PC4. Hole Symbole markieren individuelle Gangmuster der Referenzgruppe (Quadrate), der Patientengruppe zum Zeitpunkt des Pretests (Kreise) und der Patientengruppe zum Zeitpunkt des Posttests (Dreiecke). Gefüllte Symbole markieren die Mittelwerte der Bezugsgruppe. Die trennende Hyperebene ist als gestrichelte Linie dargestellt. Der Normalenvektor (Pfeil) der Hyperebene zeigt die Richtung der größten Trennbarkeit der Gruppen. Muster der Patientengruppe sind zum Vergleich ihrer Position zum Zeitpunkt des Pre- und Posttests nummeriert (Christian et al., 2016).

Die Autoren schlussfolgerten, dass SVMs, auch auf der Basis kleiner Trainingsdatensmengen, in der Lage sind Personen mit Läsionen des vorderen Kreuzbandes auf Grund der veränderten Kinematik des Ganges zu klassifizieren. In diesem Zusammenhang verwiesen sie insbesondere auf den Einfluss der Datenselektion für das Training der SVM. Ergänzend dazu sehen die Autoren die Tatsache, dass die



Definition der Trennebene der SVM wie in Kapitel 2.4.2.1 beschrieben erfolgt, als Schlüsselfaktor für die hohe Klassifikationsgüte bei kleinen Trainingsdatensätzen. Auf Grund der Ergebnisse der Klassifikation nach der therapeutischen Intervention beurteilten Christian et al. im Kontext der Annäherung der untersuchten Gruppen die therapeutische Maßnahme im Sinne einer Verbesserung der Leistungsfähigkeit der Patienten beim Gehen, als erfolgreich. Abschließend verweisen die Autoren darauf, dass trotz der eingeschränkten Validität der Studie auf Grund der geringen Probandenanzahl, die Ergebnisse vielversprechend sind und weitere Studien in vergleichbaren oder allgemeinerem Kontext notwendig sind (Christian et al., 2016).

#### *2.4.2.3 Kritische Würdigung von Support Vector Machines*

SVMs zeigen aufgrund der optimierten Methode zur Trennung von Datensätzen, wie sie in Kapitel 2.4.2.1 beschrieben ist, eine hohe Generalisierungsfähigkeit. Diese zeigt sich bei sorgfältig ausgewählten Eingangsvektoren, bereits nach dem Training des Modells mit einer geringen Anzahl von Trainingsdaten. Insbesondere die Tatsache, dass die trennende Hyperebene ausschließlich durch jene Vektoren bestimmt wird, die der Ebene am nächsten liegen, macht den Klassifikator unempfindlich gegenüber inhomogenen Datensätzen. Ergänzend wird ein Übertraining des Modells hierdurch quasi systemimmanent ausgeschlossen. Der Umstand, dass die SVM zeitabhängig diskrete Werte modelliert, macht eine Vorverarbeitung von Messdaten für die Klassifikation notwendig. Um insbesondere die Performanz des Modells bei großen Datensätzen, wie sie bei der Ganganalyse anfallen, zu gewährleisten, müssen segmentierte zeitnormalisierte Daten mittels eines geeigneten Verfahrens dimensionsreduziert (z.B. durch PCA) werden. Vor allem im Kontext der Anwendung im klinischen Alltag, könnte dies in Konflikt mit einer zeiteffizienten Untersuchungsplanung stehen. Zahlreiche Studien belegen, dass SVMs für die Klassifikation natürlicher Daten gute Ergebnisse aufweisen (Ng et al., 2011; Pradhan et al., 2015; Sudha & Bhavani, 2012; Yoo et al., 2005). Gerade im Bereich der Untersuchung menschlicher Lokomotionsbewegungen auf Basis kinematischer Kenngrößen aus videobasierten Systemen, wie sie in der biomechanischen Analyse Anwendung finden, weist der aktuelle Forschungsstand bislang Defizite auf.

## 2.4.3 Markov Modelle

### 2.4.3.1 Grundlagen der Markov Modelle

„Die einfachste Form der Markov-Modelle bilden die sogenannten *Markov-Ketten-Modelle*, die zur statistischen Beschreibung von Symbol- und Zustandsfolgen verwendet werden können“ (Fink, 2003, S. 15). Der Name geht zurück auf den russischen Mathematiker Andrij Andrejewitsch Markov, der die Modelle entwickelt hat. Markov Ketten berechnen Wahrscheinlichkeiten für das Eintreten eines Ereignisses in der Zukunft, auf der Basis von Gegenwart, Vergangenheit, oder einem zeitlichen Kontinuum. In Abhängigkeit der Grundmenge für die Berechnung der Wahrscheinlichkeiten werden Markov-Ketten unterschiedlicher Ordnung verwendet. Für eine Vorhersage aus der Gegenwart ist eine Kette erster Ordnung notwendig (Bishop, 2009).

#### *Diskrete Markov-Ketten*

Würde man z.B. einen Würfel immer wieder werfen und mit jedem Wurf notieren, wie oft welche Zahl geworfen wurde, entspräche die Abfolge der Zahlen einer diskreten unendlichen Markov-Kette. Unendlich, da der Würfel immer wieder geworfen werden würde, ohne dass ein Ziel erreicht wird. Diskret, da die Anzahl der Treffer für jede Ziffer zählbar ist. Die Wahrscheinlichkeit, dass eine bestimmte Zahl geworfen wird liegt bei  $1:0,166$  und wird als Übergangswahrscheinlichkeit eines Zustands (der zuletzt gewürfelten Zahl) in einen anderen Zustand (der nächsten gewürfelten Zahl) bezeichnet. Jede Ziffer des Würfels beschreibt einen Zustand, den der Würfel einnehmen kann. Hat man die eins gewürfelt, ergeben sich die in Abbildung 35 dargestellten Wahrscheinlichkeiten.

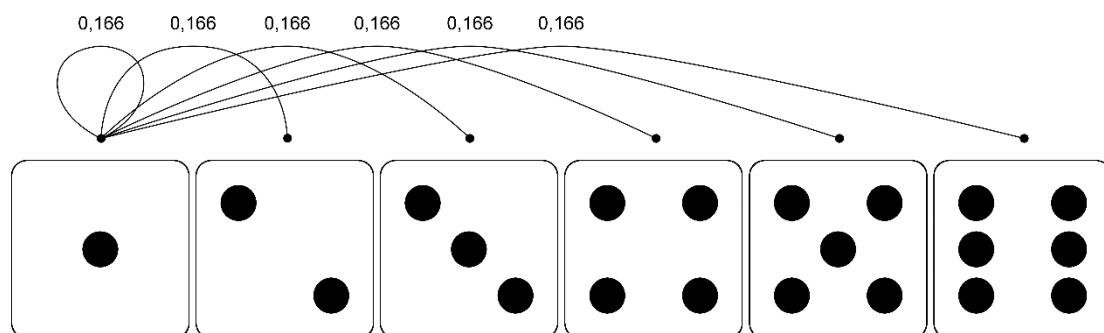


Abbildung 35. Übergangswahrscheinlichkeiten am Beispiel der Eins beim Würfeln.

Im Gegensatz dazu ist der Random Walk (symmetrische Irrfahrt) ein Beispiel für eine diskrete Markov-Kette in einem endlichen Zustandsraum (Abbildung 36). Er beschreibt die Fahrt eines Zuges, der in der Mitte der Strecke (Zustand 0) startet und sich zufällig nach rechts oder links bewegt. Auf der Strecke befinden sich rechts und links vom Start jeweils ein Bahnhof und die Zielbahnhöfe, die den endlichen Zustandsraum mit absorbierenden Zuständen beschreiben (Codling, Plank & Benhamou, 2008).




Abbildung 36. Übergangswahrscheinlichkeiten einer diskret endlicher Markov-Kette.

Beide Ansätze modellieren unterschiedliche Zustände, die ein System einnehmen kann, die Wahrscheinlichkeit vom aktuellen Zustand in einen anderen zu wechseln und welche Zustände in welcher Folge eingenommen werden können (Bishop, 2009).

### Hidden Markov Modelle

Im Gegensatz zu den Markov Ketten geht man bei Hidden Markov Modellen davon aus, dass die Zustände eines Systems verborgen und nicht beobachtbar/unbekannt sind. Nur die sogenannten Emissionen eines Zustands sind sichtbar und treten mit gewissen Wahrscheinlichkeiten auf.

HMMs sind stochastische Modelle  $\lambda = (S, \pi, A, B, V)$  zur Beschreibung von Zeitreihen mit  $N$  Zuständen  $S = \{s_1, \dots, s_N\}$ , initialen Zustandswahrscheinlichkeiten  $\pi = \{\pi_1, \dots, \pi_N\}$  und einer stochastischen Zustandsübergangsmatrix  $A = (a_{ij})$ , wobei  $a_{ij}$ , die Wahrscheinlichkeit eines Übergangs von Zustand  $s_i$  in Zustand  $s_j$  ist. Zusätzlich definieren die Beobachtungswahrscheinlichkeiten  $B = b_j(v_k)$  die Wahrscheinlichkeit  $v_k$  zu beobachten, solange man in Zustand  $s_j$  ist.  $v_k$  ist dabei aus dem Merkmalsraum  $V$ , der diskret oder kontinuierlich sein kann (Rabiner, 1989).

Bei der Modellierung mit HMMs sind drei Probleme von Interesse:

1. Berechnung der Wahrscheinlichkeit  $P(O|\lambda)$  für eine Beobachtungsfolge  $O$  und ein Modell  $\lambda$
2. Berechnung der wahrscheinlichsten Zustandsfolge  $Q = q_1q_2 \dots q_T$  mit  $q_t \in S$  für eine gegebene Beobachtungssequenz und ein HMM.

3. Anpassen der Modellparameter  $A, B$  und  $\pi$  von  $\lambda$ , um die Wahrscheinlichkeit  $P(O|\lambda)$  für eine gegebene Zustandssequenz zu erhöhen (Rabiner, 1989).

### Problem 1: Evaluation – Forward-Algorithmus

Bei einem gegebenen HMM  $\lambda$  und einer Beobachtungsfolge  $O$  (z.B. Gelenkwinkelverläufe von Gangzyklen) wird berechnet, wie wahrscheinlich es ist, dass das verwendete Modell mit seinem verborgenen Zustand  $s_i$  die Beobachtungssequenz repräsentiert. Dieses Problem kann als Evaluationsproblem bezeichnet werden, da bewertet wird, welches HMM aus einer Reihe unterschiedlich modellierter HMMs mit der größten Wahrscheinlichkeit die dargebotene Beobachtungssequenz repräsentiert. Sie berechnet sich aus der Wahrscheinlichkeit der Beobachtung für eine Sequenz

$$P(O|Q, \lambda) = \prod_{t=1}^T P(O_t|q_t, \lambda) = b_{q_1}(O_1) \cdot b_{q_2}(O_2) \dots b_{q_T}(O_T)$$

und der Wahrscheinlichkeit für die Sequenz

$$P(Q|\lambda) = \pi_{q_1} a_{q_1 q_2} a_{q_2 q_3} \dots a_{q_{T-1} q_T}$$

Für den gesamten Merkmalsraum ergibt sich die Wahrscheinlichkeit über die Summe der einzelnen Wahrscheinlichkeiten:

$$P(O|\lambda) = \sum_{q_1 \dots q_T} \pi_{q_1} b_{q_1}(O_1) a_{q_1 q_2} b_{q_2}(O_2) \dots a_{q_{T-1} q_T} b_{q_T}(O_T)$$

Da bei dieser direkten Berechnung der Wahrscheinlichkeit  $O$  der Rechenaufwand mit  $T$  im Exponenten ansteigt, erfolgt in der Praxis die Berechnung über den Forward-Algorithmus. Über ihn werden die, in der direkten Berechnung redundant erfolgten, Rechenschritte zwischengespeichert. Hierzu speichert die Vorwärtsvariable  $\alpha$  die Wahrscheinlichkeit für jeden definierten Zustand als Summe aller vorangegangenen Zustände, wie in Abbildung 37 veranschaulicht (Blunsom, 2004).




Abbildung 37. Veranschaulichung der Vorwärtsvariable  $\alpha$  (Blunsom, 2004).

Definition:  $\alpha_t(i) = P(O_1, O_2 \dots O_t, s_t = i | \lambda)$

Für die Initialisierung des Forward Algorithmus müssen die Vorwärtsvariablen für den Startzeitpunkt  $\alpha_1(i)$  festgelegt werden. Für den Fall einer Ganganalyse z.B., bei der bereits segmentierte Daten in das Modell gegeben werden, liegt die initiale Startwahrscheinlichkeit ( $\pi_i$ ) für den Beginn der Observationsfolge ( $O_1$ ) und das Erreichen des Zustands  $i$  bei 1, da durch die Vorverarbeitung festgelegt ist, dass der Gangzyklus mit dem initialen Kontakt beginnt. Auch die Emissionswahrscheinlichkeit der Observation  $b_i(O_1)$  ist in diesem Zustand gewährleistet.

Initialisierung:  $\alpha_1(i) := \pi_i b_i(O_1)$

Wurde die Berechnung erfolgreich initialisiert, so kann davon ausgegangen werden, dass  $\alpha_t(i)$  für alle vergangenen Zeitpunkte berechnet werden kann.

Rekursion:  $a_{t+1}(j) := \sum_i \alpha_t(i) a_{ij} b_j(O_{t+1})$

Die Rekursion stellt den entscheidenden Teil des Forward-Algorithmus dar. Für jeden Zustand speichert  $s_j, a_j(t)$  die Wahrscheinlichkeit in diesen Zustand zu gelangen, wie in Abbildung 38 veranschaulicht.




Abbildung 38. Veranschaulichung der Rekursion im Forward-Algorithmus (Blunsom, 2004).

Rekursionsabschluss:  $P(O|\lambda) = \sum_{i=1}^N \alpha_T(i)$

Am Ende der Berechnungen ergeben sich N Möglichkeiten die Observationsfolge  $O$  zu generieren und den Zustand  $i$  zu erreichen. Die Gesamtproduktionswahrscheinlichkeit berechnet sich dabei aus der Summe aller Teilwahrscheinlichkeiten (Fink, 2003).

## Problem 2: Dekodierung - Viterbi-Algorithmus

Das Ziel der Dekodierung besteht darin, die Sequenz der versteckten Zustände zu identifizieren, die mit der größten Wahrscheinlichkeit zur Modellierung eines gegebenen Merkmalraums geführt hat. Bezogen auf die Modellierung des Gangzyklus

einer Gehbewegung mit zwei Zuständen, könnte eine mögliche Zustandsfolge durch die jeweiligen Bodenkontakte der Ferse und den Mittelstütz repräsentiert werden (Zustand1: HeelStrike-MidStance; Zustand2: MidStance-HeelStrike). Problem 2 wird mit dem Viterbi-Algorithmus gelöst. Er ermöglicht die Bestimmung der Zustandssequenz durch ein bestimmtes HMM, die eine Beobachtungssequenz am besten beschreibt. Er stellt eine Variante des Forward-Algorithmus dar, mit dem Unterschied, dass die Übergangswahrscheinlichkeiten für jeden Zustand maximiert statt aufsummiert werden (Fink, 2003).

Problem 3: Modellanpassung - Baum-Welch-Algorithmus (unsupervised)

Problem 3 wird üblicherweise beim unbewachten Training mit dem Baum-Welch-Algorithmus gelöst (Blunsom, 2004; Fink, 2003; Rabiner, 1989). Er verbessert ein gegebenes Modell  $\lambda$  auf Basis der Gesamtproduktionswahrscheinlichkeit  $P(O|\lambda)$ . Die Produktionswahrscheinlichkeit des Modells  $\lambda$  wird dahingehend optimiert, dass die Wahrscheinlichkeit größer wird, dass der Merkmalsraum  $V$  durch das Modell produziert werden kann. Eine genaue Beschreibung des Baum-Welch-Algorithmus findet man bei Bilmes (1998) oder Fink (2003).

#### 2.4.3.2 Anwendungen von HMMs im Kontext von Sport- und Alltagsbewegungen

Boesnach et al. (2004) untersuchten die Klassifikation von Bewegungsphasen menschlicher Greifbewegungen im Kontext eines Küchenszenarios mit Elman-Netzen (EN, rekursiv, backpropagation), Netzwerken mit radialer Basisfunktion (RBN) (feed forward) und Hidden Markov Modellen. Die Winkelverläufe von neun Gelenken wurden mit einem Handschuh der Marke CyberGlove bei ausgewählten Tätigkeiten in der Küche (Tischdecken, Einschenken, Umrühren u.a.) erfasst. Ergänzend wurden die Gelenkwinkel des rechten Arms mit einem Magnet-Tracking System aufgezeichnet. Die Daten wurden in 16 Teilabschnitte segmentiert und die Erkennungswahrscheinlichkeiten für jede Phase wurden über alle Modelle berechnet. Der Vergleich der ENs und der RBNs zeigte über alle Phasen eine höhere Klassifikationswahrscheinlichkeit für die Netze auf Basis der radialen Basisfunktion.

Die durchschnittliche Erkennungsrate über alle Phasen betrug für ENs 66,74 % und RBNs 85,48 %. Die Erkennungsraten für die Hidden Markov Modelle (Fenstergröße 30, zwei Zustände) waren nahezu identisch mit denen der RBNs. Die Autoren

begründeten dies damit, dass die Modellierung der Zustände mittels Gauß-Mischverteilungen eine Generalisierung der RBNs darstellt. Bei den HMMs fiel vornehmlich auf, dass bereits eine Fenstergröße von einem Frame zu Erkennungsraten von 84,14 % führte. Boesnach et al. (2004) schlussfolgerten daraus, dass insbesondere die Merkmalsauswahl entscheidend für eine erfolgreiche Klassifizierung ist. Bereits die Modellierung der Phasen über einen Zustand lieferte hohe Erkennungsraten, die über zwei Zustände nur noch geringfügig verbessert werden konnten. Bei höherer Anzahl an Zuständen nahm die Klassifizierungsrate ab. Die Autoren führten dies auf die höhere Spezialisierung der Modelle mit einer geringen Zahl von Zuständen zurück. Zur weiteren Verbesserung der Erkennungsraten empfehlen die Autoren eine deutlich höhere Anzahl von Datensätzen (hier 140) für das Training der Modelle zu verwenden, verweisen aber gleichzeitig auf den immensen Aufwand für die manuelle Segmentierung der Trainingsdaten.

Cheng et al. (2008) klassifizierten neun Personen auf Basis ihrer Gangmuster. Die Probanden (N=80) wurden beim Gehen in einem Raum mit einer Videokamera (Frequenz: 15 Hz; Auflösung 320×240 Pixel) gefilmt. Aus den Videosequenzen wurde der vom Probanden gewählte Pfad (sechs vorgegebene Möglichkeiten) geschätzt, sowie die Silhouette der Person. Für beide Klassifikationen kamen Hidden Markov Modelle zum Einsatz, die entsprechend des Klassifizierungsziels trainiert wurden. Die Autoren testeten ihr Modell auf weiteren Videosequenzen und konnten über alle Versuche hinweg ähnlich Ergebnisse erzielen (Erkennungsraten zwischen 92 % und 100 %). Auffallend war, dass sich die Erkennungsraten mit steigender Anzahl der Probanden verschlechterten (Cheng et al., 2008).

Amma, Fischer, Stein, Schwameder und Schultz (2011) untersuchten die Klassifikation von induzierten Emotionen auf Basis der Kinematik beim Gehen auf einem Laufband. Fünf jungen Männer und fünf jungen Frauen wurden, während des Gehens auf dem Laufband mit einer selbstgewählten Geschwindigkeit, Bilder über einen Beamer und Geräusche über einen Kopfhörer präsentiert. Die Bilder, die dem *International Affective Picture Set* (Westermann, Spies, Stahl & Hesse, 1996) entnommen waren, waren so gewählt, dass sie bei den Probanden neutrale, positive, stark positive und stark negative Emotionen induzieren sollten. Die visuelle Induktion wurde durch Geräusche der entsprechenden Kategorie des *International Affective Digital Sound Systems*

(Sokolowski, 2008) verstärkt. Die Emotionsinduktion startete nach einer Adaptationsphase von 192 Sekunden gehen bei der gewählten Geschwindigkeit. Zeitgleich wurde die Datenaufnahme mit 14 Infrarotkameras (Frequenz: 200 Hz) gestartet. Für jeden emotionalen Zustand wurden Hidden Markov Modelle mit den nach Schrittzyklen segmentierten Gelenkwinkelverläufen der unteren Extremität trainiert. Die Trainingsvektoren wurden einem ersten Analyseblock entnommen, während die Testvektoren aus dem zweiten Analyseblock entstammten. Die Ergebnisse zeigten, dass durch die Klassifikation mit Hidden Markov Modellen eine Zuordnung der Gangmuster zur Emotionalen Induktion nicht möglich war. Die Erkennungsraten lagen über alle getesteten Konditionen unter 50 % und waren damit als zufällig zu betrachten (alle  $33 \% \pm 10 \%$ , weiblich  $41 \% \pm 10 \%$ , männlich  $28 \% \pm 7 \%$ ).

Die Autoren mutmaßten, dass der gewählte Versuchsaufbau im Hinblick auf die Induktion von Emotionen und die Generierung daraus resultierender Musteränderungen beim Gehen ungeeignet war, da möglicherweise das Gehen unter festgelegten Randbedingungen auf dem Laufband eine Änderung der kinematischen Muster unmöglich machte (Amma et al., 2011).

Mannini und Sabatini (2012a) untersuchten die automatische Segmentierung von Gangphasen mit Hidden Markov Modellen. Fünf junge Personen (26 – 29 Jahre) wurden beim Gehen auf dem Laufband bei unterschiedlichen Geschwindigkeiten mit einem Orientierungssensor, der am Schuh angebracht war, vermessen. Zeitgleich wurde die Kinematik der unteren Extremitäten mit einem Infrarot-Videosystem (Frequenz: 100 Hz) erfasst. Die Zeitreihen wurden auf Basis der kinematischen Daten für das Training der HMMs segmentiert. Die HMM-Architektur wurde so gewählt, dass jede Gangphase (1. HeelStrike (HS)-FlatFoot (FF); 2. FlatFoot-HeelOff (HO); 3. HeelOff-ToeOff (TO); 4. ToeOff-HeelStrike) durch einen Zustand repräsentiert wurde. Die Erkennungsleistung wurde mit der leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) getestet. Tabelle 5 zeigt die Abweichungen (Anzahl Frames) der automatisch detektierten Events auf Basis der Daten des Orientierungssensors in Relation zu den Events, die über die Positionsdaten des Referenzsystems (Fersen- und Zehenmarker) bestimmt wurden.



*Tabelle 5.* Abweichung der automatisch detektierten Events (Anzahl Frames  $\pm$  Standardabweichung) auf Basis des Orientierungssensors im Vergleich zu den Events auf Basis der Positionsdaten (Mannini & Sabatini, 2012a).

<b>HS [Frames]</b>	<b>FF [Frames]</b>	<b>HO [Frames]</b>	<b>TO [Frames]</b>
0,1 ( $\pm$ 4,3)	6,9 ( $\pm$ 11,8)	-2,7 ( $\pm$ 5,6)	2,4 ( $\pm$ 1,6)

Die Autoren schlussfolgern, dass die Segmentierung von Gangzyklen mit Hidden Markov Modellen auf der Basis der Daten eines Orientierungssensors im Hinblick auf die Leistungsfähigkeit des Algorithmus und der Genauigkeit der Event-lokalisierung vielversprechende Ergebnisse lieferte (Mannini & Sabatini, 2012a).

Khorasani und Daliri (2014) untersuchten 16 gesunde und 15 an Parkinson erkrankte Personen (PhysioBank Archive: [www.physionet.org](http://www.physionet.org)) beim Gehen. Die Probanden gingen mit instrumentierten Schuhe (acht Kraftsensoren pro Schuh) jeweils für eine Dauer von fünf Minuten mit einer selbstgewählten Geschwindigkeit. Für die Klassifizierung wurden die Rohdaten des rechten Fußes in Gangzyklen segmentiert. Jeweils ein HMM für gesund und krank mit vier Gauß-Mischverteilungen und fünf Zuständen wurde über zwanzig Iterationen trainiert. Die Erkennungsleistungen der Modelle wurden mit der leave-one-out Methode Kreuzvalidiert (Kearns & Ron, 1999). Die Autoren erzielten eine Erkennungsleistung von 90,32 % bei der Klassifizierung des Gangs im Hinblick auf gesund oder krank. Verglichen mit der Studie von Wu und Krishnan (2010), bei der eine nicht lineare Support Vector Machine für die Erkennung von Parkinson beim Gehen auf den gleichen Daten verwendet wurde, konnte im Durchschnitt die gleiche Erkennungsleistung (Tabelle 6), allerdings ohne die Berechnung von Merkmalen, erreicht werden (Khorasani & Daliri, 2014).

*Tabelle 6.* Ergebnisse der Klassifizierung von Parkinson (Khorasani & Daliri, 2014).

<b>Erkenner</b>	<b>Parkinso n -</b>	<b>Anzahl Probanden</b>	<b>Erkannt als Parkinson</b>	<b>Erkannt als gesund</b>	<b>Erkennungs- rate [%]</b>	<b>Erkennungs- rate gesamt[%]</b>
	<b>gesund</b>					
HMM	Parkinson	15	14	1	93,33	90,32
	gesund	16	2	14	87,50	
SVM	Parkinson	15	13	2	86,67	90,32
	gesund	16	1	15	93,75	

### *2.4.3.3 Kritische Würdigung von Markov Modellen*

Im Gegensatz zu Neuronalen Netzen modellieren HMMs zeitliche Zusammenhänge von aufeinander folgenden Zuständen in Mustern. Sie scheinen deshalb für die Erkennung zeitlich strukturierter Datenfolgen, wie sie bei der Analyse menschlicher Lokomotionsbewegungen mit den gängigen Analyseverfahren der Biomechanik anfallen, besonders geeignet (Bilmes, 2006). Insbesondere die Tatsache, dass die Vorverarbeitung der Messdaten auf die Segmentierung der Zeitreihen beschränkt werden kann, lässt einen geringen Informationsverlust in Bezug auf individuell geprägte Muster erwarten. Die angeführten Studien zeigen, dass HMMs, die bislang vornehmlich für die Modellierung biologischer Sequenzen und für Sprache eingesetzt wurden, bei der Abbildung menschlicher Lokomotionsmuster Erkennungswahrscheinlichkeiten aufweisen, die mit den anderen vorgestellten Verfahren vergleichbar sind. Anders als bei SVMs und KNNs, bei denen über unterschiedliche Parametereinstellungen, wie z.B. dem Gamma-Parameter der SVM oder der direkten Manipulation von Gewichten bei den KNNs, kann bei HMMs kein direkter Einfluss auf die Klassifikationsleistung des Modells genommen werden. Besonders die SVMs erlauben über die Regulierung der Klassifizierungsschärfe mittels C-Parameter eine Adaptation der Klassifikationsleistung des Modells im Hinblick auf Fehlklassifizierung (Schölkopf & Smola, 2002). Ebenso wie SVMs und KNNs scheinen HMMs bei der Diskriminierung von Gruppen, deren Muster eine große Varianz bei repetitiver Ausführung zeigen, Einschränkungen bei der Klassifikationsleistung ebendieser Muster aufzuweisen (Janssen et al., 2011). Die Auswahl der Funktionsparameter scheint entscheidend für die Diskriminierungsleistung des Modells. Die Aufarbeitung der aktuellen Literatur zeigt ein Defizit an Untersuchungen, bei denen die geeigneten Verfahren für die Analyse der Bewegungsmuster menschlicher Lokomotion im Hinblick auf ihre Klassifikationsleistung miteinander verglichen werden.

## **2.5 Synthese der Befunde und Zielstellung der Arbeit**

Die Analyse der theoretischen Grundlagen zu menschlicher Lokomotion hat gezeigt, dass der bipede Gang eine Sonderform der Fortbewegung unter den Vertebraten darstellt, der komplexen Regelungsmechanismen unterliegt. Mit den zentralen Muster-generatoren konnte, am Beispiel eines aktuellen Ansatzes aus der Motorikforschung,

aufgezeigt werden, dass die Muster des Gehens und Rennens beim Menschen unbewusst, durch vom Gehirn weitgehend unabhängige neuronale Netzwerke im Rückenmark, gesteuert werden. Ebendiese Form der Kontrolle zyklischer Bewegungsfolgen scheint erklären zu können, warum insbesondere diese Klasse von Bewegungen einer geringen individuellen Varianz in der Ausführung unterliegt und ihre Muster über alle Menschen hinweg große Ähnlichkeiten zeigen. Im Kontext des Entwicklungsprozesses über die Lebenszeit und interner Faktoren, wie z.B. Emotion und Motivation, unterliegen diese Muster individuellen Adaptationsvorgängen, die der Grundform der zyklischen Bewegung im Allgemeinen und des Gehens und Rennens im Speziellen, hochgradig individuelle Muster aufprägen. Eine Analyse der Geh- und Rennbewegung mit geeigneten Methoden scheint es zu ermöglichen, Rückschlüsse auf die Auslöser der Adaptationsvorgänge zu ziehen und z.B. physiologische von pathologischen Ursachen trennen zu können. Besonders im Hinblick auf unbemerkt ablaufende Veränderungen am Muskel-Skelett Apparat könnten auf diese Weise degenerative Prozesse im Sinne einer pathologischen Veränderung phänomenologisch frühzeitig erkannt werden. Die Analyse der aktuellen Literatur zu Verfahren für die Erkennung von Mustern hat gezeigt, dass sich im Kontext menschlicher Lokomotionsbewegungen insbesondere jene Methoden eignen, die einen nicht-deterministischen Ansatz verfolgen und somit der Variabilität natürlich erzeugter Daten Rechnung tragen. Für die Klassifikation von Geh- und Rennbewegungen wurden in der Vergangenheit in erster Linie KNNs, sowie SVMs mit Erfolg eingesetzt. Vergleiche der beiden Methoden weisen heterogene Ergebnisse im Hinblick auf die Klassifikationsleistung auf, wobei offenbar SVMs, auf Grund des optimierten Verfahrens zur Berechnung der trennenden Ebene, über eine höhere Generalisierungsfähigkeit verfügen. Im Gegensatz hierzu wurden Hidden-Markov Modelle bislang vornehmlich für die Erkennung von Sprache und biologischen Sequenzen verwendet. Einige Studien zeigen aber, dass sie ebenso für die Klassifizierung von Bewegungsmustern gute Ergebnisse liefern. Ein Vergleich der Erkennungsleistung der drei vorgestellten Methoden, im Kontext der Analyse menschlicher Lokomotionsbewegungen, wurde bislang nicht durchgeführt und veröffentlicht. Vor dem Hintergrund dieser Befunde können im Hinblick auf die Zielstellung dieser Arbeit folgende Forschungsfragen formuliert werden:

- Eignen sich HMMs zur Erkennung menschlicher Lokomotionsbewegungen?
- Welche der vorgestellten Methoden zur Mustererkennung zeigt die besten Ergebnisse bei der Klassifikation menschlicher Lokomotionsbewegungen?
- Verfügen Muster des Gehens und Rennens auf dem Laufband über individuelle Informationen, die eine Erkennung von Personen mittels eines geeigneten Verfahrens zur Musteranalyse ermöglichen?
- Zeigen Personen mit ähnlicher Spezialisierung beim Gehen und Rennen auf dem Laufband unter unterschiedlichen Randbedingungen konvergierende Änderungen der kinematischen Muster, welche mit einem geeigneten Verfahren diskriminiert werden?
- Können Personen beim nichtstationären Gehen auf unterschiedlichen Untergründen auf Basis Ihrer Muster mit einem geeigneten Verfahren zur Mustererkennung diskriminiert werden?
- Können verschiedene Untergründe auf Basis der Gangmuster mehrerer Personen diskriminiert werden.

Im Folgenden werden die Studien und deren Ergebnisse in chronologischer Reihenfolge spezifiziert, die im Hinblick auf die aufgezeigten Forschungsdefizite durchgeführt wurden (Kapitel 3 – 6). Zusammenfassend werden die Erkenntnisse und ihr wissenschaftlicher Wert im Kontext des aktuellen Forschungsstandes kritisch diskutiert, sowie die praktische Relevanz der Arbeit aufgezeigt (Kapitel 7).

### 3 Studie 1: Personenerkennung mit Hidden Markov Modellen

#### 3.1 Einleitung

Die Untersuchung zur Personenerkennung fand im Kontext des DFG Sonderforschungsbereichs 588 „Humanoide Roboter“ statt. Dieser SFB hatte das Ziel, einen lernenden und kooperierenden Serviceroboter zu entwickeln, der sich in der Umwelt des Menschen bewegt. Das Szenario verlangt vom Roboter, sich autonom zurecht zu finden und diverse Gegenstände bzw. Personen identifizieren zu können. Zur Identifizierung von Personen wurden im SFB 588 unterschiedliche Ansätze verfolgt, die am fertigen Roboter durch Fusion zu einer maximalen Erkennungsrate führen sollen. Für die Erkennung von Bewegungen und Personen wurden im SFB 588 unter anderem Hidden Markov Modelle (HMM) eingesetzt (Becher, Steinhaus & Dillmann, 2004). Für dieses Verfahren liegen Studien vor, die gute Klassifikationsleistungen bei der Erkennung von Stimmen (Bilmes, 2006; Blunsom, 2004; Fink, 2003; Rabiner, 1989) und der Modellierung biochemischer Strukturen (Chiang, Wang & McKeown, 2008; Plotz & Fink; Schuster-Bockler, Schultz & Rahmann, 2004) zeigen. Die HMMs wurden im SFB 588 primär zur Erkennung des Bewegungszustandes, der Klassifikation unterschiedlicher Oberkörperbewegungen (Stein et al., 2006) und der probabilistischen Prädiktion von Bewegungsfolgen eingesetzt (Becher et al., 2004). Für die Erkennung von Benutzern, respektive potentiellen Kooperationspartnern, wurde ein multimodaler Ansatz verfolgt, bei dem vorklassifizierte akustische als auch optische Datenflüsse fusioniert wurden. Hierdurch sollten insbesondere Szenen aufgelöst werden können, in denen entweder kein optisches oder aber kein akustisches Tracking möglich ist. Vor dem Hintergrund dieses Anforderungsprofils, sollte auf Basis von Lokomotionsdaten, die über individuelle Informationen zur Klassifikation von Personen verfügen (Schöllhorn et al., 2002; Troje, 2002; Troje et al., 2005), eine Personenerkennung realisiert werden. Cheng et al. (2008) zeigten, dass Personen auf Basis von Bewegungsmustern der Körpersilhouette, die aus Videobildern (Frequenz: 15 Hz; Auflösung: 320×240 Pixel) geschätzt wurden, mit einer Wahrscheinlichkeit zwischen 93 % und 100 % identifiziert werden konnten. Amma et al. (2011) versuchten die Emotionen auf Basis der Lokomotionsmuster von Personen zu klassifizieren, die beim Gehen auf einem Laufband Bilder des *International Affective Picture Set* (Westermann et al., 1996) zur Emotionsinduktion präsentiert bekamen.

Ergänzend wurden den Probanden über Kopfhörer Geräusche des *International Affective Digital Sound Systems* (Sokolowski, 2008) vorgespielt, was zu einer Verstärkung der Emotionsinduktion führen sollte. Auf Basis der extrahierten Gelenkwinkelverläufe der unteren Extremität wurden Hidden Markov Modelle trainiert, die die emotionalen Zustände neutral, maximale Valenz mit minimaler Erregung, maximale Valenz mit maximaler Erregung und minimale Valenz mit maximaler Erregung modellierten. Die Klassifikationsergebnisse der Modelle zeigten, dass eine Zuordnung des emotionalen Zustands zu den Mustern der Gelenkwinkel der unteren Extremität nicht möglich war. Die Autoren vermuteten, dass insbesondere die induzierte Bewegungsgeschwindigkeit durch die Zwangsbedingung Laufbandgeschwindigkeit ursächlich für die Klassifikationsergebnisse war. Mannini und Sabatini (2012a) segmentierten auf Basis der Daten eines Orientierungssensors die Phasen des Gangs automatisch. Zu diesem Zweck wurden in den Orientierungs-Zeit Verläufen anhand der Winkel-Zeit Verläufe, die durch ein Infrarotvideosystem (Frequenz: 100 Hz) erfasst wurden, die Zeitpunkte HeelStrike, FlatFoot, HeelOff und ToeOff bestimmt. Ein HMM, in dem die Gangphasen über vier Zustände repräsentiert waren, wurde mit den segmentierten Daten des Orientierungssensors trainiert. Mit dieser Methode konnten die Autoren eine Erkennungswahrscheinlichkeit der Gangphasen zwischen 90,5 % und 96,8 % erreichen, wobei eine Phase als detektiert angenommen wurde, wenn der Zeitpunkt auf  $\pm 30$  ms genau durch das HMM detektiert wurde. Die Erkennungsleistung wurde mit der leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) getestet. Khorasani und Daliri (2014) klassifizierten mit HMMS, die über fünf Zustände und fünf Gauß-Mischverteilungen verfügten, gesunde und an Parkinson erkrankte Personen anhand kinetischer Daten des Gehens. Eine Erkennungsleistung von 90,32 % konnte erzielt werden, die mit der leave-one-out Kreuzvalidierung (Kearns & Ron, 1999) getestet wurde. Der Überblick der aktuellen Literatur zeigt, dass eine Klassifikation von Merkmalen auf Basis der Muster beim Gehen möglich ist. Die Diskriminierung auf Basis kinematischer Daten der unteren Extremität zeigt dabei die besten Erkennungswahrscheinlichkeiten. Insgesamt ist anzumerken, dass die Beschreibungen der HMM-Topologien in der Literatur lückenhaft erscheinen, da eine exakte Beschreibung der HMMs (Modelltyp, Anzahl der Zustände, Modellierung der Zustände, Anzahl der Gauß-Mischverteilungen, Anzahl der Trainingsdatensätze u.a.) nur selten erfolgt. Die Erkennung von Personen wurde zudem bislang nur auf Basis von Silhouetten, die aus Videobildern extrahiert wurden, durchgeführt, was einerseits ein Problem der

Performanz beinhaltet und andererseits feste Blickwinkel der Kameras voraussetzt. Im Hinblick auf die Erkennung von Personen, auf Basis präziser dreidimensionaler Gelenkwinkelverläufe der Lokomotion, ergibt sich aus der Literaturanalyse ein Forschungsdefizit, welches im Hinblick auf die Anforderungen im Kontext des SFB 588 durch diese Studie behoben werden soll. Ziel dieser Studie ist es, zu überprüfen, inwieweit sich Hidden Markov Modelle für die Modellierung menschlicher Lokomotionssequenzen eignen. Auf Basis kinematischer Funktionsparameter einer Ganganalyse auf dem Laufband, werden Personen anhand ihrer Bewegungsmuster diskriminiert. Die Güte der Erkennungsleistung kann dabei als Kriterium für die Qualität der Abbildung der Bewegungssequenz durch das Modell herangezogen werden. Auf Basis der Klassifikationsergebnisse soll gezeigt werden, dass sich Hidden Markov Modelle für die Abbildung und Klassifizierung von Mustern menschlicher Lokomotionsbewegungen eignen.

### **3.2 Methodik**

#### *Stichprobe*

An der Studie nahmen zehn Probanden im Alter zwischen 19 und 24 Jahren ( $20,8 \pm 1,62$  Jahre) ohne spezielle Vorbildung im Hinblick auf die untersuchte Bewegung freiwillig teil. Zwei gesunde Frauen und acht gesunde Männer wurden zufällig ausgewählt, wodurch die Heterogenität der Stichprobe gewährleistet werden sollte.

#### *Biomechanische Messwertaufnahme, -verarbeitung und -modellierung*

Im Anschluss an die Aufklärung der Probanden wurden ihre kinematischen Daten auf einem Laufband bei Geschwindigkeiten von  $1,3 \text{ ms}^{-1}$ ,  $2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$  erfasst. Die Datenerhebung erfolgte mit einem Infrarot Kamerasystem mit zehn Kameras (Frequenz: 250 Hz). Alle Probanden wurden gemäß dem Plug-In Gait Markerset mit reflektierenden Markern (14 mm Durchmesser) vom selben Testleiter versehen. Jeder Proband absolvierte drei Versuche bei jeder Geschwindigkeit, in chronologischer Reihenfolge. Die Aufnahmedauer wurde so gewählt, dass Daten von 120 Schrittzyklen für jeden Probanden über alle Geschwindigkeiten zur Verfügung standen, wobei der jeweils erste Versuch als Adaptationsphase an die neue Stufe gewertet wurde. Die

Datenverarbeitung erfolgte mit der VICON® Workstation Software. Zur Bereinigung wurden Lücken in den Rohdaten mit unterschiedlichen Algorithmen gefüllt. Vornehmlich wurde versucht auf Basis der Positionsdaten von Markern, die sich auf dem gleichen starren Segment befanden, fehlende Positionsinformationen zu berechnen. Hierdurch sollte eine möglichst hohe Güte der Daten sichergestellt werden. Erst danach wurden situationsbedingt die in Workstation implementierten Algorithmen *Pattern Fill* und *Spline Fill* angewendet. Lücken, die mehr als zehn Frames in Folge umfassten, wurden nicht gefüllt. Gangzyklen mit verblieben Lücken wurden als ungültig nicht in die Auswertung mit einbezogen. Die kinematische Modellierung erfolgte ebenfalls in Workstation mit dem Plug-In Gait-Modell (VICON®, 2002). Anschließend wurden die Daten auf Basis der Fersen- und Zehenmarker (L/R-HEE, L/R-TOE) segmentiert. Hierzu wurden in jedem Versuch vier Positionen (Events) für ToeOff und HeelStrike anhand der vertikalen Komponente der Koordinate markiert. Die folgenden Zeitpunkte wurden über die Autokorrelationsfunktion in VICON® Workstation automatisiert markiert. Abschließend wurden alle Events kontrolliert und gegebenenfalls manuell korrigiert. Die Winkel-Zeitreihen wurden als CSV-Daten exportiert und in Excel eingelesen. Die Zeitreihen wurden manuell nach den Zeitstempeln der Events segmentiert und in Excel sortiert.

### *Stochastische Modellierung*

Die Winkel-Zeit Verläufe der Geh- und Renndaten bildeten die Grundlage für das Training von HMMs. HMMs sind stochastische Modelle  $\lambda = (S, \pi, A, B, V)$  zur Beschreibung von Zeitreihen mit  $N$  Zuständen  $S = \{s_1, \dots, s_N\}$ , initialen Zustandswahrscheinlichkeiten  $\pi = \{\pi_1, \dots, \pi_N\}$  und einer stochastischen Zustandsübergangsmatrix  $A = (a_{ij})$ , wobei  $a_{ij}$ , die Wahrscheinlichkeit eines Übergangs von Zustand  $s_i$  in Zustand  $s_j$  ist. Zusätzlich definieren die Beobachtungswahrscheinlichkeiten  $B = b_j(v_k)$  die Wahrscheinlichkeit  $v_k$  zu beobachten, solange man in Zustand  $s_j$  ist.  $v_k$  ist dabei aus dem Merkmalsraum  $V$ , der diskret oder kontinuierlich sein kann (Kapitel 2.4.3.1).

Zur Modellierung der Geh- und Rennbewegungen wurden links-rechts HMMs mit kontinuierlichen Beobachtungswahrscheinlichkeiten verwendet. Aus den Merkmalsvektoren mit der folgenden Gleichung wurden mit Gauß-Mischverteilungen die Beobachtungswahrscheinlichkeiten berechnet:



$$b(v_k) = \sum_{l=1}^M c_l \frac{1}{\sqrt{(2\pi)^n |\Sigma|}} e^{-\frac{1}{2}((v_k - \mu)^T \Sigma^{-1} (v_k - \mu))}$$

Das Training und die Auswertung der HMMs erfolgten in MATLAB mit der Toolbox von Kevin Murphy (Murphy, 1998). Für die HMMs wurde entsprechend der einfachen zyklischen Geh- und Rennbewegung eine einfache lineare Topologie gewählt, bei der eine Übergangswahrscheinlichkeit vom letzten Zustand (letzte Phase des Gangzyklus) zum ersten Zustand (Beginn des Gangzyklus) implementiert wurde. Jeder Zustand des HMMs repräsentierte eine von vier Phasen des Gangzyklus (Abbildung 39).



Abbildung 39. Phaseneinteilung des Doppelschrittzklus.

Zur Konstruktion des HMM, das für die Erkennung der Geh- und Rennbewegungen trainiert wurde, wurden unterschiedliche Anzahlen von Zuständen getestet. Auf der Basis dieser einfachen HMMs erfolgte die Konstruktion spezifischer, auf die menschliche Geh- und Rennbewegung abgestimmter HMMs. In MATLAB wurden HMMs auf die Weise konstruiert, dass die Anzahl ihrer Gauß-Mischverteilungen, sowie die Anzahl der Zustände variiert wurden. Die Anzahl der Phasen wurde auf Grund der ersten Ergebnisse nicht geändert. Die entsprechenden Phasen der linken und rechten Seite wurden gleich modelliert. Die Anzahl der Gauß-Mischverteilungen wurde jeweils verdoppelt und von einer bis acht Gauß-Mischverteilungen pro Zustand getestet. Die Anzahl der Zustände wurde für die Phasen I und III von einem Zustand bis fünf Zustände um eins inkrementiert, sowie für die Phasen II und IV von fünf bis 30 um fünf inkrementiert. Insgesamt wurde die Erkennungsleistung von 120 unterschiedlich konfigurierten HMMs getestet.

### Datenanalyse

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet. Die Funktion bietet gegenüber den typischen Verfahren zur Prüfung auf Normalverteilung (z.B. Shapiro-Wilk, Chi-Quadrat) den Vorteil, dass sie sowohl bei

sehr kleinen als auch sehr großen Datenmengen angewendet werden kann. Zusätzlich erlaubt sie eine schnelle Prüfung und gibt Hinweise auf die Art der Verteilung (normal, left/right skewed, fat tailed)

(<http://de.mathworks.com/help/stats/normplot.html>). Ein p-Wert wird für die Verteilung nicht berechnet und die ausschließlich grafische Darstellung lässt Raum für unterschiedliche Interpretationen. Da für die Anwendung von HMMs eine Normalverteilung der Daten zwar sinnvoll, nicht aber zwingend notwendig ist, reichte die Prüfung über die grafische Darstellung an dieser Stelle aus.

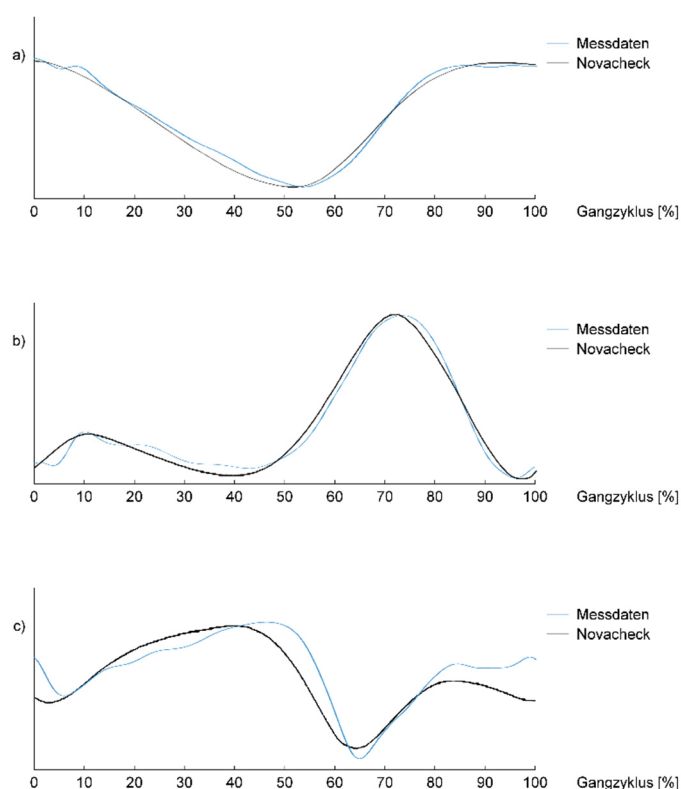
Es folgte eine kinematische Analyse der Geh- und Rennbewegung. Für alle Winkel-Zeit Verläufe von Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles), Sprunggelenk (L/R-AnkleAngles), Schulter (L/R-ShoulderAngles), Ellbogen (L/R-ElbowAngles), Handgelenk (L/R-WristAngles), Nacken (L/R-NeckAngles), Wirbelsäule (L/R-SpineAngles), Kopf (L/R-HeadAngles), Thorax (L/R-ThoraxAngles), Becken (L/R-PelvisAngles) und Fußaufsatz (L/R-FootProgressAngles) jedes Probanden wurden die mittleren Standardabweichungen über 60 Doppelschritte berechnet und über die Gesamtamplitude relativiert. Dies diente dem Zweck, jenen Parameter zu identifizieren, der durch die Testpersonen am stabilsten reproduziert wurde. Die Zeitreihen des kinematischen Parameters mit der geringsten relativen Standardabweichung wurden für einen ersten Test verwendet.

Für fünf männliche Testpersonen wurde für die Winkel-Zeit Verläufe von Hüfte, Knie, Sprunggelenk, Schulter, Ellbogen, Handgelenk, Nacken, Wirbelsäule, Kopf, Thorax, Rumpf über drei Dimensionen und dem Körperschwerpunkt jeweils ein HMM mit 17 Doppelschrittzyklen für die Geschwindigkeiten von  $2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$  trainiert (23 HMMs pro Person pro Geschwindigkeit). Über das Training bildeten sich für jedes HMM charakteristische Gauß-Mischverteilungen aus, die Mittelwert und Varianz des modellierten Winkel-Zeit Verlaufs in drei Dimensionen repräsentierten. Die Erkennung der Personen erfolgte über den Fit des jeweiligen Datensatzes auf die HMMs aller Personen, die für den jeweiligen Winkel trainiert wurden (Kapitel 2.4.3.1 HMM-Problem 1).

### 3.3 Ergebnisse

#### *Analyse der Plausibilität der Messdaten*

Um die Güte der Daten zu gewährleisten, wurden die Gelenkwinkel der unteren Extremität einer Prüfung unterzogen und mit vergleichbaren Analysen aus der Literatur im Hinblick auf Geschwindigkeit und Stichprobe gegenübergestellt. Der Vergleich der Kurven für die Winkeldaten der unteren Extremität beim Gehen mit einer frei gewählten Geschwindigkeit und den skalierten Verläufen von Novacheck (1998) zeigt nahezu identische Verläufe (Abbildung 40).



*Abbildung 40.* Vergleich der Winkelverläufe in der Sagittalebene von Hüfte (a), Knie (b) und Sprunggelenk (c) dieser Studie zu skalierten Normwerten (Gehen mit  $2\text{ms}^{-1}$ ) (Novacheck, 1998).

Auffallend war, dass die Verläufe von Novacheck einen kontinuierlicheren Verlauf aufwiesen, was auf eine starke Filterung der Daten oder auf eine große Anzahl von Winkel-Zeit Verläufen, die zur Mittelung verwendet wurden, zurückgeführt werden könnte. Lediglich die Mittelwerte der Verläufe des Sprunggelenks (c) zeigten Abweichungen am Beginn und am Ende des Gangzyklus. Im Gegensatz hierzu zeigte der Vergleich der Daten zu Normdaten von Perry und Burnfield (2010, S. 53) wiederum

nahezu identische Verläufe, insbesondere bei der Betrachtung der Tendenz der Verläufe.




Abbildung 41. Vergleich der Winkelverläufe in der Sagittalebene des Sprunggelenks zu skalierten Normwerten von Perry und Burnfield (2010).

Die Gruppierung der Wahrscheinlichkeits-Winkeldaten-Werte der zehn Probanden für die Gelenke Hüfte (a), Knie (b) und Sprunggelenk (c) (gemittelt über 20 Zyklen) entlang der theoretischen Wahrscheinlichkeits-Winkeldaten-Funktion (rot) in Abbildung 42, weist auf die Normalverteilung der Winkelverläufe zum Zeitpunkt Heel Strike hin. Die Normalverteilung wurde für alle detektierten Zeitpunkte über alle Gelenkwinkel getestet, aber nur für den Zeitpunkt Heel Strike und die Winkeldaten von Hüfte, Knie und Sprunggelenk exemplarisch aufgeführt.




Abbildung 42. Summenhäufigkeits-Wahrscheinlichkeiten der zehn Probanden für gemittelte Winkeldaten von Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Summenhäufigkeits-Wahrscheinlichkeiten (rot) zum Zeitpunkt Heel Strike bei einer Geschwindigkeit von  $2 \text{ ms}^{-1}$ .

Abbildung 43 zeigt exemplarisch die segmentierten und über die Zeit normalisierten Kniewinkelverläufe im inter- und intraindividuellen Vergleich.

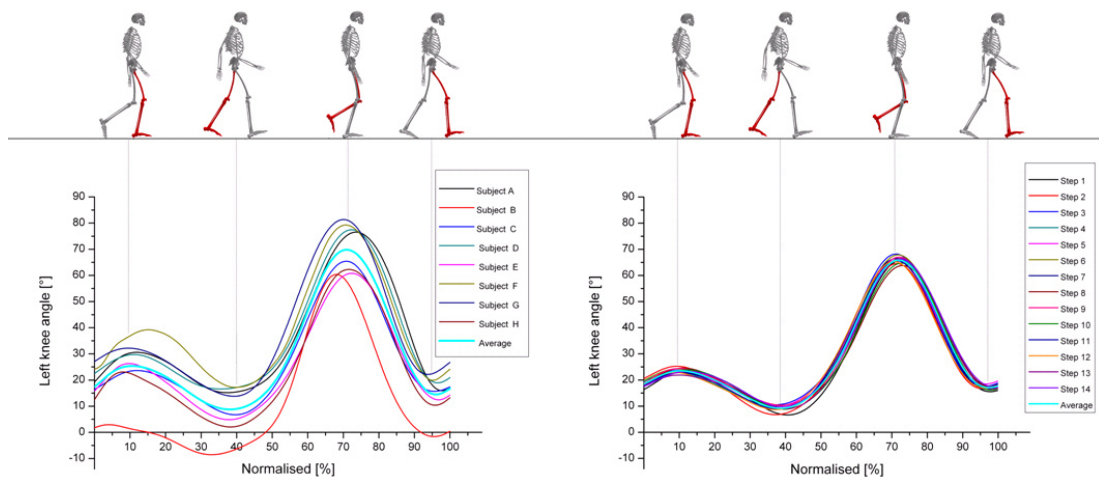


Abbildung 43. Segmentierte Winkeldaten des Knies in der Sagittalebene im inter- und intraindividuellen Vergleich für das Gehen bei  $1,2 \text{ ms}^{-1}$ .

Insbesondere die Winkelverläufe des intraindividuellen Vergleichs lassen auf eine exakte Segmentierung der Schrittzyklen auf Basis der gewählten Methode schließen. Die Verläufe des interindividuellen Vergleichs dokumentieren die Heterogenität der individuellen Bewegungsmuster exemplarisch für das Kniegelenk.

### Erkennungsraten der HMMs

Der intraindividuelle Vergleich, der auf die Amplitude normierten mittleren Standardabweichungen kinematischer Parameter, zeigte den geringsten Wert für den Flexion-/Extensionswinkel des Knies (Abbildung 44). Das mit Kniewinkeln trainierte HMM zeigte in ersten Versuchen Erkennungsraten von über 80 %.

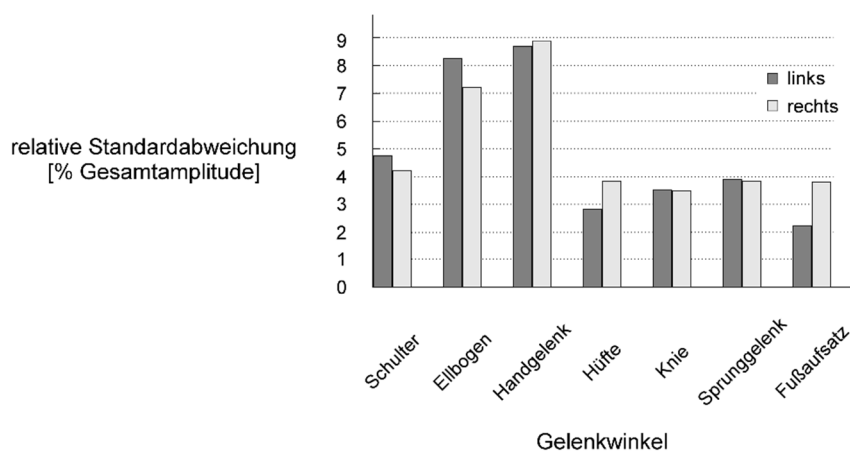


Abbildung 44. Standardabweichung relativiert auf die Gesamtamplitude der Winkel Zeit Verläufe beim Rennen mit  $2 \text{ ms}^{-1}$ .

Aus allen getesteten HMMs wurde das HMM mit dem besten Fit über die kinematischen Parameter mit der geringsten relativen Standardabweichung für die weiteren Tests ausgewählt. Es verfügte über eine Gauß-Mischverteilung für die Phasen I und III und jeweils vier Gauß-Mischverteilungen für die Phasen II und IV (Abbildung 45).



Abbildung 45. Gauß-Mischverteilungen zur Modellierung der Zustände über die Phasen des Doppelschrittzklus beim Rennen mit  $2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$ .

Die HMMs wurden mit Zeitreihen von 17 Doppelschritten für alle Winkel-Zeit Verläufe (Hüfte, Knie, Sprunggelenk, Schulter, Ellbogen, Handgelenk, Nacken, Wirbelsäule, Kopf, Thorax, Rumpf) sowie dem Körperschwerpunkt für jeden Probanden bei den Geschwindigkeiten  $2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$  auf ihre Erkennung hin getestet. Alle Winkel, außer dem Beugewinkel des Ellbogens, konnten über drei Freiheitsgrade den Personen zugeordnet werden. Die Erkennungsraten lagen gemittelt über alle Versuche eines Merkmals über beide getesteten Geschwindigkeiten zwischen 66 % und 100 %. Die beste Erkennung lieferten erwartungsgemäß Winkel, die in Relation zum globalen Koordinatensystem standen (Kopfwinkel), da die Körpergröße der Probanden als zusätzlicher Parameter die Erkennung begünstigte.

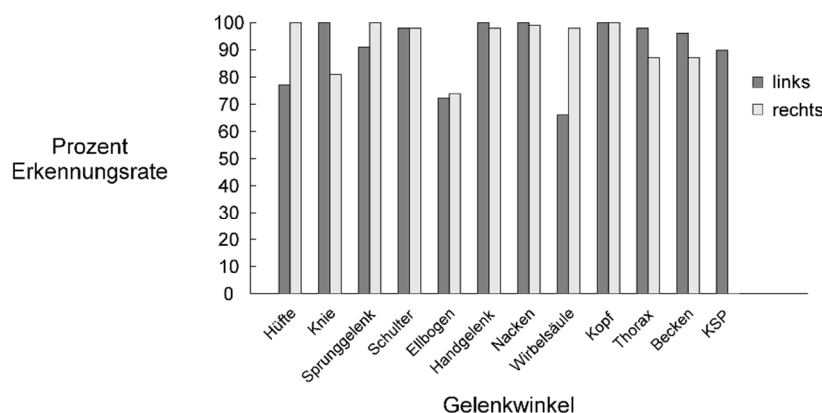


Abbildung 46. Prozentuale Erkennungsraten bei 17 Versuchen über fünf Personen bei Geschwindigkeiten von  $2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$ .

Bei den Winkeln, die über ein lokales Koordinatensystem am Gelenk bestimmt wurden (VICON®, 2002), konnten insbesondere die Muster von Hüfte, Knie und Sprunggelenk mit Wahrscheinlichkeiten von bis zu 100 % klassifiziert werden, wobei sich Unterschiede zwischen rechter und linker Seite zeigten. Die Muster des Ellbogenwinkels lieferten die niedrigsten Erkennungsraten mit 72 % für die linke und 73 % für die rechte Seite.

### **3.4 Diskussion**

Ziel dieser Studie war es, auf Basis der Klassifikationsergebnisse zu zeigen, dass sich Hidden Markov Modelle dafür eignen Muster menschlicher Lokomotion abzubilden und anhand individueller Bewegungsmuster Personen diskriminiert werden können. Die kinematischen Muster der Merkmale konnten mit Wahrscheinlichkeiten von 72 % - 100 % den Personen zugeordnet werden. Die höchste Erkennungswahrscheinlichkeit zeigte sich für den Winkel-Zeit Verlauf des Kopfes, der gemessen in Relation zum globalen Koordinatensystem, Informationen über die Körpergröße des Probanden beinhaltet. Die größten Erkennungswahrscheinlichkeiten für Winkel, gemessen in Relation zu einem lokalen Koordinatensystem ergaben sich für die Winkel-Zeitverläufe der unteren Extremität (Hüfte, Knie und Sprunggelenk), die für jeweils eine Seite mit 100 % klassifiziert werden konnten. Cheng et al. (2008) konnten in ihrer Studie auf Basis von Silhouetten, die aus Videobildern extrahiert wurden, Personen mit einer Wahrscheinlichkeit zwischen 92 % und 100 % in Abhängigkeit des Blickwinkels identifizieren. Im Hinblick darauf, dass die von Cheng et al. (2008) gewählten Parameter Informationen über die Größe der Probanden beinhalteten, bestätigen deren Ergebnisse die Befunde dieser Studie. Auffallend war, dass für Winkel Zeit Verläufe dieser Studie ein unterschiedlich guter Modellfit für die linke und die rechte Seite zu beobachten war. Dieses Phänomen könnte darauf zurückzuführen sein, dass bei der Konstruktion des HMMs Lateralität nicht berücksichtigt wurde. Die Segmentierung der Doppelschrittzyklen erfolgte für alle Zyklen nach den initialen Merkmalen der gleichen Seite. Bei der Konstruktion des HMMs wurde die Modellierung der rechten und linken Seite mit jeweils der gleichen Anzahl an Zuständen und Gauß-Mischverteilungen realisiert. Es wäre denkbar, dass eine getrennte Betrachtung der Seiten zu einer Verbesserung der Klassifikationsergebnisse führt.

In Bezug auf die Personenerkennung über Merkmale, die gemessen in Relation zu einem lokalen Koordinatensystem keine Informationen zur Körpergröße beinhalteten, konnten bereits über die Klassifikation nur eines kinematischen Parameters zufriedenstellende Ergebnisse erzielt werden. Ursächlich für die hohe Klassifikationsleistung scheinen die verwendeten Funktionsparameter zu sein. Im Vergleich mit den in der Literaturanalyse beschriebenen Parametern (Khorasani & Daliri, 2014; Mannini & Sabatini, 2012b), sind diese durch eine hohe Datengüte gekennzeichnet. Dies liegt einerseits an der vergleichsweise hohen zeitlichen Datendichte (Aufnahmefrequenz: 250 Hz), andererseits auch an der hohen Messgenauigkeit des eingesetzten Infrarotvideosystems. Zur weiteren Verbesserung der Erkennungsleistung der HMMs ist eine Kombination mehrerer Parameter durch z.B. ein Mehrheitsvotum denkbar und soll in weiteren Untersuchungen getestet werden. Nachdem gezeigt werden konnte, dass Muster menschlicher Lokomotion mit Hidden Markov Modellen, die über eine geeignete Topologie verfügen, abgebildet werden können, soll in der folgenden Studie 2 die Erkennungsleistung unterschiedlicher probabilistischer Klassifikatoren miteinander verglichen werden.



## **4 Studie 2: Vergleich der Klassifikationsleistung von Künstlichen Neuronalen Netzen, Support Vector Machines und Hidden Markov Modellen bei der Personenerkennung**

### **4.1 Einleitung**

Bei der Analyse von Prozessmustern, die im zeitlich-räumlichen Kontext dynamischen Änderungen unterliegen, kamen in der Vergangenheit vor allem Künstliche Neuronale Netze zum Einsatz (Perl, 2007; Schöllhorn et al., 2002). Diese modellieren aktuelle und künftige Systemzustände unter Berücksichtigung der Systemhistorie und beurteilen Zustände im Kontext der multidimensionalen Systemdynamik. Im Hinblick auf eine Unterscheidung von individuellen Bewegungsmustern lassen optimierte Modellansätze zur Musteranalyse bessere Ergebnisse bei der Diskriminierung erwarten als herkömmliche Künstliche Neuronale Netze. In dieser Studie wird die Analyse von individuellen Bewegungsmustern am Beispiel einer Laufanalyse mit Support Vector Machines (Schölkopf & Smola, 2002), Künstlichen Neuronalen Netzen (McCulloch & Pitts, 1943) und Hidden Markov Modellen (Rabiner, 1989) untersucht, und deren Eignung zur Klassifizierung von Mustern vergleichend diskutiert. Ng et al. (2011) extrahierten aus einfachen Videobildern einer Kamera (Frequenz: 25 Hz; Auflösung: 720×576 px), welche orthogonal zur Bewegungsrichtung aufgestellt war, die Silhouetten von elf Personen beim Gehen (SOTON covariate Database; Lotfi & Garibaldi, 2004; zitiert nach Ng et al., 2011). Für jeden Proband wurden mehrere Sequenzen gefilmt, bei denen unterschiedliche Kleidung, sowie unterschiedliche Gegenstände von den Testpersonen getragen wurden. Im Anschluss bestimmten Ng et al. die Funktionsparameter Schrittlänge, Spurbreite und Schritthöhe zu dem Zeitpunkt, an dem die Oberschenkeltrajektorie (nicht näher spezifiziert) den größten Wert aufwies. Zusätzlich wurden die Mittelwerte der lokalen Maxima für Schrittlänge, Spurbreite und Schritthöhe berechnet. Hieraus ergaben sich 2722 Sequenzen, die für eine lineare Diskriminanzanalyse und das Training eines fuzzy k-nearest Neighbour-Models und einer SVM verwendet wurden. Für das Training wurden Eingangsvektoren berechnet, die mit Gaußfiltern mit unterschiedlichem Sigma gefiltert wurden. Ng et al. konnten mit dieser Methode für ein Sigma von 1,7 die beste Erkennungsrate mit der SVM von 84 % erreichen, die mit einer zweifachen Kreuzvalidierung gesichert wurde. Sudha und Bhavani (2012) haben auf der Basis von Funktionsparametern, die aus

Videobildern extrahiert wurden (Frequenz: 25 Hz; Auflösung: 352×240 px), die Klassifikationsleistungen von SVMs und einem k-nearest Neighbour Modell verglichen. Insgesamt wurden die Daten von 20 Personen verwendet. Für jede Person standen vier Aufnahmesequenzen aus drei Perspektiven zur Verfügung (National Laboratory of Pattern Recognition gait database). Aus sogenannten Boundingboxes, Rechtecke, welche in einem Videobild die Silhouette einer Person umgeben, wurden räumliche Parameter (mittlere Höhe, mittlere Breite, mittlerer Winkel und das mittlere Seitenverhältnis der Boundingbox) für jeden Probanden bestimmt. Die zeitlichen Parameter Schrittlänge, Schrittzykluslänge, Kadenz und Geschwindigkeit wurden direkt aus den Videosequenzen extrahiert. Ergänzend wurde eine Wavelet-Transformation durchgeführt und der mittlere Energiekoeffizient mittels Haar Wavelet bestimmt (Ng et al., 2011, S. 361). Die beschriebenen Funktionsparameter wurden zu einem Merkmalsvektor zusammengefasst, der für das Training des k-nearest Neighbour Modells und der SVM verwendet wurde. Für die SVM wurden unterschiedliche Kernel-Funktionen getestet (linear, polynomial und radial basis function). Die SVM mit RBF-Kernel lieferte die besten Klassifikationsresultate. Mit dem k-nearest Neighbour Modell konnte eine Klassifikationsrate von 95,83 % erreicht werden. Mit der SVM hingegen konnten 97,92 % der Merkmalsvektoren der richtigen Person zugeordnet werden. Khorasani und Daliri (2014) klassifizierten den Gang von 16 gesunden Personen ( $39 \pm 18,5$  Jahre) und 15 Personen, die an Parkinson erkrankt waren ( $67 \pm 10,9$  Jahre) mit HMMs. Die HMMs wurden so konstruiert, dass sie über fünf Zustände verfügten, die über vier Gauß-Mischverteilungen modelliert wurden. Für das Training und die Erkennung wurden Merkmalsvektoren erstellt, welche die Rohdaten von Kraftsensoren eines instrumentierten Schuhs (acht Sensoren pro Schuh) enthielten. Die Autoren konnten mit dieser Methode eine Erkennungsleistung von 90,32 % erreichen. Die Ergebnisse konnten mit der Erkennungsleistung einer SVM von Wu und Krishnan (2010) verglichen werden, deren Ergebnisse auf dem identischen Datensatz basierten. Sie verwendeten eine lineare Diskriminanzanalyse, sowie eine SVM mit unterschiedlichen Kernel-Funktionen für die Klassifizierung der Bewegungsmuster. Die beste Erkennungsleistung konnte mit der SVM mit polynomialen Kernel nachgewiesen werden. Mit ihr konnten 90,32 % aller Merkmalsvektoren richtig zugeordnet werden.

In Studie 1 konnte gezeigt werden, dass sich Hidden Markov Modelle zur Abbildung und Klassifizierung von Mustern in kinematischen Daten menschlicher Lokomotionsbewegungen eignen. Die Analyse der aktuellen Literatur hat aufgezeigt, dass Künstliche Neuronale Netze und Support Vector Machines die besten Ergebnisse bei der Klassifikation menschlicher Bewegungsmuster beim Gehen liefern. Khorasani und Daliri (2014) konnten aber zeigen, dass Hidden Markov Modelle verglichen, mit der SVM, bei der Klassifizierung auf Basis der Daten von Kraftsensoren lediglich eines Fußes, vergleichbare Ergebnisse liefern. Erkenntnisse zum Vergleich der Leistung der beschriebenen Modelle bei einer Klassifikation über hochdimensionale Merkmalsvektoren auf der Basis von Gelenkwinkeln der unteren, als auch oberen Extremität beim Gehen und Rennen, werden in der Literatur bislang nicht beschrieben. Ziel dieser Studie ist es, auf Basis der kinematischen Daten einer Laufbandanalyse, die Erkennungsleistung der gängigen Modelle zur Klassifizierung von Mustern beim Gehen und Rennen mit HMMs zu vergleichen. Auf Basis der Klassifikationsleistung, die als Kriterium für die Güte der Abbildung der Lokomotionsbewegung angenommen wird, soll jenes Verfahren identifiziert werden, das sich am besten für die Modellierung der Bewegungsmuster menschlicher Lokomotion eignet. Ergänzend hierzu soll auf Basis der Klassifikationsleistung bei der Erkennung von Personen anhand individueller kinematischer Muster von Geschwindigkeiten, die nicht für das Training verwendet wurden, die Generalisierungsfähigkeit der Modelle getestet werden.

## **4.2 Methodik**

### *Stichprobe*

An der Studie nahmen acht Männer zwischen 20 und 25 Jahren ( $21,75 \pm 1,67$  Jahre) teil. Die Probanden verfügten alle über Erfahrung im Rennen und nahmen aktiv an Wettkämpfen über die Lang- oder Mittelstreckendistanz auf nationalem Niveau teil. Alle Probanden wurden im Vorfeld der Studie zum Ablauf der Untersuchung aufgeklärt und bestätigten ihre Bereitschaft zur freiwilligen Teilnahme.

### *Biomechanische Messwertaufnahme, -verarbeitung und -modellierung*

Alle Testpersonen wurden gemäß dem Plug-In Gait Markerset (VICON®, 2002) mit Markern von 14 mm Durchmesser durch den gleichen Testleiter versehen: Dies geschah, um zufälligen Fehlern bei der Markerpositionierung vorzubeugen und eine

hohe Datengüte zu gewährleisten. Die Datenerhebung für das Training und die Erkennung zum Vergleich der Modelle erfolgte mit 10 Infrarotkameras bei einer Abtastfrequenz von 250 Hz. Alle Probanden wurden auf einem Laufband der Marke Woodway bei Geschwindigkeiten von  $1,2 \text{ ms}^{-1}$ ,  $3,0 \text{ ms}^{-1}$  und  $4,0 \text{ ms}^{-1}$  kinematisch vermessen. Jeder Proband absolvierte bei jeder Geschwindigkeit drei Versuche, wobei der erste Versuch als Einlaufphase nicht in die Analyse mit einbezogen wurde. Die verbleibenden Versuche wurden für das Training und die Erkennung verwendet. Die Messintervalle wurden so gewählt, dass von jedem Probanden für jeden Versuch Daten von mindestens 24 Doppelschrittzyklen erfasst werden konnten. Die Bereinigung der Daten erfolgte analog zu dem in Kapitel 3.2 beschriebenen Verfahren. Lücken in Positions-Zeit Verläufen, die mehr als zehn Frames in Folge umfassten, wurden nicht gefüllt. Gangzyklen mit verbliebenen Lücken wurden als ungültig nicht in die Auswertung mit einbezogen. Für die Segmentierung der Gangzyklen wurden die Daten in MATLAB importiert. Zur Detektion der Events Heel Strike und Toe Off wurden Algorithmen implementiert, die auf Basis der Steigung des Positions-Zeit Graphen der Fersen- und Zehenmarker die Zeitpunkte stabil für alle Probanden identifizierten (Anhang, Abbildung 2). Die Filterung der Positions-Zeit Verläufe erfolgte mit einem Butterworthfilter vierten Grades bei einer CuttOff Frequenz von 20 Hz (Kapitel Anhang, Abbildung 1).

### *Stochastische Modellierung*

Das Training und die Erkennung erfolgten auf Daten aus unterschiedlichen Versuchen. Um Klassifikationsmodelle für Gehbewegungen mit Künstlichen Neuronalen Netzen (KNN) wie auch Support Vector Machines (SVM) einlernen zu können, wurde mittels Hauptkomponentenanalyse (PCA) eine bestimmte Anzahl von Key-Frames, die charakteristische Geschwindigkeitsänderungen aufzeigten, aus den Positions-Zeit Verläufen ermittelt von Schulter (L/R-SHO), Ellbogen (L/R-ELB), Handgelenk (L/R-WRA und L/R-WRB gemittelt), Becken (L/R-ASI, L/R-PSI), Knie (L/R-KNEE), Sprunggelenk (L/R-ANK) und Fuß (L/R-TOE, L/R-HEE) zu einer Trainingsdatenmenge für jedes der vier Segmente des Gangzyklus zusammengefasst. Auf diese Weise konnte die Trainingsdatenmenge im Hinblick auf die Leistungsfähigkeit der Modelle reduziert und die zeitliche Invarianz sichergestellt werden.

Für das Vorgehen mit den KNNs wurde die frei verfügbare Bibliothek FANN (Nissen, 2003) integriert, welche eine effiziente Konstruktion und ein schnelles Training des

KNN für die binäre Klassifikation ermöglicht. Zur Realisation eines Multiklassen-Klassifikators wurden 1-gegen-alle-Modelle trainiert und miteinander gekoppelt (Abbildung 47). Im Kontext der Klassifizierung von Bewegungen, deren Struktur mit der Segmentierung über Bodenkontakte als bekannt vorausgesetzt wurde und somit nicht erlernt werden musste, bieten 1-gegen-alle-Modelle den Vorteil eines effizienten Trainings im Hinblick auf die Laufzeit und die Anzahl der Trainingsdaten.

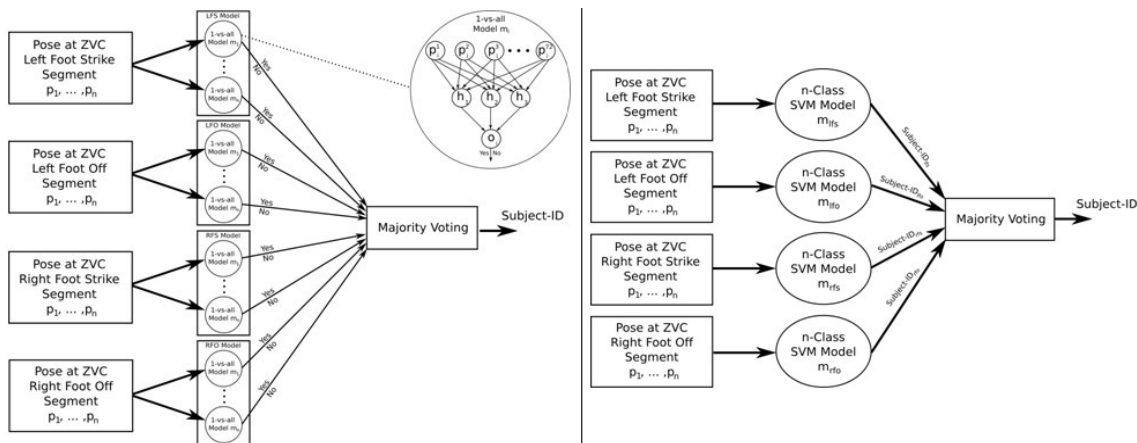


Abbildung 47. Struktur des NN-Klassifikators und des SVM-Klassifikators für Gehen und Rennen.  $p_n$  repräsentiert einen Merkmalsvektor für die Demonstration von  $n$ .

Für die Support Vector Machine wurde eine Multiklassen-SVM mit Gaussian radial basis function kernel (RBF Kernel) implementiert (Horst et al., 2015).

Für die Erkennung mit den Hidden Markov Modellen wurde ebenfalls eine frei verfügbare Bibliothek verwendet. Die Positions-Zeit Verläufe der Ganganalyse bildeten die Grundlage für das Training der HMMs. Das Training und die Auswertung erfolgten in MATLAB mit der *Hidden Markov Model (HMM) Toolbox for MATLAB* (Murphy, 1998). Für das HMM wurde basierend auf den Ergebnissen aus Studie 1 eine einfache lineare Topologie (Blunsom, 2004) gewählt. Jeder der vier Zustände des HMMs repräsentierte eine von vier Phasen des Gangzyklus (Segmentierung nach Bodenkontakten). Zustand 1 und 3 wurden über eine Gauß-Mischverteilung und 2 und 4 über vier Gauß-Mischverteilungen modelliert. Da es sich beim Gehen um eine zyklische Bewegung handelt, gab es eine Übergangswahrscheinlichkeit vom letzten in den ersten Zustand des Gangzyklus. Die Anpassung des HMMs erfolgte über das Training mit den Positions-Zeit Verläufen der Marker gemäß dem Markerset von VICON® Plug-In Gait (VICON®, 2002). Es wurden die Positions-Zeit Verläufe von Schulter (L/R-SHO), Ellbogen (L/R-ELB), Handgelenk (L/R-WRA und L/R-WRB

gemittelt), Becken (L/R-ASI, L/R-PSI), Knie (L/R-KNEE), Sprunggelenk (L/R-ANK) und Fuß (L/R-TOE, L/R-HEE) für jede Person und jede Geschwindigkeit in jeweils einem Merkmalsvektor zusammengefasst.

### *Datenanalyse*

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet.

Zur Ermittlung der allgemeinen Klassifikationsgüte der KNN und der SVM wurden vier Trainingsdatensammlungen von ca. 885 Segmenten für jeden Segmenttyp aus einer Menge von insgesamt 1776 Schrittzyklen (222 Zyklen für jeden Probanden) mit drei unterschiedlichen Geschwindigkeiten generiert. Für die Evaluation der Klassifikationsleistung wurde für die Geschwindigkeit von  $1,2 \text{ ms}^{-1}$ ,  $3,0 \text{ ms}^{-1}$ , und  $4,0 \text{ ms}^{-1}$  jeweils eine SVM, sowie ein KNN für alle Probanden mit den Trainingsdatensammlungen der entsprechenden Geschwindigkeit trainiert (drei SVMs, sowie drei KNNs). Zur Evaluation der Erkennungsleistung wurden die verbliebenen Datensammlungen verwendet. Um eine Bewegung, bestehend aus vier Segmenten, zu klassifizieren, wurden sowohl den SVMs als auch den KNNs Daten für jeden Segmenttyp getrennt präsentiert. Die Klassifikationsergebnisse der einzelnen Modelle wurden durch ein Mehrheitsvotum zusammengeführt (Abbildung 47). Für die HMMs wurde pro Probanden ein Modell für jede Geschwindigkeit mit den segmentierten Trainingsdatensammlungen trainiert (24 HMMs). Zur Evaluation der Erkennungsleistung wurden den HMMs die Positions-Zeit Verläufe unsegmentierter Gangzyklen präsentiert. Die Erkennung der Personen erfolgte über den Fit des jeweiligen Datensatzes auf die HMMs aller Personen. Zusätzlich wurde die Generalisierungsfähigkeit der Modelle getestet. Zu diesem Zweck wurden den Modellen Trainingsvektoren mit Daten der Geschwindigkeiten von  $1,2 \text{ ms}^{-1}$  und  $3,0 \text{ ms}^{-1}$  präsentiert. Die Evaluation erfolgte über eine Geschwindigkeit von  $4,0 \text{ ms}^{-1}$ .

### 4.3 Ergebnisse

#### *Analyse der Plausibilität der Messdaten*

Um die Güte der Daten sicher zu stellen, wurden die Gelenkwinkel der unteren Extremität einer Prüfung unterzogen und mit Ergebnissen vergleichbaren Analysen aus der Literatur im Hinblick auf Geschwindigkeit und Stichprobe gegenübergestellt. Der Vergleich der Kurvenverläufe für die Winkeldaten der unteren Extremität, mit den skalierten Verläufen von Novacheck (1998) für eine Geschwindigkeit von  $3 \text{ ms}^{-1}$ , zeigt starke Ähnlichkeiten im Verlauf (Abbildung 48). Auffallend ist, dass die Messwerte dieser Studie über alle Winkelverläufe, verglichen mit den Verläufen von Novacheck, eine Rechtsverschiebung im Winkel-Zeit-Diagramm aufweisen (time shift). Der Versatz lässt sich auf die unterschiedliche Detektion der Events Heel Strike und Toe Off zurückführen und beruht nicht auf Differenzen in den Messdaten. Dies müsste für die Berechnung von Parametern, die auf Basis der prozentualen Verteilung des Gangzyklus bestimmt werden, berücksichtigt werden. Da Events für diese Studie ausschließlich im Sinne einer Segmentierung der sich zyklisch wiederholenden Daten von Bedeutung sind, hat der zeitliche Versatz hier keinen Einfluss und kann vernachlässigt werden. Betrachtet man die Daten von Novacheck, so fällt außerdem auf, dass die Anfangs- und Endwerte der Winkeldaten der Doppelschrittzyklen stark divergieren. Im Hinblick darauf, dass es sich bei den Verläufen um über Doppelschrittzyklen gemittelte Messdaten handelt, wäre zu erwarten, dass Anfangs- und Endwerte der Winkelverläufe nahezu identisch sind. Für die Winkelverläufe dieser Studie trifft dies zu.

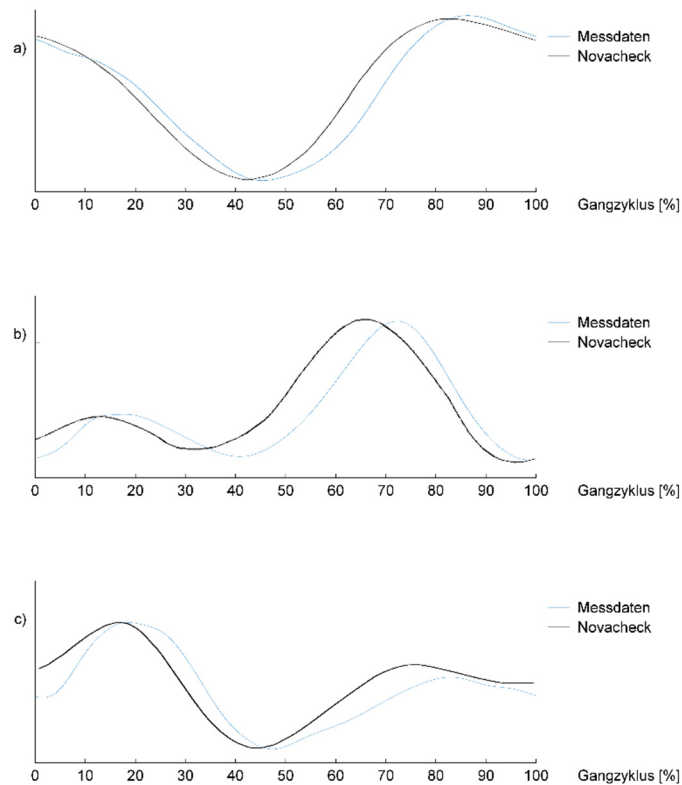


Abbildung 48. Vergleich der Winkelverläufe in der Sagittalebene von Hüfte (a), Knie (b) und Sprunggelenk (c) dieser Studie zu skalierten Normwerten (Rennen mit  $3 \text{ ms}^{-1}$ ) (Novacheck, 1998).

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet (Anhang A).




Abbildung 49. Summenhäufigkeits-Wahrscheinlichkeiten der acht Probanden für über 24 Zyklen gemittelte Winkeldaten von Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Summenhäufigkeits-Wahrscheinlichkeiten (rot) zum Zeitpunkt Heel Strike bei einer Geschwindigkeit von  $3 \text{ ms}^{-1}$ .

Die Gruppierung der Wahrscheinlichkeits-Winkeldaten-Werte der acht Probanden für die Gelenke Hüfte (a), Knie (b) und Sprunggelenk (c) (gemittelt über 24 Zyklen) entlang



der theoretischen Wahrscheinlichkeits-Winkeldaten-Funktion (rot) in Abbildung 49, weist auf die Normalverteilung der Winkelverläufe zum Zeitpunkt Heel Strike hin. Die Normalverteilung wurde über alle detektierten Zeitpunkte hinweg überprüft und an dieser Stelle nur stellvertretend für den Zeitpunkt Heel Strike angeführt.

Im Hinblick auf die Modellierung der Gangphasen im HMM mit Gauß-Mischverteilungen ist davon auszugehen, dass sich die Muster der Probanden für die dargestellten Winkelverläufe gut durch das Modell abbilden lassen.

### *Vergleich der Klassifikationsleistung*

Während durch den Einsatz der KNNs in Abhängigkeit der getesteten Geschwindigkeit zwischen 94 % und 95,5 % der Personen erkannt wurden, konnten mit der SVM und den HMMs über alle Geschwindigkeiten Klassifikationsraten von 100 % erreicht werden. Bei der Erkennung des individuellen Musters bei einer Geschwindigkeit von  $4 \text{ ms}^{-1}$  mit Modellen, die mit den Geschwindigkeiten von  $1,2 \text{ ms}^{-1}$  und  $3 \text{ ms}^{-1}$  trainiert wurden, erreichte die SVM eine Erkennungsrate bezüglich der Person von 98,6 % im Gegensatz zu einer Klassifizierung von 94 % durch KNNs. Mit den HMMs konnten 71 % bis 100 % der Winkelverläufe einzelner Gelenke klassifiziert werden. Über alle Gelenkwinkel ergab sich über ein Mehrheitsvotum eine Erkennungsrate von 99,3 %.

*Tabelle 7.* Klassifikationswahrscheinlichkeiten von KNNs, SVMs und HMMs im Vergleich.

	<b>Personen bei 1.2 m/s[%]</b>	<b>Personen bei 3.0 m/s [%]</b>	<b>Personen bei 4.0 m/s [%]</b>	<b>Personen bei 1.2, 3.0, 4.0 m/s [%]</b>	<b>Personen bei 4.0 m/s mit Training bei 1.2, 3.0 m/s [%]</b>
KNN	95,0	95,3%	95,5	94,0	94 ,0
SVM	100,0	100,0	100,0	100,0	98,6
HMM	100,0	100,0	100,0	100,0	99,3

Neben der Erkennung von Personen wurde auch evaluiert, ob die Laufgeschwindigkeit des Probanden klassifiziert werden konnte. Bezüglich dieses Testszenarios ergab die Auswertung der KNNs eine Rate von 90,2 %, der SVMs eine Rate von 95 % und der HMMs eine Rate von 98,7 %.

#### 4.4 Diskussion

Ziel dieser Studie war es, die Erkennungsleistung der gängigen probabilistischen Modelle (KNN und SVM) zur Klassifizierung von Mustern kinematischer Funktionsparameter beim Gehen und Rennen auf dem Laufband mit HMMs zu vergleichen. Sowohl die SVMs, als auch die HMMs konnten bei der Erkennung der Personen über die Bedingungen, mit denen die Modelle trainiert wurden, Muster mit einer Wahrscheinlichkeit von 100 % den Personen zuweisen. KNNs erreichten über diese Bedingungen eine Erkennungswahrscheinlichkeit von 94 % - 95,5 %. Die Ergebnisse dieser Studie werden durch die Erkenntnisse von Khorasani und Daliri (2014), die eine SVM mit HMMs verglichen haben, sowie Ng et al. (2011), die ein fuzzy k-nearest Neighbour Modell mit einer Diskriminanzanalyse und einer SVM verglichen haben, gestützt. Sie konnten vergleichbare Unterschiede in der Klassifikationsleistung aufzeigen.

Während KNNs eine Tendenz zum Overfitting aufweisen (Perl, 2002, S. 2002), besitzen SVMs und HMMs durch die optimierten Klassifizierungsvorschriften eine höhere Generalisierungsfähigkeit (Bishop, 2009). Insbesondere die HMMs zeigten bei der Klassifikation unbekannter Daten hohe Erkennungsraten. Die ähnlich guten Leistungen der HMMs und der SVM sind, wie auch von Boesnach et al. (2004) berichtet, auf die Verwendung der Gaußschen Mischverteilung für beide Verfahren zurückzuführen (Ng et al., 2011; Sudha & Bhavani, 2012). Im Hinblick auf die Fragestellung dieser Studie scheinen die Hidden Markov Modelle und Support Vector Machines ähnlich geeignet Muster menschlicher Lokomotion abzubilden. Im Gegensatz zu HMMs ist für SVMs eine Vorverarbeitung der Daten in Form der Auswahl von diskreten Variablen zu ausgewählten Zeitpunkten (z.B. PCA), oder einer Normalisierung der Daten über die Zeit, Voraussetzung für die Klassifikation von Mustern. Gerade im Hinblick auf die Performanz der Systeme im Kontext der Ganganalyse und der Untersuchung von Geh- und Rennbewegungen im klinischen Umfeld, bei denen eine schnelle Datenverarbeitung gefordert wird (Kramers-de Quervain et al., 2008), scheint der Einsatz von HMMs erfolgversprechend. Vor diesem Hintergrund sollen in den folgenden Studien HMMs unter verschiedenen Randbedingungen auf die Möglichkeiten und Grenzen der Abbildung von Mustern beim Gehen und Rennen untersucht werden.

## **5 Studie 3: Erkennung von Breiten- und Leistungssportlern auf Basis kinematischer Parameter beim Rennen auf dem Laufband**

### **5.1 Einleitung**

In den Studien 1 und 2 konnte gezeigt werden, dass die Muster des Gehens und Rennens auf dem Laufband biometrische Informationen enthalten, die mit probabilistischen Verfahren zur Erkennung von Mustern diskriminiert und Personen zugeordnet werden können. Wie in Kapitel 2.1 aufgezeigt wurde, verfügen Muster dieser Klasse über geringe intraindividuelle Variabilitäten bei repetitiver Ausführung der zyklischen Bewegungsfolge. Interindividuell hingegen sind diese Muster durch Adaptationsvorgänge im Verlauf der Lebenszeit geprägt und weisen Unterschiede auf, welche die Kinematik des Gehens und Rennens als hochgradig individuelles biometrisches Mas ausweist (BenAbdelkader, Cutler & Davis, 2002; Troje, 2002). Mit steigendem Grad der Spezialisierung hingegen, orientiert sich die Bewegungsausführung zunehmend an einem technischen Leitbild, welches durch die Optimierung im Kontext biomechanischer und physiologischer Gesetzmäßigkeiten mit dem Ziel einer Leistungsmaximierung geprägt ist. Im Rahmen der anthropometrischen Merkmale und des individuellen Stiles eines Sportlers, nähern sich die Muster mit steigender Spezialisierung einer optimalen Bewegungsausführung an (Kortmann, T., & Schöllhorn, W. I., 2010), während ihre Variabilität abnimmt (Fujii, Kudo, Ohtsuki & Oda, 2009; Nakayama, Kudo & Ohtsuki, 2010; Tyldesley & Whiting, 1975). Morgan, Martin, Krahenbuhl und Baldini (1991) konnten in ihrer Untersuchung zeigen, dass sich dies vor allem in den kinematischen Daten widerspiegelt, die nicht nur über die Schrittzyklen eines Tages hinweg eine hohe Stabilität in der Bewegungsausführung zeigen, sondern auch im Vergleich der Variabilität über mehrere Tage hinweg.

Neben dem Grad der Spezialisierung im Hinblick auf eine Bewegung hat die Bewegungsgeschwindigkeit einen entscheidenden Einfluss auf die Variabilität der Bewegungsmuster. Beim Rennen auf dem Laufband mit unterschiedlichen Geschwindigkeiten konnten Belli, Lacour, Komi, Candau und Denis (1995) bei 17 Personen, ohne spezielle Vorbildung für die untersuchte Bewegung, zeigen, dass die Variabilität der Bewegungsausführung abhängig von der gewählten Geschwindigkeit ist. Sie fanden heraus, dass die Varianzen der Schrittzeit und der Auslenkung in

vertikaler Richtung mit zunehmender Geschwindigkeit größer werden. Zu vergleichbaren Ergebnissen kamen Li, Haddad und Hamill (2005), die den Einfluss der Geschwindigkeit auf die Stabilität sowie die Variabilität untersuchten. Jordan, Challis und Newell (2007) konnten die Befunde für das Rennen auf dem Laufband für eine Dauer von 40 min. für den Parameter Gangzyklusintervall über 80 %, 90 %, 100 %, 110 % und 120 % der bevorzugten Geschwindigkeit bestätigen. Sie zeigten über acht Personen eine Abnahme des Variationskoeffizienten mit steigender Geschwindigkeit. Auch beim Gehen fanden die Autoren bei 11 Personen in einer Folgestudie vergleichbare Ergebnisse (Jordan, Challis & Newell, 2006). Die Probanden gingen 12 min. auf einem Laufband ebenfalls für 80 % – 120 % der bevorzugten Geschwindigkeit. Sie fanden signifikante Änderungen für Schritintervall und Ganzzyklusintervall, sowie für Ganzzykluslänge und Impuls.

Zusätzlichen Einfluss auf die Varianz der kinematischen Muster hat die Neigung des Untergrunds (Padulo, Annino, Migliaccio, D'Ottavio & Tihanyi, 2012; Slawinski et al., 2008; Telhan et al., 2010). Slawinski et al. (2008) konnten zeigen, dass die Varianz der kinematischen Parameter beim Laufen mit Steigung im Vergleich zur Ebene abnimmt. Die Änderung des Neigungswinkels wirkt sich ebenso auf die absoluten Gelenkwinkel aus und führt in der Sagittalebene zu einer Abnahme des Kniewinkels zum Zeitpunkt Heel Strike um 4 %, des Hüftwinkels um 15 % zum Zeitpunkt Mid Stance, sowie der Gesamtauslenkung des Knies um 38 % und des Sprunggelenks um 17 %.

Im Kontext der aufgezeigten Unterschiede der spezialisierten Leistungssportler und der Breitensportler ohne spezielle Ausbildung, hinsichtlich der Lauftechnik beim Rennen unter differierenden Neigungen und Geschwindigkeiten, wird in der vorliegenden Studie, auf Basis der kinematischen Muster der Ganganalyse, die Gruppenzugehörigkeit von Personen erkannt. Es soll somit gezeigt werden, dass die Muster innerhalb der Gruppen konvergierende Änderungen in Abhängigkeit von Geschwindigkeit und Neigung aufweisen, die mit HMMs klassifiziert werden können. Zusätzlich werden HMMs dazu verwendet, auf Basis der individuellen kinematischen Muster von Personen zu erkennen, mit welcher Geschwindigkeit sowie Neigung eine Person läuft. Es soll so geprüft werden, ob die kinematischen Muster Informationen enthalten, welche Aufschluss über veränderte Randbedingungen im Hinblick auf

Neigung und Geschwindigkeit geben, die mit HMMs klassifiziert werden können. Auf Basis der individuellen kinematischen Muster werden ergänzend die Personen beim Rennen unter den unterschiedlichen Randbedingungen erkannt. Es soll somit festgestellt werden, ob sowohl die Muster der Breitensportler als auch jene der Leistungssportler in Abhängigkeit von veränderten Varianzen in der Bewegungsausführung beim Rennen mit Steigung und Neigung, individuellen Änderungen unterliegen, die Einfluss auf die Klassifizierbarkeit der Muster mit HMMs haben.

## **5.2 Methodik**

### *Stichprobe*

Die Stichprobe der Breitensportler bestand aus 15 männlichen Probanden im Alter von 19 bis 24 Jahren ( $22,73 \pm 1,62$  Jahre;  $1,81 \pm 0,08$  m;  $80,39 \pm 11,93$  kg). Die körperlich sportliche Aktivität wurde mit einem Fragebogen ermittelt (Anhang B), in dem alle Probandenangaben in mindestens einer Sportart, mit einer durchschnittlichen Aktivität von  $428,67 \pm 286,677$  Minuten pro Woche, aktiv zu sein. Alle anthropometrischen Merkmale der Probanden weisen eine Normalverteilung auf ( $p > 0,05$ ).

Die Stichprobe der Leistungssportler bestand aus 18 männlichen Personen im Alter von 19 bis 24 Jahren ( $21,89 \pm 1,81$  Jahre;  $1,82 \pm 0,07$  m;  $68,59 \pm 7,89$  kg). Auch hier weisen die anthropometrischen Merkmale eine Normalverteilung auf ( $p > 0,05$ ). Ihre sportliche Aktivität wurde nicht gesondert erfasst, da über die Teilnahme an Wettkämpfen in den Disziplinen der Lang- und/oder Mittelstrecke auf nationaler Ebene das Leistungsniveau sichergestellt war. Alle Probanden wurden vor Beginn der Untersuchung über den Ablauf aufgeklärt und bestätigten ihre Teilnahme auf freiwilliger Basis.

### *Biomechanische Messwertaufnahme, -verarbeitung und -modellierung*

Die Erfassung der Kinematik von Breitensportlern und Leistungssportlern fand in zwei voneinander unabhängigen Studien statt. Bei einer ersten Untersuchung wurden Leistungssportler, die in einer Laufdisziplin der Lang- oder Mittelstrecke auf nationalem Niveau Wettkämpfe bestritten, auf einem Laufband der Firma HP Cosmos unter Laborbedingungen vermessen. Die Untersuchung wurde am Institut für Sportwissenschaft der Eberhard Karls Universität Tübingen gemeinsam mit Prof. Dr. Veit Wank durchgeführt. Die Probanden liefen bei Steigungen von  $0^\circ - 10^\circ$  (Steigerung in  $2,5^\circ$ -

Schritten) Geschwindigkeiten von  $2 \text{ ms}^{-1}$  –  $5 \text{ ms}^{-1}$  (Steigerung in  $1 \text{ ms}^{-1}$ -Schritten). Zusätzlich wurde in der Ebene mit  $7 \text{ ms}^{-1}$  gerannt und bis zu einer Steigung von  $5^\circ$  mit  $6 \text{ ms}^{-1}$ . Die negativen Steigungen von  $(-2,5^\circ)$  –  $(-10^\circ)$  wurden alle mit Geschwindigkeiten von  $2 \text{ ms}^{-1}$  –  $6 \text{ ms}^{-1}$  absolviert (Tabelle 8). Jede Stufe wurde so lange durchlaufen, bis mindestens zwölf Doppelschritt-Zyklen aufgenommen werden konnten. Die kinematischen Daten der Breitensportler wurden bei Steigungen von  $0^\circ$  –  $7,5^\circ$  und  $(-2,5^\circ)$  –  $(-7,5^\circ)$  mit Geschwindigkeiten von  $2 \text{ ms}^{-1}$  –  $5 \text{ ms}^{-1}$  (Steigerung in  $1 \text{ ms}^{-1}$ -Schritten) am Institut für Sport und Sportwissenschaft des Karlsruher Instituts für Technologie auf einem Laufband der Marke HP Cosmos aufgenommen (Tabelle 8). Auf Grund der physischen Leistungsfähigkeit der Breitensportler konnten keine höheren Geschwindigkeiten absolviert werden, ohne Stürze der Probanden in Kauf zu nehmen.

*Tabelle 8.* Laufgeschwindigkeiten und Neigungen der Laufbandanalyse für Leistungssportler (LS) und Breitensportler (BS) im Vergleich.

Steigung	Geschwindigkeit [ $\text{ms}^{-1}$ ]					
	2	3	4	5	6	7
0,0	LS/BS	LS/BS	LS/BS	LS/BS	LS	LS
2,5	LS/BS	LS/BS	LS/BS	LS/BS	LS	-
5,0	LS/BS	LS/BS	LS/BS	LS/BS	LS	-
7,5	LS/BS	LS/BS	LS/BS	LS/BS	-	-
10,0	LS	LS	LS	LS	-	-
-2,5	LS/BS	LS/BS	LS/BS	LS/BS	LS	-
-5,0	LS/BS	LS/BS	LS/BS	LS/BS	LS	-
-7,5	LS/BS	LS/BS	LS/BS	LS/BS	LS	-
-10,0	LS	LS	LS	LS	LS	-

Die kinematischen Daten der Leistungssportler wurden mit zehn Infrarotkameras erfasst. Für die Analyse der Breitensportler (Abbildung 50) standen zwölf Infrarotkameras zur Verfügung. Die Aufnahmen erfolgten für beide Stichproben mit einer Frequenz von 250 Hz. Die Stichprobe der Leistungssportler wurde mit der VICON® Workstation Software (Vers. 5.2.9) erfasst. Für die Stichprobe der Breitensportler stand die neue VICON® Nexus (Vers. 1.7X) Software zur Verfügung. Zusätzlich zu den Infrarotkameras wurden die Läufe mit jeweils einer synchronisierten DV-Videokamera aufgezeichnet.




Abbildung 50. Testaufbau für die Analyse von Breitensportlern. Steigung:  $0^\circ$ , Geschwindigkeit:  $5 \text{ ms}^{-1}$ .

Die Bereinigung der Daten erfolgte für beide Gruppen analog zu dem in Kapitel 3.2 beschriebenen Verfahren. Lücken in Positions-Zeit Verläufen, die mehr als zehn Frames in Folge umfassten, wurden nicht gefüllt. Gangzyklen mit verbliebenen Lücken wurden als ungültig nicht in die Auswertung mit einbezogen. Die bereinigten Markerdaten beider Gruppen wurden in VICON® Nexus mit Plug-In Gait (VICON®, 2002) kinematisch modelliert und als ASCII-Daten exportiert (Anhang A). Die Segmentierung der Gangzyklen erfolgte in MATLAB auf Basis der Vertikalkomponente der Positionsdaten der Fersen- (L/R-HEE) und Zehenmarker (L/R-TOE). Neben der automatischen Detektion der Bodenkontakte wurden die Zeitpunkte über eine grafische Darstellung visuell kontrolliert, um eine hohe Güte der Segmentierung sicherzustellen. Alle Winkel-Zeit Verläufe wurden in MATLAB mit einem Butterworthfilter 4. Ordnung und mit einer CutOff Frequenz von 20 Hz gefiltert (Kapitel Anhang A, Abbildung 1). Der mittlere Kniewinkel zum Zeitpunkt Heel Strike wurde über die Winkel LKneeAngles und RKneeAngles des Plugin Gait Modells (VICON®, 2002) berechnet.

### *Stochastische Modellierung*

Die Modellierung der HMMs erfolgte analog zu dem in Kapitel 3.2 beschriebenen Verfahren.

### *Datenanalyse*

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet. Ergänzend erfolgte eine statistische Auswertung der Daten in IBM SPSS Statistics (Vers. 19). Das Signifikanzniveau wurde auf 5 % ( $p \leq 0,05$ ) festgelegt. Mittels t-Tests (intervallskaliert und normalverteilt) wurden Unterschiede in diskreten Parametern (Schrittlänge, Schrittlängenänderung, Schrittfrequenz, Bodenkontaktzeit, Flugzeit, mittlerer Kniewinkel bei Heel Strike) festgestellt, bzw. des Mann-Whitney-U-Tests ermittelt. Korrelationen wurden mittels Spearmans Rangkorrelation bzw. der Pearson Korrelation ermittelt.

Für die Klassifikation des Grades der Spezialisierung wurde jeweils ein HMM für die Gruppe der Breitensportler und eines für die Gruppe der Leistungssportler für vier Neigungen ( $-5^\circ$ ;  $0^\circ$ ;  $2,5^\circ$ ;  $7,5^\circ$ ) und zwei Geschwindigkeiten ( $2 \text{ ms}^{-1}$ ;  $5 \text{ ms}^{-1}$ ) trainiert. Für jede Gruppe wurde pro Bedingung (4 Steigungen  $\times$  2 Geschwindigkeiten = 8 Bedingungen) ein Merkmalsvektor erstellt, der die Gelenkwinkelverläufe der unteren Extremität (L/R-AnkleAngles, L/R-KneeAngles, L/R-HipAngles) und des Beckens (L/R-PelvisAngle) in drei Dimensionen über zehn Schrittzyklen von zehn zufällig ausgewählten Personen enthielt. Das Training der HMMs erfolgte anhand dieser Merkmalsvektoren (2100 Winkel-Zeitverläufe; 100 Schrittzyklen pro Gruppe und Merkmal). Die Daten von fünf Personen jeder Gruppe wurden für die Bestimmung der Erkennungsleistung eingesetzt (1050 Winkel-Zeit Verläufe; 50 Schrittzyklen je Gruppe).

Für die Erkennung der Neigungen ( $-5^\circ$ ;  $0^\circ$ ;  $2,5^\circ$ ;  $7,5^\circ$ ) wurde für beide Gruppen jeweils ein HMM je Neigung für zwei Geschwindigkeiten ( $2 \text{ ms}^{-1}$ ;  $5 \text{ ms}^{-1}$ ) mit den Daten der zehn zufällig ausgewählten Personen mit den Merkmalsvektoren trainiert (s.o.).

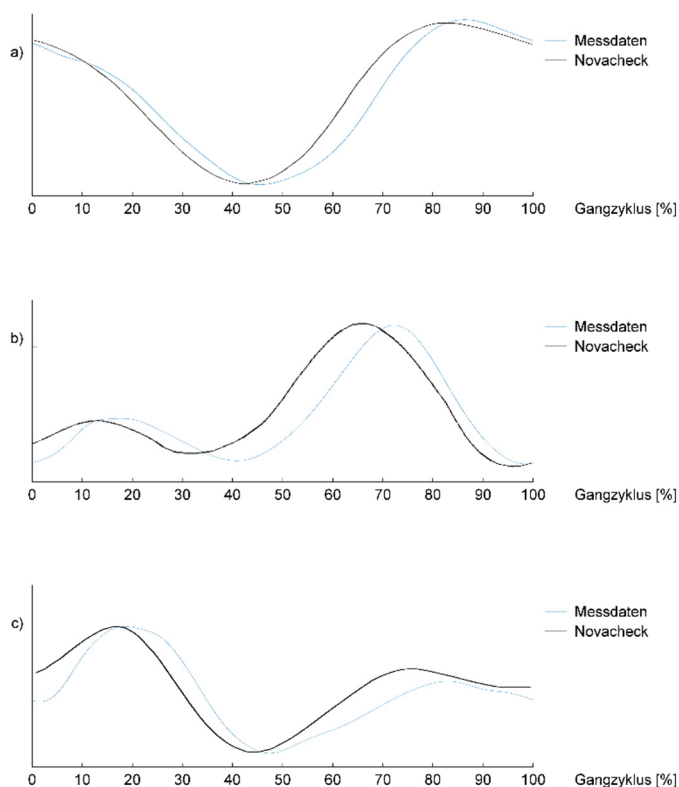
Zusätzlich wurde für die Klassifizierung der Personen für jede Person beider Gruppen ein HMM mit jeweils einem Merkmalsvektor trainiert, der die Winkel-Verläufe (s.o.) von zehn Schrittzyklen enthielt. Dies wurde für zwei Geschwindigkeiten ( $2 \text{ ms}^{-1}$ ;  $5 \text{ ms}^{-1}$ ) bei Steigungen von  $0^\circ$  und  $7,5^\circ$  durchgeführt.



### 5.3 Ergebnisse

#### *Analyse der Plausibilität der Messdaten*

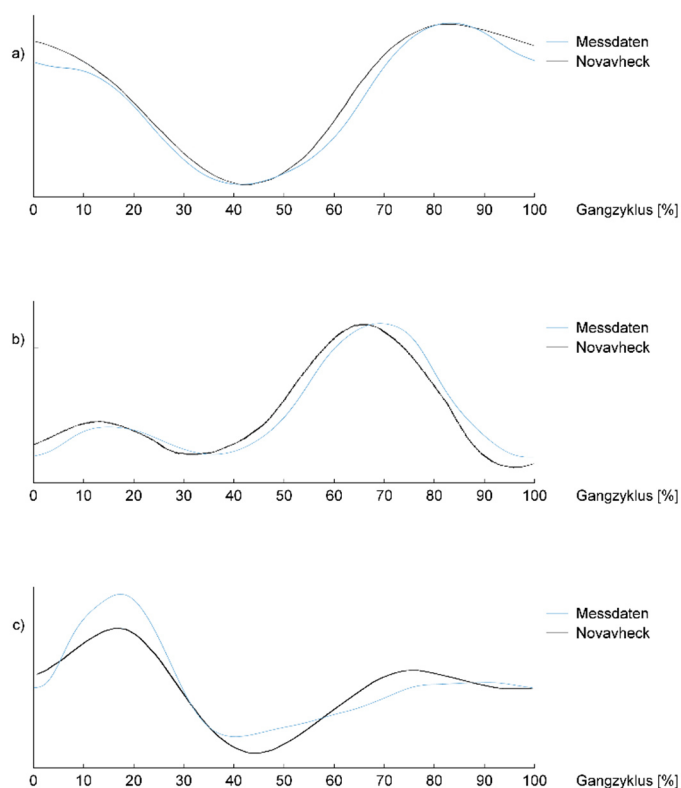
Um die Güte der Daten sicherzustellen, wurden die Gelenkwinkel der unteren Extremität einer Prüfung unterzogen und mit Ergebnissen vergleichbaren Analysen aus der Literatur im Hinblick auf Geschwindigkeit und Stichprobe gegenübergestellt.



**Abbildung 51.** Vergleich der Winkelverläufe in der Sagittalebene von Hüfte (a), Knie (b) und Sprunggelenk (c) der Breitensportler zu skalierten Normwerten (Rennen in der Ebene mit 3 ms<sup>-1</sup>) (Novacheck, 1998).


Der Vergleich der Kurvenverläufe der Sportstudierenden für die Winkeldaten der unteren Extremität mit den skalierten Verläufen von Novacheck (1998) für eine Geschwindigkeit von 3 ms<sup>-1</sup>, zeigt starke Ähnlichkeiten im Verlauf (Abbildung 51). Auffallend ist, dass die Messwerte dieser Studie über alle Winkelverläufe verglichen mit den Verläufen von Novacheck eine Rechtsverschiebung im Winkel-Zeit-Diagramm aufweisen. Der Versatz lässt sich auf die unterschiedliche Detektion der Events Heel Strike und Toe Off zurückführen und beruht nicht auf Differenzen in den Messdaten. Dies müsste für die Berechnung von Parametern, die auf Basis der prozentualen Verteilung des Gangzyklus bestimmt werden, berücksichtigt werden. Da Events für diese Studie ausschließlich im Sinne einer Segmentierung der sich zyklisch

wiederholenden Daten von Bedeutung sind, hat der zeitliche Versatz hier keinen Einfluss und kann vernachlässigt werden.




*Abbildung 52.* Vergleich der Winkelverläufe in der Sagittalebene von Hüfte (a), Knie (b) und Sprunggelenk (c) der Leistungssportler zu skalierten Normwerten (Rennen in der Ebene mit  $3 \text{ ms}^{-1}$ ) (Novacheck, 1998).

Der Vergleich der Kurvenverläufe der Leistungssportler für die Winkeldaten der unteren Extremität mit den skalierten Verläufen von Novacheck (1998) für eine Geschwindigkeit von  $3 \text{ ms}^{-1}$ , zeigt ebenfalls für das Hüft- (a) und Kniegelenk (b) starke Ähnlichkeiten im Verlauf (Abbildung 52). Im Sprunggelenk (c) zeigen sich Unterschiede im Verlauf der Plantar-/Dorsiflexion, deren Ursache auf Abweichungen in der Lauftechnik zwischen Leistungssportler und Breitensportler zurückgeführt werden kann. Wiederum zeigt sich die Rechtsverschiebung im Winkel-Zeit-Diagramm auf Grund der unterschiedlich detektierten Events im Vergleich zu Novacheck (1998).



**Abbildung 53.** Summenhäufigkeits-Wahrscheinlichkeiten der 15 Breitensportler für Winkel von Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Summenhäufigkeits-Wahrscheinlichkeiten (rot) zum Zeitpunkt Heel Strike bei einer Geschwindigkeit von  $3 \text{ ms}^{-1}$  in der Ebene.

Die Summenhäufigkeitsfunktion wird exemplarisch für den Zeitpunkt Heel Strike über die Gelenkwinkel von Hüfte, Knie und Sprunggelenk in der Sagittalebene beim Rennen in der Ebene dargestellt. Die Gruppierung der Wahrscheinlichkeits-Winkeldaten-Werte der Sportstudierenden für die Gelenke Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Wahrscheinlichkeits-Winkeldaten-Funktion (rot) in Abbildung 53 weist auf die Normalverteilung der Winkelverläufe zum Zeitpunkt Heel Strike hin. Die Normalverteilung wurde über alle detektierten Zeitpunkte hinweg überprüft und wies vergleichbare Ergebnisse auf.



**Abbildung 54.** Summenhäufigkeits-Wahrscheinlichkeiten der 18 Leistungssportler für Winkel von Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Summenhäufigkeits-Wahrscheinlichkeiten (rot) zum Zeitpunkt Heel Strike bei einer Geschwindigkeit von  $3 \text{ ms}^{-1}$  in der Ebene.

Die Gruppierung der Wahrscheinlichkeits-Winkeldaten-Werte der Sportstudierenden für die Gelenke Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Wahrscheinlichkeits-Winkeldaten-Funktion (rot) in Abbildung 54, weist auf die Normalverteilung der Winkelverläufe zum Zeitpunkt Heel Strike hin. Die Normalverteilung wurde über alle detektierten Zeitpunkte hinweg überprüft und an dieser Stelle nur stellvertretend für den Zeitpunkt Heel Strike angeführt. Ergänzend wurden die

räumlich-zeitlichen Kenngrößen *Schrittlänge*, *Schrittfrequenz* und *Kniewinkel* für die unterschiedlichen Bedingungen bestimmt.

### *Schrittlänge*

Über alle Neigungen war die Schrittlänge der Breitensportler bei  $5 \text{ ms}^{-1}$  signifikant kürzer als die der Leistungssportler. Über beide Gruppen zeigte sich eine Verringerung der Schrittlänge mit steigender Geschwindigkeit. Für eine Steigung von  $5^\circ$  bei einer Geschwindigkeit von  $5 \text{ ms}^{-1}$  konnten signifikante Unterschiede zwischen Breitensportlern und Leistungssportlern gefunden werden. Ebenfalls signifikante Unterschiede wurden bei  $7^\circ$  Steigung und  $5 \text{ ms}^{-1}$  und einem Gefälle von  $-2^\circ$ ,  $-5^\circ$  und  $-7^\circ$  bei einer Geschwindigkeit von  $5 \text{ ms}^{-1}$  gefunden (Tabelle 9).

*Tabelle 9.* Vergleich der Schrittlängen zwischen Breiten- und Leistungssportlern über Geschwindigkeit und Neigung. Signifikante Unterschiede sind mit \* gekennzeichnet.

Neigung	Geschwindigkeit [m/s]	Schrittlänge Breitensportler [m]	Schrittlänge Leistungssportler [m]	Signifikanzwert (p)
0°	2	0,78 ± 0,44	0,79 ± 0,04	-
	5	1,66 ± 0,18	1,70 ± 0,09	-
2°	2	0,78 ± 0,04	0,79 ± 0,04	-
	5	1,60 ± 0,10	1,67 ± 0,09	-
5°	2	0,78 ± 0,037	0,78 ± 0,03	-
	5	1,52 ± 0,12*	1,62 ± 0,07*	0,019
7°	2	0,78 ± 0,03	0,78 ± 0,04	-
	5	1,42 ± 0,8*	1,54 ± 0,08*	0,001
-2°	2	0,78 ± 0,04	0,79 ± 0,04	-
	5	1,63 ± 0,07*	1,73 ± 0,07*	0,007
-5°	2	0,78 ± 0,05	0,81 ± 0,04	-
	5	1,66 ± 0,11*	1,75 ± 0,08*	0,024
-7°	2	0,80 ± 0,06	0,82 ± 0,04	-
	5	1,67 ± 0,12*	1,75 ± 0,09*	0,049

Bei Neigungen von  $5^\circ$ ,  $7,5^\circ$ ,  $-2,5^\circ$  und  $-5,0^\circ$  konnten sowohl für die Breiten-, als auch für die Leistungssportler signifikante Unterschiede in der Änderung der Schrittlänge über die Geschwindigkeiten von  $2 \text{ ms}^{-1}$  und  $5 \text{ ms}^{-1}$  ermittelt werden. (Tabelle 10).

*Tabelle 10.* Vergleich der Schrittlängen zwischen Breiten- und Leistungssportlern über Geschwindigkeit und Neigung. Signifikante Unterschiede sind mit \* gekennzeichnet.

Steigung [°]	Breitensportler	Leistungssportler
	mittlere Schrittlängenänderung [m]	
0	0,89 ± 0,19	0,91 ± 0,10
2,5	0,82 ± 0,09	0,88 ± 0,07
5,0	0,74 ± 0,10*	0,83 ± 0,06*
7,5	0,64 ± 0,08*	0,76 ± 0,06*
-2,5	0,85 ± 0,10*	0,95 ± 0,06*
-5,0	0,88 ± 0,10*	0,95 ± 0,07*
-7,5	0,87 ± 0,10	0,93 ± 0,08

Die Befunde bezüglich der Schrittlänge decken sich mit den Befunden aus der Literatur. Cavanagh und Kram (1989) stellten fest, dass sich Schrittlänge mit einem Anstieg der Geschwindigkeit erhöht. Novacheck (1998) konnte diese Befunde bestätigen und zeigen, dass sich die Schrittlänge mit steigender Geschwindigkeit durch einen Anstieg des Flexionswinkels in der Hüfte verlängert.

Bezüglich der Schrittlängenänderung im Kontext einer veränderten Neigung zeigten Paradisis und Cooke (2001), dass beim Rennen bergab eine höhere Renngeschwindigkeit über die Vergrößerung der Schrittlänge erreicht wird. Sowohl Gottschall und Kram (2005) als auch Telhan et al. (2010) konnten diesbezüglich keine signifikanten Unterschiede finden, berichten aber von einer entsprechenden Tendenz. Bezüglich des Rennens mit positiver Steigung stellten Padulo et al. (2012) fest, dass bei gleichbleibender Geschwindigkeit eine größere Steigung mit der Verkürzung der Schrittlänge einhergeht. Zu vergleichbaren Ergebnissen kamen auch Paradisis und Cooke (2001), Gottschall und Kram (2005), Telhan et al. (2010) sowie Silverman, Wilken, Sinitski und Neptune (2012).

### Schrittfrequenz

Für den Vergleich der Schrittfrequenz (Tabelle 11) zeigten sich erwartungsgemäß ähnliche Ergebnisse wie für die Schrittlänge. Für eine Geschwindigkeit von  $5 \text{ ms}^{-1}$  konnten bei Steigungen von  $2^\circ$ ,  $5^\circ$  und  $7^\circ$ , sowie beim Bergabrennen mit  $-2^\circ$ ,  $-5^\circ$  und  $-7^\circ$  signifikante Unterschiede zwischen den Gruppen gefunden werden.

Tabelle 11. Vergleich der Schrittlängen zwischen Breiten- und Leistungssportlern über Geschwindigkeit und Neigung. Signifikante Unterschied sind mit \* gekennzeichnet.

Neigung	Geschwindigkeit [m/s]	Schrittfrequenz Breitensportler [1/s]	Schrittfrequenz Leistungssportler [1/s]	Signifikanzwert (p)
0°	2	155,14 ± 8,51	152,28 ± 7,50	-
	5	184,46 ± 11,47	177,36 ± 9,68	-
2°	2	155,35 ± 8,62	152,72 ± 8,81	-
	5	188,29 ± 11,77*	179,71 ± 8,57*	0,045
5°	2	154,45 ± 7,73	154,02 ± 6,63	-
	5	198,12 ± 14,61*	185,93 ± 8,75*	0,012
7°	2	153,36 ± 5,98	155,89 ± 8,23	-
	5	211,58 ± 10,62*	196,41 ± 10,75*	0,001
-2°	2	154,97 ± 8,22	153,67 ± 7,09	-
	5	185,05 ± 12,56*	173,64 ± 7,06*	0,006
-5°	2	154,19 ± 9,13	148,89 ± 7,38	-
	5	181,11 ± 12,81*	171,44 ± 7,53*	0,021
-7°	2	150,84 ± 11,31	146,43 ± 8,65	-
	5	180,88 ± 12,90*	172,18 ± 8,61*	0,044

Auch diese Ergebnisse können durch die analysierte Literatur gestützt werden.

Cavanagh und Kram (1989) berichten von einem geringen Anstieg der Schrittfrequenz (ca. 4%) bei einer Steigerung der Geschwindigkeit auf dem Laufband. Padulo et al. (2012) fanden heraus, dass eine zunehmende Steigung bei gleichbleibender Geschwindigkeit mit einer Erhöhung der Schrittfrequenz einhergeht. Die Ergebnisse wurden durch die Untersuchungen von Paradisis und Cooke (2001), Gottschall und Kram (2005), sowie Telhan et al. (2010) und Silverman et al. (2012) bestätigt.

### *Kniewinkel*

Für den Kniewinkel konnten für den Zeitpunkt Toe Off keine signifikanten Unterschiede zwischen den Gruppen festgestellt werden. Für den Zeitpunkt Heel Strike (Tabelle 12) zeigten sich bei 2 ms<sup>-1</sup> für alle Neigungen Signifikanzen. Für eine Geschwindigkeit von 5 ms<sup>-1</sup> wiesen die Winkel nur bergab einen signifikanten Unterschied auf. Über die Geschwindigkeit betrachtet wiesen die Winkel mit steigender Geschwindigkeit auf eine stärkere Beugung im Kniegelenk zum Zeitpunkt Heel Strike hin. Über die Geschwindigkeiten zeigte das Knie zum Zeitpunkt Heel Strike für beide Gruppen mit zunehmender Steigung ebenfalls einen signifikant größeren Flexionswinkel.

*Tabelle 12.* Vergleich der Kniewinkel in der Sagittalebene zwischen Breiten- und Leistungssportlern über Geschwindigkeit und Neigung zum Zeitpunkt Heel Strike. Signifikante Unterschiede sind mit \* gekennzeichnet.

Neigung	Geschwindigkeit [m/s]	Kniewinkel Breitensportler [°]	Kniewinkel Leistungssportler [°]	Signifikanzwert (p)
0°	2	7,45 ± 3,22*	11,72 ± 4,90*	0,016-
	5	9,99 ± 5,38	15,16 ± 9,2	-
2°	2	8,68 ± 4,35*	14,01 ± 5,84*	0,015
	5	14,62 ± 4,83	15,93 ± 5,84	-
5°	2	10,64 ± 4,28*	15,75 ± 6,53*	0,013
	5	17,93 ± 6,52	16,71 ± 5,07	-
7°	2	13,05 ± 5,66*	18,43 ± 5,67*	0,023
	5	23,68 ± 6,55	22,62 ± 7,80	-
-2°	2	5,89 ± 2,97*	11,44 ± 3,83*	0,000-
	5	9,05 ± 4,27*	15,67 ± 5,57*	0,001
-5°	2	5,45 ± 2,86*	11,97 ± 5,39*	0,001
	5	7,30 ± 3,24*	13,78 ± 5,01*	0,000
-7°	2	6,78 ± 3,99*	12,74 ± 6,32*	0,008
	5	8,04 ± 3,23*	14,71 ± 6,17*	0,002

Sowohl Swanson und Caldwell (2000), als auch Slawinski et al. (2008) zeigten in Ihren Studien ähnliche Befunde. Sie bestätigten den höheren Flexionswinkel zum Zeitpunkt des Fersenaufsatzes und konnten ebenso keine signifikanten Unterschiede für den Zeitpunkt Toe Off finden.

### *Erkennungsleistung der HMMs*

Die Klassifikation des *Spezialisierungsgrades* (Tabelle 13) zeigte Erkennungswahrscheinlichkeiten zwischen 89,7 % und 100 % über alle Merkmalsvektoren. Die

Muster beim Rennen in der Ebene und mit 2,5° und 5° Steigung konnten bei einer Geschwindigkeit von 5 ms<sup>-1</sup> mit einer Wahrscheinlichkeit von 100 % klassifiziert werden.

Tabelle 13. Erkennungswahrscheinlichkeiten der Spezialisierung (Breitensportler/Leistungssportler) über unterschiedliche Geschwindigkeiten und Steigungen.

Geschwindigkeit [m/s]	2				5			
	Steigung [°]							
	-5	0	2,5	7,5	-5	0	2,5	7,5
Erkennungsrate [%]	89,7	96,9	97,2	99,6	98,3	100	100,0	100,0

Die *Randbedingung* Geschwindigkeit konnte mit einer Wahrscheinlichkeit zwischen 96,3 % und 100 % über alle getesteten Merkmalsvektoren klassifiziert werden (Tabelle 14). Die Leistungssportler zeigten über das Rennen in der Ebene und mit positiver Steigung die höchsten Erkennungswahrscheinlichkeiten zwischen 99,3 % (2,5° Steigung) und 100 % (Ebene und 5° Steigung). Die Geschwindigkeiten konnten beim Rennen mit negativer Steigung mit 96,3 % für Breitensportler und 98,3 % für Leistungssportler mit der niedrigsten Wahrscheinlichkeit klassifiziert werden.

Tabelle 14. Erkennungswahrscheinlichkeiten der Geschwindigkeit über unterschiedliche Spezialisierungen und Steigungen.

Spezialisierung Steigung [°]	Breitensportler				Leistungssportler			
		-5	0	2,5	7,5	-5	0	2,5
Erkennungsrate [%]	96,3	99,2	99,4	98,1	98,3	100	99,3,0	100,0

Die *Randbedingung* Steigung konnte mit einer Wahrscheinlichkeit von 84,7 % – 99,7% auf Basis der Merkmalsvektoren korrekt zugeordnet werden. Die niedrigsten Erkennungswahrscheinlichkeiten ergaben sich mit 84,7 % – 89,6 % für beide Gruppen, sowohl bei 2ms<sup>-1</sup>, als auch bei 5 ms<sup>-1</sup> für das Rennen in der Ebene und mit Steigungen von ±2,5°. Bei Steigungen von ±7,5° konnte sowohl für die Breitensportler, als auch für die Leistungssportler die beste Klassifikationsleistung erzielt werden (Tabelle 15).



Tabelle 15. Erkennungswahrscheinlichkeiten der Steigung über unterschiedliche Spezialisierungen und Geschwindigkeiten.

Geschwindigkeit [m/s]	Spezialisierung	Steigung [°]						
		-7,5	-5	-2,5	0	2,5	5	7,5
		Erkennungsrate [%]						
2	Breitensportler	97,6	96,7	84,7	87,2	86,5	96,6	97,1
	Leistungssportler	99,3	96,7	87,0	89,6	85,4	96,3	98,4
5	Breitensportler	98,9	96,8	86,9	89,6	88,0	97,8	98,9
	Leistungssportler	99,6	96,9	87,7	89,3	89,6	97,1	99,7

Bei der *Personenerkennung* beider Gruppen konnten sowohl für das Rennen mit  $2 \text{ ms}^{-1}$  als auch für das Rennen mit  $5 \text{ ms}^{-1}$  Personen mit einer Wahrscheinlichkeit von 100 % anhand der Muster der Winkel-Zeit Verläufe der unteren Extremität klassifiziert werden (Tabelle 16).

Tabelle 16. Erkennungswahrscheinlichkeiten der Personen über unterschiedliche Geschwindigkeiten und Steigungen.

Geschwindigkeit [m/s]	Steigung [°]		
	-7,5	0	7,5
Erkennungsrate [%]			
2	100	100	100
5	100	100	100

## 5.4 Diskussion

Ziel der vorliegenden Studie war es, auf Basis der Winkle-Zeit Verläufe einer Ganganalyse bei unterschiedlichen Neigungen und Geschwindigkeiten auf dem Laufband mit HMMs, die Bewegungsmuster von Breitensportlern und Leistungssportlern zu klassifizieren. Auf diese Weise sollte gezeigt werden, dass sich in Abhängigkeit von Geschwindigkeit und Neigung konvergierende Änderungen über die Muster der Gruppen ergeben, die im Hinblick auf die *Spezialisierung* mit HMMs klassifiziert werden können. Ergänzend hierzu wurde eine Erkennung von Geschwindigkeit und Neigung auf Basis der individuellen kinematischen Muster durchgeführt. Dies sollte Aufschluss darüber geben, ob die Muster der Personen über Informationen verfügen, die eine Klassifizierung der *Randbedingungen* ermöglichen. Die *Personenerkennung* auf Basis der individuellen kinematischen Muster sollte zeigen, inwieweit sich Varianzen in der Bewegungsausführung im Kontext veränderter Randbedingungen zeigen und diese Einfluss auf die Differenzierbarkeit der Personen haben. Die Analyse

der Plausibilität der Daten hat gezeigt, dass die räumlich-zeitlichen Parameter, die in dieser Studie verwendet wurden, sowohl bezüglich der Gruppen, als auch im Hinblick auf Steigung und Geschwindigkeit hinsichtlich der Befunde aus der Literatur vergleichbare Werte aufweisen.

### *Spezialisierung*

Die Erkennung der Spezialisierung in dieser Studie zeigte insbesondere für die Geschwindigkeit von  $5 \text{ ms}^{-1}$  beim Rennen in der Ebene und mit positiver Steigung hohe Erkennungsraten von 100 %. Sowohl bei negativer Steigung als auch beim Rennen mit  $2 \text{ ms}^{-1}$  in der Ebene und mit positiver Steigung, lagen die Erkennungswahrscheinlichkeiten mit 89,7 % – 99,6 % niedriger. Die Unterschiede in der Klassifikationsleistung lassen sich dahingehend interpretieren, dass vor allem Bewegungen unter erschwerten Randbedingungen im Kontext von Steigung und Geschwindigkeit Muster enthalten, die eine Differenzierung der Spezialisierung über HMMs ermöglichen. Die Annahme wird von den Ergebnissen von Padulo et al. (2012) und Nakayama et al. (2010) gestützt, die Unterschiede in der Kinematik und der Bewegungsvariabilität von ungeübten und geübten Läufern beim Rennen mit unterschiedlichen Geschwindigkeiten in der Ebene und mit Steigungen fanden.

### *Randbedingungen*

Die Klassifikation der Geschwindigkeit konnte über alle Probanden hinweg mit einer Wahrscheinlichkeit von 96,3 % – 100 % erfolgen. Die geringe Variabilität in der Bewegungsausführung bei spezialisierten Leistungssportler (Nakayama et al., 2010) begründet die höchsten Erkennungsraten für diese Gruppe. Die nicht korrekt klassifizierten Muster lassen sich auf eine Variabilität der Geschwindigkeit beim Rennen auf dem Laufband zurückführen (Wank, Frick & Schmidtbleicher, 1998). Auf Grund des Handlungsspielraumes im Sinne einer Änderung der Position des Läufers in Relation zum Laufband handelt es sich beim Rennen auf dem Laufband nur um ein quasi-stationäres Rennen. Die Änderung der Position des Läufers geht dabei mit einer Änderung der relativen Bewegungsgeschwindigkeit einher. In diesem Kontext liegt die Vermutung nahe, dass die pauschale Zuordnung der Gangzyklen auf Basis der Laufbandgeschwindigkeit zu einer Verfälschung der Klassifikationsergebnisse geführt hat. Die Überprüfung der Relativgeschwindigkeit Läufer – Laufband über die

Gangzyklen wurde nicht durchgeführt. Eine Validierung der Geschwindigkeit und somit der falschen Klassifikationen ist aus diesem Grund nur auf Basis der Laufbandgeschwindigkeit möglich.

Die Klassifikation der Laufbandneigung konnte zu 84,7 % – 99,7 % realisiert werden. Insbesondere beim Laufen in der Ebene und den geringen Laufbandsteigungen von  $\pm 2,5^\circ$  kam es zu Fehlern bei der Erkennung. Die größere Varianz in der Bewegungsausführung bei geringen Geschwindigkeiten und einer geringen Anforderung an die physische Leistungsfähigkeit, führte zu einer Überlagerung von Mustern unterschiedlicher Steigung. Mit zunehmender Geschwindigkeit und Laufbandneigung nahm die Klassifikationsleistung erwartungsgemäß zu. Das lässt auf Basis der Erkennungswahrscheinlichkeiten vermuten, dass bei niedrigen Geschwindigkeiten und Neigungen eine hohe Variabilität beobachtet werden kann und bei hohen Geschwindigkeiten und Neigungen die Randbedingungen den Bewegungsspielraum einschränken und somit die Ausführung weniger variabel wird. Diese Annahme kann durch vorangestellte statistische Analyse von Schrittlänge, Schrittfrequenz und Kniewinkel für die räumlich-zeitlichen Parameter dieser Studie bestätigt werden und wird durch die Befunde von Janssen et al. (2011) bestätigt.

### *Personenerkennung*

Analog zu Studie 2 konnte über die Winkel-Zeit Verläufe von Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles), Sprunggelenk (L/R-AnkleAngles) und Becken (L/R-PelvisAngles) eine Erkennungsleistung der Personen von 100 % erreicht werden. Diese Ergebnisse decken sich mit Studien zur Mustererkennung beim Gehen/Rennen, bei denen vergleichbare Erkennungsraten mit SVMs (Fukuchi et al., 2011) und SOMs (Janssen et al., 2011; Schöllhorn et al., 2002) erreicht werden konnten. Studien zur Erkennung von Personen beim Gehen mit HMMs lieferten auf der Basis von Funktionsparametern, die aus Videosequenzen extrahiert wurden, mit Erkennungsraten von 93 % – 100% ähnliche Klassifikationsleistungen (Cheng et al., 2008) und bestätigen die Ergebnisse dieser Studie.

Im Kontext der Ergebnisse dieser Studie eröffnet sich die Frage, in wieweit Varianzen in der Bewegungsausführung beim Gehen unter natürlichen Bedingungen, ohne die durch das Laufband induzierten Zwangsbedingungen, zu einer Überlagerung von

Bewegungsmustern führen. Studien von Nigg, Boer und Fisher (1995), Wank et al. (1998), Alton, Baldey, Caplan und Morrissey (1998) sowie Dingwell, Cusumano, Cavanagh und Sternad (2001) konnten Unterschiede in den räumlich-zeitlichen Parametern finden und eine Zunahme der Varianz in der Bewegungsausführung aufzeigen.

## 6 Studie 4: Erkennung von unterschiedlichen Untergründen mit Hidden Markov Modellen

### 6.1 Einleitung

In den vorangegangenen Studien konnte gezeigt werden, dass Bewegungsmuster beim Gehen und Rennen auf normalem Untergrund in standardisierter Laborumgebung durch die konstruierten HMMs mit gewählter Topologie gut abgebildet werden können, und sowohl Personen mit unterschiedlicher Expertise als auch verschiedene Randbedingungen (Neigungen) beim stationären Gehen und Rennen auf dem Laufband klassifiziert werden können. In Bezug auf die Reproduzierbarkeit der Bewegung unter diesen Bedingungen kann, wie in Kapitel 2.1 beschrieben, davon ausgegangen werden, dass die Muster der Winkeldaten auf Grund der zyklischen Natur der automatisiert ablaufenden Bewegung minimale intraindividuelle Varianzen aufweisen, interindividuell aber gut differenzierbar sind. Bezüglich der Erkennung von Personen sollen in dieser Studie Gehbewegungen untersucht werden, die zum einen im Kontext einer praxisnahen Ganganalyse erfasst werden, zugleich aber, durch eine höhere Varianz in der Bewegungsausführung, eine Generalisierungsfähigkeit des Modells für eine erfolgreiche Klassifikation voraussetzen. Im Kontext dieser Randbedingungen soll das Gehen auf unterschiedlichen Untergründen untersucht werden.

Thies, Richardson und Ashton-Miller (2005) beschreiben in ihrer Studie die Einflüsse von unebenem Untergrund und schlechten Lichtverhältnissen auf die Schrittbreite, Schrittdauer und die frei gewählte Ganggeschwindigkeit. Zwölf gesunde junge Frauen ( $22,2 \pm 3$  Jahre) und zwölf gesunde ältere Frauen ( $70,2 \pm 4,1$  Jahre) gingen mit einer frei gewählten Geschwindigkeit über einen 10m langen Laufsteg, auf dem unterschiedliche Untergründe aufgebracht wurden. Der ebene Untergrund bestand aus handelsüblichen Vinyl-Bodenplatten. Die Konstruktion eines unebenen Untergrunds wurde mit dreieckigen Holzprismen (H:1,5 cm, B:3,5 cm, L: 6 – 16 cm; 26 Stück / qm), die stochastisch unter einem Teppich verteilt wurden, realisiert. Die vier unterschiedlichen Bedingungen (1) ebener Boden bei normaler Beleuchtung (927 Lux), (2) ebener Boden bei schwacher Beleuchtung (47 Lux), (3) unebener Boden bei normaler Beleuchtung und (4) unebener Boden bei schlechter Beleuchtung, wurden in randomisierter Reihenfolge getestet. Zur Erfassung der Bodenkontakte wurde

standardisiertes Schuhwerk im Ballen- und Fersenbereich mit Kraftmessdosen instrumentiert. Die Kinematik der Gehbewegung wurde mit einem Videosystem unter Verwendung von aktiven Sensoren aufgezeichnet, die an den Füßen und der Taille der Probanden befestigt wurden. Die Funktionsparameter Ganggeschwindigkeit (Tailenmarker), Schrittbreite (Fußmarker) und Schrittdauer (Kraftsensoren) wurden bestimmt. Es konnten signifikante Unterschiede hinsichtlich der Schrittweitenvariabilität über den Untergrund, der Schrittdauer über den Untergrund und der Schrittdauervariabilität über den Untergrund festgestellt werden (Tabelle 17). Im Vergleich zum ebenen Untergrund vergrößerte sich die Schrittdauervariabilität auf unebenem Untergrund um 54,2 %. Hinsichtlich einer Veränderung der Schrittbreite und einer Anpassung der Ganggeschwindigkeit konnten die Autoren keine signifikanten Unterschiede finden.

*Tabelle 17.* Vergleich der Mittelwerte räumlich-zeitlicher Parameter gesunder junger Frauen ( $\pm$  Standardabweichung) beim Gehen auf unterschiedlichen Untergründen (Thies, Richardson, & Ashton-Miller, 2005, S. 29).

<b>Gangparameter</b>	<b>eben</b>	<b>uneben</b>	<b>p-Wert</b>
Schrittweite [mm]	133,6 ( $\pm$ 8,49)	132,1 ( $\pm$ 8,66)	
Schrittweitenvariabilität [mm]	25,0 ( $\pm$ 1,7)	30,3 ( $\pm$ 1,35)	0,012
Schrittdauer [s]	0,58 ( $\pm$ 0,02)	0,60 ( $\pm$ 0,02)	0,040
Schrittdauervariabilität [s]	1,08 ( $\pm$ 0,06)	0,037 ( $\pm$ 0,003)	0,004
Geschwindigkeit [m/s]	1,08 ( $\pm$ 0,06)	1,05 ( $\pm$ 0,06)	

Die Autoren schlussfolgerten, dass unebene Untergründe die Variabilität der Schrittbreite und der Schrittdauer erhöhen. Die Ergebnisse dieser Studie decken sich mit den Befunden von Menz, Lord und Fitzpatrick (2003) sowie Thies et al. (2005).

Müller und Blickhan (2010) untersuchten die Auswirkungen von veränderter Bodenhöhe auf die Kinetik und die Kinematik der unteren Extremität beim Gehen. Kinematische und kinetische Kenngrößen von zehn Probanden ( $25,1 \pm 2$  Jahre;  $76,8 \pm 10,8$  kg;  $182,8 \pm 9,6$  cm) wurden mit Infrarotkameras und zwei Kraftmessplatten (eine höhenverstellbar) auf einem Laufsteg mit 17 m Länge erfasst. Sie erfassten kinematische und kinetische Daten beim Überrennen einer Erhöhung von 10 cm, sowie beim Rennen auf ein um 10 cm erhöhtes Niveau. Es konnten signifikante Unterschiede hinsichtlich der Bodenreaktionskräfte, der Beinlänge, der Beinsteifigkeit und des Anstellwinkels des Beines aufgezeigt werden. Beim Rennen auf ein erhöhtes Niveau zeigte sich über den ersten Schritt eine signifikante Vergrößerung der

Beinlänge, was die Autoren mit der Versteifung des Kniegelenks als Vorbereitung für die Niveauerhöhung interpretierten. Im Gegensatz hierzu konnte beim Überlaufen der Erhöhung eine Verkürzung der Beinlänge festgestellt werden, was auf ein Nachgeben im Kniegelenk im Hinblick auf eine Energieminimierung interpretiert werden kann.

Im Hinblick auf die Reproduzierbarkeit der Bewegung fanden die Autoren für das Überlaufen der Erhöhung, sowohl für das Auf- als auch das Absteigen von der Erhöhung, eine Zunahme der Varianz in der Geschwindigkeit in Bewegungsrichtung. Für das Rennen auf ein erhöhtes Niveau konnte nur für den Schritt vor und auf die Erhöhung eine Änderung der Varianzen, ebenfalls in Bewegungsrichtung, beobachtet werden. Das Rennen von der Erhöhung auf das Grundniveau zeigte bezüglich der Geschwindigkeit keine Effekte.

Auf Grund der Tatsache, dass es sich beim Überschreiten von Hindernissen oder dem Auftreten auf ein erhöhtes Niveau in der Regel nicht um automatisierte Bewegungsausführungen handelt, ist im Vergleich zum automatisierten Gehen ein erhöhtes Maß an Aufmerksamkeit erforderlich. Dies impliziert eine kortikale Bewegungssteuerung, im Gegensatz zu willkürlichen automatisierten Handlungen, die, wie in Kapitel 2.2 erläutert, über CPGs im Rückenmark gesteuert werden. Wie in Kapitel 2.1 dargestellt, weisen Bewegungen dieser Kategorie eine größere Varianz in der Bewegungsausführung auf.

Gates, Wilken, Scott, Sinitski und Dingwell (2012) untersuchten in ihrer Studie kinematische Adaptationsprozesse der unteren Extremitäten an das Gehen auf unebenem Untergrund. 15 gesunde, junge Probanden (3 weiblich, 12 männlich;  $22,5 \pm 5$  Jahre;  $1,71 \text{ m} \pm 0,09 \text{ m}$  Körpergröße;  $76,6 \text{ kg} \pm 11,6 \text{ kg}$  Masse) wurden beim Gehen mit vier unterschiedlichen Geschwindigkeiten auf ebenem Untergrund (5 m Laborboden) und einem mit Kieselsteinen gefüllten Becken (L:4,6 m, B: 1,2 m, T: 0,1 m) getestet. Für jede Geschwindigkeit wurde auf beiden Böden die Kinematik von fünf Doppelschrittzyklen mit 20 Infrarotkameras erfasst. Es fand eine Normalisierung der Gehgeschwindigkeiten auf Basis der Beinlänge der Probanden statt. Die räumlich-zeitlichen Gangparameter wurden auf Basis der Marker der unteren Extremität bestimmt. Die Autoren konnten eine signifikante Erhöhung der Schrittlänge sowie eine Verkürzung der Schrittdauer mit zunehmender Geschwindigkeit feststellen. Die Mittelwerte der anderen räumlich-zeitlichen Gangparameter zeigten keine Veränderungen. Analog zu den Studien von Thies et al. (2005) und Müller und Blickhan

(2010) konnte eine Erhöhung der Variabilität in der Bewegungsausführung auf instabilem Untergrund bezüglich der Parameter Schrittdauer, Schrittlänge und Schrittweite nachgewiesen werden. Bezüglich der Winkel-Zeit Verläufe zeigten sich signifikante Änderungen im Fußanstellwinkel und im Hüftflexionswinkel sowie bei der Knieflexion in der frühen Standphase (0 % – 25 % Gangzyklus). Auch konnte ein signifikant größerer Flexionswinkel für Knie, Hüfte und Sprunggelenk während der Schwungphase nachgewiesen werden. Auch bezüglich der Variabilität der Gelenkwinkelverläufe der unteren Extremität zeigte sich eine größere Variabilität in der Bewegungsausführung. Im Gegensatz zu den signifikanten Änderungen der Gelenkwinkel, die in Phase B (early stance) und Phase D (swing phase) zu beobachten waren, zeigte sich eine Zunahme der Bewegungsvariabilität über alle drei Phasen und alle Winkel der unteren Extremität. Die erhöhten Flexionswinkel in Hüfte und Knie in der frühen Standphase unterstützten den Befund von Thies et al., dass der Körperschwerpunkt auf unebenem, lockerem Untergrund tiefer verläuft. Bezüglich der Auslenkung des Körperschwerpunktes konnten die Autoren ebenfalls eine Zunahme der Variabilität feststellen, wohingegen bei der durchschnittlichen Höhe des KSP keine Veränderung identifiziert werden konnte.

Auf Grund der einheitlich berichteten Einflüsse, die unebene Untergründe auf die Reproduzierbarkeit von Gehbewegungen auch unter kontrollierten Laborbedingungen haben, kann davon ausgegangen werden, dass durch den Einsatz von unterschiedlichen Untergründen eine Erhöhung der Varianz in der Bewegungsausführung zyklischer Muster, wie sie beim Gehen und Rennen auftreten, induziert werden kann. Auf Basis der erschwerten Klassifizierung von Daten mit einer (im Vergleich zu den vorangegangenen Studien) größeren intraindividuellen Varianz, sollen in dieser Studie HMMs, welche zur Personenerkennung auf Basis kinematischer Funktionsparameter beim Gehen und Laufen konstruiert wurden, auf ihre Klassifikationsleistung im Kontext eines praxisnahen Analyseszenarios geprüft werden. Zu diesem Zweck werden Personen anhand ihrer kinematischen Muster beim Gehen und Rennen auf unterschiedlichen Untergründen mit HMMs erkannt. Es soll somit untersucht werden, inwieweit die Induktion von Varianzen in der Bewegungsausführung durch nichtstationäre Lokomotion sowie durch unebene Untergründe Einfluss auf die Klassifizierbarkeit der individuellen Bewegungsmuster hat. Ergänzend dazu soll auf Basis der Klassifizierung der unterschiedlichen Untergründe über die



individuellen Muster gezeigt werden, ob die kinematischen Muster beim Gehen auf unterschiedlichen Untergründen Informationen enthalten, die eine Differenzierung der Bedingung mit HMMs ermöglichen.

## 6.2 Methodik

### *Stichprobe*

An der Studie nahmen 18 männlichen Probanden im Alter von 21 bis 29 Jahren ( $25,18 \pm 1,98$  Jahre,  $82,03 \pm 11,90$  kg,  $183,24 \pm 7,81$  cm) teil. Vor Beginn der Untersuchung füllten die Probanden einen Fragebogen zur körperlich sportlichen Aktivität, sowie dem gesundheitlichen Zustand im Hinblick auf das Untersuchungsziel aus (Anhang C). Alle Probanden waren sportlich aktiv ( $8,09 \pm 2,87$  Std. / Woche) und wiesen keine bekannten Verletzungen, Gelenkfehlstellung oder andersgeartete Einschränkungen auf, die das Gangbild hätten beeinträchtigen können. Keiner der Probanden musste sich im Zeitraum eines Jahres vor Studienbeginn einer Operation unterziehen. Zwölf Probanden (66,66 %) gaben ihr rechtes Bein als stärkeres und 4 Personen (22,22 %) ihr linkes als stärkeres Bein an. 2 Probanden (11,11 %) schätzten ihr rechtes und linkes Bein als gleich stark ein. Die anthropometrischen Merkmale der Teilnehmer wiesen eine Normalverteilung auf. Alle Probanden wurden im Vorfeld der Studie zum Ablauf der Untersuchung aufgeklärt und bestätigten ihre Bereitschaft zur freiwilligen Teilnahme.

### *Biomechanische Messwertaufnahme, -verarbeitung und -modellierung*

Für die kinematische Analyse wurden die Teilnehmer der Studie mit Markern mit einem Durchmesser von 14 mm gemäß dem Plug-In Gait Modell (VICON®, 2002) durch den gleichen Testleiter versehen. Dies geschah, um zufällige Fehler bei der Platzierung der Marker durch unterschiedliche Testleiter auszuschließen. Für die Datenerhebung liefen die Probanden mit Geschwindigkeiten von  $1,4 \text{ ms}^{-1}$  (Gehen) und  $2,8 \text{ ms}^{-1}$  (Rennen) auf einem Laufsteg (8 m Länge, 0,62 m Breite), welcher mit vier unterschiedlichen Untergründen (Laborboden, Rollrasen, 3 cm Pflasterboden, 5 cm Pflasterboden) bestückt werden konnte und wurden mit einem Infrarot Kamerasystem mit 12 Kameras (Frequenz: 250 Hz) aufgenommen. Der Pflasterboden bestand aus insgesamt 320 Holzklötzen ( $10 \text{ cm} \times 15 \text{ cm}$ ), welche in acht unterschiedlichen Höhen zur Verfügung standen. Die größte Differenz zwischen dem niedrigsten und dem

höchsten Holzklötz betrug 3 cm für das Pflaster 3 cm und 5 cm für das Pflaster 5 cm. Die Holzklötze wurden zufällig über die Fläche des Laufstegs verteilt. Für die Segmentierung der kinematischen Daten wurde das Schuhwerk der Probanden mit drucksensitiven Einlegesohlen (Frequenz: 100 Hz) instrumentiert (Abbildung 55). Alle Probanden nutzten Schuhe gleichen Typs eines Herstellers.




Abbildung 55. Messaufbau für das Gehen auf Laborboden, Rasen und Pflaster.

Jede Bedingung wurde über fünf Versuche hinweg getestet, sodass in Summe insgesamt 20 Gangzyklen für jede Bedingung erfasst werden konnten (vier Zyklen pro Versuch). Die Aufbereitung der Daten erfolgte analog zu dem in Kapitel 3.2 beschriebenen Verfahren. Die Positions-Zeit Verläufe wurden in VICON® Nexus mit Plug-In Gait (VICON®, 2002) kinematisch modelliert und als ASCII-Daten exportiert (Anhang A).

Die Segmentierung der Gangzyklen erfolgte in MATLAB auf Basis der Bodenreaktionskräfte, die über die Summe der Einzeldrücke der Einlegesohlen ermittelt wurden. Es wurde eine Routine implementiert, die auf Basis der Steigung des Kraft-Zeit Verlaufs die Zeitpunkte Heel Strike, Mid Stance und Toe Off identifizierte (Anhang A, Abbildung 2). Parallel zur automatisierten Detektion der Events erfolgte eine visuelle Kontrolle aller identifizierten Zeitpunkte über eine grafische Darstellung in MATLAB mit der Möglichkeit der manuellen Korrektur. Zur Beschreibung der kinematischen Kenngrößen der Geh- und Rennbewegungen wurden die Daten in drei Segmente unterteilt (Abbildung 56).




Abbildung 56. Segmentierte und normalisierte Winkelverlauf des Kniegelenks einer Person in sagittaler Ebene beim Gehen auf Laborboden.

### Stochastische Modellierung

Das Training und die Auswertung wurde in MATLAB mit der Toolbox von Murphy (1998) durchgeführt. Die Modellierung der HMMs erfolgte analog zu dem in Kapitel 3.2 beschriebenen Verfahren.

### Datenanalyse

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet.

Für die *Personenerkennung* wurde für jeden Proband ein HMM mit den Merkmals-Zeit Verläufen von Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles), Sprunggelenk (L/R-AnkleAngles), Schulter (L/R-ShoulderAngles), Ellenbogen (L/R-ElbowAngles), Handgelenk (L/R-WristAngles), Nacken (L/R-NeckAngles), Kopf (L/R-HeadAngles), Wirbelsäule (L/R-SpineAngles), Rumpf (L/R-ThoraxAngles) und die des Beckens (L/R-Pelvis) in drei Dimensionen für die rechte und linke Seite, sowie die Positions-Zeit Verläufe des Körperschwerpunkts in drei Dimensionen aus 15 Zufällig aus der Gesamtdatenmenge ausgewählten Schrittzyklen trainiert. Die Merkmale wurden für jedes HMM zu einem Trainingsvektor mit 1125 Merkmals-Zeit Verläufen (25 Merkmals-Zeit Verläufe  $\times$  3 Dimensionen  $\times$  15 Schrittzyklen) zusammengefasst. Für die Erkennung jeder Person standen Daten aus fünf nicht im Training verwendeter Schrittzyklen zur Verfügung (375 Winkel-Zeit Verläufe).

Für die *Randbedingungen* Laborboden, Rasen, Pflaster 3 cm und Pflaster 5 cm wurde jeweils für das Gehen mit  $1,4 \text{ ms}^{-1}$  und das Rennen mit  $2,8 \text{ ms}^{-1}$  ein HMM trainiert, das für die Erkennung der Untergründe verwendet wurde. Zu diesem Zweck wurden die Gelenkwinkel von Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles), Sprunggelenk (L/R-AnkleAngles), Schulter (L/R-ShoulderAngles), Ellenbogen (L/R-ElbowAngles), Handgelenk (L/R-WristAngles), Nacken (L/R-NeckAngles), Kopf (L/R-HeadAngles), Wirbelsäule (L/R-SpineAngles), Rumpf (L/R-ThoraxAngles) und des Beckens (L/R-Pelvis) in drei Dimensionen für die rechte und linke Seite, sowie die Positions-Zeit Verläufe des Körperschwerpunkts in drei Dimensionen für 15 zufällig gewählte Schrittzyklen pro Proband in einem Merkmalsvektor mit 20250 Winkel-Zeit Verläufen ( $25 \times \text{Merkmals-Zeit Verläufe} \times 3 \text{ Dimensionen} \times 15 \text{ Zyklen} \times 18 \text{ Probanden}$ ) für jede Bedingung zusammengefasst. Diese wurden den HMMs zum Training präsentiert. Die Daten von 90 Schrittzyklen über 18 Probanden (6750 Merkmals-Zeit Verläufe) standen für den Test der Erkennungsleistung für jede Bedingung zur Verfügung.

Für die Überprüfung der *Generalisierungsfähigkeit* wurde jeweils ein HMM mit Trainingsvektoren über 1125 Merkmals-Zeit Verläufe für das Gehen auf dem Rasen je Proband trainiert ( $25 \text{ Merkmals-Zeit Verläufe} \times 3 \text{ Dimensionen} \times 15 \text{ Zyklen}$ ). Die Überprüfung der Klassifikationsleistung wurde mit Merkmals-Vektoren der anderen Untergründe realisiert. Für jeden Untergrund wurden zu diesem Zweck die Merkmale eines Schrittzklus für jeden Proband zusammengefasst (75 Merkmals-Zeit Verläufe).

Im Rahmen einer Interferenzstatistik wurde über die Winkel-Zeit Verläufe von Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles) und Sprunggelenk (L/R-AnkleAngles) zu den Zeitpunkten Heel Strike, Mid Stance und Toe Off ein t-Test für verbundene Stichproben gerechnet.

### 6.3 Ergebnisse

#### *Analyse der Plausibilität der Messdaten*

Der Vergleich der Kurven für die Winkeldaten der unteren Extremität beim Gehen auf Laborboden mit  $1,4 \text{ ms}^{-1}$ , mit den skalierten Verläufen von Novacheck (1998) für eine Geschwindigkeit von  $1,2 \text{ ms}^{-1}$  zeigt ähnliche Verläufe (Abbildung 57). Insbesondere die gemittelten Winkeldaten der Hüfte sind nahezu identisch. Wie in den Vergleichen

der Messwerte aus den vorangegangenen Studien zeigten sich die größten Abweichungen im Bereich des Sprunggelenks, vor allem auch im Hinblick auf die Tendenz des Verlaufs zu Beginn und Ende des Gangzyklus.

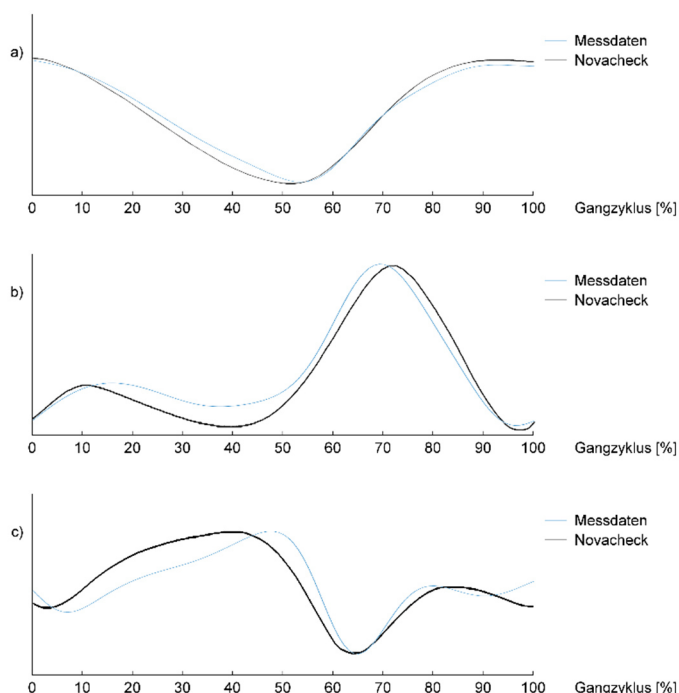


Abbildung 57. Vergleich der Winkelverläufe in der Sagittalebene von Hüfte (a), Knie (b) und Sprunggelenk (c) beim Gehen auf Laborboden dieser Studie zu skalierten Normwerten (Novacheck, 1998).

Der Vergleich mit den Normdaten von Perry und Burnfield (2010) weist, wie auch in Studie 1, größere Ähnlichkeiten im Verlauf und insbesondere auch in der Tendenz des Verlaufs zu Beginn und Ende das Gangzyklus auf (Abbildung 58).





Abbildung 58. Vergleich der Winkelverläufe in der Sagittalebene des Sprunggelenks zu skalierten Normwerten von Perry und Burnfield (2010).

Zur Prüfung der Normalverteilung der Daten wurde die grafische Darstellung der Normalverteilungswahrscheinlichkeit (Summenhäufigkeitsfunktion) in MATLAB verwendet.



*Abbildung 59.* Summenhäufigkeits-Wahrscheinlichkeiten von 18 Probanden für über 20 Zyklen gemittelte Winkeldaten von Hüfte (a), Knie (b) und Sprunggelenk (c) entlang der theoretischen Summenhäufigkeits-Wahrscheinlichkeiten (rot) zum Zeitpunkt Heel Strike bei einer Geschwindigkeit von  $1,4\text{ms}^{-1}$ .

Die Gruppierung der Wahrscheinlichkeits-Winkeldaten-Werte der 18 Probanden für die Gelenke Hüfte (a), Knie (b) und Sprunggelenk (c) (gemittelt über 20 Zyklen) entlang der theoretischen Wahrscheinlichkeits-Winkeldaten-Funktion (rot) in Abbildung 59, weist auf die Normalverteilung der Winkelverläufe zum Zeitpunkt Heel Strike hin. Die Normalverteilung wurde über alle detektierten Events getestet und hier nur exemplarisch für den Zeitpunkt Heel Strike auf Laborboden dargestellt.

Hinsichtlich der, auf Basis der Literaturanalyse erwarteten, Zunahme der Varianz in der Bewegungsausführung, zeigt Abbildung 60 exemplarisch für die Winkelverläufe der Hüfte eines Probanden, dass mit zunehmender Unebenheit des Bodens der erwartete Effekt auch auf die Daten dieser Studie zutraf. Analoge Entwicklungen bezüglich der Variabilität fanden sich auch für die Winkelverläufe des Knie- und des Sprunggelenks.

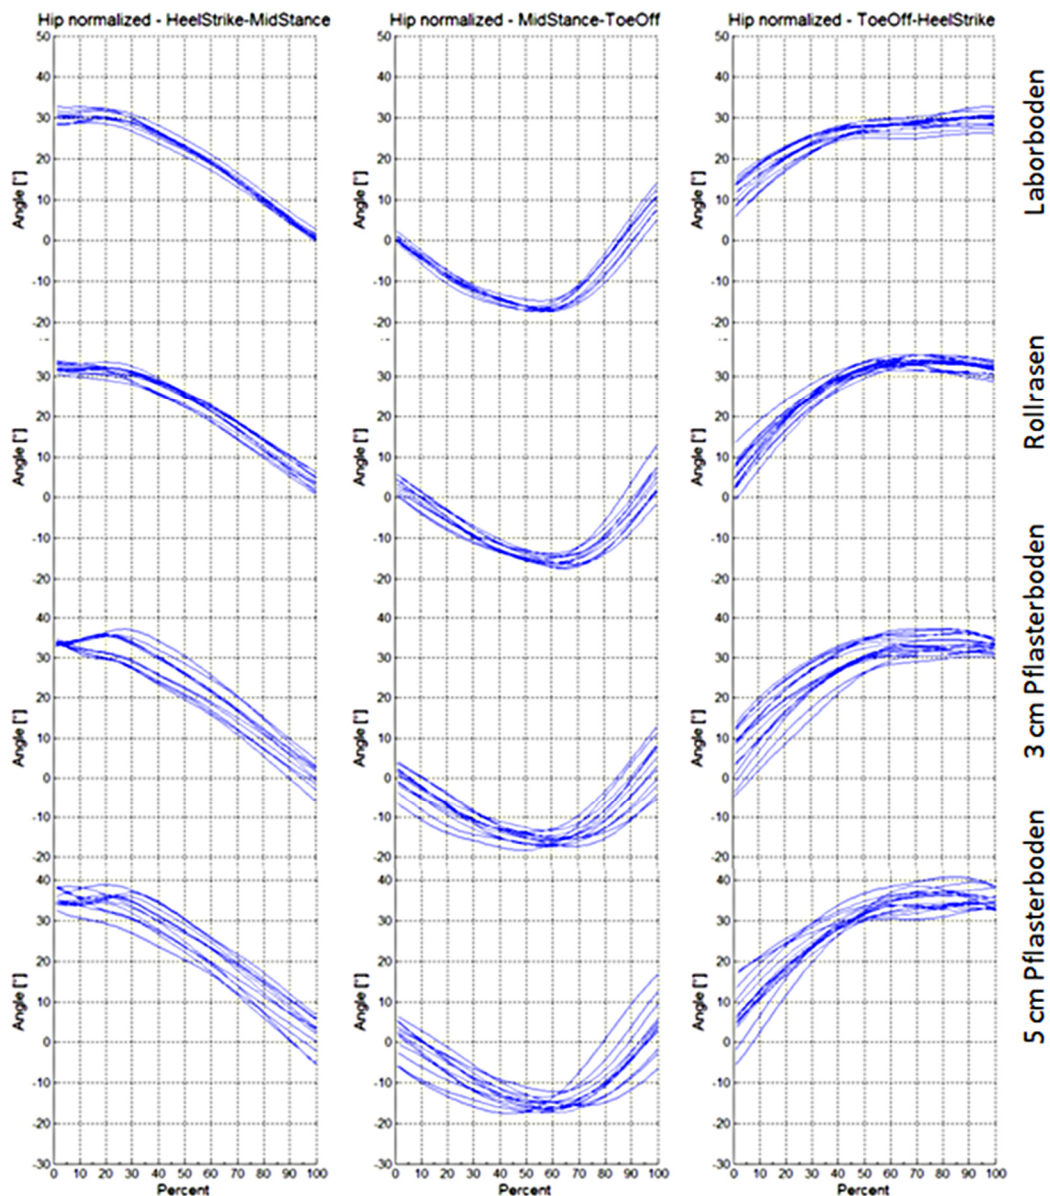


Abbildung 60. Segmentierte zeitnormalisierte Winkelverläufe der Hüfte über alle Untergründe für einen Probanden in der Sagittalebene.

### Erkennungsleistung der HMMs

Bezüglich der *Personenerkennung* über die unterschiedlichen Untergründe konnte, vergleichbar zu den Studien 1 und 2, eine Klassifikationsrate von bis zu 100 % über einzelne Funktionsparameter auf allen Untergründen erzielt werden. Die höchsten Klassifikationsleistungen konnten auch in dieser Studie über Gelenkwinkelverläufe der unteren Extremität erreicht werden. Die Erkennungsleistungen über die Verläufe der Thorax- (L/R-ThoraxAngles) und der Beckenwinkel (L/R-PelvisAngles) lagen bei 85 % – 98 %. Über den Körperschwerpunkt konnte über alle Probanden eine

Erkennungsrate von 100 % erzielt werden. Die Muster von Ellenbogen, Handgelenk und Nacken, sowie Wirbelsäule und Kopf, zeigten mit 47 % – 72 % die niedrigsten Klassifikationsleistungen. Abbildung 61 zeigt die Erkennungsraten für einzelne Funktionsparameter über die Daten aller Untergründe.




Abbildung 61. Erkennungsraten der Merkmale beim Gehen mit  $1,4 \text{ ms}^{-1}$  über alle Untergründe.

Die Klassifizierung der Personen beim Rennen (Abbildung 62) lieferte vergleichbare Ergebnisse. Wie auch beim Gehen konnten bereits über einzelne Gelenkwinkel Klassifikationsraten von 100 % erreicht werden.




Abbildung 62. Erkennungsraten der Merkmale beim Rennen mit  $2,8 \text{ ms}^{-1}$  über alle Untergründen.



Auf Basis eines Mehrheitsvotums über die Erkennungsraten der Winkelverläufe von Becken (L/R-PelvisAngles), Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles) und Sprunggelenk (L/R-AnkleAngles) ergab sich für die Erkennung der Personen auf allen Untergründen für das Gehen und Rennen eine Klassifikationsleistung von 100 % (Tabelle 18).

*Tabelle 18.* Erkennungsraten der Personen auf unterschiedlichen Untergründen beim Gehen mit  $1,4\text{ms}^{-1}$  und Rennen mit  $2,8\text{ms}^{-1}$ .

Geschwindigkeit [m/s]	Untergründe			
	Laborboden	Rasen	Pflaster 3cm	Pflaster 5cm
1,4	100	100	100	100
2,8	100	100	100	100

Die Klassifizierung der Untergründe konnte beim Gehen mit  $1,4\text{ms}^{-1}$  mit einer Wahrscheinlichkeit von 96,1 % – 99,2 % erfolgen. Für die Erkennung der Untergründe beim Rennen mit  $2,8\text{ms}^{-1}$  ergaben sich mit Raten von 95,5 % – 99,3 % ähnliche Ergebnisse (Tabelle 19). Die mittlere Erkennungsrate über alle Untergründe lag für das Gehen bei 97,8 % und das Rennen bei 97,5 %.

*Tabelle 19.* Erkennungsraten der Untergründe beim Gehen mit  $1,4\text{ms}^{-1}$  und Rennen mit  $2,8\text{ms}^{-1}$ .

Geschwindigkeit [m/s]	Untergründe			
	Laborboden	Rasen	Pflaster 3cm	Pflaster 5cm
1,4	99,2	98,7	96,1	97,1
2,8	99,3	99,1	95,9	95,5

Durch die Reduzierung der Bedingungen um den Pflasterboden mit 3 cm Höhenunterschied konnte die mittlere Erkennungsleistung beim Gehen auf 99,6 % und beim Rennen auf 99,3 % gesteigert werden.

Im Kontext der Generalisierungsfähigkeit der Modelle wurde ergänzend die Klassifikationsleistung von Modellen getestet, die mit Merkmalsvektoren der kinematischen Daten vom Gehen auf Laborboden trainiert wurden. Die Erkennungswahrscheinlichkeit bezüglich der Muster vom Gehen auf Rasen lag bei 92,7 %. Die Erkennungswahrscheinlichkeit für Pflaster mit einem Höhenunterschied von 3 cm bei 90,2 % und für Pflaster mit einem Höhenunterschied von 5 cm bei 89,4 % (Tabelle 20).

*Tabelle 20.* Erkennungsraten der Untergründe beim Gehen mit  $1,4\text{ms}^{-1}$  über ein Training auf Daten der Randbedingung Laborboden.

Geschwindigkeit [m/s]	Untergründe		
	Rasen	Pflaster 3cm Erkennungsraten [%]	Pflaster 5cm
1,4	92,7	90,2	89,4

## 6.4 Diskussion

Ziel der vorliegenden Studie war es, auf Basis von Mustern mit einer größeren intraindividuellen Varianz HMMs auf ihre Klassifikationsleistung im Kontext eines praxisnahen Analyseszenarios zu prüfen. Zu diesem Zweck wurden Personen anhand ihrer kinematischen Muster beim Gehen und Rennen auf unterschiedlichen Untergründen mit HMMs erkannt. Auf die Weise sollte gezeigt werden, welche Auswirkungen Varianzen in der Bewegungsausführung durch nichtstationäre Lokomotion sowie durch unebene Untergründe auf die Klassifizierbarkeit der individuellen Bewegungsmuster haben. Ergänzend hierzu sollte die Randbedingung der Untergründe über die individuellen Muster der Probanden klassifiziert werden. Es galt so herauszufinden, ob die kinematischen Muster beim Gehen auf unterschiedlichen Untergründen Informationen enthalten, die eine Differenzierung der Bedingung mit HMMs ermöglichen.

### *Personenerkennung*

Wie in den vorangegangenen Studien konnten über die Winkel-Zeit Verläufe von Becken (L/R-PelvisAngles), Hüfte (L/R-HipAngles), Knie (L/R-KneeAngles) und Sprunggelenk (L/R-AnkleAngles) Erkennungsleistungen der Personen von 100 % erreicht werden. Die stabilen Klassifikationsleistungen über alle Konditionen hinweg

unterstützen die Ergebnisse anderer Studien zur Mustererkennung beim Gehen/Rennen, bei denen vergleichbare Erkennungsraten mit SOMs (Janssen et al., 2011; Schöllhorn et al., 2002) bei nicht stationären Lokomotionsbewegungen und SVMs erreicht werden konnten. Cheng et al. (2008) konnten auf der Basis von Funktionsparametern, die auf Basis von Videobildern extrahiert wurden, beim nicht stationären Gehen Personen mit einer Wahrscheinlichkeit von 93 % – 100 % erkennen. Im Kontext des Transfers der Methode zur Klassifizierung von Bewegungsmustern in Bedingungen des klinischen Alltags konnte gezeigt werden, dass die Winkel-Zeit Verläufe menschlicher Lokomotionsbewegungen beim nicht stationären Gehen und Rennen ausreichend stabile individuelle Muster aufweisen, um Personen diskriminieren zu können. Die Bewegungsvervariabilität scheint durch den Wegfall der Zwangsbedingung, einer durch das Laufband vorgegebenen Geschwindigkeit, nicht in der Art zu verändert zu werden, dass eine personenübergreifende Überlagerung von Mustern induziert wird. Dies deckt sich mit den Untersuchungen zum Rennen auf dem Boden und dem Laufband von Wank et al. (1998), der zwar systematische Änderung der Kinematik zwischen den Bedingungen aufzeigen konnte, jedoch keine signifikanten Änderungen der Variabilität in der Bewegungsausführung fand.

### *Randbedingungen*

Die Klassifizierung der Untergründe konnte in dieser Studie mit einer Wahrscheinlichkeit von 97,5 % – 99,6 % realisiert werden. Insbesondere die geringen Unterschiede in der Kinematik, die durch die unterschiedlichen Pflasterböden induziert werden konnten, führten dazu, dass die Varianzen in der Bewegungsausführung einen größeren Einfluss auf die Bewegungsmuster hatten als die Änderung der Muster auf Grund der unterschiedlichen Randbedingungen (Janssen et al., 2011). Dies zeigte sich in einer vergleichsweise häufigen Fehlklassifikation der Untergründe Pflaster 3 cm und Pflaster 5 cm.

### *Generalisierungsfähigkeit*

Die Klassifikationsergebnisse dieser Studie bezüglich der Erkennung von unebenen Untergründen auf Basis eines HMMs, welches mit Merkmals-Zeit Verläufen trainiert wurde, die bei einer Ganganalyse auf Laborboden erfasst wurden, weisen darauf hin,

dass Hidden Markov Modelle über eine hohe Generalisierungsfähigkeit bei der Klassifikation von menschlichen Bewegungsmustern beim Gehen verfügen. Vergleichbare Ergebnisse konnten in Studie 2 gezeigt werden. Ergebnisse im Hinblick auf eine Generalisierungsfähigkeit der HMMs bei der Klassifikation menschlicher Lokomotionsbewegungen anderer Autoren konnten nicht gefunden werden. Die Ergebnisse scheinen aber im Kontext der theoretischen Betrachtung der Methode plausibel (Bishop, 2009; Schölkopf & Smola, 2002).

Trotz der erwarteten hohen Variabilität in der Bewegungsausführung, induziert durch die unterschiedlichen Bedingungen, konnten sowohl Personen, als auch Untergründe mit Wahrscheinlichkeiten von 89,4 % – 100 % klassifiziert werden. Im Hinblick auf eine Anwendung der Methode zur Analyse von Lokomotionsmustern im klinischen Alltag konnte gezeigt werden, dass die Muster menschlicher nicht stationärer Lokomotion ebenso wie die Muster von Laufbandanalysen, individuelle Informationen enthalten, die sowohl eine Diskriminierung von Personen, als auch von Randbedingungen über die Personen hinweg ermöglicht. Diese Ergebnisse werden gestützt durch die Erkenntnisse anderer Studien, bei denen SVMs und SOMs für die Klassifizierung von Mustern verwendet wurden (Janssen et al., 2011; Schöllhorn et al., 2002). Die Klassifikationsleistungen bezüglich der Erkennung der Untergründe haben insbesondere im Hinblick auf die Pflasterböden mit geringem Höhenunterschied gezeigt, dass die Auswahl der Randbedingungen entscheidend für die Performanz der Methode ist. Auffallend war, dass für Winkel-Zeit Verläufe dieser Studie vergleichbar zu Studie 1 ein unterschiedlich guter Modellfit für die linke und die rechte Seite zu beobachten war. Der Vergleich der Mittelwerte in der Bewegungsausführung für die linke und rechte Seite zum Zeitpunkt Heel Strike zeigte, dass Winkel-Zeit Verläufe durch Lateralität geprägt sind. Mittels t- Test für verbundene Stichproben konnten signifikante Unterschiede zwischen Pflasterboden (3 cm) und Laborboden (Effektgröße =  $3,66^\circ$ ), zwischen Pflasterboden (3 cm) und Rollrasen (Effektgröße =  $3,48^\circ$ ) und zwischen Pflasterboden (5 cm) und Rollrasen (Effektgröße =  $1,5^\circ$ ) gefunden werden (Tabelle 21). Signifikante Unterschiede für die anderen Gelenkwinkel der unteren Extremität konnten nicht gezeigt werden.

*Tabelle 21.* Mittelwerte und Standardabweichungen (SD) des Kniewinkels beim Gehen zu den Zeitpunkten Heel Strike, Mid Stance und Toe Off in sagittaler Ebene für die linke und rechte Seite.

<b>Untergrund</b>	<b>Seite</b>	<b>Heel Strike [°]</b>	<b>SD</b>	<b>Mid Stance [°]</b>	<b>SD</b>	<b>Toe Off [°]</b>	<b>SD</b>
Laborboden	links	6,72	4,84	9,55	3,70	55,06	5,75
	rechts	11,99	4,25	14,95	4,34	8,72	6,58
Rasen	links	6,91	2,68	8,35	3,60	58,34	5,66
	rechts	13,79	3,71	13,54	4,39	9,80	7,26
Pflaster 3cm	links	10,39	5,85	9,38	3,43	56,67	7,44
	rechts	15,02	4,86	13,61	4,60	10,55	7,60
Pflaster 5cm	links	8,42	4,27	10,38	3,95	57,12	7,13
	rechts	15,42	4,47	14,81	4,20	10,06	7,63

Im Hinblick auf die automatische Erkennung von pathologischen Veränderungen von Bewegungsmustern auf Basis von klinischen Ganganalysen muss gezeigt werden, dass Varianzen in der Bewegungsausführung nicht zu einer Überlagerung der pathologischen Muster führen, bzw. wie stark Pathologien ausgeprägt respektive fortgeschritten sein müssen, um mit ausreichend hoher Wahrscheinlichkeit klassifiziert werden zu können.

## 7 Zusammenfassung und Ausblick

Im Mittelpunkt des Forschungsinteresses dieser Arbeit stehen die Bewegungsmuster menschlicher Geh- und Rennbewegungen unter verschiedenen Randbedingungen. Die Formen der menschlichen Lokomotion stellen sowohl im Alltag als auch im Sport eine wichtige Klasse menschlicher Bewegungen dar, die im Kontext von Aufgabe, Person und Umwelt, zu unterschiedlichen Handlungssituationen führt. Im Kontext der Erforschung dieser Muster repräsentiert die Ableitung modifizierter Handlungssituationen im Hinblick auf eine instrumentelle Analyse Laborbedingungen einen Teilaspekt der vorliegenden Arbeit. Zur Sicherung sowohl reliabler als auch valider Ergebnisse zu den Untersuchungen der Handlungssituationen, müssen der Fragstellung angepasste Analysescenarien entwickelt und angepasste Messplätze im Kontext von Messmethodik und Untersuchungsziel entworfen werden. Im Zusammenhang der Untersuchung von Bewegungsmustern beim Gehen und Rennen unter verschiedenen Randbedingungen, stellt die Entwicklung ebendieser Messplätze einen weiteren Teilaspekt vorliegenden Arbeit dar. Neben der Sicherung einer qualitativ hochwertigen Messwertaufnahme und -verarbeitung liegt eine wissenschaftliche Herausforderung in der Entwicklung einer neuen Methode zur Analyse von Messwerten, oder aber im Transfer einer bestehenden geeigneten Methode, auf Basis von Forschungsberichten, aus anderen Wissenschaftsbereichen. Auf Grundlage der erfassten kinematischen Merkmale beim Gehen und Rennen werden, als dritter Teilaspekt dieser Arbeit, unkonventionelle Methoden zur Analyse von Bewegungsmustern auf ihre Abbildungsleistung im Kontext menschlicher Lokomotion untersucht. Die allgemeinen Problemstellungen und die, aus der Analyse der aktuellen Literatur abgeleiteten, Forschungsfragen werden in vier chronologisch aufeinander aufgebauten Studien bearbeitet. Studie 1 ist in diesem Kontext im weitesten Sinn als Machbarkeitsstudie zu verstehen, in der überprüft wird, ob sich Hidden Markov Modelle, die bislang vornehmlich im Zusammenhang mit der Erkennung von Sprache und der Analyse biologischer Sequenzen verwendet wurden, für die Klassifizierung menschlicher Lokomotionsbewegungen eignen. Auf Basis einer Ganganalyse auf dem Laufband, bei der die kinematischen Muster von zehn Personen erfasst wurden, konnte eine Modelltopologie entwickelt werden, welche die individuellen Lokomotionsmuster der Probanden abbildete. Bereits über einzelne kinematische Funktionsparameter (Winkel-Zeit Verläufe der unteren Extremität) war

es möglich, Bewegungsmuster mit einer Wahrscheinlichkeit von 72 % – 100 % den Personen zuzuordnen. Die Analyse der aktuellen Literatur zeigte auf, dass Studien, die HMMs zur Erkennung von Personen auf Basis von Funktionsparametern, die aus Videosequenzen einfacher Videokameras extrahiert wurden, verwendeten, niedrigere Klassifikationsraten erreichten. Auf Basis der Erkennungsleistung als Kriterium für die Abbildungsgüte der kinematischen Muster durch das Modell, konnte einerseits gezeigt werden, dass ein Transfer der Methoden und deren Verwendung für die Klassifikation von menschlichen Lokomotionsbewegungen vielversprechende Ergebnisse lieferte. Andererseits ließen die hohen Erkennungsraten den Rückschluss zu, dass die Güte der verwendeten Funktionsparameter, sowie deren Auswahl, die Vorhaltung individueller Informationen in den Bewegungsmustern sicherstellten.

Nachdem in Studie 1 die Eignung für die Abbildung von Lokomotionsbewegungen aufgezeigt werden konnte, wurden HMMs in Studie 2 gängigen probabilistischen Verfahren zur Klassifikation von Lokomotionsbewegungen, die sich aus der Analyse der Literatur ergeben hatten, vergleichend gegenübergestellt. Auf Basis kinematischer Funktionsparameter einer Ganganalyse auf einem Laufband wurden mittels einer Hauptkomponentenanalyse Merkmale mit charakteristischen Geschwindigkeitsänderungen über vier Segmente des Gangzyklus extrahiert, die zu einer Trainingsdatenmenge für SVMs und KNNs zusammengefasst wurden. Die HMMs wurden analog zur Topologie, die in Studie 1 für die Abbildung von Lokomotionsbewegungen ermittelt wurde, konstruiert. Die Ergebnisse der Klassifikation der Personen anhand ihrer kinematischen Muster konnte sowohl für die SVMs, als auch für die HMMs mit Wahrscheinlichkeiten von 100 % realisiert werden. Die Erkennungsleistung der KNNs fielen mit Wahrscheinlichkeiten von 94 % – 95,5 % hingegen niedriger aus. Im Kontext der Klassifikationsleistung der Modelle konnte aufgezeigt werden, dass Muster menschlicher Lokomotionsbewegungen über HMMs ähnlich gut abgebildet werden können wie mit SVMs. Die Analyse der aktuellen Literatur zeigte, dass Studien zum Vergleich von HMMs und SVMs (Khorasani & Daliri, 2014), sowie von SVMs und LDA (Ng et al., 2011), ähnliche Befunde aufwiesen. Besonders bei der Erkennung von unbekanntem Daten dieser Studie, bei denen Modelle mit Geschwindigkeiten von  $1,2 \text{ ms}^{-1}$  und  $3,0 \text{ ms}^{-1}$  trainiert wurden und die Erkennungsleistung über eine Geschwindigkeit von  $4,0 \text{ ms}^{-1}$  evaluiert wurde, zeigten HMMs (99,3 %) eine größere Generalisierungsfähigkeit verglichen mit SVMs (98,6 %) und KNNs (94 %). Im Hinblick

auf einen Transfer der Methode für die Anwendung zur Ganganalyse im klinischen Alltag zeigten SVMs auf Grund der obligatorischen Vorverarbeitung der Daten gegenüber den HMMs Nachteile in der Performanz. Vor dem Hintergrund dieser Befunde konnte gezeigt werden, dass sich im Kontext der Zielstellung dieser Arbeit insbesondere HMMs zur Klassifikation von Mustern menschlicher Lokomotionsbewegungen eignen.

Aufbauend auf die Befunde aus Studie 2 wurden HMMs in Studie 3 dafür verwendet, die kinematischen Muster von Breitensportlern und Leistungssportlern beim Rennen auf dem Laufband mit unterschiedlichen Randbedingungen zu klassifizieren. Aus der Literatur ist bekannt, dass sich die Muster dieser Gruppen sowohl hinsichtlich der räumlich-zeitlichen Verläufe als auch der Varianzen in der Bewegungsausführung unterscheiden. Im Kontext der Erkennung von Mustern ergibt sich die Frage, ob die durch Training induzierten Adaptation der Laufmuster mit HMMs abgebildet und differenziert werden können. Die kinematischen Daten von 15 Breitensportlern ohne spezielle Ausbildung hinsichtlich der Lauftechnik, sowie von 18 Leistungssportlern, die auf nationalem Niveau an Wettkämpfen in Disziplinen der Lang- oder Mittelstrecke teilnahmen, wurden beim Rennen auf dem Laufband bei unterschiedlichen Geschwindigkeiten und Neigungen erfasst. HMMs für die Erkennung der Spezialisierung (Breitensportler vs. Athlet), die Erkennung der Steigung, sowie die Personenerkennung wurden mit kinematischen Funktionsparameter, die in Trainingsvektoren zusammengefasst den HMMs präsentiert wurden, trainiert. Die Topologie, die sich aus den Erkenntnissen aus Studie 1 und Studie 2 für die Konstruktion der HMMs als geeignet herausgestellt hatte, wurde für die weiteren Tests beibehalten und sollte vor dem Hintergrund veränderter Randbedingungen eingehend untersucht werden. Die Klassifikation der Spezialisierung zeigte über Geschwindigkeiten von  $2 \text{ ms}^{-1}$  und  $5 \text{ ms}^{-1}$  über alle Neigungen Erkennungsraten von 89,7 % – 100 %. Die Muster bei  $5 \text{ ms}^{-1}$  und Neigungen von  $0^\circ$  –  $7,5^\circ$  konnten zu 100 % bezüglich der Gruppen diskriminiert werden. Diese Befunde konnten durch Studien gestützt werden, in denen aufgezeigt wurde, dass die Variabilität der kinematischen Funktionsparameter mit steigender Geschwindigkeit beim Rennen abnimmt (Belli et al., 1995; Jordan et al., 2006, 2007). Eine größere Differenzierbarkeit dieser Daten scheint in diesem Kontext plausibel.



Die Steigung konnte über die Gruppen und Geschwindigkeiten mit einer Wahrscheinlichkeit von 84,7 % – 99,7 % auf Basis der Merkmalsvektoren zugeordnet werden. Die niedrigsten Erkennungswahrscheinlichkeiten zeigten sich mit 84,7 % – 89,6 % für beide Gruppen sowohl bei  $2 \text{ ms}^{-1}$  als auch bei  $5 \text{ ms}^{-1}$  für das Rennen in der Ebene und mit Steigungen von  $\pm 2,5^\circ$ . Die vergleichsweise niedrigen Erkennungswahrscheinlichkeiten für diese Bedingung lassen vermuten, dass die Varianzen in der Bewegungsausführung bei niedrigen Geschwindigkeiten und Neigungen eine Differenzierbarkeit von Mustern, die unter nur gering unterschiedlichen Randbedingungen erfasst wurden, erschweren, da eine Überlappung der Bewegungsmuster stattfindet. Diese Annahme konnte durch die Klassifikationsergebnisse der Spezialisierung, sowie Studien zur Erkennung von Mustern beim Rennen mit SVMs (Janssen et al., 2011) gestützt werden. Die Ergebnisse der Studie zeigten, dass Bewegungsmuster von Personen mit unterschiedlicher Erfahrung beim Rennen Informationen über den Grad der Spezialisierung enthalten und mittels HMMs diskriminiert werden können. Ergänzend dazu wiesen die Klassifikationsergebnisse darauf hin, dass die Auswahl der Randbedingung (Geschwindigkeit und Steigung) vergleichsweise großen Einfluss auf die Klassifikationsleistung der HMMs hat. Die Erkennungswahrscheinlichkeiten der Randbedingungen zeigten Grenzen in der zuverlässigen Trennung von Daten auf, deren Muster starke Ähnlichkeiten zwischen den Gruppen aufweisen, aber durch eine vergleichsweise große Variabilität innerhalb der Gruppen gekennzeichnet sind. Im Hinblick auf Befunde aus der Literatur sollte in diesem Zusammenhang versucht werden Funktionsparameter anderer Messsysteme, wie Bodenreaktionskräfte (Horst et al., 2015) und EMG (Schultz & Wand, 2010), ergänzend zur Klassifikation heranzuziehen.

Auf Grundlage der bislang erlangten Befunde, die Möglichkeiten und Grenzen bei der Klassifikation von Mustern menschlicher Lokomotion auf dem Laufband aufzeigen konnten, wurde in Studie 4 der Transfer der Methode von Mustern stationärer Lokomotion auf dem Laufband hin zur nicht stationären Lokomotion auf unterschiedlichen Untergründen getestet. Im Hinblick auf die Veränderung der kinematischen Bewegungsmuster beim Gehen und Rennen auf dem Laufband (Nigg et al., 1995; Wank et al., 1998) erscheint die Untersuchung der Bewegungsmuster auch unter nichtstationären Bedingungen für die Abbildung der natürlichen Muster des

Gehens und Rennens sinnvoll. Um die Abbildungsleistung der HMMs eingehend zu testen, wurde über unterschiedliche unebene Untergründe eine Varianz in der Bewegungsausführung induziert (Gates et al., 2012; Müller & Blickhan, 2010; Thies et al., 2005). 18 Probanden wurden beim Gehen ( $1,4 \text{ ms}^{-1}$ ) und Rennen ( $2,8 \text{ ms}^{-1}$ ) auf Laborboden, Rasen und Pflaster mit Höhenunterschieden von 3 cm und 5 cm, kinematisch vermessen. Zur Klassifikation der Personen wurde für jeden Proband ein HMM für jeden Untergrund bei jeder Geschwindigkeit mit den kinematischen Funktionsparametern trainiert. Sowohl beim Gehen als auch beim Rennen konnten die Personen bereits über einzelne Merkmale über alle Untergründe mit einer Wahrscheinlichkeit von 100 % identifiziert werden. Die Ergebnisse deckten sich mit den Erkennungswahrscheinlichkeiten der Personen in den vorangegangenen Studien und der analysierten Literatur (Cheng et al., 2008; Khorasani & Daliri, 2014). Unterschiede in den Bewegungsmustern einzelner Personen waren offensichtlich so stark ausgeprägt, dass durch die Induktion von Variabilität in der Bewegungsausführung beim Gehen und Rennen durch unebene Untergründe keine Überlappung der Bewegungsmuster provoziert werden konnte, welche zu einer Fehlklassifikation geführt hätte.

Für die Klassifikation der Untergründe wurden jeweils vier HMMs mit den Funktionsparametern aus der kinematischen Analyse für beide Geschwindigkeiten getrennt trainiert. Die Erkennung der Untergründe konnte beim Gehen mit  $1,4 \text{ ms}^{-1}$  mit einer Wahrscheinlichkeit von 96,1 % – 99,2 % erfolgen. Für die Erkennung der Untergründe beim Rennen mit  $2,8 \text{ ms}^{-1}$  ergaben sich mit Raten von 95,5 % – 99,3 % ähnliche Ergebnisse. Analog zu den Ergebnissen aus Studie 3 zeigte sich eine Überlappung der heterogenen Muster über Randbedingungen, die durch geringe Unterschiede gekennzeichnet waren. Dies wurde durch die Tatsache gestützt, dass durch die Erkennungsleistung über drei heterogene Bedingungen (Laborboden, Rasen, Pflaster 5 cm) eine Steigerung der Erkennungsleistung auf 99,6 % für das Gehen und 99,3 % für das Rennen erzielt werden konnte. Mit Blick auf die Zielstellung dieser Studie konnte gezeigt werden, dass der Einsatz von HMMs zur Klassifikation nicht stationärer Muster des Gehens und Rennens auf unterschiedlichen Untergründen ähnliche Ergebnisse liefert wie sie bei Mustern gezeigt werden konnten, die durch das Laufen unter Zwangsbedingungen, die durch ein Laufband induziert

wurden, geprägt sind. In Einklang mit den Ergebnissen aus Studien, die Veränderungen in der Kinematik beim Gehen und Rennen auf dem Laufband und über den Boden nachweisen konnten (Belli et al., 1995; Nigg et al., 1995; Wank et al., 1998), scheint es durch die Änderung der Art und Weise der Lokomotion, im Kontext von Geschwindigkeit und Neigung, zwar zu Änderungen in der Kinematik zu kommen, nicht aber zu einer Veränderung der Differenzierbarkeit der Muster menschlicher Lokomotion. Ergänzend hierzu konnte wiederum gezeigt werden, dass die zuverlässige Trennung von Daten, deren Muster starke Ähnlichkeiten zwischen den Gruppen aufweisen, aber durch eine vergleichsweise große Variabilität innerhalb der Gruppen gekennzeichnet sind, problematisch scheint.

Im Hinblick auf die Forschungsfragen im Kontext dieser Arbeit konnte gezeigt werden, dass HMMs dazu geeignet sind, Muster menschlicher Lokomotionsbewegungen sowohl beim stationären Gehen und Rennen auf dem Laufband als auch beim nichtstationären Gehen und Rennen abzubilden. Die Klassifikationsleistung der Modelle bezüglich der Erkennung von Personen über alle Studien lassen den Schluss zu, dass im Zusammenhang von Klassifikationsgüte und Abbildungsgüte die individuellen Merkmale der Bewegungsmuster für die vorliegende Arbeit hinreichend gut im Modell repräsentiert wurden. Vor dem Hintergrund der kleinen Stichproben, die sich über alle Studien dieser Arbeit zeigen, kann jedoch nicht verallgemeinert werden. Gerade im Hinblick auf große Stichproben ist zu erwarten, dass die individuellen Muster der Lokomotionsbewegungen größere Ähnlichkeiten aufweisen und eine Klassifizierung der Muster dadurch erschwert wird.

Am Beispiel von Breitensportlern und Leistungssportlern konnte demonstriert werden, dass konvergierende Muster von Gruppen unter verschiedenen Randbedingung Informationen beinhalten, die mit HMMs differenzierbar sind. Im Hinblick auf den Stand der Forschung konnte bereits mit anderen Methoden gezeigt (Kortmann, T., & Schöllhorn, W. I., 2010) werden, dass die gewählten Gruppen über Varianzen in der Bewegungsausführung verfügen, über die Breitensportler und Leistungssportler differenziert werden können. Im Hinblick auf weitere Untersuchungen der Abbildungsleistung von HMMs sollten die Modelle in folgenden Studien auf Mustern getestet werden, die größere Ähnlichkeiten zwischen den Gruppen aufweisen. Dies

könnte einerseits über die Größe der Stichprobe realisiert werden oder über die Auswahl der zu diskriminierenden Gruppen.

Die Klassifikation der Randbedingungen konnte bezüglich Geschwindigkeit, Neigung und Untergrund beim Gehen und Rennen auf dem Laufband realisiert werden. Im Hinblick auf die Klassifikationsleistung konnten im Kontext der verwendeten Funktionsparameter Grenzen der Klassifizierbarkeit von Mustern mit HMMs aufgezeigt werden. Zwar wiesen die Befunde darauf hin, dass die Auswahl der Merkmale, mit denen die Modelle trainiert werden, starken Einfluss auf das Klassifikationsergebnis haben, ein Überblick über die gängigen biomechanischen Messmethoden konnte jedoch nicht realisiert werden. Für zukünftige Studien gilt es aufzuzeigen, welche Kenngrößen (Kinematik, Dynamik, EMG) die Basis für eine verbesserte Erkennungsleistung bilden können.

Der Transfer der Methode, von der stationären Ganganalyse hin zur nichtstationären Analyse des Gehens über den Boden, zeigte bezüglich der Erkennung der Personen keine Unterschiede in der Erkennungsleistung. Analog zur Klassifikation von Neigung und Geschwindigkeit muss jedoch postuliert werden, dass eine Klassifizierung der Untergründe, im Hinblick auf den Anspruch einer vollständigen Differenzierbarkeit der Muster, nur unter Vorbehalt möglich ist. Im Hinblick auf die ausgewählten Funktionsparameter und den unterschiedlichen Modellfit für die linke und rechte Seite der Winkelverläufe, sollte die Topologie der HMMs einer erneuten Prüfung unterzogen werden. Es wäre denkbar, dass unterschiedliche Anzahlen von Zuständen und Gaußmischverteilungen für die linke und rechte Seite zu einer Verbesserung der Erkennungsleistung auch von Randbedingungen führen.

Vor dem Hintergrund dieser Befunde sollen auf Basis des Modellansatzes, der sich auf Grundlage der Ergebnisse dieser Arbeit am besten zur Abbildung der Muster beim Gehen und Rennen eignet, in weiterführenden Arbeiten pathologische Muster bei Geh- und Rennbewegungen frühzeitig identifiziert werden können. Im Kontext eines medizinischen Screenings könnte somit z.B. durch eine präventive Intervention bei einer Arthrose im initialen oder frühen Stadium (Sulzbacher, 2000) der degenerative Prozess über geeignete Maßnahmen (Greitemann, 2009; Häuselmann & Hedbom, 2002; Madry & Kohn, 2004) verlangsamt werden. Die zuverlässige Differenzierbarkeit

der pathologischen und physiologischen Muster wäre in diesem Zusammenhang nachzuweisen.

Ergänzend wäre, auf Basis der trainierten Modelle eines Ansatzes zur Erkennung von Lokomotionsbewegungen, eine Synthese von Bewegungen denkbar. Diese wäre natürlichen Gesetzmäßigkeiten entlehnt und würde Variabilitäten in der Bewegungsausführung ähnlich der menschlichen aufzeigen. Besonders im Kontext der Forderung nach menschenähnlichen Bewegungsmustern bei Robotern (Asfour et al., 2006; Hirose & Ogawa, 2007), scheint ein stochastischer Ansatz vielversprechend. Nicht zuletzt kann die Modellbildung auf Basis eines stochastischen Ansatzes zum Erkenntnisgewinn über menschliche Bewegungen und Gesetzmäßigkeiten, auf deren Grundlage sie generiert werden, beitragen (Baca, 2008).

## 8 Literaturverzeichnis

- Alton, F., Baldey, L., Caplan, S. & Morrissey, M. C. (1998). A kinematic comparison of overground and treadmill walking. *Clinical Biomechanics*, 13 (6), 434-440.
- Amma, C., Fischer, A., Stein, T., Schwameder, H. & Schultz, T. (2011). Emotionserkennung auf der Basis von Gangmustern. In D. Link & J. Wiemeyer (Hrsg.), *Sportinformatik trifft Sporttechnologie. 8. Symposium der dvs-Sektion Sportinformatik in Kooperation mit der Deutschen Interdisziplinären Vereinigung für Sporttechnologie vom 15. - 17. September 2010 in Darmstadt* (Schriften der Deutschen Vereinigung für Sportwissenschaft, Bd. 217, S. 91-95). Hamburg: Feldhaus Ed. Czwalina.
- Andriacchi, T. P., Ogle, J. A. & Galante, J. O. (1977). Walking speed as a basis for normal and abnormal gait measurements. *Journal of Biomechanics*, 10 (4), 261-268.
- Arbib, M. A. (2012). *How the brain got language. The mirror system hypothesis* (Oxford studies in the evolution of language, Bd. 16). Oxford: Oxford Univ. Press.
- Asfour, T., Regenstein, K., Azad, P., Schroder, J., Bierbaum, A., Vahrenkamp, N. et al. (2006). ARMAR-III: An Integrated Humanoid Platform for Sensory-Motor Control. In *2006 6th IEEE-RAS International Conference on Humanoid Robots* (S. 169-175).
- Astephen, J. L., Deluzio, K. J., Caldwell, G. E. & Dunbar, M. J. (2008). Biomechanical changes at the hip, knee, and ankle joints during gait are associated with knee osteoarthritis severity. *Journal of orthopaedic research : official publication of the Orthopaedic Research Society*, 26 (3), 332-341.
- Baca, A. (2008). Informatische Methoden zur biomechanischen Analyse und Simulation. *Informatik Spektrum*, 31 (4), 308-315.
- Banzer, W. & Vogt, L. (2005). Instrumentelle Ganganalyse. *Deutsche Zeitschrift für Sportmedizin*, 56 (4), 108-109. Abt. Sportmedizin, Johann Wolfgang Goethe-Universität, Frankfurt/M.
- Bartlett, R. (2006). Artificial intelligence in sports biomechanics: new dawn or false hope? *Journal of sports science & medicine*, 5 (4), 474-479.

- Becher, R., Steinhaus, P. & Dillmann, R. (2004). The collaborative research center 588. Humanoid Robots— Learning and cooperating multimodal robots. *International Journal of Humanoid Robotics*, 01 (03), 429-448.
- Begg, R. K., Palaniswami, M. & Owen, B. (2005). Support vector machines for automated gait classification. *IEEE transactions on bio-medical engineering*, 52 (5), 828-838.
- Bellach, B.-M. (1999). Der Bundes-Gesundheitssurvey 1998. Erfahrungen, Ergebnisse, Perspektiven. *Das Gesundheitswesen* (61 (Sonderheft 2)), 55-56.
- Belli, A., Lacour, J. R., Komi, P. V., Candau, R. & Denis, C. (1995). Mechanical step variability during treadmill running. *European journal of applied physiology and occupational physiology*, 70 (6), 510-517.
- BenAbdelkader, C., Cutler, R. & Davis, L. (2002). Motion-based recognition of people in EigenGait space. In *Fifth IEEE International Conference on Automatic Face Gesture Recognition* (S. 267-272).
- Bernard, C. (1885). *Leçons sur les phénomènes de la vie communs aux animaux et aux végétaux* (2. Aufl.). Paris: Librairie J.-B. Baillière et fils. Zugriff am 16.07.2016. Verfügbar unter <http://gallica.bnf.fr/ark:/12148/bpt6k62986637/f7.item.zoom>
- Bernštejn, N. A. (1927). Kymozyclographion, ein neuer Apparat für Bewegungsstudium. *Pflügers Arch.*, 217 (5/6), 782-792.
- Bernštejn, N. A. (1967). *The coordination and regulation of movement*. Oxford: Pergamon Press.
- Bernštejn, N. A., Pickenhain, L. & Schnabel, G. (Hrsg.). (1988). *Bewegungsphysiologie* (Sportmedizinische Schriftenreihe der Deutschen Hochschule für Körperkultur Leipzig und des Forschungsinstitutes für Körperkultur und Sport Leipzig, Bd. 9, 2., durchges. und erw. Aufl.). Leipzig: Barth.
- Bilmes, J. A. (1998). *A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models*. Berkeley CA (S. 2-7).
- Bilmes, J. A. (2006). What HMMs can do. *IEICE Transactions on Information and Systems*, E89-D (3), 869-891.

- Bishop, C. M. (2009). *Pattern recognition and machine learning* (Information science and statistics, Corrected at 8. printing 2009). New York, NY: Springer.
- Bishop, C. M. (2010). *Neural networks for pattern recognition* (Reprinted.). Oxford: Oxford Univ. Press.
- Bizzi, E., Cheung, V. C. K., d'Avella, A., Saltiel, P. & Tresch, M. (2008). Combining modules for movement. *Brain research reviews*, 57 (1), 125-133.
- Blickhan, R. (1989). The spring-mass model for running and hopping. *Journal of Biomechanics*, 22 (11-12), 1217-1227.
- Blunsom, P. (2004). *Hidden Markov Models*. Lecture Notes, School of Engineering. Melbourne.
- Boesnach, I., Moldenhauer, J., Burgmer, C., Beth, T., Wank, V. & Bos, K. (2004). Classification of phases in human motions by neural networks and hidden Markov models. In *IEEE Conference on Cybernetics and Intelligent Systems, 2004* (S. 976-981).
- Borelli, G. A. & Maquet, P. (1989). *On the movement of animals*. Berlin: Springer.
- Borghese, N. A., Bianchi, L. & Lacquaniti, F. (1996). Kinematic determinants of human locomotion. *The Journal of physiology*, 494 (Pt 3), 863-879.
- Bös, K. (Hrsg.). (2009). *Motorik-Modul. Eine Studie zur motorischen Leistungsfähigkeit und körperlich-sportlichen Aktivität von Kindern und Jugendlichen in Deutschland ; Abschlussbericht zum Forschungsprojekt* (Forschungsreihe / Bundesministerium für Familie, Senioren, Frauen und Jugend, Bd. 5, 1. Aufl., Stand: Januar 2009). Baden-Baden: Nomos-Verl.; Publikationsversand der Bundesregierung.
- Braune, W. & Fischer, O. (1987). *The Human Gait*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Breathnach, C. S. (2004). Charles Scott Sherrington's Integrative action: a centenary notice. *Journal of the Royal Society of Medicine*, 97 (1), 34-36.
- Breuer, R. (Hrsg.). (2004). *Die Evolution des Menschen. Der Ursprung des Menschen ; frühe Hominiden ; Spuren des aufrechten Ganges ; auf der Suche nach Adam und Eva ; Neandertaler gegen Homo sapiens* (Spektrum der Wissenschaft Dossier, Bd. 2004,2). Heidelberg: Spektrum der Wissenschaft.



- Brown, T. G. (1914). On the nature of the fundamental activity of the nervous centres; together with an analysis of the conditioning of rhythmic activity in progression, and a theory of the evolution of function in the nervous system. *The Journal of physiology*, 48 (1), 18-46.
- Cappozzo, A. (1984). Gait analysis methodology. *Human Movement Science*, 3 (1-2), 27-50.
- Cavanagh, P. R. & Kram, R. (1989). Stride length in distance running: velocity, body dimensions, and added mass effects. *Medicine and science in sports and exercise*, 21 (4), 467-479.
- Centers for Disease Control and Prevention. (1996). Surgeon General's report on physical activity and health. *JAMA*, 276 (7), 522.
- Chamary, J. V. (2016). Homöostase. In J. V. Chamary (Hrsg.), *50 Schlüsselideen Biologie* (S. 136-139). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Cheng, M.-H., Ho, M.-F. & Huang, C.-L. (2008). Gait analysis for human identification through manifold learning and HMM. *Pattern Recognition*, 41 (8), 2541-2553.
- Chiang, J., Wang, Z. J. & McKeown, M. J. (2008). A Hidden Markov, Multivariate Autoregressive (HMM-mAR) Network Framework for Analysis of Surface EMG (sEMG) Data. *IEEE Transactions on Signal Processing*, 56 (8), 4069-4081.
- Christian, J., Kröll, J., Strutzenberger, G., Alexander, N., Ofner, M. & Schwameder, H. (2016). Computer aided analysis of gait patterns in patients with acute anterior cruciate ligament injury. *Clinical biomechanics (Bristol, Avon)*, 33, 55-60.
- Cimolin, V. & Galli, M. (2014). Summary measures for clinical gait analysis: a literature review. *Gait & Posture*, 39 (4), 1005-1010.
- Clever, D., Harant, M., Koch, H., Mombaur, K. & Endres, D. (2016). A novel approach for the generation of complex humanoid walking sequences based on a combination of optimal control and learning of movement primitives. *Robotics and Autonomous Systems*.
- Codling, E. A., Plank, M. J. & Benhamou, S. (2008). Random walk models in biology. *Journal of the Royal Society, Interface / the Royal Society*, 5 (25), 813-834.

- Cohen, A. H., Rossignol, S. & Grillner, S. (Eds.). (1988). *Neural control of rhythmic movements in vertebrates* (Wiley series in neurobiology). New York: Wiley.  
Verfügbar unter <http://www.loc.gov/catdir/enhancements/fy0706/87021573-b.html>
- Collins, S., Ruina, A., Tedrake, R. & Wisse, M. (2005). Efficient bipedal robots based on passive-dynamic walkers. *Science (New York, N.Y.)*, 307 (5712), 1082-1085.
- Coomans, D. & Massart, D. L. (1982). Alternative k-nearest neighbour rules in supervised pattern recognition. *Analytica Chimica Acta*, 136, 15-27.
- Cortes, C. & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20 (3), 273-297.
- Darwin, C. (2006). *On the origin of species by means of natural selection, or, The preservation of favoured races in the struggle for life* (Dover giant thrift ed.). Mineola, NY: Dover Publications.
- Dingwell, J. B., Cusumano, J. P., Cavanagh, P. R. & Sternad, D. (2001). Local Dynamic Stability Versus Kinematic Variability of Continuous Overground and Treadmill Walking. *Journal of Biomechanical Engineering*, 123 (1), 27.
- Domingos, P. & Pazzani, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, 29 (2/3), 103-130.
- Facchini, F. (1991). *Der Mensch. Ursprung und Entwicklung*. Augsburg: Natur-Verl.
- Faisal, A. A., Selen, L. P. J. & Wolpert, D. M. (2008). Noise in the nervous system. *Nature reviews. Neuroscience*, 9 (4), 292-303.
- Fink, G. A. (2003). *Mustererkennung mit Markov-Modellen. Theorie - Praxis - Anwendungsgebiete* (Leitfäden der Informatik). Wiesbaden: Vieweg+Teubner Verlag. Verfügbar unter <http://dx.doi.org/10.1007/978-3-322-80065-7>
- Firmani, F. & Park, E. J. (2013). Theoretical analysis of the state of balance in bipedal walking. *Journal of biomechanical engineering*, 135 (4), 41003.
- Forssberg, H. & Hirschfeld, H. (1988). Phasic modulation of postural activation patterns during human walking. *Progress in brain research*, 76, 221-227.
- Fuchs, P. & Lames, M. (1990). Mathematische Modellierung des Wettkampfvhaltens im Sprint. *Leistungssport*, 20 (5), 35-41.

- Fujii, S., Kudo, K., Ohtsuki, T. & Oda, S. (2009). Tapping performance and underlying wrist muscle activity of non-drummers, drummers, and the world's fastest drummer. *Neuroscience letters*, 459 (2), 69-73.
- Fukuchi, R. K. & Duarte, M. (2008). Comparison of three-dimensional lower extremity running kinematics of young adult and elderly runners. *Journal of sports sciences*, 26 (13), 1447-1454.
- Fukuchi, R. K., Eskofier, B. M., Duarte, M. & Ferber, R. (2011). Support vector machines for detecting age-related changes in running kinematics. *Journal of Biomechanics*, 44 (3), 540-542.
- Fung, J., Stewart, J. E. & Barbeau, H. (1990). The combined effects of clonidine and cyproheptadine with interactive training on the modulation of locomotion in spinal cord injured subjects. *Journal of the neurological sciences*, 100 (1-2), 85-93.
- Gabler, H., Nitsch, J. R. & Singer, R. (2001). *Einführung in die Sportpsychologie* (Sport und Sportunterricht, Bd. 3, 2., erw. u. verb. Aufl.).
- Gates, D. H., Wilken, J. M., Scott, S. J., Sinitski, E. H. & Dingwell, J. B. (2012). Kinematic strategies for walking across a destabilizing rock surface. *Gait & Posture*, 35 (1), 36-42.
- Ghez, C. & Krakauer, J. (2000). Principles of neural science. In E. R. Kandel (Ed.), *Principles of neural science* (4<sup>th</sup> ed., pp. 653-673). New York, NY: McGraw-Hill Medical.
- Giakas, G. & Baltzopoulos, V. (1997). Time and frequency domain analysis of ground reaction forces during walking. An investigation of variability and symmetry. *Gait & Posture*, 5 (3), 189-197.
- Gioftos, G. & Grieve, D. W. (1995). The use of neural networks to recognize patterns of human movement: gait patterns. *Clinical Biomechanics*, 10 (4), 179-183.
- Gottschall, J. S. & Kram, R. (2005). Ground reaction forces during downhill and uphill running. *Journal of Biomechanics*, 38 (3), 445-452.
- Götz-Neumann, K. (2016). *Gehen verstehen. Ganganalyse in der Physiotherapie* (physiofachbuch, 4. Auflage). Stuttgart: Georg Thieme Verlag.

- Graf, C., Dordel, S., Koch, B. & Predel, H. (2006). Bewegungsmangel und Übergewicht bei Kindern und Jugendlichen. *Deutsche Zeitschrift für Sportmedizin*, 57 (9), 220-225.
- Greitemann, B. (2009). Conservative therapy of osteoarthritis. Technical orthopedic fittings. *Zeitschrift für Rheumatologie*, 68 (10), 797-803.
- Grillner, S. (1996). Bewegungssteuerung im Wirbeltier-Rückenmark. *Spektrum der Wissenschaft* (3), 50.
- Grillner, S. (2003). The motor infrastructure: from ion channels to neuronal networks. *Nature reviews. Neuroscience*, 4 (7), 573-586.
- Grillner, S. (2006). Biological pattern generation: the cellular and computational logic of networks in motion. *Neuron*, 52 (5), 751-766.
- Guertin, P. A. (2012). Central pattern generator for locomotion: anatomical, physiological, and pathophysiological considerations. *Frontiers in neurology*, 3, 183.
- Guyon, I. & Elisseeff, A. (2003). An introduction to variable and feature selection. *The Journal of Machine Learning Research* (3), 1157-1182.
- Guyon, I. & Elisseeff, A. (2006). An Introduction to Feature Extraction. In I. Guyon, M. Nikravesh, S. Gunn & L. A. Zadeh (Hrsg.), *Feature Extraction* (Studies in Fuzziness and Soft Computing, Bd. 207, S. 1-25). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Hamill, J., Knutzen, K. & Derrick, T. R. (2015). *Biomechanical basis of human movement* (4. ed.). Philadelphia, PA: Wolters Kluwer.
- Hausdorff, J. M., Mitchell, S. L., Firtion, R., Peng, C. K., Cudkowicz, M. E., Wei, J. Y. et al. (1997). Altered fractal dynamics of gait: reduced stride-interval correlations with aging and Huntington's disease. *Journal of applied physiology (Bethesda, Md. : 1985)*, 82 (1), 262-269.
- Hausdorff, J. M., Peng, C. K., Ladin, Z., Wei, J. Y. & Goldberger, A. L. (1995). Is walking a random walk? Evidence for long-range correlations in stride interval of human gait. *Journal of applied physiology (Bethesda, Md. : 1985)*, 78 (1), 349-358.

- Häuselmann, H. J. & Hedbom, E. (2002). Von der Pathogenese der Arthrose zu therapeutischen Empfehlungen und Knorpelersatz. *Schweiz Med Forum* (25), 610-615.
- Hebb, D. O. (1949). *The organization of behavior. A neuropsychological theory*. Mahwah, NJ: Erlbaum.
- Hebenstreit, F., Leibold, A., Krinner, S., Welsch, G., Lochmann, M. & Eskofier, B. M. (2015). Effect of walking speed on gait sub phase durations. *Human Movement Science*, 43, 118-124.
- Heinert, M. (2010). Support Vector Machines. Teil 1: Ein theoretischer Überblick. *Zeitschrift für Geodäsie, Geoinformation und Landmanagement*, 135 (3), 179-189.
- Hirose, M. & Ogawa, K. (2007). Honda humanoid robots development. *Philosophical transactions. Series A, Mathematical, physical, and engineering sciences*, 365 (1850), 11-19.
- Hollman, J. H., McDade, E. M. & Petersen, R. C. (2011). Normative spatiotemporal gait parameters in older adults. *Gait & Posture*, 34 (1), 111-118.
- Holzreiter, S. H. & Kohle, M. E. (1993). Assessment of gait patterns using neural networks. *Journal of Biomechanics*, 26 (6), 645-651.
- Horst, F., Scherdel, N., Mildner, M., Kronemayer-Wurm, K., Corell, D. & Schöllhorn, W. I. (2015). Identification of individual gait patterns by means of support vector machines. In *Book of Abstracts of the International Conference of Exercise for Health and Rehabilitation* (S. 32-35).
- Hotz, A. (2001). *Ein Plädoyer für Nikolai Alexandrowitsch Bernstein (1896-1966)*. Universität Erfurt, Institut für Sport und Bewegungswissenschaften: Unveröffentlichtes Skript. Verfügbar unter [https://www2.uni-erfurt.de/sport/download-all/Hotz\\_ueber\\_Bernstein\\_2001.pdf](https://www2.uni-erfurt.de/sport/download-all/Hotz_ueber_Bernstein_2001.pdf)
- Inman, V. T. (1966). Human locomotion. *Canadian Medical Association journal*, 94 (20), 1047-1054.
- Inman, V. T., Ralston, H. J. & Todd, F. (1981). *Human walking*. Baltimore: Williams & Wilkins.

- Jansen, H., Fenwick, A., Doht, S., Frey, S. & Meffert, R. (2013). Clinical outcome and changes in gait pattern after pilon fractures. *International orthopaedics*, 37 (1), 51-58.
- Janssen, D., Schöllhorn, W. I., Lubienetzki, J., Fölling, K., Kokenge, H. & Davids, K. (2008). Recognition of Emotions in Gait Patterns by Means of Artificial Neural Nets. *Journal of Nonverbal Behavior*, 32 (2), 79-92.
- Janssen, D., Schöllhorn, W. I., Newell, K. M., Jager, J. M., Rost, F. & Vehof, K. (2011). Diagnosing fatigue in gait patterns by support vector machines and self-organizing maps. *Human Movement Science*, 30 (5), 966-975.
- Jordan, K., Challis, J. H. & Newell, K. M. (2006). Long range correlations in the stride interval of running. *Gait & Posture*, 24 (1), 120-125.
- Jordan, K., Challis, J. H. & Newell, K. M. (2007). Walking speed influences on gait cycle variability. *Gait & Posture*, 26 (1), 128-134.
- Jordan, K. & Newell, K. M. (2008). The structure of variability in human walking and running is speed-dependent. *Exercise and sport sciences reviews*, 36 (4), 200-204.
- Kadaba, M. P., Ramakrishnan, H. K., Wootten, M. E., Gaine, J., Gorton, G. & Cochran, G. V. B. (1989). Repeatability of kinematic, kinetic, and electromyographic data in normal adult gait. *Journal of Orthopaedic Research*, 7 (6), 849-860.
- Kearns, M. & Ron, D. (1999). Algorithmic Stability and Sanity-Check Bounds for Leave-One-Out Cross-Validation. *Neural Computation*, 11 (6), 1427-1453.
- Khorasani, A. & Daliri, M. R. (2014). HMM for classification of Parkinson's disease based on the raw gait data. *Journal of medical systems*, 38 (12), 147.
- Kirtley, C., Whittle, M. W. & Jefferson, R. J. (1985). Influence of walking speed on gait parameters. *Journal of Biomedical Engineering*, 7 (4), 282-288.
- Kling, U. & Székely, G. (1968). Simulation of rhythmic nervous activities. *Kybernetik*, 5 (3), 89-103.
- Klinke, R., Silbernagl, S. & Bauer, C. (Hrsg.). (2003). *Lehrbuch der Physiologie*. 55 Tabellen (4., korrigierte Aufl.). Stuttgart: Thieme.
- Knieling, S. (2007). *Einführung in die Modellierung künstlich neuronaler Netzwerke*. Duisburg: WiKu-Verl.

- Kohl, H. W., Craig, C. L., Lambert, E. V., Inoue, S., Alkandari, J. R., Leetongin, G. et al. (2012). The pandemic of physical inactivity. Global action for public health. *The Lancet*, 380 (9838), 294-305.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43 (1), 59-69.
- Kohonen, T. (1990). The self-organizing map. *Proceedings of the IEEE*, 78 (9), 1464-1480.
- Konczak, J. (2003). Neurophysiologische Grundlagen der Motorik. In H. Mechling & K. Blischke (Hrsg.), *Handbuch Bewegungswissenschaft - Bewegungslehre* (Beiträge zur Lehre und Forschung im Sport, Bd. 141, S. 81-104). Schorndorf: Hofmann.
- Kortmann, T., & Schöllhorn, W. I (2010). Neue Ansätze der Bewegungswissenschaft als Grundlage für ein modernes Techniktraining im Rudern – Bewegungsstabilität durch Wiederholung oder durch Adaptation? In V. Grabow, U. Hartmann & R. Kilzer (Hrsg.), *Berichtsband Rudersymposium* (S. 259-270).
- Kramers-de Quervain, I. A., Stüssi E. & Stacoff A. (2008). Ganganalyse beim Gehen und Laufen. *Schweizerische Zeitschrift für Sportmedizin und Sporttraumatologie*, 2008 (56(2)), 35-42.
- Kriesel, D. (2007). *Ein kleiner Überblick über Neuronale Netze*. Zugriff am 12.05.2016. Verfügbar unter <http://www.dkriesel.com>
- Krug, S., Jordan, S., Mensink, G. B. M., Muters, S., Finger, J. & Lampert, T. (2013). Physical activity: results of the German Health Interview and Examination Survey for Adults (DEGS1). *Bundesgesundheitsblatt, Gesundheitsforschung, Gesundheitsschutz*, 56 (5-6), 765-771.
- Lamb, P. & Bartlett, R. (2013). Neural Networks for Analysing Sports Techniques. In T. McGarry, P. O'Donoghue & J. Sampaio (Eds.), *Routledge Handbook of Sports Performance Analysis* (Routledge International Handbooks, pp. 225-236). Hoboken: Taylor and Francis.
- Lamb, P. F., Mündermann, A., Bartlett, R. M. & Robins, A. (2011). Visualizing changes in lower body coordination with different types of foot orthoses using self-organizing maps (SOM). *Gait & Posture*, 34 (4), 485-489.

- Lames, M. & Perl, J. (1999). Identifikation von Ballwechselltypen mit Neuronalen Netzen. In K. Roth (Hrsg.), *Dimensionen und Visionen des Sports. Evaluation, Profilbildung, Globalisierung ; Beiträge zum 14. Sportwissenschaftlichen Hochschultag der Deutschen Vereinigung für Sportwissenschaft vom 27.-29.9.1999 in Heidelberg* (Schriften der Deutschen Vereinigung für Sportwissenschaft, Bd. 108, 1. Aufl., S. 133). Hamburg: Czwalina.
- Langenderfer, J. E., Hughes, R. E. & Carpenter, J. E. (2005). A stochastic model of elbow flexion strength for subjects with and without long head biceps tear. *Computer methods in biomechanics and biomedical engineering*, 8 (5), 315-322.
- Latash, M. L. (2001). *Classics in movement science*. Champaign, Ill.: Human Kinetics.
- Li, L., Haddad, J. M. & Hamill, J. (2005). Stability and variability may respond differently to changes in walking speed. *Human Movement Science*, 24 (2), 257-267.
- Little, J. J. & Boyd, J. E. (1998). Recognizing people by their gait: The shape of motion. *Videre: Journal of Computer Vision Research*, 1 (2), 1-32.
- Loffi, A. & Garibaldi, J. M. (Hrsg.). (2004). *Applications and Science in Soft Computing*. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Lu, J. & Zhang, E. (2007). Gait recognition for human identification based on ICA and fuzzy SVM through multiple views fusion. *Pattern Recognition Letters*, 28 (16), 2401-2411.
- Lu, W., Zong, W., Xing, W. & Bao, E. (2014). Gait recognition based on joint distribution of motion angles. *Journal of Visual Languages & Computing*, 25 (6), 754-763.
- Lynn, S. K., Reid, S. M. & Costigan, P. A. (2007). The influence of gait pattern on signs of knee osteoarthritis in older adults over a 5-11 year follow-up period: a case study analysis. *The Knee*, 14 (1), 22-28.
- Madry, H. & Kohn, D. (2004). Conservative treatment of knee osteoarthritis. *Der Unfallchirurg*, 107 (8), 689-99; quiz 700.
- Mannini, A. & Sabatini, A. M. (2012a). Automatic gait phase segmentation method using a Hidden Markov Model. *Gait & Posture*, 35, 17-18.



- Mannini, A. & Sabatini, A. M. (2012b). Gait phase detection and discrimination between walking-jogging activities using hidden Markov models applied to foot motion data from a gyroscope. *Gait & Posture*, 36 (4), 657-661.
- Manoonpong, P., Geng, T., Kulvicius, T., Porr, B. & Wörgötter, F. (2007). Correction. Adaptive, Fast Walking in a Biped Robot under Neuronal Control and Learning. *PLoS Computational Biology*, 3 (9), e191.
- Maus, H.-M., Revzen, S., Guckenheimer, J., Ludwig, C., Reger, J. & Seyfarth, A. (2015). Constructing predictive models of human running. *Journal of the Royal Society, Interface / the Royal Society*, 12 (103).
- McClelland, J. L. & Rumelhart, D. E. (1986). *Psychological and Biological Models* (Computational Models of Cognition and Perception, Vol. 1 + 2). Cambridge.
- McCrea, D. A. & Rybak, I. A. (2008). Organization of mammalian locomotor rhythm and pattern generation. *Brain research reviews*, 57 (1), 134-146.
- McCulloch, W. S. & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5 (4), 115-133.
- McMahon, T. A. & Cheng, G. C. (1990). The mechanics of running. How does stiffness couple with speed? *Journal of Biomechanics*, 23, 65-78.
- Medved, V. (2001). *Measurement of human locomotion*: CRC Press.
- Menz, H. B., Lord, S. R. & Fitzpatrick, R. C. (2003). Age-related differences in walking stability. *Age and ageing*, 32 (2), 137-142.
- Mercer, J. (1909). Functions of Positive and Negative Type, and their Connection with the Theory of Integral Equations. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 209 (441-458), 415-446.
- Mester, J. & Perl, J. (2000). Grenzen der Anpassungs- und Leistungsfähigkeit aus systemischer Sicht. Zeitreihenanalyse und ein informatisches Metamodell zur Untersuchung physiologischer Adaptationsprozesse. *Leistungssport*, 30 (1), 43-51.
- Miller, B. C., Buffinton, E. M., Bieryla, K. A. & Pratt, J. E. (2016). Biomechanics of Step Initiation After Balance Recovery With Implications for Humanoid Robot Locomotion. *Journal of biomechanical engineering*, 138 (3), 4032468.

- Miller, W. L. & Sigvardt, K. A. (2000). Extent and role of multisegmental coupling in the Lamprey spinal locomotor pattern generator. *Journal of neurophysiology*, 83 (1), 465-476.
- Mombaur, K. (2015). Das Wunder der Bewegung. *Universität Heidelberg: Ruperto Carola* (6), 58-65. Gehen wie ein Mensch.
- Morgan, D. W., Martin, P. E., Krahenbuhl, G. S. & Baldini, F. D. (1991). Variability in running economy and mechanics among trained male runners. *Medicine and science in sports and exercise*, 23 (3), 378-383.
- Müller, R. & Blickhan, R. (2010). Running on uneven ground: leg adjustments to altered ground level. *Human Movement Science*, 29 (4), 578-589.
- Mündermann, A., Dyrby, C. O. & Andriacchi, T. P. (2005). Secondary gait changes in patients with medial compartment knee osteoarthritis: increased load at the ankle, knee, and hip during walking. *Arthritis and rheumatism*, 52 (9), 2835-2844.
- Murphy, K. (1998). *Hidden Markov Model (HMM) Toolbox for Matlab*. Zugriff am 09.05.2016. Verfügbar unter <https://www.cs.ubc.ca/~murphyk/Software/HMM/hmm.html>
- Murray, M. P., Drought, A. B. & Kory, R. C. (1964). Walking Patterns of normal men. *The Journal of bone and joint surgery. American volume*, 46, 335-360.
- Nakayama, Y., Kudo, K. & Ohtsuki, T. (2010). Variability and fluctuation in running gait cycle of trained runners and non-runners. *Gait & Posture*, 31 (3), 331-335.
- Ng, H., Ton, H. L., Tan, W. H., Yap, T. T. V., Chong, P. F. & Abdullah, J. (2011). Human identification based on extracted gait features. *International Journal of New Computer Architectures and their Applications (IJNCAA)*, 1 (2), 358-370.
- Nigg, B. M., Boer, R. W. de & Fisher, V. (1995). A kinematic comparison of overground and treadmill running. *Medicine and science in sports and exercise*, 27 (1), 98-105.
- Nissen, S. (2003). *Implementation of a fast artificial neural network library (fann)*. Technical Report. : Department of Computer Science, University of Copenhagen (DIKU).
- Novacheck, T. F. (1998). The biomechanics of Running. *Gait and Posture*, 7, 77-95.

- Opper, E., Worth, A., Wagner, M. & Bös, K. (2007). The module "Motorik" in the German Health Interview and Examination Survey for Children and Adolescents (KiGGS). Motor fitness and physical activity of children and young people. *Bundesgesundheitsblatt, Gesundheitsforschung, Gesundheitsschutz*, 50 (5-6), 879-888.
- Orlovskij, G. N., Deliagina, T. G. & Grillner, S. (1999). *Neuronal control of locomotion. From mollusc to man*. Oxford: Oxford Univ. Press.
- Padulo, J., Annino, G., Migliaccio, G. M., D'Ottavio, S. & Tihanyi, J. (2012). Kinematics of running at different slopes and speeds. *Journal of strength and conditioning research / National Strength & Conditioning Association*, 26 (5), 1331-1339.
- Paradisis, G. P. & Cooke, C. B. (2001). Kinematic and postural characteristics of sprint running on sloping surfaces. *Journal of sports sciences*, 19 (2), 149-159.
- Pearson, K. G. (1993). Common principles of motor control in vertebrates and invertebrates. *Annual review of neuroscience*, 16, 265-297.
- Perl, J. (2002). DYCON: Ein neuer Ansatz zur Modellierung und Analyse von Sportspiel-Prozessen mit Hilfe neuronaler Netze. In K. Ferger (Hrsg.), *Sportspiele erleben, vermitteln, trainieren. 2. Sportspiel-Symposium der dvs vom 4. - 6.10.2000 in Gießen* (Schriften der Deutschen Vereinigung für Sportwissenschaft, Bd. 124, Bd. 124, S. 253-265). Hamburg: Czwalina.
- Perl, J. (2007). Qualitative Analyse von Prozessen im Sport mit Hilfe von Methoden des Soft Computing. *E-Journal Bewegung und Training* (1), 65-73.
- Perl, J. (2008). Modellbildung und Simulation von Prozessen im Sport. *Informatik Spektrum*, 31 (4).
- Perl, J. (2009). Trainingswirkungsanalyse: Planung und Optimierung mithilfe des antagonistischen Metamodells PerPot. *Zeitschrift für angewandte Trainingswissenschaft*, 16 (2), 117-127.
- Perl, J. & Dauscher, P. (2006). Dynamic Pattern Recognition in Sport by Means of Artificial Neural Networks. In R. Begg & M. Palaniswami (Hrsg.), *Computational Intelligence for Movement Sciences* (S. 299-319). IGI Global.

- Perret, C. & Cabelguen, J. M. (1980). Main characteristics of the hindlimb locomotor cycle in the decorticate cat with special reference to bifunctional muscles. *Brain research*, 187 (2), 333-352.
- Perry, J. (1992). *Gait analysis. Normal and pathological function*. Thorofare, NJ: SLACK.
- Perry, J. & Burnfield, J. M. (2010). *Gait analysis. Normal and pathological function* (2. ed.). Thorofare, NJ: SLACK.
- Pfeiffer, M., Hohmann, A. & Fuhrmann, S. (2012). Optimierung der Trainingssteuerung im Schwimmsport mittels simulationsgestützter Trainingswirkungsanalyse mit dem Performance-Potential Modell (PerPot). In *BISp-Jahrbuch. Forschungsförderung 2011/12* (1., Aufl., S. 31-36). Köln: Sportverlag Strauß.
- Plotz, T. & Fink, G. A. Feature extraction for improved profile HMM based biological sequence analysis. In *Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004* (315-318 Vol.2).
- Pradhan, C., Wuehr, M., Akrami, F., Neuhaeusser, M., Huth, S., Brandt, T. et al. (2015). Automated classification of neurological disorders of gait using spatio-temporal gait parameters. *Journal of electromyography and kinesiology : official journal of the International Society of Electrophysiological Kinesiology*, 25 (2), 413-422.
- Rabiner, L. R. (1989). A tutorial on hidden Markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77 (2), 257-286.
- Rey, G. D. & Wender, K. F. (2008). *Neuronale Netze. Eine Einführung in die Grundlagen, Anwendungen und Datenauswertung* (Programm Verlag Hans Huber Psychologie Lehrbuch, 1. Aufl.). Bern: Huber. Verfügbar unter [http://sub-hh.ciando.com/book/?bok\\_id=15205](http://sub-hh.ciando.com/book/?bok_id=15205)
- Richards, J. (2008). *Biomechanics in clinic and research. An interactive teaching and learning course*. Edinburgh: Churchill Livingstone Elsevier.
- Robert Koch Institut (Hrsg.). (2005) Körperliche Aktivität [Themenheft] (26).
- Robins, B., Dautenhahn, K., Boekhorst, R. T. & Billard, A. (2005). Robotic assistants in therapy and education of children with autism. Can a small humanoid robot help

- encourage social interaction skills? *Universal Access in the Information Society*, 4 (2), 105-120.
- Rojas, R. (1996). *Neural Networks. A Systematic Introduction*. Berlin, Heidelberg: Springer.
- Rose, J. & Gamble, J. G. (Eds.). (2006). *Human walking* (3. ed.). Philadelphia: Lippincott Williams & Wilkins. Verfügbar unter <http://www.loc.gov/catdir/enhancements/fy0712/2005022885-d.html>
- Roth, K. & Roth, C. (2009). Entwicklung motorischer Fertigkeiten. In J. Baur, C. Klenk & D. Alfermann (Hrsg.), *Handbuch motorische Entwicklung* (Beiträge zur Lehre und Forschung im Sport, Bd. 106, 2., komplett überarb. Aufl., S. 227-248). Schorndorf: Hofmann.
- Roth, K. & Willimczik, K. (1999). *Bewegungswissenschaft* (rororo rororo-Sport, Bd. 18679, Orig.-Ausg). Reinbek bei Hamburg: Rowohlt-Taschenbuch-Verl.
- Schaal, S. (1999). Is imitation learning the route to humanoid robots? *Trends in Cognitive Sciences*, 3 (6), 233-242.
- Schlicht, W. (1988). *Einzelfallanalysen im Hochleistungssport. Zum Verlauf u. zur Wirkung selbstbezogener Aufmerksamkeit im 400-Meter-Hürdenlauf* (Schriftenreihe des Bundesinstituts für Sportwissenschaft, Bd. 64, 1. Aufl.). Univ., Diss.--Gießen, 1987. Schorndorf: Hofmann.
- Schmidt, A. (2012). Movement pattern recognition in basketball free-throw shooting. *Human Movement Science*, 31 (2), 360-382.
- Schmidt, R. A. & Lee, T. D. (2005). *Motor control and learning. A behavioral emphasis* (4. ed.). Champaign, Ill.: Human Kinetics.
- Schölkopf, B. & Smola, A. J. (2002). *Learning with kernels. Support vector machines, regularization, optimization, and beyond* (Adaptive computation and machine learning). Cambridge, Mass: MIT Press.
- Schölkopf, B., Vert, J.-P. & Tsuda, K. (Eds.). (2004). *Kernel methods in computational biology* (Computational biology). Cambridge, Mass: MIT Press. Verfügbar unter <http://ieeexplore.ieee.org/servlet/opac?bknumber=6267331>

- Schöllhorn, W. I. (1993). Prozessorientierte Modellierung der Diskuswurfbewegung, 55, 109-116. 1. Symposium der DVS-Sektion Biomechanik vom 29. - 31. Oktober 1992 in Oberhof/Thüringen.
- Schöllhorn, W. I. (1999). Individualität - ein vernachlässigter Partner. *Leistungssport* (2), 3-12.
- Schöllhorn, W. I. (2004). Applications of artificial neural nets in clinical biomechanics. *Clinical biomechanics (Bristol, Avon)*, 19 (9), 876-898.
- Schöllhorn, W. I., Jäger, J. M. & Janssen D. (2008). Artificial Neural Network Models of Sports Motions. In Y. Hong & R. Bartlett (Eds.), *Routledge Handbook of Biomechanics and Human Movement Science* (pp. 50-64). Oxon, New York: Routledge.
- Schöllhorn, W. I., Nigg, B. M., Stefanyshyn, D. J. & Liu, W. (2002). Identification of individual walking patterns using time discrete and time continuous data sets. *Gait and Posture*, 15, 180-186.
- Schöllhorn, W. I. & Perl, J. (2002). Prozessanalysen in der Bewegungs- und Spielforschung. Verlaufsorientierte Ansätze zur Quantifizierung "neuer" Qualitäten in der Bewegungs- und Sportspielforschung. *Spectrum*, 14 (1), 30-52.
- Schultz, T. & Wand, M. (2010). Modeling coarticulation in EMG-based continuous speech recognition. *Speech Communication*, 52 (4), 341-353.
- Schuster-Bockler, B., Schultz, J. & Rahmann, S. (2004). HMM Logos for visualization of protein families. *BMC bioinformatics*, 5, 7.
- Selverston, A. I. (2005). A neural infrastructure for rhythmic motor patterns. *Cellular and molecular neurobiology*, 25 (2), 223-244.
- Selverston, A. I. (2010). Invertebrate central pattern generator circuits. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, 365 (1551), 2329-2345.
- Shepherd, G. M. (1993). *Neurobiologie* (Springer-Lehrbuch). Berlin: Springer. Verfügbar unter <http://dx.doi.org/10.1007/978-3-642-77591-8>
- Shik, M. L. & Orlovskij, G. N. (1976). Neurophysiology of locomotor automatism. *Physiological reviews*, 56 (3), 465-501.

- Shumway-Cook, A. & Woollacott, M. H. (2012). *Motor control. Translating research into clinical practice* (4th ed.). Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins.
- Silverman, A. K., Wilken, J. M., Sinitski, E. H. & Neptune, R. R. (2012). Whole-body angular momentum in incline and decline walking. *Journal of Biomechanics*, 45 (6), 965-971.
- Simon, S. R. (2004). Quantification of human motion: gait analysis-benefits and limitations to its application to clinical problems. *Journal of Biomechanics*, 37 (12), 1869-1880.
- Slawinski, J., Dorel, S., Hug, F., Couturier, A., Fournel, V., Morin, J.-B. et al. (2008). Elite long sprint running: a comparison between incline and level training sessions. *Medicine and science in sports and exercise*, 40 (6), 1155-1162.
- Sokolowski, K. (2008). Emotion. In J. Müsseler (Hrsg.), *Allgemeine Psychologie* (2., neu bearbeitete Auflage, Nachdruck als limitierte, einfarbige Sonderausgabe, S. 294-333). Berlin: Springer.
- Statistisches Bundesamt. *Pressemitteilung Nr. 132. Gesundheitsausgaben im Jahr 2013*. Zugriff am 16.07.2016. Verfügbar unter <https://www.destatis.de/DE/PresseService/Presse/Pressemitteilungen>
- Stein, T., Fischer, A., Bös, K., Wank, V., Boesnach, I. & Moldenhauer, J. (2006). Guidelines for Motion Control of Humanoid Robots: Analysis and Modelling of Human Move-ments. *International Journal of Computer Science in Sport*, 5 (1), 15-30.
- Sudha, L. R. & Bhavani, R. (2012). Performance comparison of SVM and kNN in automatic classification of human gait patterns. *International Journal of Computers*, 6 (1), 19-28.
- Sulzbacher, I. (2000). Arthrose - Histologie und pathogenetische Ansätze. *Der Radiologe*, 40 (12), 1126-1133.
- Swanson, S. C. & Caldwell, G. E. (2000). An integrated biomechanical analysis of high speed incline and level treadmill running. *Medicine and science in sports and exercise*, 32 (6), 1146-1155.

- Takenaka, T. (2006). The control system for the Honda humanoid robot. *Age and ageing, 35 Suppl 2*, ii24-ii26.
- Telhan, G., Franz, J. R., Dicharry, J., Wilder, R. P., Riley, P. O. & Kerrigan, D. C. (2010). Lower limb joint kinetics during moderately sloped running. *Journal of athletic training, 45* (1), 16-21.
- Thies, S. B., Richardson, J. K. & Ashton-Miller, J. A. (2005). Effects of surface irregularity and lighting on step variability during gait: a study in healthy young and older women. *Gait & Posture, 22* (1), 26-31.
- Thorpe, S. K. S., Holder, R. L. & Crompton, R. H. (2007). Origin of Human Bipedalism As an Adaptation for Locomotion on Flexible Branches. *Science, 316* (5829), 1328-1331.
- Tresch, M. C., Saltiel, P. & Bizzi, E. (1999). The construction of movement by the spinal cord. *Nature neuroscience, 2* (2), 162-167.
- Troje, N. F. (2002). Decomposing biological motion. A framework for analysis and synthesis of human gait patterns. *Journal of Vision, 2* (5), 2.
- Troje, N. F., Westhoff, C. & Lavrov, M. (2005). Person identification from biological motion. Effects of structural and kinematic cues. *Perception & Psychophysics, 67* (4), 667-675.
- Tyldesley, D. A. & Whiting, H. T. (1975). Operational timing. *Journal of Human Movement Studies, 1* (4), 172-177.
- VICON®. (2002). *Plug-In Gait Manual* (VICON®Motion Systems, Oxford Metrics Ltd., Hrsg.), Oxford, UK.
- Vukobratovic, M. & Borovac, B. (2004). Zero-Moment Point — Thirty five years of its life. *International Journal of Humanoid Robotics, 01* (01), 157-173.
- Wang, J., She, M., Nahavandi, S. & Kouzani, A. (2010). A Review of Vision-Based Gait Recognition Methods for Human Identification. In J. Zhang (Ed.), *International Conference on Digital Image Computing: Techniques and Applications (DICTA), 2010. 1 - 3 Dec. 2010, Sydney, Australia ; proceedings* (pp. 320-327). Piscataway, NJ: IEEE.



- Wank, V., Frick, U. & Schmidtbleicher, D. (1998). Kinematics and Electromyography of Lower Limb Muscles in Overground and Treadmill Running. *International Journal of Sports Medicine*, 19 (07), 455-461.
- Westermann, R., Spies, K., Stahl, G. & Hesse, F. W. (1996). Relative effectiveness and validity of mood induction procedures. A meta-analysis. *European Journal of Social Psychology*, 26 (4), 557-580.
- Whittle, M. W. (2008). *Gait analysis. An introduction* (4th ed., reprinted.). Edinburgh: Butterworth-Heinemann Elsevier.
- Williams, K. R. (1985). Biomechanics of running. *Exercise and sport sciences reviews*, 13, 389-441.
- Winter, D. A. (1984). Kinematic and kinetic patterns in human gait: Variability and compensating effects. *Human Movement Science*, 3, 51-76.
- Winter, D. A., Patla, A. E., Frank, J. S. & Walt, S. E. (1990). Biomechanical walking pattern changes in the fit and healthy elderly. *Physical therapy*, 70 (6), 340-347.
- Wu, J. & Wang, J. (2008). PCA-based SVM for automatic recognition of gait patterns. *Journal of applied biomechanics*, 24 (1), 83-87.
- Wu, Y. & Krishnan, S. (2010). Statistical analysis of gait rhythm in patients with Parkinson's disease. *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, 18 (2), 150-158.
- Yamato, J., Ohya, J. & Ishii, K. (1992). Recognizing human action in time-sequential images using hidden Markov model. In A. Rosenfeld, N. Ahuja & T. Huang (Hrsg.), *Conference on Computer Vision and Pattern Recognition* (S. 379-385).
- Yoo, J.-H., Hwang, D. & Nixon, M. S. (2005). Gender Classification in Human Gait Using Support Vector Machine. In D. Hutchison, T. Kanade, J. Kittler, J. M. Kleinberg, F. Mattern, J. C. Mitchell et al. (Hrsg.), *Advanced Concepts for Intelligent Vision Systems* (Lecture Notes in Computer Science, Bd. 3708, S. 138-145). Berlin, Heidelberg: Springer Berlin Heidelberg.

## Anhang A

### Framework zur Datenaufbereitung und -analyse

Die Methoden der Erfassung von Messdaten in der Biomechanik unterliegen einer fortlaufenden Entwicklung, die in Abhängigkeit des Stands der Technik und der wissenschaftlichen Fragestellung der Untersuchungen stattfindet. In den vergangenen Jahren wurden die Möglichkeiten der Datenspeicherung sowohl im Hinblick auf die absolute Kapazität als auch in Bezug auf die Datenmenge, die pro Zeiteinheit gespeichert werden kann, stark verbessert. Für die Messungen von biomechanischen Kenngrößen bedeutet das einerseits, dass die gleichzeitige Aufnahme mit unterschiedlichen Methoden und deren Fusion kein grundlegendes Problem mehr darstellt. Andererseits kann, auch im Zuge der Entwicklung neuer Sensoren zur Messwertaufnahme, durch die Steigerung von Aufnahmefrequenz und Auflösung (Sensordichte, optische Auflösung, Farbdichte u.a.) eine bedeutend höhere Messgenauigkeit erreicht werden. Im Zuge der veränderten Messtechnik werden die Software-Umgebungen zur Aufnahme und Analyse der Messdaten von den Anbietern der Aufnahmesysteme iterativ angepasst. Um dennoch eine fortwährend, in der Grundstruktur unveränderte, Analysemethode gewährleisten zu können, wurde im Zuge dieser Arbeit ein Framework für die Aufbereitung und Auswertung der Messdaten entwickelt. Die Software wurde auf Basis von MATLAB programmiert und modular aufgebaut. Im Verlauf der Arbeit wurde die Software für die Auswertung der Daten mit den Fragestellungen und Methoden der einzelnen Studien um Module erweitert, bzw. wurden vorhandene Module generalisiert und angepasst.

#### *Import*

Im Verlauf der Arbeit wurden mit den Messdaten der Studien unterschiedliche Fragestellungen bearbeitet, die den Einsatz von mehreren Messtechniken erforderten. Für das Einlesen der heterogenen Datenstrukturen der unterschiedlichen Systeme in MATLAB wurden Importfunktionen erstellt. Um eine Verwendung des Frameworks auch über diese Arbeit hinaus durch Dritte zu gewährleisten, wurden die Importfunktionen für die jeweiligen Datenstrukturen allgemeingültig programmiert und können auch für veränderte Messkonfigurationen verwendet werden. Das Framework stellt Importfunktionen für folgende Datenformate zur Verfügung:

- VICON® txt
- VICON® csv
- DiaMess txt
- Pedar csv

### Filterung

Unterschiedliche Methoden zur Filterung und Glättung der Daten wurden getestet, um eine hohe Güte der Analysedaten zu gewährleisten. Auf Basis der qualitativen Bewertung der Kurvenähnlichkeit der Rohdaten im Verhältnis zu den gefilterten/geglätteten Messdaten und der Bewertung der Kurvenverläufe der ersten und zweiten Ableitung der geglätteten/gedfilterten Daten wurde ein einstellbarer (Frequenz und Ordnung) Butterworthfilter in das Framework integriert. Um die differenzierte Einstellung des Filters für die jeweiligen Messdaten zu ermöglichen, kann die Stapelverarbeitung des Frameworks so konfiguriert werden, dass der Rohdaten/Filterdaten-Vergleich grafisch dargestellt wird und in einem iterativen Prozess die Anpassung des Filters möglich ist. In Abbildung 1 ist ein Filter 4. Ordnung mit einer CuttOff-Frequenz von 20Hz auf den Daten des Kniewinkels ( $f(t)$ ) zu sehen.




Abbildung 1. Butterworthfilter 4. Ordnung mit einer CuttOff-Frequenz von 20Hz am Beispiel des Winkelverlaufs des rechten Knies ( $f(t)$ ) beim Rennen mit  $2\text{ms}^{-1}$ .

### Synchronisation

Damit Daten unterschiedlicher Messsysteme fusioniert werden können, die nicht zeitsynchron aufgenommen wurden, wurden Funktionen zur zeitlichen Synchronisation implementiert. Es stehen Skripte für folgende Messdaten zur Verfügung:

- VICON® Positionsdaten (.txt)
- VICON® Analogdaten (.csv)
- Pedar In-Shoe Druckverteilung (.csv)

### Segmentierung

Die Segmentierung der Zeitreihen kann sowohl auf Basis von Positionsdaten als auch auf Basis von Bodenreaktionskräfte (VICON® txt) und Druckmessung (Pedar csv) erfolgen. Tabelle 1 zeigt die Zuordnung der zeitlichen Events zu den Messsystemen.

Tabelle 1. Möglichkeiten der Eventdetektion im Kontext der Messsysteme

Event	VICON	Pedar	Kraftmessplatte	% Gangzyklus
Heel Strike	+	+	+	0
Toe Off	+	+	+	+
Loading Response	0	0	0	+
Mid Stance	+	0	0	+
Terminal Stance	0	0	0	+
Pre Swing	0	0	0	+
Initial Swing	0	0	0	+
Mid Swing	0	0	0	+
Terminal Swing	0	0	0	+
Fett Adjacent	+	0	0	0
Double Support	+	0	+	+
Single Support	+	0	+	+
Limb orthogonal	+	0	0	0

Um auf Basis von VICON® Positionsdaten eine möglichst hohe Genauigkeit bei der Bestimmung von Events zu erreichen, kann die Segmentierung (Heel Strike, Mid Stance, Toe Off) wie in Abbildung 2 auf Basis der Pedar-Daten erfolgen.




Abbildung 2. Bestimmung von Heel Strike, Mid Stance und Toe Off auf Basis von summierten Pedar Druckverteilungen beim Gehen auf Rasen

Stehen VICON® Positionsdaten und Daten von zwei Kraftmessplatten zur Verfügung, erfolgt die Segmentierung auf Basis der Positionsdaten, korrigiert auf Basis der Kraftdaten. Über alle Doppelschrittzyklen einer Session werden hierfür die Zeitpunkte Heel Strike und Toe Off für die Kraftmessplatten bestimmt. Der Fehler für die korrespondierenden Zeitpunkte der Positionsdaten wird für eine Frequenz von 1000Hz (upsampling der Positionsdaten) für alle Versuche bestimmt und ein gemittelter Offset bestimmt. Auf Basis der offset-korrigierten Events erfolgt die Segmentierung über die Positionsdaten.

Zur Segmentierung von Messdaten, die beim Gehen/Rennen mit Steigung erfasst wurden, kann in Abhängigkeit der Steigung die Höhe des zu erwartenden Heel Strikes /Toe Offs korrigiert werden.

### *Analyse/Visualisierung*

Die Analyse der Messdaten erfolgt auf Basis der klassischen ganganalytischen Parameter (Hollman et al., 2011; Murray et al., 1964) und umfasst folgende Algorithmen:

- Datennormalisierung (Zeit, Gewicht u.a.)
- Diskrete Werte zu den Gangphasen für die untere Extremität (Gelenkwinkel, Fußwinkel, Zeit)
- Range of Motion
- Minima & Maxima
- Räumlich-zeitliche Gangparameter
- Mittelwertbildung für unterschiedliche Kriterien (Person, Bedingung u.a.)
- Visualisierung von Verläufen
- 

### *Export*

Um die Weiterverarbeitung der Daten in anderen Programmen zu gewährleisten, wurden Module zum Export in folgende Datenformate programmiert:

- MATLAB
- DiaMess
- png
- csv
- xls

## Anhang B

### Fragebogen Studie 2 - körperlich sportliche Aktivität

Name, Vorname:

Geburtsdatum:

Größe:

Gewicht:

Sportart:

Wie lange betreibst du diese Sportart in der Woche (in Minuten)?

Wie oft gehst du in der Woche Laufen?

Wie lange dauert bei dir eine durchschnittliche Laufeinheit (in Minuten und km)?

Hast du schon einmal an einem Lauftraining teilgenommen (Lauf-ABC, Lauftechnik,...)?

Ja

Nein

Wenn ja, wie oft?

Aktuelle Verletzungen bzw. sonstige Störfaktoren, die das Laufbild beeinflussen könnten (Wenn ja, welche)?

Ja

Nein

Codenummer:

## Anhang C

### Fragebogen Studie 3 - körperlich sportliche Aktivität

Name, Vorname \_\_\_\_\_

Geburtsdatum \_\_\_\_\_

Sportliche Aktivität \_\_\_\_\_

Größe \_\_\_\_\_

Gewicht \_\_\_\_\_

---

Gab es in letzter Zeit schwerwiegende Verletzungen? (Wenn ja, welche?)

---

Sind Fehlstellungen der unteren Extremität bekannt? (Wenn ja, welche?)

---

Sind sonstige Störfaktoren, die das Gangbild beeinflussen könnten bekannt? (Wenn ja, welche?)

---

Mit welchem Bein schießt Du einen Ball?

Links                      Rechts                      Beide

Welches Bein schätzt Du stärker ein?

Links                      Rechts                      Beide