


STUTTGARTER BEITRÄGE ZUR PRODUKTIONSFORSCHUNG

HARALD BARON VON ROSENBERG

Identifikation von Willkürsignalen zur Bewegungskontrolle einer Beinprothese



Universität Stuttgart



Fraunhofer

IPA

Herausgeber:

Univ.-Prof. Dr.-Ing. Thomas Bauernhansl

Univ.-Prof. Dr.-Ing. Dr. h. c. Alexander Verl

Prof. Dr.-Ing. Prof. e. h. Dr.-Ing. e. h. Dr. h. c. mult. Engelbert Westkämper

Harald Baron von Rosenberg

**Identifikation von Willkürsignalen zur
Bewegungskontrolle einer Beinprothese**

Kontaktadresse:

Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA, Stuttgart
Nobelstraße 12, 70569 Stuttgart
Telefon 07 11 9 70-00, Telefax 07 11 9 70-13 99
info@ipa.fraunhofer.de, www.ipa.fraunhofer.de

STUTTGARTER BEITRÄGE ZUR PRODUKTIONSFORSCHUNG**Herausgeber:**

Univ.-Prof. Dr.-Ing. Thomas Bauernhansl
Univ.-Prof. Dr.-Ing. Dr. h. c. Alexander Verl
Prof. Dr.-Ing. Prof. e. h. Dr.-Ing. e. h. Dr. h. c. mult. Engelbert Westkämper

Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA, Stuttgart
Institut für Industrielle Fertigung und Fabrikbetrieb (IFF) der Universität Stuttgart
Institut für Steuerungstechnik der Werkzeugmaschinen und Fertigungseinrichtungen (ISW)
der Universität Stuttgart

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie;
detaillierte bibliografische Daten sind im Internet über <http://dnb.d-nb.de> abrufbar.
ISBN: 978-3-8396-0435-9

D 93

Zugl.: Stuttgart, Univ., Diss., 2012

Druck: Mediendienstleistungen des
Fraunhofer-Informationszentrum Raum und Bau IRB, Stuttgart

Für den Druck des Buches wurde chlor- und säurefreies Papier verwendet.

© by **FRAUNHOFER VERLAG**, 2012

Fraunhofer-Informationszentrum Raum und Bau IRB
Postfach 80 04 69, 70504 Stuttgart
Nobelstraße 12, 70569 Stuttgart
Telefon 07 11 9 70-25 00
Telefax 07 11 9 70-25 08
E-Mail verlag@fraunhofer.de
URL <http://verlag.fraunhofer.de>

Alle Rechte vorbehalten

Dieses Werk ist einschließlich aller seiner Teile urheberrechtlich geschützt. Jede Verwertung, die über die engen Grenzen des Urheberrechtsgesetzes hinausgeht, ist ohne schriftliche Zustimmung des Verlages unzulässig und strafbar. Dies gilt insbesondere für Vervielfältigungen, Übersetzungen, Mikroverfilmungen sowie die Speicherung in elektronischen Systemen.

Die Wiedergabe von Warenbezeichnungen und Handelsnamen in diesem Buch berechtigt nicht zu der Annahme, dass solche Bezeichnungen im Sinne der Warenzeichen- und Markenschutz-Gesetzgebung als frei zu betrachten wären und deshalb von jedermann benutzt werden dürften. Soweit in diesem Werk direkt oder indirekt auf Gesetze, Vorschriften oder Richtlinien (z.B. DIN, VDI) Bezug genommen oder aus ihnen zitiert worden ist, kann der Verlag keine Gewähr für Richtigkeit, Vollständigkeit oder Aktualität übernehmen.

GELEITWORT DER HERAUSGEBER

Produktionswissenschaftliche Forschungsfragen entstehen in der Regel im Anwendungszusammenhang, die Produktionsforschung ist also weitgehend erfahrungsbasiert. Der wissenschaftliche Anspruch der „Stuttgarter Beiträge zur Produktionsforschung“ liegt unter anderem darin, Dissertation für Dissertation ein übergreifendes ganzheitliches Theoriegebäude der Produktion zu erstellen.

Die Herausgeber dieser Dissertations-Reihe leiten gemeinsam das Fraunhofer-Institut für Produktionstechnik und Automatisierung IPA und jeweils ein Institut der Fakultät für Konstruktions-, Produktions- und Fahrzeugtechnik an der Universität Stuttgart.

Die von ihnen betreuten Dissertationen sind der marktorientierten Nachhaltigkeit verpflichtet, ihr Ansatz ist systemisch und interdisziplinär. Die Autoren bearbeiten anspruchsvolle Forschungsfragen im Spannungsfeld zwischen theoretischen Grundlagen und industrieller Anwendung.

Die „Stuttgarter Beiträge zur Produktionsforschung“ ersetzt die Reihen „IPA-IAO Forschung und Praxis“ (Hrsg. H.J. Warnecke / H.-J. Bullinger / E. Westkämper / D. Spath) bzw. ISW Forschung und Praxis (Hrsg. G. Stute / G. Pritschow / A. Verl). In den vergangenen Jahrzehnten sind darin über 800 Dissertationen erschienen.

Der Strukturwandel in den Industrien unseres Landes muss auch in der Forschung in einen globalen Zusammenhang gestellt werden. Der reine Fokus auf Erkenntnisgewinn ist zu eindimensional. Die „Stuttgarter Beiträge zur Produktionsforschung“ zielen also darauf ab, mittelfristig Lösungen für den Markt anzubieten. Daher konzentrieren sich die Stuttgarter produktionstechnischen Institute auf das Thema ganzheitliche Produktion in den Kernindustrien Deutschlands. Die leitende Forschungsfrage der Arbeiten ist: Wie können wir nachhaltig mit einem hohen Wertschöpfungsanteil in Deutschland für einen globalen Markt produzieren?

Wir wünschen den Autoren, dass ihre „Stuttgarter Beiträge zur Produktionsforschung“ in der breiten Fachwelt als substantiell wahrgenommen werden und so die Produktionsforschung weltweit auf ein neues Niveau heben.

Alexander Verl

Thomas Bauernhansl

Identifikation von Willkürsignalen zur Bewegungskontrolle einer Beinprothese

Von der Fakultät Konstruktions-, Produktions- und Fahrzeugtechnik
der Universität Stuttgart
zur Erlangung der Würde eines
Doktors der Ingenieurwissenschaften (Dr.-Ing.)
genehmigte Abhandlung

von

Dipl.-Ing. Harald Baron von Rosenberg
aus Karlsruhe

Hauptberichter: Professor Dr.-Ing. Dr. h.c. Alexander Verl
Mitberichter: Professor Dr.-Ing. Jörg Krüger

Tag der mündlichen Prüfung: 12.06.2012

Institut für Steuerungstechnik der Werkzeugmaschinen
und Fertigungseinrichtungen
der Universität Stuttgart

2012

für meine Eltern

Vorwort

Die vorliegende Arbeit entstand im Rahmen des internen Fraunhofer-Forschungsprojekts „**MEF AdaptPro**“ am Fraunhofer Institut für Produktionstechnik und Automatisierung (IPA) in Stuttgart.

Im Rahmen der vorliegenden Arbeit entstanden die Diplomarbeiten von Szücs (2009) und Dennerlein (2009), die vom Autor dieser Arbeit ausgeschrieben und verantwortlich betreut wurden und die einzelne Fragestellungen und Voruntersuchungen aus dem Gesamtkonzept dieser Arbeit zum Gegenstand hatten; deren Ergebnisse werden in dieser Arbeit teilweise aufgegriffen. Auch die Diplomarbeit von Klasen (2008) wurde in der gleichen Projektgruppe angefertigt, die der Autor dieser Arbeit leitete.

Die Verfahren, Methoden und Algorithmen, die in dieser Arbeit beschrieben und untersucht werden und das Willkürerkennungssystem als Gesamtsystem definieren, wurden am 02.12.2009 beim Deutschen Patent- und Markenamt unter dem amtlichen Aktenzeichen **10 2009 056 466.7** angemeldet. Am 09.06.2011 wurde unter der amtlichen Nummer **DE 10 2009 056 166 A1** die deutsche und unter der Nummer **WO 2011/066940 A1** die internationale Patentschrift offengelegt.

Danksagung

An erster Stelle bedanke ich mich beim Fraunhofer IPA, dass ich im Rahmen meiner wissenschaftlichen Tätigkeit am Institut in der Abteilung „Orthopädie und Bewegungssysteme“ die Forschungsarbeiten zu dieser Arbeit durchführen und diese Arbeit anfertigen konnte.

Der Institusleitung des Fraunhofer IPA, Herrn Prof. Dr.-Ing. Alexander Verl danke ich für die Übernahme der Betreuung und der Hauptbegutachtung.

Dem Abteilungsleiter der Abteilung „Orthopädie und Bewegungssysteme“, Herrn Dr. med. Urs Schneider möchte ich danken, dass er mich als Projektleiter für dieses herausfordernde Projekt eingesetzt hat und dass ich es als Promotionsthema bearbeiten konnte. Ferner danke ich ihm für die Beratung zu allen medizinischen Themen, die im Zusammenhang mit dieser Arbeit stehen.

Herzlich bedanke ich mich bei meinem ehemaligen Diplomanden und jetzigen Kollegen, Dipl.-Inform. Florian Dennerlein, der ausgezeichnete und wertvolle Vorarbeiten durchführte. Auch möchte ich seinen unermüdlichen und aufopferungsvollen Einsatz bei den Messungen hervorheben, die bei ihm „bleibenden Eindruck“ hinterließen ;-)

Auch meinem ehemaligen Kollegen, Herrn Dipl.-Ing. (FH) Sebastian Klasen, möchte ich ganz besonders für seine Hilfestellung bei dem Aufbau der Sensor-Arrays, der Unterstützung bei der Messtechnik und bei der Versuchsdurchführung danken.

Ferner möchte ich mich bei meinen Kollegen der Abteilung „Orthopädie und Bewegungssysteme“ für die Unterstützung bei den Versuchen und Messreihen sowie den Messaufbauten bedanken. Meinen Kollegen, Herrn Dipl.-Ing Bernhard Budaker und Herrn Dipl.-Ing. Berhard Kleiner, danke ich für die konstruktive Zusammenarbeit, welche schließlich zur Patentanmeldung des vorgestellten Systems geführt hat. Herrn Dipl.-Ing. Christof Giers möchte ich für den kniffligen Aufbau und die Verschaltung der bei den Versuchen verwendeten EMG-Sensor-Arrays danken.

Auch bei den Studenten, welche ich im Rahmen dieses Projekts bei ihren Praktika und Diplomarbeiten betreut habe, möchte ich mich bedanken, da sich in Diskussionen während der Betreuung für mich viele interessante Fragestellungen und Sichtweisen ergeben haben: Lena te Boekhorst, Rita Szücs, Florian Dennerlein und Michael Lalli.

Bei meiner Schwester Sylvia möchte ich mich für ihre Hilfe bei Fragen zu medizinischen Fachbegriffen bedanken.

Von ganzem Herzen bedanke ich mich bei meinen Eltern für ihre Unterstützung, Motivation und Zuspruch sowohl während meines Studiums als auch während der Zeit, die diese Dissertation benötigte.

Schließlich möchte ich mich bei Donald E. Knuth und Leslie Lamport für \LaTeX^1 , bei Christian Schenk für \MiKTeX^2 , bei Alexander Tsyplakov für \TpX^3 , bei Krzysztof Kowalczyk für SumatraPDF⁴, bei S. Wiegand, T. Weinkauff und den anderen Helfern für TeXnicCenter⁵ und bei Morten O. Alver, Nizar N. Batada und den anderen Helfern für JabRef⁶ bedanken. Sie haben die großartigen Software-Programme, mit denen ich diese Arbeit angefertigt habe, entwickelt und stellen diese kostenlos der Allgemeinheit zur Verfügung.

¹<http://www.latex-project.org/>

²<http://www.miktex.org/>

³<http://tpx.sourceforge.net/>

⁴<http://blog.kowalczyk.info/software/sumatrapdf/free-pdf-reader.html>

⁵<http://www.texniccenter.org/>

⁶<http://jabref.sourceforge.net/>

Kurzfassung

Diese Arbeit stellt ein Verfahren zur adaptiven Steuerung und Regelung von Prothesen vor, wobei an einem Muskel eines Prothesenträgers eine Vielzahl von Muskelaktivitätssignalen gemessen wird. Parallel sollen Zustandsinformationen aus der Bewegung des Prothesenträgers ermittelt werden, aus denen der aktuelle Bewegungszustand bestimmt wird. Mit diesen Informationen werden aus den Muskelaktivitätssignalen mit Hilfe eines Verfahrens zur Detektion von Signalmustern Muskelaktivitätsmerkmale extrahiert. Anschließend wird aus den extrahierten Muskelaktivitätssignalen unter Berücksichtigung des aktuellen Bewegungszustandes das medizinische Willkürsignal, das einen Bewegungswunsch des Prothesenträgers repräsentiert, bestimmt. Es kann zur Ansteuerung oder für die Regelung einer aktiven Prothese verwendet werden. Die Ergebnisse zeigen, dass das Erkennen und Unterscheiden der Bewegungszustände zu einer Steigerung der Genauigkeit des Erkennungssystems führt. Die Bewegungserkennung und Prädiktion ermöglicht eine zusätzliche Filterung und Plausibilisierung der Steuerkommandos, bevor diese an die Aktorik geleitet werden. Der Signalraum der EMG-Merkmale aus der Muskelaktivität kann bewegungszustandsabhängig stark in seiner Dimension reduziert werden, und wenige Merkmale bilden den Haupteinfluss des Merkmalsvektors, der bei der Klassifikation verwendet wird. Der Klassifikator in Form einer Support-Vector-Machine liefert akkurate Erkennungsergebnisse, wenn dieser auf jeden Bewegungszustand angepasst wird. Ferner lässt sich ein Großteil der inneren und äußeren Merkmale des Erkennungssystems, das sich aus Bewegungszustandsdetektion und Muskelsignalerfassung zusammensetzt, verallgemeinern.

Summary

This work presents a method for an adaptive voluntary control system for prostheses which is based on numerous readings of an amputee's muscles activity signals in the residual limb. In parallel the most likely current motion state is estimated by using motion and pressure sensors going into a state estimator. Based on this information the voluntary control signal is extracted from the muscle readings using methods of pattern recognition. The motion state depending and time varying classification result is post-filtered and will be the control input of an active prosthesis for lower limb amputees. The results show that the identification and distinction of the motion states increase the accuracy of the identification and recognition system. The motion state identification and estimation offer additional filtering and plausibility checks of the control commands before being directed to the actuator. The dimension of the signal space of the EMG features which are derived from the muscle activity can be reduced considerably and only few features build the main decision part of the feature vector that is used in the pattern recognition system. The support vector machine classifier provides high accuracy if it is tuned properly for each motion state. The majority of internal and external features which are used in the identification system composed of motion state detection and muscle readings can be generalized.

Inhaltsverzeichnis

Vorwort	ix
Danksagung	xi
Kurzfassung	xiii
Summary	xv
Abkürzungsverzeichnis	xxi
Mathematische Konventionen	xxii
Physikalische Einheiten und Größen	xxii
Aufstellung der mathematischen Symbole	xxiii
1 Einleitung	1
1.1 Motivation	1
1.2 Überblick über die Arbeit	3
2 Medizinischer Hintergrund	5
2.1 Prothesengang	5
2.2 Abgriff von Steuerbefehlen	6
2.2.1 Definition Willkürsignal	6
2.2.2 Elektroenzephalogramm	7
2.2.3 Elektromyographie	8
2.2.4 Ultraschall	10
2.3 Überblick über die Prothesentechnik	13
2.3.1 Aktive Prothesen	14
2.3.2 Vom Benutzer gesteuerte aktive Prothesen	14
2.3.3 Aktive Arm-Prothesen	15
2.3.4 Bewegungszustände an Arm-Prothesen	16
2.3.5 Aktive Bein-Prothesen	17
2.4 Willkürerkennung an Bein-Prothesen	17
2.4.1 Medizinische Aspekte	18
2.4.2 Signalverarbeitungs-Aspekte	18
2.4.3 Ziel der Willkürerkennung am Bein	19

3	Architektur des hybriden Sensorfusionsfilters	21
3.1	EMG-Signalerfassung	23
3.1.1	Stand der Technik EMG-Signalverarbeitung	24
3.1.2	EMG-Array	26
3.1.3	Signalverarbeitung beim EMG-Array	27
3.1.4	Verarbeitung des räumlichen EMG-Signals	29
3.1.5	Virtuelles EMG	29
3.2	Drucksensorik	31
3.3	Bewegungssensorik	32
3.4	Architekturen für EMG-Signalverarbeitung	33
3.5	Architektur des Gesamtsystems	35
4	Messungen und Messreihen	39
4.1	Messaufbau	39
4.1.1	EMG-Array	39
4.1.2	Drucksensorik	41
4.1.3	Inertialsensorik	43
4.1.4	Gesamtsystem	44
4.2	Beschreibung der Messreihen	46
5	EMG-Signalverarbeitung und Filterung	51
5.1	Merkmale für Mustererkennung aus EMG	52
5.1.1	Merkmale im Zeitbereich	52
5.1.2	Merkmale im Frequenzbereich	56
5.2	Generierung des virtuellen EMG	64
5.2.1	Ansätze und Verfahren	64
5.2.2	Vergleich der EMG-Kanäle	68
5.2.3	Kombination und Prädiktion des vEMG	71
5.3	Vergleich EMG und vEMG	73
5.4	Beeinflussung der Merkmale für Mustererkennung durch virtuelles EMG	75
6	Mustererkennung und Klassifizierung des EMG	77
6.1	Merkmalsextraktion	78
6.2	Dimensionsreduktion	79
6.2.1	Hauptkomponentenanalyse (PCA)	79
6.2.2	Weitere Dimensionsreduktionsverfahren	82
6.3	Klassifikatoren	82

6.3.1	Künstliche Neuronale Netze	83
6.3.2	Fuzzy-Systeme	84
6.3.3	Lineare Diskriminanten-Analyse	84
6.3.4	Hidden Markov Modell	86
6.3.5	Support Vector Machines	87
6.3.6	Weitere Ansätze für Klassifikatoren	91
6.4	Diskussion der Klassifikations-Verfahren	91
7	Bewegungszustandsschätzung	93
7.1	Gang und Bewegungsformen	93
7.2	Identifikation von Bewegungsmustern	94
7.3	Merkmalsgenerierung aus Bewegungsdaten	95
7.4	Schätzung und Prädiktion des Bewegungszustands	102
7.4.1	Hidden-Markov-Modell	103
7.4.2	Kontinuierlicher Zustandsschätzer	104
7.5	Ergebnisse der Bewegungszustandsschätzung	107
8	Implementierung des hybriden Sensorfusionsfilters	111
8.1	Klassifizierung des vEMG	111
8.2	Kombination Bewegungszustand und Willkürerkennung	115
8.3	Zeitliche Filterung	116
9	Ergebnisse	119
9.1	Vergleich Mustererkennung EMG und vEMG	119
9.2	Dimensionsreduktion	121
9.3	Generalisierbarkeit der PCA-Dimensionsreduktion	127
9.4	Willkürerkennung des hybriden Systems	130
9.5	Generalisierbarkeit der Support-Vector-Machine	132
10	Diskussion	135
10.1	Bewegungserkennung	135
10.2	EMG-Signalverarbeitung	137
10.2.1	Weiterentwicklung EMG-Array	137
10.2.2	Generierung virtuelles EMG	139
10.2.3	EMG-Merkmalsgenerierung und Klassifikation	141
10.2.4	Implementierung	144
10.3	Gesamtsystem	145
10.4	Fazit	146

Abkürzungsverzeichnis

AP	Aktionspotential
AR	Autoregression
CAS	Kovarianz der absoluten Werte
COV	Kovarianz
CWT	Continous Wavelet Transformation
DFT	Diskrete Fourier Transformation
DGL	Differentialgleichung
DWT	Diskrete Wavelet Transformation
EEG	Elektroenzephalogramm
EMG	Elektromyografie
EOD	Energy of Difference
EV	Eigenvektor
EW	Eigenwert
FFT	Fast Fourier Transform
FT	Fourier Transformation
FWT	Fast Wavelet Transform
IMU	Inertial Measurement Unit (Inertiale Messeinheit)
INS	Integrated Navigation System
KaFi	KALMAN-Filter
KNN	Künstliches Neuronales Netz
LDA	Linear Discriminant Analysis
MAV	Mean Absolute Value
MAVS	Mean Absolute Value Slope
MLP	Multilayer Perzeptron
MUAP	Motor Unit Action Potential
PCA	Principal Component Analysis
RBF	Radial Basis Function
RMS	Root Mean Square
RX	Receiver
SSC	Slope Sign Changes
STFT	Short Time Fourier Transformation
SVM	Support Vector Machine
TX	Transmitter
VAR	Varianz
vEMG	virtuelles EMG
WKS	Willkür-Signal
WL	Waveform Length
WT	Wavelet Transformation
XCS	Kreuzkorrelation
ZC	Zero Crossings

Mathematische Konventionen

\mathbf{x}	Vektor $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$
\dot{x}	$\dot{x} = \frac{dx}{dt}$
$\ \mathbf{x}\ $	2-Norm des Vektors \mathbf{x}
$ x $	Betrag von x
\mathbf{X}	Matrix $\mathbf{X} = [x_{i,j}]$, $i, j \in \mathbb{N}$
\mathcal{X}	Menge $\mathcal{X} = \{x_1, \dots, x_i\}$, $i \in \mathbb{N}$, (kalligraphisches X)
$\bar{\mathbf{x}}$	Mittelwertsvektor von \mathbf{X}
\mathbf{X}_i	i -te Zeile der Matrix \mathbf{X}
\mathbf{x}^T	Transponierte des Vektors
\mathbf{X}^T	Transponierte der Matrix \mathbf{X}
$ \mathbf{X} $	Determinante von \mathbf{X}
$X(f)$	Fourier-Transformierte von $x(t)$
$x(t)$	zeitdiskrete Messreihe
x_i	Messwert i von $x(t = i)$
$f(x)^*$	komplexe Konjugation von $f(x)$
\bar{x}_{MAV}	Mean Absolut Value von $x(t)$
\bar{x}_{RMS}	Root Mean Square Value von $x(t)$
Cov	Kovarianzmatrix
$\text{Cov}(\mathbf{X}_i, \mathbf{X}_j)$	Kovarianz
$\text{Var}(\mathbf{x})$	Varianz von \mathbf{x}
$E[\mathbf{x}]$	Erwartungswert
$\kappa(\mathbf{x}_i, \mathbf{x}_j)$	Kernel-Funktion
\mathcal{O}	Ordnung
$\text{sgn}(x)$	Vorzeichenfunktion
$\langle \mathbf{a}, \mathbf{b} \rangle$	Skalarprodukt von \mathbf{a} und \mathbf{b}
$\mathbf{a} \otimes \mathbf{b}$	Dyadisches Produkt zweier Vektoren \mathbf{a} und \mathbf{b}
$\max_i x_{i,j}$	Maximum von x entlang Dimension i
\mathbf{A}^T	Transponierte der Matrix A
\mathbf{A}^{-1}	Inverse der Matrix A
$\hat{\mathbf{x}}$	Schätzung für \mathbf{x}
\tilde{x}	Zwischenergebnis: $\tilde{x} = f(x)$
\bar{X}	Negation von X bezüglich des logischen Zustands
$A \rightarrow B$	Vollzogener Zustandsübergang von Zustand A nach B

Physikalische Einheiten und Größen

g	Erdschwerebeschleunigung
$^\circ$	Winkel in Grad
Hz	Hertz
m	Meter
N	Newton
s	Sekunde

Aufstellung der mathematischen Symbole

Trotz sorgfältiger Auswahl und Definition der Symbole mussten einige Symbole doppelt vergeben werden. Sie werden in thematisch abgeschlossenen Bereichen verwendet und jeweils in der Textpassage nochmals zum eindeutigen Verständnis definiert.

Symbol	Beschreibung	Einheit
α_i	Lagrange-Multiplikatoren und allgm. Parameter	
a	Skalierungsfaktor bei der WT	
a_x, a_y, a_z	Beschleunigungen im xyz-Koordinatensystem	g
A	Zustandsübergangsmatrix in DGL	
b	Translationsfaktor bei der WT	
B	Eingangsmatrix im Systemmodell	
B	Merkmalsmatrix in PCA	
β^{CAS}	Vergleichskoeffizient für CAS	
β^{EOD}	Vergleichskoeffizient für EOD	
β^{XCS}	Vergleichskoeffizient für XCS	
c	Klassenzugehörigkeit eines Merkmalsvektors	
$c_{i,j}$	Zustandsübergang von i nach j	
C	Vergleichs-Index beim vEMG	
C	Straf-Parameter im SVM	
C_ψ	Calderon-Konstante	
χ	reduzierte Dimension eines Vektors oder Anzahl einer Menge	
d	Abstand	m
d	Grad der SVM-Kernelfunktion	
d_{CAS}	Gewichtungsfaktoren für CAS	
d_{EOD}	Gewichtungsfaktoren für EOD	
d_{XCS}	Gewichtungsfaktoren für XCS	
δ	Gangslope: $\delta = \dot{\phi}$	s^{-1}
E	Erwartungswert	
ϵ	Rauschen	
η	Koeffizient in κ_{poly} und κ_{sig}	
f	Frequenz	Hz
$f(\mathbf{q})$	Zuordnungsfunktion bei SVM	
$f(net)$	Aktivierungsfunktion in einem KNN	
F	Übergangsmatrix im Systemmodell	
$g(k)$	Tiefpassfilter bei FWT	
Γ	Matrix mit Eigenvektoren in jeder Spalte	
γ_{kernel}	Parameter in k_{RBF} und k_{poly}	
γ_i	Eigenvektor einer Transformationsmatrix	
G	Jacobi-Matrix	
$h(k)$	Hochpassfilter bei FWT	
h	Hilfsvektor passender Dimension: $\mathbf{h} = [1, \dots, 1]$	

Fortsetzung auf nächster Seite ...

Symbol	Beschreibung	Einheit
H_i	Hyperebene i der SVM	
\mathbf{H}	Beobachtungsmatrix	
i	Zählvariable	
I	Strom	
\mathbf{I}	Einheitsmatrix	
j	Zählvariable	
k	Zeitindex $x_k = x(t = k)$	
κ_{lin}	lineare Kernel-Funktion	
κ_{poly}	polynomielle Kernel-Funktion	
κ_{RBF}	RBF-Kernel	
κ_{sig}	sigmoidale Kernel-Funktion	
\mathbf{K}	Kalman-Matrix	
l_0	Waveform Length von $x(t)$	
L	Anzahl der bipolaren EMG-Kanäle vom Array, $L = N_E/2$	
L	Lagrange-Funktion bei SVM	
λ_i	Eigenwert zum Eigenvektor γ_i	
Λ	Diagonalmatrix mit Eigenwerten	
ς	Leitfähigkeit des Mediums	
$\mu_{\mathbf{B}_i}$	Mittelwert in Richtung \mathbf{B}_i in PCA	
\mathbf{m}	Merkmalsvektor mit ursprünglicher Dimension n	
$\bar{\mathbf{m}}$	Mittelwertsvektor in PCA und LDA	
\mathcal{M}	Menge von Merkmalen $\mathcal{M} = \{m_i\}$	
M	Länge einer Datensatz-Sequenz bzw. Teil-Länge aus dieser	
n	Dimension eines Vektors bzw. Anzahl Elemente einer Menge	
N	Länge der Messreihe	
N	Länge eines Datensatzes in Messpunkten	
N_E	Gesamtanzahl der EMG-Elektroden im EMG-Array	
N_E^z	Anzahl der Sensor-Zeilen im EMG-Array	
N_E^s	Anzahl der Sensor-Spalten im EMG-Array	
N_P^z	Anzahl der Sensor-Zeilen im Druck-Array	
N_P^s	Anzahl der Sensor-Spalten im Druck-Array	
N_P	Gesamtanzahl der Drucksensoren im Druck-Array	
ω	Kreisfrequenz = $2\pi f$	
$\omega_x, \omega_y, \omega_z$	Drehraten im xyz-Koordinatensystem	rad^{-1}
p	Wahrscheinlichkeit	
\mathcal{P}	Menge von Wahrscheinlichkeiten $\mathcal{P} = \{p_1, \dots, p_n\}$	
\mathbf{P}	Kovarianzmatrix des KALMAN-Filters	
P_{noise}	mittlere Leistung eines Rauschsignals	
P_{signal}	mittlere Leistung eines Nutzsignals	
ϕ	Gangphase: $\phi = \int \delta dt$	

Fortsetzung auf nächster Seite ...

Symbol	Beschreibung	Einheit
φ_i	AR-Koeffizient	
$\varphi(t)$	Vater-Wavelet	
Φ	Potential	
$\psi(t)$	Mutter-Wavelet	
$\psi_{a,b}(t)$	Wavelet mit Skalierung a und Translation b	
q	Merkmal mit reduzierter Dimension	
\mathbf{q}	Merkmalsvektor mit reduzierter Dimension χ	
\mathcal{Q}	Menge von Merkmalen reduzierter Dimension	
\mathbf{Q}	Kovarianz-Matrix im KALMAN-Filter	
r	Anzahl der aus einer Messreihe erzeugten Merkmalsvektoren	
ρ	Druck	
ρ_Z	Druck an Zeh	
ρ_F	Druck an Ferse	
$\rho_{EMG}^{i,j}$	normierter Druck am EMG-Array in Zeile i und Spalte j	
\mathbf{R}	Matrix der Intensitäten des Messrauschens	
s	Signifikanzwert	
s_{tres}	Schwellenwert, verwendet bei Merkmalsberechnung	
\mathbf{S}	Signifikanzmatrix, $\mathbf{S} = [s_{i,j}]$	
\mathbf{S}_b	Intervarianz-Matrix (Between-Class Scatter Matrix)	
\mathbf{S}_w	Intravarianz-Matrix (Within-Class Scatter Matrix)	
$S_{\varphi,j}(k)$	Approximations-Koeffizienten	
σ	Standardabweichung	
t	Zeit	s
τ	Verschiebung der Fensterfunktion bei der STFT	
θ	Nickwinkel	°
\mathbf{u}	Eingangsvektor in System	
v	Grad in k_{poly}	
v	Geschwindigkeit	m/s
v	Anzahl an Klassen	
V	Klasse	
\mathcal{V}	Menge von Klassen $\mathcal{V} = \{V_1, \dots, V_v\}$	
w	Vom Muskel generiertes Willkürsignal	
\hat{w}	Vom Klassifikator erkanntes Willkürsignal	
$w(t)$	Fensterfunktion	
$W_{\psi}(a, b)$	Wavelet-Transformierte von $x(t)$	
$W_{\psi,j}(k)$	Detail-Koeffizienten	
\mathbf{x}	Zustandsvektor im System	
ξ_i	Bewegungszustand i	
y_i	i -tes Gewicht in einer SVM	
\mathbf{y}	Ausgangsvektor aus System	

Fortsetzung auf nächster Seite ...

Symbol	Beschreibung	Einheit
\mathbf{z}	Stützvektor im System	
Z_i	Wahrscheinlichkeit für Bewegungszustand ξ_i : $Z_i = p(\xi = \xi_i)$	
ζ	Diskretes Merkmal für Zustandsschätzer	
\diamond	Merker für Merkmalsberechnung	

1 Einleitung

Träger einer Beinprothese weisen ein wesentlich höheres Risiko für Stürze auf als nicht Amputierte. Dies resultiert aus der Unfähigkeit, den Fuß während der Bewegung in einem Gangzyklus oder vor einem Hindernis anzuheben (Dorsalextension). Die Vermeidung der Sturzgefahr führt zu einem asymmetrischen und hinkenden Gang, der den Bewegungsapparat wesentlich stärker belastet und vom Prothesenträger eine erhöhte Aufmerksamkeit während des Gehens verlangt, da kleine Hindernisse bewusst erkannt und in der Gangmotorik berücksichtigt werden müssen. Nicht amputierte Personen können dies durch die Anpassbarkeit des oberen und unteren Sprunggelenks intuitiv ausführen.

Die Einführung und kontinuierliche Weiterentwicklung von aktiven Beinprothesen eröffnet dabei Wege, die diese Nachteile und Gefahren reduzieren können. Zu einem Beinprothesensystem, welches aktiv angetrieben ist und vom Träger direkt beeinflusst werden kann, gehören neben der Mechanik samt Aktorik insbesondere die Sensorik, die Signalerfassung und ihre Auswertung. Die vorliegende Arbeit behandelt dabei ein Sensoriksystem, welches in einen Beinprothesenschaft integriert werden und einen immanenten Bewegungswunsch des Prothesenträgers erfassen kann. Weiterhin werden Methoden zur Signalverarbeitung untersucht, die aus dem Sensorsignal ein Steuersignal für die Aktorik generieren.

1.1 Motivation

Obwohl es zahlenmäßig mehr beinamputierte als armamputierte Menschen gibt, ist die Entwicklung von aktiven Armprothesen weiter vorangeschritten als jene für aktive Beinprothesen. Dies resultiert aus einer komplizierteren Signalerfassung und Sensorauswertung am Bein, welche zusätzliche Eigenschaften erfüllen und sich an die Bewegungssituation angepasst verhalten muss (Hargrove u. a., 2009). Somit ergeben sich für die Auslegung und Entwicklung des hier beschriebenen Systems folgende Prämissen:

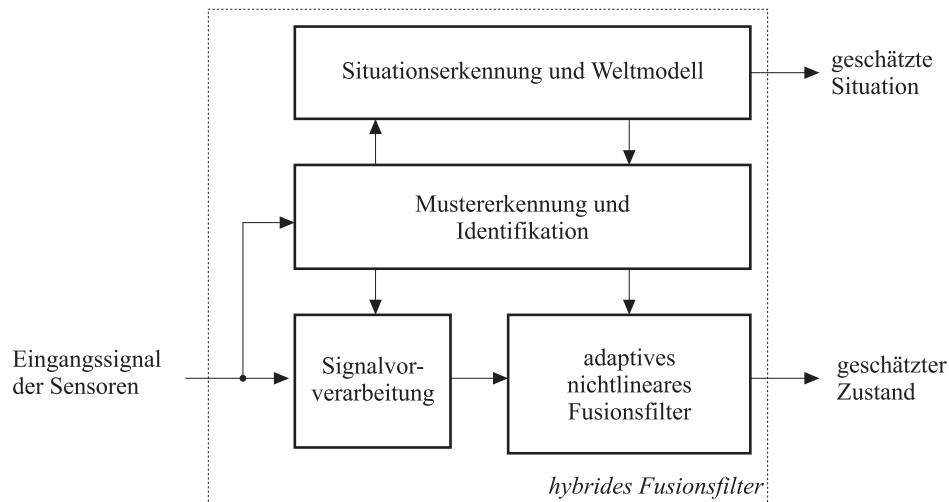


Abbildung 1.1: Hybrides Sensorfusionsfilter (von Rosenberg, 2007)

Für eine aktive Beinprothese soll zu ihrer Beeinflussung und Aktion ein allgemein gültiges Steuersignal gewonnen werden. Dieses Steuersignal wird *Willkürsignal* genannt, da es einen jederzeit möglichen Bewegungswunsch des Prothesenträgers widerspiegeln soll. Das Willkürsignal soll unabhängig von der aktuell vorliegenden Bewegungsform des Prothesenträgers sicher erkannt werden. Dies setzt eine robuste und hohe Erkennungssicherheit und Fehlertoleranz voraus und muss insbesondere während des Gehens eine an den Menschen angepasste Echtzeitfähigkeit erfüllen.

Ferner sollen sowohl vor Verwendung als auch während der Benutzung der Lernaufwand und die notwendige Anpassung des Systems an den Prothesenträger vereinfacht werden, indem möglichst viel modellbasiertes Wissen verwendet wird.

Diese Anforderungen können mittels einer situativen Zustandsschätzung mit einem hybriden Sensorfusionsfilter erfüllt werden. Nach Kealy u. a. (2007) kann dies als Methode beschrieben werden, bei der aus gemessenen Daten Informationen gewonnen werden sollen, aus denen schließlich Wissen folgt. Dieses aktuelle Forschungsgebiet ist insbesondere im Bereich von Mensch-Maschine-Schnittstellen, zu denen das hier beschriebene Willkürsystem gehört, relevant, da die gemessenen Daten in einen kontextuellen Zusammenhang gestellt werden müssen, um aussagekräftige Informationen zu erhalten. Das Willkürsteuerungssystem kann daher den kognitiven Systemen zugeordnet werden.

Die Abbildung 1.1 zeigt den schematischen Aufbau eines hybriden Sensorfusionsfilters, in dem sowohl eine Situation als auch ein Zustand geschätzt werden, wobei die Schichten „Fusionsfilter“, „Mustererkennung und Identifikation“ und „Situationserkennung und

Weltmodell“ unterschieden werden.

Damit kann das Thema der Arbeit wie folgt umrissen werden: Die *situative Zustandsschätzung* erfasst die Zustände eines Prothesenträgers, welche unterschiedlichen und charakteristischen Situationen zugeordnet werden, die dabei helfen, das *Willkürsignal* zu *identifizieren*, mit dem mittels einer *Bewegungskontrolle* eine *Beinprothese* angesteuert werden soll.

In dieser Arbeit soll keine medizinische Feldstudie über Prothesenansteuerung mit einer Anzahl von Probanden behandelt werden, sondern der gewählte Ansatz und Methoden für die Signalverarbeitung innerhalb eines solchen protheseninternen Sensorsystems entwickelt und exemplarisch an einem einzelnen Prothesenträger untersucht und bewertet werden.

1.2 Überblick über die Arbeit

Im Kapitel 2 wird, ausgehend vom Stand der Technik, die medizinische Sicht des Projekts dargestellt mit den speziellen Anforderungen, die das System wesentlich beeinflussen. Es werden ferner Methoden und Verfahren für den Abgriff von Steuersignalen am Prothesenträger vorgestellt.

Das Kapitel 3 stellt den Gesamtaufbau und das Konzept des hybriden Sensorfusionsfilters vor. Es werden Ansätze für die Architektur der Signalverarbeitung entwickelt und das dazu notwendige Sensorsystem aufgestellt.

Im folgenden Kapitel 4 werden der Versuchsaufbau und die Messreihen beschrieben, welche die Grundlage für die Analyse- und Auswerteschritte der einzelnen Subfunktionen bilden.

Das Kapitel 5 untersucht die Signalverarbeitung und Merkmalsextraktion des Muskelsignals, wobei Merkmale aus dem Zeit- und Frequenzbereich behandelt werden. Es wird eine Methode zur Kombination von einzelnen Messkanälen zu einem virtuellen Sensorsignal entwickelt und bewertet. In Kapitel 6 wird die Klassifikation der Merkmale aus den Muskelsignalen behandelt. Hierzu wird der Merkmalsvektor einer Dimensionsreduktion unterzogen und es wird ein geeigneter Klassifikator ausgewählt.

Das Kapitel 7 geht auf die Zustandsschätzung der Bewegungsform ein und stellt das Bindeglied zum Kapitel 8 dar, in dem die Muskelsignale mit den Bewegungssignalen kombiniert werden.

Das anschließende Kapitel 9 stellt die Ergebnisse dieser Kombination und des Gesamtsystems dar und untersucht den inneren Wirkmechanismus und die Abhängigkeiten, aus denen eine Verallgemeinerung gefolgert werden kann. In dem abschließenden Kapitel 10 werden die Ergebnisse diskutiert und es wird ein Ausblick auf Weiterentwicklungen gegeben.

2 Medizinischer Hintergrund

In Europa gibt es über 425.000 beinamputierte Menschen, wenn die von Nat (2005) für England vorliegenden Zahlen auf Europa hoch gerechnet werden. Nach Klasen (2008) haben die Amputierten dabei in 69 % der Fälle ein Alter zwischen 54 und 74 Jahren, wobei vom Rest 28 % über 74 Jahre und 3 % unter 16 Jahre alt sind. Insbesondere die Gruppe der über 50-Jährigen kann dabei von einem Willkürsystem profitieren, da mit zunehmendem Alter noch mit anderen Ausfallerscheinungen zu rechnen ist.

Beinamputationen stellen dabei mit ca. 80 % die Mehrheit der Amputationen dar, nur 20 % fallen auf Amputationen am Arm. Neben der größeren Häufigkeit weisen die Beinamputationen einen weiteren wichtigen Faktor auf: Durch die Amputation am Bein verliert der Mensch seine Mobilität, welche im Gegensatz zu den Einschränkungen einer Armamputation nicht durch ein Umlernen des Patienten kompensiert werden kann. Darüber hinaus gibt es bei Prothesen am Arm ein Akzeptanzproblem, da der Arm mit dem Oberkörper zu sehr als „körpereigen“ betrachtet wird, wohingegen bei Bein-Prothesen der nützliche Faktor der Fortbewegung im Vordergrund steht.

Somit werden Beinprothesen williger von Amputierten angenommen als Armprothesen, und neue Erscheinungen zeigen, dass Bein-Prothesen nicht mehr versteckt werden, sondern durchaus von ihren Trägern als technisches „Mode-Accessoire“ öffentlich gezeigt und präsentiert werden.

2.1 Prothesengang

Der Gang mit Beinprothesen verursacht nach Isakov u. a. (2000) Asymmetrien in den Gangparametern zwischen dem amputierten und dem gesunden Bein. So ist beispielsweise die Schrittlänge, die Schwungphase und die Schrittdauer beim Amputierten signifikant länger. Ferner haben Au u. a. (2006) ermittelt, dass insbesondere bei Unterschenkel-Amputierten der Prothesengang mit einem starren Fußgelenk neben den Asymmetrien auch höhere körperliche Belastung und Abnutzung hervorruft, welche

zu weiteren Folgeschäden führen können. Einen weiteren Aspekt haben Schmalz u. a. (2002) untersucht und stellen fest, dass die Energiebilanz im prothetischen Gehen mit passiven Prothesen wesentlich ineffizienter als das normale Gehen ist. Die Progression des Gangs ist eingeschränkt und gehemmt, und der Prothesenträger erfährt während des Gangzyklusses Phasen, die einem Überwinden eines Hindernisses bei jedem Schritt vergleichbar sind. Das asymmetrische und hinkende Gangbild kann ferner zu einem sozialen und kosmetischen Problem führen, da eine vorhandene Behinderung selbst durch das Vorhandensein einer Prothese nicht kaschiert werden kann und häufig ungewollt offensichtlich wird. Dies kann die Teilhabe am öffentlichen Leben beeinträchtigen.

2.2 Abgriff von Steuerbefehlen

Soll eine Prothese sich nicht nur auf eine Bewegungsform des Prothesenträgers einstellen, was in der Regel mittels Lernens aus aufgezeichneten Messwerten geschieht, sondern vom Prothesenträger direkt und unmittelbar beeinflussbar sein, so muss eine Verbindung zwischen dem Prothesenträger und der Prothese hergestellt werden, welche eine Signalübertragung ermöglicht. Im Folgenden sollen die wichtigsten dieser Schnittstellen beschrieben werden, wobei zuvor der Begriff des medizinischen Willkürsignals definiert werden soll.

2.2.1 Definition Willkürsignal

Das Willkürsignal beschreibt im Kontext dieser Arbeit ein binäres Signal, welches der Träger einer Prothese gezielt zur Manipulation seiner Prothese geben kann. Es ist begrifflich an den medizinischen Begriff der Willkür angelehnt, welcher die bewusste Kontrolle von Körperfunktionen über das Nervensystem beschreibt. Die Willkürlichkeit ist dabei dadurch charakterisiert, dass sie an keine spezielle Bewegungsform oder einen Bewegungszustand gekoppelt und eine jederzeit durchführbare Operation ist. Folgende Unterscheidungen sind dabei zu treffen:

1. Abzugrenzen ist das Willkürsignal von Forschungsansätzen, welche versuchen, Gedanken zu erfassen und zu deuten. Weiterhin soll das Willkürsignal ein Signal sein, welches bei einem Prothesenträger über nach der Amputation übrig bleibende Geberquellen (z. B. Muskeln) ausgelöst werden kann. Dabei soll das noch vorhandene Stimulationssignal zur Bewegung des nicht mehr vorhandenen

Gliedmaßes verwendet werden, indem die Nervenimpulse abgegriffen werden. Der Abgriff der Nervenimpulse muss dabei nicht direkt im Prothesenschaft lokalisiert sein, sondern es können auch außerhalb des Amputationsbereichs geeignete Körperstellen herangezogen werden.

2. Eine zweite Möglichkeit besteht in der Verwendung von Muskelpartien, welche die originäre Stimulation oder mit dieser zusammenhängende Aktionen partiell ausführen. Es bieten sich im Bein Muskelpartien an, welche durch die Amputation nicht vollständig entfernt wurden.
3. Als dritte Möglichkeit ergibt sich die Verwendung von Signalquellen, welche der Prothesenträger ohne expliziten Lernaufwand stimulieren kann, wobei diese vorteilhaft räumlich lokalisiert um die Prothese angeordnet und abgegriffen werden. In diesem Fall wird die Signalquelle durch ein gezieltes Muskelzucken generiert.

2.2.2 Elektroenzephalogramm

Das Elektroenzephalogramm (EEG) entstammt der neurologischen Diagnostik zur Hirnstrommessung und wird dort beispielsweise zur Untersuchung der Epilepsie verwendet. In der Forschung als Eingabegerät ist es insbesondere als „Brain-Computer-Interface“ bekannt geworden: Eine auf dem Kopf vom Prothesenträger getragene Haube ist mit einer Reihe räumlich verteilter Elektroden ausgestattet, welche an der Schädeloberfläche die Hirnströme erfassen, die durch die Aktivität der Nervenzellen direkt am Ursprung der neuronalen Stimulation generiert werden. Die Gedanken beeinflussen dabei das Aktivitätsmuster des Gehirns, was über die Elektroden gemessen wird. Eine Signalverarbeitung, welche diese Muster erkennt, kann daraus dann das Willkürsignal extrahieren, sofern es erfolgreich an den Träger angepasst und auf ihn eintrainiert wurde.

Nachteilig für eine Prothesensteuerung der unteren Extremitäten zeigt sich dabei die Reaktionszeit bzw. Verzögerung bei der Erkennung der Gedankenmuster, die bei aktuellen Arbeiten bei einer Sekunde liegen und sich deshalb nicht für eine Beinprothesensteuerung eignen, da der menschliche Gang wesentlich schnellere Entscheidungshorizonte bedingt.

Als weiterer Nachteil ergibt sich die Befestigung und Trageweise am menschlichen Körper. Wie bereits oben angerissen, spielen kosmetische Aspekte bei Prothesen stets eine

wichtige Rolle, weswegen die notwendige Sensorik so diskret wie möglich ausgestattet sein sollte. Dies ist durch den notwendigen „Datenhelm“ beim Brain-Computer-Interface offensichtlich nicht gegeben.

Neben den oberflächlich abgegriffenen Hirnströmen können auch Elektroden implantiert werden, was Miller u. a. (2010) in ihrer Arbeit vorstellen: Testpersonen wurden Elektroden ins Gehirn implantiert, und die reine Vorstellung an eine Bewegung reichte zur Identifikation und Extraktion der notwendigen Steuerinformationen aus.

Es muss jedoch diskutiert und abgewogen werden, ob bei einer Beinamputation ein weiterer wesentlicher körperlicher Eingriff an einer Stelle gewünscht ist, welche durch den ursächlichen medizinischen Befund gar nicht betroffen ist.

2.2.3 Elektromyographie

Die Elektromyographie (EMG) ist das durch eine Stimulation eines Muskels hervorgerufene Aktionspotential, welches in Form eines elektrischen Feldes detektiert werden kann. Die vom Gehirn kommenden Nervenfasern verzweigen sich innerhalb des Muskels und innervieren über die motorischen Endplatten die einzelnen Muskelfasern.

Ursprung der Elektromyographie

Merletti u. Parker (2004) beschreiben das EMG als ein oszillierendes elektrisches Wellensignal, dessen Amplitude ansteigt, wenn der zugehörige Muskel kontrahiert wird. Die spektrale Leistungsdichte des Signals befindet sich hauptsächlich im Frequenzbereich¹ von 5 bis 250 *Hz*. Zur sicheren und vollständigen Erfassung und Auswertung des EMG-Signals sollte das Frequenzband von 0 bis 500 *Hz* aufgelöst werden können, wodurch sich nach dem Abtasttheorem eine minimale Abtastfrequenz von 1000 *Hz* für das EMG-Signal ergibt.

Ein Motor Unit Action Potential (MUAP) eines Muskels kann als Summe der einzelnen Muskelfaserpotentiale beschrieben werden. Dadurch, dass die einzelnen Fasern nicht gleichzeitig aktiv sind, bildet sich ein stochastisches Signal wie in Abbildung 2.1 gezeigt aus.

¹vgl. Abbildung 5.1 auf Seite 59

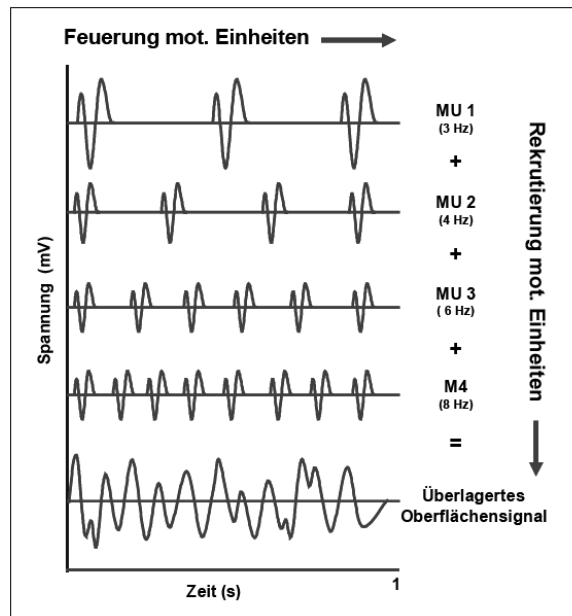


Abbildung 2.1: Superposition mehrerer MUAP-Aktionspotentiale zum abgegriffenen Summensignal. (Bildquelle: Konrad (2005) nach Kumar u. Mital (1996))

Oberflächen-EMG

Das Oberflächen-EMG ist das an der Hautoberfläche mit Elektroden abgegriffene Aktionspotential der darunter liegenden Muskeln (MUAP). Durch die Größe der Abtastfläche und den Abstand zum Muskel überlagern sich zahlreiche Motorunits und ermöglichen die Erfassung von EMG-Signalen mit größerer Quantität. Eingesetzt werden die Oberflächen-Elektroden nach Gesch (2000) unter anderem bei psycho-physiologischen Steuerungen von äußerlichen elektromechanischen Vorrichtungen, beispielsweise bei einer myoelektrischen Handprothese oder bei einer in dieser Arbeit vorgestellten aktiven Prothesensteuerung.

Implantierte Elektroden

Wie bereits beim EEG beschrieben, können auch beim EMG die Signale über eine invasive Technik gewonnen werden. Dabei können nach Saponas u. a. (2009) implantierte EMG-Elektroden sehr akkurat das Muskelsignal erfassen, und es findet keine Beeinflussung durch das umgebende Gewebe im Vergleich zum Oberflächen-EMG statt.

Diesen Vorteilen steht jedoch der Nachteil gegenüber, dass ein invasiver Eingriff not-

wendig ist. Die Erreichung einer Biokompatibilität der zu implantierenden Sensorik und Signalübertragung ist aktueller Gegenstand der Forschung; die Langzeitstabilität konnte noch nicht nachgewiesen werden, da der Körper Implantate abkapselt und mit isolierendem Bindegewebe umgibt. Durch diese Verwachsungen an den implantierten Elektroden verlieren diese nach geringer Zeit ihre Funktionalität, was einen erneuten invasiven Eingriff notwendig macht (Michaud, 1993).

Weitere Herausforderungen liegen in der Signalübertragung und Energieversorgung, da insbesondere im Beinprothesenschaft keine oberflächlich austretenden Kabelverbindungen möglich sind, und der zur Verfügung stehende Raum, in den eine Sensoreinheit eingebracht werden könnte, im Gegensatz zum Oberkörper (z. B. Brustkorb mit Herzschrittmacher) äußerst eingeschränkt ist. Somit muss die Energieversorgung und Signalübertragung drahtlos erfolgen. Diese externe Einkopplung der Energie in das Implantat muss jedoch kritisch abgewogen werden, da dadurch das Haut- und Muskelgewebe andauerndem Energieeintrag ausgesetzt ist, der Effekte wie Hautverbrennungen hervorrufen oder das Gewebe dauerhaft schädigen kann.

Feinnadel-EMG

Das Feinnadel-EMG stellt eine Zwischenlösung zwischen Oberflächen-EMG und implantierten Elektroden dar. Es kann nach Wirth u. Zichner (2002) ebenfalls zu den invasiven Methoden gezählt werden und ermöglicht eine gezielte Muskeluntersuchung. Der Einsatzbereich liegt insbesondere in der Validierung des Oberflächen-EMGs, da das ultraschallgeführte Feinnadel-EMG eine eindeutige Rückführbarkeit auf den Muskel ohne Störeinflüsse wie Crosstalk ermöglicht.

Das Feinnadel-EMG kann jedoch nicht als Sensorsystem in dem Prothesenschaft zur Signalgewinnung eingesetzt werden, da durch das Gehen und die dynamischen Kräfte mechanische Belastungen auftreten. Ferner widerspricht das Feinnadel-EMG dem Ziel des Willkürerkennungssystems, das einen Komfortgewinn und eine leichte Applizierbarkeit anstrebt, da die Nadeln jeweils manuell positioniert und durch die Haut gestochen werden müssen.

2.2.4 Ultraschall

Eine weitere Möglichkeit zur Detektion und Erfassung von Muskelsignalen besteht in der Messung mittels Ultraschall. Dabei wird ein fächerförmiger oder ein punktförmiger

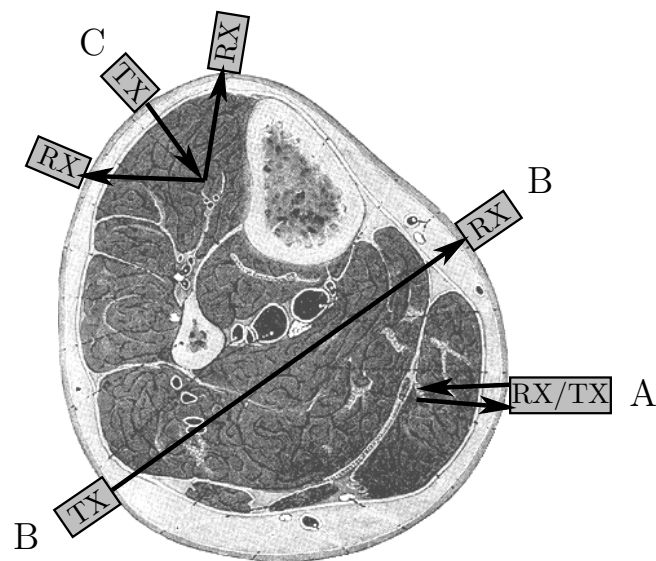


Abbildung 2.2: Ultraschallmessung am Unterschenkel mit drei möglichen Muskelkonfigurationen (A = Puls-Echo, B = Transmission, C = Triangulation, TX = Schallsender, RX = Schallempfänger, Querschnitt Unterschenkel nach Gray (1918))

Ultraschallwandler eingesetzt und entweder im Puls-Echo, Triangulations- oder Transmissionsverfahren gemessen, wie in Abbildung 2.2 dargestellt.

Tamura u. a. (1982) dokumentieren, dass die Ultraschallgeschwindigkeit eine Beziehung zur Anspannung im Muskel aufweist, woraus Tsutsui u. a. (2005) ein System zur Bestimmung der Muskelaktivität aufbauen, welches als Geber eines Willkürsignals betrachtet werden kann.

Koyama u. a. (2005) erfassen die Oberschenkelmuskeln *Biceps Femoris* und *Brachii* mittels Transmissionsmessung am nicht-amputierten Menschen und stellen fest, dass das resultierende Ultraschallmesssignal abhängig ist von der jeweiligen Testperson. Sie schließen auf einen Zusammenhang zum Body-Mass-Index (BMI) und Körperfettanteil, welcher unterschiedliche Impedanzen des Gewebes verursacht. Zudem stellen sie fest, dass sich das Ultraschallmesssignal verändert, wenn sich die Last auf den Muskel verändert, was im Fall der Amputation durch die hervorgerufenen Bodenreaktionskräfte im Prothesenschaft der Fall ist. Dieser Befund konnte bei Messungen, welche am Fraunhofer IPA im Rahmen der Prothesenforschung durchgeführt wurden, bestätigt werden.

Im Vergleich zum EMG ergeben sich somit einige Vorteile:

- Der Ultraschallwandler kann mit einem gelartigen und zugleich festen Kontaktpad zur Schalleinkopplung auf die Haut aufgesetzt werden, wodurch eine günstige Kontaktierung der Haut ohne punktuelle Belastungen und Druckstellen erreicht wird.
- Das Ultraschallsystem stellt im Gegensatz zum Oberflächen-EMG einen aktiven Sensor dar, welcher ein höheres Signal-zu-Rausch-Verhältnis ermöglicht.
- Es können durch die aktive Sensorwirkweise auch tiefere Muskelstränge erfasst werden, wohingegen EMG nur oberflächliche Muskeln erfassen kann, sofern keine invasiven Techniken verwendet werden (Tsutsui u. a., 2005).
- Die Signalverarbeitungszeit ist trotz des Aussendens einer Schallsignatur und notwendigerweisem Abwarten der vollständigen Antwort kurz und im Rahmen einer Prothesensteuerung als echtzeitfähig zu betrachten.

Diesen Vorteilen stehen jedoch auch wesentliche Nachteile gegenüber, welche insbesondere für den Protheseneinsatz von Relevanz sind:

- Es findet ein permanenter Energieeintrag durch den Ultraschall in das Gewebe statt, weshalb ein Dauereinsatz wie beim vorgestellten Prothesensystem als kritisch angesehen werden muss (Laubach u. a., 2008). Der Langzeiteffekt und die Auswirkung wurde bisher hauptsächlich im Tierversuch untersucht (Soetanto u. a., 1998).
- Insbesondere beim Auftreten wird durch die Bodenreaktion und die daraus resultierenden dynamischen Kräfte auf den Beinmuskel eine Verfälschung² in das Ultraschallsignal induziert (Koyama u. a., 2005).
- Der Ultraschall stellt ein großflächiges und räumlich verteiltes Sensorsystem bezüglich des Prothesenschafts dar, sofern ein Transmissionsverfahren verwendet wird. Zwar ist bei einer harten Schale eines Prothesenschafts eine solche räumliche Anordnung möglich, allerdings verliert damit der Anspruch, ein allgemeines und universelles Willkürsignal zu detektieren, seine Bedeutung, da die räumliche Geometrie die möglichen zu erfassenden Muskelgruppen limitiert.

Wegen dieser Nachteile wurde in der vorliegenden Arbeit ein rein passiv messendes Sensorsystem ausgewählt und in Form eines Oberflächen-EMG-System entwickelt. Als

²Abgeleitet aus den Muskeluntersuchungen während des Gangzyklusses innerhalb der Standphase von Klasek (2008) und Szücs (2009), die mittels EMG gewonnen wurden.



Abbildung 2.3: Cheetah-Prothese von Össur. (Bildquelle: Össur (a))

temporäres Messsystem und Stützsytstem bietet der Ultraschall große Potentiale, die in späteren Weiterentwicklungen des vorgestellten Systems untersucht werden können.

2.3 Überblick über die Prothesentechnik

Historische Arm- und insbesondere Beinprothesen sind einfache mechanische Systeme. Sie dienten primär einer Abstützung und rudimentären Unterstützung im Gang. Kontinuierliche Weiterentwicklungen der Prothesentechnik führten zu passiven Prothesen, welche durch ihre Form und Materialeigenschaften eine federnde oder dämpfende Wirkung aufweisen können.

Untersuchungen von Au u. a. (2006) ergeben, dass passive Prothesen im Gegensatz zum natürlichen menschlichen Gang den Nachteil aufweisen, dass sie nur wenig Energie zwischenspeichern können, was durch bewegliche und aktive Elemente ermöglicht wird. Darüber hinaus führen die passiven Prothesen bei einseitiger Anwendung zu einem asymmetrischen Gang, der den Prothesenträger schneller ermüden lässt und zu einer verstärkten Körper- und Gelenkbelastung führt.

In einzelnen Nischenanwendungen, wie im Hochleistungssport beim Sprint, konnten sich speziell auf eine Aufgabe angepasste passive Prothesen etablieren, wie sie in Abbildung 2.3 gezeigt sind. Durch ihre spezielle Formgebung sind diese Prothesen in der

Lage, Energie derart im Laufen zwischenzuspeichern, dass die Träger eine höhere Leistungsfähigkeit erzielen als ein vergleichbarer nichtamputierter Sportler. Für die alltägliche Anwendung haben diese Spezialkonstruktionen jedoch keine Relevanz.

Durch die schnell voranschreitende Mikrosystemtechnik, Biotechnologie, leistungsfähige Mikrocomputer und Antriebe mit hoher Leistungs- und Energiedichte können heutige Prothesen sich nicht nur an den Träger anpassen, sondern von ihm gezielt beeinflusst und gesteuert werden, was die Klasse der aktiven Prothesen definiert.

2.3.1 Aktive Prothesen

Aktive Prothesen sind dadurch gekennzeichnet, dass sie ein mechanisches oder elektromechanisches Element aufweisen, welches von einer Kontroll-Logik verändert oder angetrieben werden kann. Somit sind aktive Prothesen in der Lage, Parameter im Betrieb zu verändern. Die vorgenommenen Eingriffe fokussieren dabei hauptsächlich auf die Veränderung der Dämpfung, auf eine Anpassung der Federhärte oder auf einen aktiven Antrieb über Motoren.

Eine aktive Prothese kann jedoch auch dadurch charakterisiert und definiert werden, dass sie neben einem aktiven Element über eine Signalerfassungseinheit mit passender Auswertung verfügt, so dass vom Prothesenträger Befehle oder Eingaben erfasst werden können, die das aktive Element direkt oder indirekt beeinflussen.

2.3.2 Vom Benutzer gesteuerte aktive Prothesen

Eine Prothese muss auf jeden Patienten individuell angepasst werden, da sich Faktoren wie Form, Geometrie und Sitz von Person zu Person unterscheiden. Diese unterschiedlichen mechanischen und orthopädischen Parameter wirken sich ebenfalls auf die Erzeugung, Übertragung und den Abgriff von Biosignalen am menschlichen Körper aus, weswegen eine aktive Prothese im Allgemeinen auch von der Signalverarbeitung an den konkreten Patienten angepasst und parametrisiert werden muss. Dieser Lernvorgang kann in internes und externes Lernen unterschieden werden.

Internes Lernen Das interne Lernen ist das Einstellen und Anpassen an benutzerindividuelle Signale, was insbesondere beim EMG-Signal und den daraus gewonnenen Messwerten vorliegt. Jene Signale unterliegen insbesondere starken Schwankungen, die




Abbildung 2.4: LifeHand von Otto Bock (Bildquelle: Spiegel Online (2009))

zwischen verschiedenen Personen beobachtet werden können, aber auch bei einer einzelnen Person als tagesabhängige Einflüsse auftreten. Im Fall des EMG können Faktoren wie die Hautfeuchte das tagesaktuelle Messergebnis beeinflussen. Das Mess- und Auswertesystem muss daher in der Lage sein, diese Unterschiede zu erkennen oder es muss sich darauf adaptieren lassen.

Externes Lernen Externes Lernen kann beschrieben werden als Prozess, der allgemeingültige Größen und Muster erfasst und identifiziert, welche generell für einen Patienten oder sogar eine größere Personengruppe gültig sind. Dies betrifft insbesondere Größen, die aus technischen Sensoren gewonnen werden, die keine direkte Benutzerinteraktion aufweisen, beispielsweise die inertielle Navigation, welche die Orientierung und Geschwindigkeit einer Prothese erfassen kann. Weiterhin umfasst das externe Lernen Parameter und Größen, die verallgemeinerbar sind, wie es das prinzipielle Gangmuster in verschieden schnellen Gehformen darstellt.

2.3.3 Aktive Arm-Prothesen

Aktive Unterarm- und Handprothesen sind bereits seit Jahren im praktischen Einsatz und Amputierte werden mit diesen mechatronischen Prothesen versorgt. Zu nennen ist hier die *SUVA-Hand* von Otto Bock oder die *Life-Hand* vom gleichen Anbieter, welche in der Abbildung 2.4 gezeigt ist. Während die *SUVA-Hand* über ein System aus EMG-Elektroden angesteuert wird, werden bei der *Life-Hand* implantierte Elektroden

im Arm zur Signalerfassung verwendet. Der Abgriff direkt am Nerv weist bei diesem Prothesensystem den Vorteil auf, dass der Prothesenträger die Bewegungen intuitiv ausführen kann und kein Umdenken oder Einlernen der Bewegungen notwendig ist.

Das Applied Physics Laboratory (APL) der Johns Hopkins University stellte eine aktive Armprothese vor, welche über Nervenimpulse gesteuert werden kann (Burck u. a., 2009). Dabei werden sowohl Oberflächen-EMGs als auch implantierbare myoelektrische Sensoren verwendet. Eine Besonderheit stellt der Ansatz dar, dass über kontaktierte Nerven (kortikale und periphere Neuroimplantate) eine Rückmeldung an den Prothesenträger gegeben werden kann. Die gewonnenen Rohdaten werden mithilfe von Mustererkennungs-Algorithmen interpretiert, um daraus die Absichten des Nutzers abzuleiten und an das Regelungsmodul weiterzugeben. Im Regelungsmodul werden diese Befehle in Motorsignale umgewandelt, welche gezielt die einzelnen zur Bewegung von Arm, Hand und Fingern vorhandenen Aktuatoren ansteuern.

Eine Voraussetzung für diese beiden Prothesen ist jedoch eine Operation, bei der eine Verlagerung der Nerven erfolgt und diese kontaktiert werden mit den in Abschnitt 2.2.3 geschilderten Nachteilen.

2.3.4 Bewegungszustände an Arm-Prothesen

Die beiden im vorherigen Abschnitt beschriebenen Armprothesen sind in ihren Bewegungszuständen dadurch charakterisiert, dass der Oberkörper des Prothesenträgers als unbewegt angenommen wird, und nur eine Bewegung der Armprothese selbst betrachtet wird. Selbst wenn der Prothesenträger mit der Armprothese vorwärts geht, so können der Gang und die Prothese als entkoppelte Systeme bezüglich der Bewegung betrachtet werden.

Chan u. Englehart (2005) berichten von einem Ansatz, der, basierend auf vier am Arm einer Person befestigten EMG-Elektroden, sechs verschiedene Bewegungsarten und Zustände des Arms unterscheiden kann. Saponas u. a. (2009) beschreiben einen Anwendungsfall für EMG-Steuerung abseits der Prothesentechnik. Ein neuartiges Eingabegerät, z.B. für Computer oder Musikabspielgeräte, wird über ein EMG-Band realisiert, das über den Arm gestreift wird und in Höhe des Ellenbogens verschiedene Gesten und Griffmuster der Hand erkennen kann, wobei dies in Echtzeit funktioniert. Es verwendet 10 EMG-Elektroden und unterscheidet bei der Signalverarbeitung und Erkennung verschiedene Armhaltungen.

2.3.5 Aktive Bein-Prothesen

Im Gegensatz zur Armprothese bildet eine aktive Beinprothese ein gekoppeltes System zwischen der Gangbewegung des Prothesenträgers und der Ansteuerung der Prothese.

Aktive Beinprothesen lassen sich nach dem Stand der Technik hauptsächlich in aktive Knie-Gelenke und aktive Fuß-Gelenke einteilen.

So ermittelt das *Rheo Knee* von Össur (b) über zwei eingebaute Drucksensoren und einen Winkelmesser, welcher den aktuellen Kniewinkel erfasst, die aktuelle Gangsituation des Prothesenträgers und passt sich daraufhin an die Bewegungsform an. Die Analyse der Bewegung findet dabei über ein künstliches Neuronales Netz statt, und als aktives Element wird ein Drehgelenk im Knie verwendet, das über eine magnetorheologische Flüssigkeit in seiner Dämpfung angepasst werden kann (Johansson u. a., 2005).

Das Prothesenfuß-System *Proprio*, ebenfalls von Össur (a), verwendet eine ähnliche Signalverarbeitung und kann sich auf unterschiedliche Untergrundbedingungen wie Treppenstufen und Längsneigung automatisch nach einem Erkennungszeithorizont einstellen. Die Prothese kann dabei verschiedene Bewegungsmuster erkennen und unterscheiden und besitzt bei konstantem Gang eine Zehenhebefunktion in der Schwungphase.

In der folgenden Abhandlung soll eine *aktive Prothese* generell dadurch gekennzeichnet sein, dass sie über eine Aktorik verfügt und einen vom Prothesenträger direkt geäußerten Wunsch erfassen und umsetzen kann.

2.4 Willkürerkennung an Bein-Prothesen

Die Willkürerkennung an der Beinprothese verfolgt andere Ziele als jene an der Armprothese: Bei der Armprothese geht es darum, möglichst viele Freiheitsgrade und Steuerungsfunktionen für die Prothese zu erhalten, wohingegen der dynamische Ablauf innerhalb der Bewegung nur eine untergeordnete Rolle spielt.

Ein weiteres Unterscheidungsmerkmal liegt in der gezielten Stimulierbarkeit der einzelnen Muskelpartien, damit das geforderte Eingabealphabet für die Steuerungsfunktionen der Prothese realisiert werden kann. So können bei einer Beinprothese im Allgemeinen im Stehen einzelne Muskeln gezielt angeregt werden, während beim Gehen dafür ein

Lernaufwand notwendig ist, sofern die Muskelkontraktion der natürlichen Gangbewegung nicht widerspricht. Hierbei soll kein proportionales Steuersignal gewonnen werden, da es für den Prothesenträger einen zusätzlichen Lern- und Gewöhnungsaufwand bedeuten würde, den Muskel während des Gehens mit unterschiedlicher Intensität anzuregen.

2.4.1 Medizinische Aspekte

Ein weiterer Unterschied zwischen der Armprothese und der Beinprothese besteht in der physischen Belastung der Prothese und des Prothesenschafts selbst. Während eine Armprothese nur ihr Eigengewicht und eine eventuelle Nutzlast in der Hand der Prothese tragen muss, muss eine Beinprothese das vollständige Körpergewicht des Prothesenträgers und das Vielfache davon bei dynamischen Bewegungen tragen, weswegen der Prothesenschaft und der amputierte Stumpf wesentlich stärker belastet werden. Aus diesem Grund stellen implantierte Elektroden am Bein ein Problem dar, da die kabelgebundene Signalführung von der implantierten Elektrode zur externen Prothese vielen mechanischen Reizen und Belastungen ausgesetzt ist. Verschärft wird diese potentielle Infektionsquelle durch Schweißbildung im Prothesenschaft.

Neben dem reduzierten Tragekomfort für den Prothesenträger durch die implantierten Elektroden ergeben sich auch bei diesen Signalartefakte durch die Eigenbewegung der Muskeln innerhalb des Prothesenschafts bei Gangbelastung. Eine Lösung dieses Kontaktierungsproblems könnten implantierte Elektroden darstellen, welche drahtlos per Funk die Messsignale zur externen Auswerteeinheit an der Prothese senden. Dabei werden jedoch neue Fragestellungen wie Energieversorgung, Bauvolumen und Implantierbarkeit des Moduls aufgeworfen, welche sich durch den Einsatz von Oberflächen-Elektroden umgehen lassen.

2.4.2 Signalverarbeitungs-Aspekte

Das Willkür-Erkennungssystem stellt bezüglich der Signalverarbeitung ein Echtzeitsystem dar, wobei die Echtzeit folgendermaßen definiert wird: Eine vom Benutzer ausgelöste Aktion soll ohne eine für ihn wahrnehmbare Verzögerung an der Prothese ausgeführt werden. Während bei Armprothesen eine Verzögerung von bis zu 300 ms als Echtzeit betrachtet werden kann (Chu u. a., 2006), liegt diese bei Beinprothesen typischerweise im Bereich von 10 *ms* bis 50 *ms*.

Die kürzere Auslöse- und Reaktionszeit hängt direkt mit dem Gang zusammen. Im Gangzyklus muss die Bewegung der aktiven Prothese in einem definierten Zeitfenster ausgeführt werden, welches in der jeweiligen Bewegungsform einen sicheren Prothesengang ermöglicht. So muss ein in der Schwungphase des Beins ausgelöstes Willkürsignal zum Anheben des Fußes zu einem angewinkelten Fuß beim Durchschwingen des Beines um den unteren Lotpunkt geführt haben.

Ausgefeilte Signalverarbeitungen und insbesondere Mustererkennungssysteme bauen häufig auf komplexen Algorithmen und Methoden auf, die eine bedeutende Rechenleistung des ausführenden Systems voraussetzen. Das Erkennungssystem, das diese Arbeit zum Ziel hat, soll jedoch als Embedded-System in einer autonomen Prothese implementierbar sein, wodurch die Kapazität der benötigten Rechenleistung und die Energieversorgung begrenzt sind. Da in dieser Arbeit diese Aspekte jedoch nicht berücksichtigt werden sollen, werden lediglich die untersuchten und implementierten Methoden hinsichtlich der prinzipiellen Echtzeiteigenschaft nach obiger Definition ausgewählt und bewertet.

2.4.3 Ziel der Willkürerkennung am Bein

Das Ziel des in der vorliegenden Arbeit dargestellten Systems besteht folglich darin, eine für den Prothesenträger komfortabel zu tragende Messeinheit und ein Auswertesystem zu entwerfen, die in den Prothesenschaft oder in den Silikon-Liner, welcher zwischen Prothesenschaft-Schale und Beinstumpf getragen wird, integriert werden können. Der Komfort für den Träger ergibt sich folglich aus der Tatsache, dass keine separaten Elektroden oder sonstige Messeinrichtungen separat und gezielt angebracht oder aufgeklebt werden müssen, und die Sensorik bereits durch das Anlegen der Prothese sicher und zuverlässig platziert und kontaktiert wird.

Für den Prothesenträger soll sich keine Änderung beim Ablauf des Prothesenanlegens ergeben. Lediglich eine kurze Funktionskontrolle der aktiven Prothese und Initialisierung sollen als zusätzliche Schritte verlangt werden.

Das extrahierte und erkannte Willkürsignal soll ein allgemeingültiges und unabhängiges Steuersignal darstellen, welches verschiedene Funktionen an einer aktiven Beinprothese erfüllen kann. Für die praktische Erprobung und Evaluierung des Systems wird die Funktion des benutzergesteuerten Fußanhebens ausgewählt, die eine direkte Verknüpfung zu bestehenden Beinprothesen-Systemen aus Unterabschnitt 2.3.5 darstellt. Ein

herausforderndes Szenario stellt dabei das Anheben der Fußspitze über das aktive Fußgelenk vor Hindernissen oder beim Treppensteigen innerhalb der ersten Treppenstufen dar.

Das Hauptunterscheidungsmerkmal zum aktuellen Stand der Technik liegt darin, dass eine Aktion oder Anpassung nicht nur als Reaktion auf erfasste Umgebungsbedingungen oder zurückliegende Bewegungen erfolgt, sondern dass proaktiv vorausliegende Umgebungssituationen einbezogen werden können.

3 Architektur des hybriden Sensorfusionsfilters

Wie im vorangehenden Kapitel dargestellt, weisen aktuelle Prothesensysteme einen isolierten Funktionsumfang auf: Sie sind entweder nur reaktiv, passen sich also an eine Bewegungsform an, oder können eine bestimmte Aktion aktiv auslösen. Dies gilt insbesondere für Beinprothesen, bei denen keine vollständige Integration der Bewegungserfassung mit der Aktorik bei benutzergesteuerten Befehlen und gleichzeitiger Anpassung an Veränderungen der Bewegungsform stattfindet, wie es mit diesem Willkürsystem angestrebt wird.

Das Willkürsystem basiert hauptsächlich auf der Erkennung und Identifikation des vom Muskel per Stimulation generierten Signals, weswegen die EMG-Signalerfassung und Verarbeitung die Basis darstellt und in Abschnitt 3.1 näher betrachtet werden soll.

Das EMG-Messsystem soll neuartig fest in den Prothesenschaft integriert werden, wodurch sich ein gesteigerter Trage- und Handhabungskomfort für den Prothesenträger ergibt. Anders als die aktuell eingesetzten Klebeelektroden, welche an einer unbelasteten Hautpartie aufgeklebt werden, stellt die Elektrode im vorliegenden Fall einen Teil des Prothesenschafts dar. Da sich die exakte Positionierung des Beinstumpfes im Prothesenschaft von Tag zu Tag und während der Bewegung verändern kann, muss eine ausreichend große Fläche über dem Muskel erfasst werden, so dass die am Zentrum des Muskelbauchs am stärksten vorhandenen Signale sicher erfasst werden können. Diese Aspekte können mit einer Vergrößerung des Erfassungsbereichs berücksichtigt werden, welcher in mehrere Einzelelektroden aufgeteilt wird. Dieses EMG-Array wird in Unterabschnitt 3.1.2 untersucht.

Da das EMG-Signal gestört ist und seine Qualität schwankt, und der EMG-Sensor nur lose ohne Verklebung auf der Haut aufliegen soll, müssen Vorkehrungen getroffen werden, mit denen Störungen sicher erkannt und auch bei Bewegung des Arrays korrigiert werden können. Außerdem ist eine Reduktion der Komplexität der Signalverarbeitung

für den Protheseneinsatz anzustreben, weswegen aus dem EMG-Array ein einzelnes Signal erzeugt werden soll, das im Unterabschnitt 3.1.5 als *virtuelles EMG* bezeichnet wird.

Die in der Bewegung auftretenden Bodenreaktionskräfte, dynamische Kräfte und die variierende Kontaktierung der Elektroden beeinflussen signifikant und qualitativ das gewonnene EMG-Signal und induzieren überlagerte Artefakte. Die von Klasen (2008) vorgeschlagene Drucksensorik an der EMG-Elektrode kann als Kenngröße für diese Effekte herangezogen werden und wird in dieser Arbeit am EMG-Array appliziert, woraus sich ein Sensor-Aufbau in Sandwich-Technologie ergibt. Die Einordnung in das Erkennungssystem folgt in Abschnitt 3.2.

Die am Fraunhofer IPA im Rahmen der vorliegenden Arbeit durchgeführten Vorversuche von Szücs (2009) und Dennerlein (2009) ergaben weiterhin, dass das EMG-Signal in Stärke und Eigenschaft signifikant von der aktuellen Bewegungsform des Prothesenträgers abhängt, und dass das EMG-Signal je nach Bewegungsform unterschiedliche Merkmale aufweist.

So weist das EMG-Willkürsignal sehr unterschiedliche Signalintensitäten und Amplituden auf, welche sich bis zu Faktor 10 zwischen *Sitzen* und *Gehen* unterscheiden können.

Im Gangzyklus und bei anderen Bewegungen werden noch die Muskelaktionspotentiale von der Gangbewegung gemessen sowie die Bodenreaktionskräfte erfasst und diese müssen vom EMG-Signal separiert werden (Szücs, 2009).

Die Bewegungszustände *Sitzen* und *Stehen* sind keine dynamischen und zyklischen Bewegungsformen, weswegen eine andere Erkennungslogik für das Willkürsignal als beim Gehen angewendet werden muss. So kann im *Sitzen* und *Stehen* jederzeit das Willkürsignal gegeben werden, während es im Gangzyklus nur in der Schwungphase des Beins erkannt und detektiert werden soll.

Deshalb muss die Bewegungsform für eine optimale Erkennung des Willkürsignals mit erfasst und ausgewertet werden. Dies ist der Hauptgrund, weswegen es bisher keine vom Benutzer per EMG zu steuernden Beinprothesen am Markt gibt, da bisherige Ansätze für die EMG-Signalverarbeitung beim EMG-Signal an Beinprothesen scheitern (Hargrove u. a., 2009).

Für die Bewegungserfassung wird eine Drucksensorik verwendet, die die unter dem Prothesenfuß auftretenden Kräfte des Fußes erfassen kann, und es wird eine Inertialsensorik eingesetzt, welche berührungslos Beschleunigungen, Drehraten und Orientie-

rungswinkel in allen Raumrichtungen bestimmen kann; sie ist Gegenstand von Unterabschnitt 4.1.3.

Die möglichen Architekturen zur Berechnung und Verarbeitung der oben beschriebenen Sensor- und Signalströme sowie Zustände werden in Abschnitt 3.4 betrachtet, woraus das in dieser Arbeit erstellte und untersuchte System in Abschnitt 3.5 folgt.

3.1 EMG-Signalerfassung

Das Elektromyographie-Signal am menschlichen Körper ist bereits seit langer Zeit Gegenstand der medizinischen und technischen Forschung, und es wurden verschiedene Theorien und Zusammenhänge formuliert und in Studien untersucht. Dabei kommen Luo u. a. (2006) zu dem Ergebnis, dass das verallgemeinerte Oberflächen-EMG als ein zufälliges Signal betrachtet werden kann, welches durch Nichtlinearitäten und nur kurzzeitige Stationarität gekennzeichnet ist.

Weitere Signaleigenschaften werden durch die individuelle Physiologie beeinflusst. So haben die Haut und das Gewebe zwischen Hautoberfläche und Muskel nach Lowery u. a. (2004) eine Tiefpassfilterwirkung, und Zhou u. Rymer (2003) beschreiben, dass eine räumliche Integration der Einzelsignale stattfindet, welche mit den Oberflächen-EMG abgegriffen werden. Dadurch wird die Identifizierung und die Lokalisierung von einzelnen Muskelfasern erschwert. Das an der Haut abgegriffene und der Signalverarbeitung zugeführte Signal des Oberflächen-EMG ist somit stets ein Produkt aus MUAP-Aktivität und Übertragungsfunktion des Haut-Gewebe-Komplexes.

Die Ergebnisse von Lowery u. a. (2002) der Finite-Element-Modellierung des Oberflächen-EMGs lassen sich in der Praxis mangels Kenntnis der Haut- und Gewebe-Parameter nicht anwenden. Untersuchungen von Fuglevand u. a. (1992) ergeben, dass nur MUAPs mit einem Abstand von weniger als 10 – 12 mm zum Oberflächen-EMG beitragen und die Größe der Elektrode nur eine geringe Auswirkung auf die mögliche Tiefe der MUAP-Detektion hat.

Das an der Oberfläche abgreifbare Potential Φ ist abhängig von dem durch Ionen im Muskel hervorgerufenen Strom I , der Leitfähigkeit ς des Gewebes und des Abstands d zwischen Elektrode und der Quelle des Stroms I und ergibt sich nach dem in (3.1) dargestellten Zusammenhang (Fuglevand u. a., 1992):

$$\Phi = \frac{I}{4\pi\epsilon} \frac{1}{d} \quad (3.1)$$

Um den Gleichtaktanteil des EMG-Signals zu reduzieren, werden bipolare Elektroden verwendet, welche an einen differentiellen Verstärker angeschlossen werden, wodurch sich der Signalgleichanteil idealerweise eliminiert. Praktische Versuche von van Vugt u. van Dijk (2001) ergeben jedoch, dass in realem Muskelgewebe, in dem es keine örtlich isolierte Quelle des Aktionspotentials gibt, 30% des mittels bipolarer Elektroden detektierten EMG-Signals aus Übersprechen von anderen Quellen bestehen.

3.1.1 Stand der Technik EMG-Signalverarbeitung

Das EMG-Signal, welches im Prothesenschaft an der Beinprothese gemessen wird, ist neben den oben beschriebenen Effekten mit weiteren Störungen und Signalanteilen überlagert, wodurch sich drei Hauptquellen unterscheiden lassen: Zum einen ist dies die normale und natürlich vorhandene Muskelaktivität durch Gehen und Stehen, welche von den verbliebenen Muskeln nach einer Amputation ausgeführt wird. Weiterhin sind dies die Bodenreaktionskräfte auf Grund der Kompression des Muskel- und Bindegewebes beim statischen Stand und bei dynamischen Beschleunigungen wie dem Auftreten oder Abspringen. Schließlich addiert sich noch das eigentliche Willkürsignal, welches als Signalquelle für eine Prothesenfunktion verwendet werden soll.

Neben den bereits ausgeführten Studien zu dem Aufbau und dem Entstehungsmechanismus des EMG-Signals wurden auch mögliche Strategien für Orte am Körper zur Anbringung und zum Abgriff des EMG-Signals untersucht, welche offensichtlich eine Auswirkung auf die Funktionsweise einer aktiv angesteuerten Prothese aufweisen. So schlagen beispielsweise Lee u. Lee (2005) einen Aufbau mit zwei diskreten EMG-Elektroden vor, welche am nicht-amputierten Bein, gegenüber der Prothese, angebracht werden. Vorteilhaft ist hierbei, dass Informationen vom ungestörten, nicht-amputierten Bein für die Prothese gewonnen werden können und im konstanten Gehen eine regelungstechnisch nutzbare Phasenverschiebungsinformation der beiden Beine im Gangzyklus als zusätzliche Eingangsgröße für die Prothesensteuerung gewonnen werden kann. Nachteilig wirkt sich aus, dass dieses Prinzip nur bei einseitig Amputierten funktioniert und durch das Abgriffsystem auch am nicht-amputierten Bein stets eine Vorrichtung getragen werden muss, die eine sichere Kontaktierung der Haut garantiert.

Chu u. a. (2006) verwenden vier diskrete und räumlich weit verteilte EMG-Elektroden, welche durch unterschiedliche Aktivitätsmuster der nun unabhängigen Elektroden ein großes Eingabealphabet an möglichen Steuerbefehlen ermöglichen, jedoch das Befestigungs- und Tragekomfort-Problem im täglichen Einsatz weiter verschärfen. Zur Lösung dieses Zielkonflikts schlagen Saponas u. a. (2009) eine interessante Lösung vor: Sie setzen einen Aufbau aus zehn äquidistant und ringförmig angeordneten EMG-Elektroden ein, welcher als Armreif getragen werden kann. Es handelt sich folglich um gezielt und örtlich bestimmt aufgebrachte Elektroden, welche jeweils einen speziellen Zweck oder Muskel erfassen sollen. Durch die Trageweise als Armreif kann der Anpressdruck der Elektroden auf die Haut gut kontrolliert werden, und der Armreif kann als eigenständige Einheit komfortabel an- und abgelegt werden, ohne dass einzelne Elektroden platziert werden müssen.

Die Anzahl und der Anbringungsort der EMG-Elektroden beeinflussen wesentlich die anschließende Filterung und Signalverarbeitung des EMG-Signals, welches je nach Qualität des Signals einen unterschiedlichen Informationsgehalt besitzt und damit verschiedene Erkennungs- und Auswerteverfahren zulässt.

Englehart u. a. (1999) verwenden ein stationäres EMG-Signal, aus welchem die Amplitude und die Flankensteilheit als Kenngrößen verwendet werden. Weiterhin wird festgestellt, dass neben den stationären Signalen insbesondere die transienten Signale für eine Steuerung wertvolle Informationen beinhalten, weswegen die von Hudgins u. a. (1993) vorgeschlagenen Methoden aus dem Zeitbereich die gängige Verarbeitung der EMG-Signale repräsentieren. Erkennungssysteme am Arm, welche ein größeres Alphabet mit mehreren erkannten Mustern abdecken, verwenden nach Glette u. a. (2008a) EMG-Signale, die zu einer konstanten Anregungsform gehören, die während einer Zeitdauer von drei Sekunden vorherrscht. Dieses Vorgehen eignet sich somit nicht für ein aktives Beinprothesensystem, welches im dynamischen Gang reagieren muss.

Seit Englehart u. a. (2001) kann die EMG-Signalverarbeitung im Frequenzbereich in Form der Wavelet-Transformation zum Stand der Technik gezählt werden, welche als Wavelet-Packet-Transformation von Englehart u. a. (1999) bereits vorgeschlagen wurde. Diese Arbeit liefert ferner die Erkenntnis, dass ein Dimensionsreduktionsverfahren, welches dem Klassifikator vorgeschaltet wird, die Erkennungsleistung signifikant erhöhen kann.

Damit ergibt sich als Stand der Technik für die Verarbeitung von nicht-stationären und transienten EMG-Signalen, dass eine Kombination aus Merkmalen des Zeit- und Frequenzbereichs einen Merkmalsvektor bildet, welcher nach einer Dimensionsreduktion

einem Klassifikator zugeführt wird, wobei sich Klassifikatoren, die nichtlineare Trennebenen zwischen den zu klassifizierenden Klassen ermöglichen, als überlegen erwiesen haben.

3.1.2 EMG-Array

Die bereits aufgeführten Beispiele aus der Literatur verwenden teilweise mehrere EMG-Elektroden, wobei primär größere Bereiche abgedeckt und damit mehrere unterschiedliche Muskeln gleichzeitig erfasst werden sollen. Ein anderer Ansatz ist die Konzentration von vielen Elektroden auf einem kleinen Raum, wodurch sich eine Anordnung der EMG-Elektroden in Matrixform ergibt. Dieser zweidimensionale Aufbau soll im Folgenden als EMG-Array bezeichnet werden.

Die enge Anordnung vieler Elektroden in Matrixform hat wesentliche Vorteile. So stellen Boschmann u. a. (2009) fest, dass EMG-Einzelelektroden zur Erzielung einer hohen Erkennungsrate exakt positioniert werden müssen, wenn ein Muskel nur über eine einzige Elektrode erfasst werden soll. Dies erfordert speziell an den jeweiligen Prothesenträger angepasste Prothesenschäfte und ist nur durch eine aufwändige dreidimensionale Geometrieerfassung des Prothesenstumpfes zu realisieren.

Weiterhin sollen die Elektroden, wie bereits beschrieben, fest in das Prothesensystem¹ integriert werden. Beim Anlegen einer Beinprothese zieht der Patient zuerst einen strumpffartigen Silikon-Liner über den Beinstumpf an, mit dem er dann in den formgebenden Schaft der Prothese steigt. In dieser Konfiguration müssen die Elektroden in den flexiblen Liner integriert werden, damit ein gleichmäßiger Anpressdruck erreicht wird. Hätte der Liner eine Aussparung und wären die Elektroden am festen Prothesenschaft befestigt, so würde sich der Liner verziehen und an dem Elektroden-Ausschnitt im Liner würden sich innerhalb kurzer Zeit Hautirritationen und Blasen durch kleine Druckspitzen ergeben, welche ein dauerndes Tragen der Prothese unmöglich machen.

Da der Silikon-Liner flexibel ist, liegen die Elektroden nicht immer exakt an der gleichen Stelle auf der Haut auf und es kann zu Verschiebungen zwischen Elektrode und Muskelbauch kommen. Dies ist einer der Gründe für das Konzept des EMG-Arrays, durch welches ein größerer Bereich abgedeckt werden kann und damit die Redundanz erhöht wird.

¹siehe Abbildung 3.5 auf Seite 32

Die Redundanz ist aus einem weiteren Grund erstrebenswert, da es innerhalb des Liners neben der Verschiebung insbesondere während des Gehens zu Schwankungen des Anpressdrucks von einzelnen Elektroden des Arrays kommen kann, wodurch sich eine partielle oder vollständige Ablösung der Elektrode von der Hautoberfläche oder eine undefinierte Konditionierung der Haut unter der Elektrode mit damit verbundenen veränderten Signaleigenschaften ergeben kann. Ein Festkleben der Elektroden auf der Hautoberfläche ist in der Liner-Konfiguration weder gewünscht noch sinnvoll, da die erprobte Trageweise nicht beeinträchtigt werden soll und eine aktive Prothese zu einem Komfortgewinn beitragen soll.

Das Einbringen der Elektroden in die Beinprothese innerhalb des Prothesenschaftes hat ferner den Vorteil, dass verbleibende Muskeln innerhalb des Schaftes, die für das Gehen nicht mehr im ursprünglichen Umfang benötigt werden, zur Generierung des Willkür-Signals verwendet werden können. Die Verwendung der verbliebenen Muskeln als unabhängige Signalquelle wird von Kuiken u. a. (2009) erfolgreich am Beispiel einer Armprothese demonstriert.

3.1.3 Signalverarbeitung beim EMG-Array

Die klassische Herangehensweise an die Signalverarbeitung beim EMG-Array ist das Betrachten der Elektroden innerhalb des Arrays als Einzelelektroden und die anschließende Anwendung von Signalverarbeitungen, wie sie von Einzelelektroden bekannt sind. Dabei ergeben sich Effekte, wie sie von Fuglevand u. a. (1992) beschrieben werden: Der erhöhte Elektrodenabstand im Array ermöglicht eine größere Tiefenauflösung der MUAPs im Vergleich zur Einzelelektrode, und Abstände von einigen Millimetern zwischen den Array-Elektroden führen zu einer vorteilhaften Hochpassfilterung des EMG-Signals, da diese ebenfalls das störende Gleichtaktsignal unterdrückt, und tieffrequente Störungen durch die Bodenreaktionskräfte und die Gangdynamik sich nur vermindert auf das eingeleitete Signal auswirken (Reucher u. a., 1987a,b).

Die Arbeiten von Klasen (2008) und Dennerlein (2009), welche im Rahmen des in dieser Arbeit beschriebenen Entwicklungssystems am Fraunhofer IPA durchgeführt wurden, bestätigen, dass ein Elektrodenabstand² im Array von 5 mm die aufgeführten Effekte zeigt, sofern die Elektroden des Arrays differenziell abgegriffen werden.

²vgl. dazu auch Unterabschnitt 4.1.1




Abbildung 3.1: Doppel-Differentielle Array-Verschaltung: Die drei sich in einer Spalte befindenden Elektroden A , B und C werden über hintereinander geschaltete Differenzverstärker geführt.

Eine Erweiterung dieses Ansatzes entwickeln van Vugt u. van Dijk (2001), die eine Verschaltung des EMG-Arrays gemäß Abbildung 3.1 vorschlagen. Dabei erhöht sich die räumliche Selektivität des EMG-Signals, da Gleichanteile in $A - B$ und $B - C$ im zweiten Subtraktionsschritt entfernt werden. Staudenmann u. a. (2006) verwenden zusätzliche Kanäle, die sich aus diagonalen Kombinationen von EMG-Elektroden ergeben, wodurch ein horizontales, vertikales und diagonales Differenzsignal gewonnen wird, in dem das Signal aus den diagonalen Elektroden bei größeren rotatorischen Verdrehungen des Arrays bezüglich der Muskelfaserichtung Verwendung findet.

Ein weiterer Ansatz für die Verschaltung der EMG-Elektroden bietet das Subband-Verfahren (Mikut u. a., 2006), bei dem die jeweils benachbarten Elektroden mit 5 mm Abstand Signalanteile von 200 Hz bis 400 Hz erfassen und die Elektroden mit 10 mm Abstand (jede zweite Zeile / Spalte) Signalanteile bis 200 Hz erfassen, wobei eine Tiefpass-Filterung wirkt. Diese Subbänder werden anschließend addiert, und es wird das Signal mit dem vollständigen Spektrum gewonnen.

Im vorliegenden Fall soll das EMG-Array, wie zuvor beschrieben, die Redundanz und Signalerfassungs-Robustheit erhöhen, weswegen auf diese doppelte Differenzbildung verzichtet wird. Die Elektroden werden nur bipolar abgegriffen und jeweils zusammengehörige Kanäle einem Differenzverstärker zugeführt.

Die Abbildung 3.2 zeigt zusammenfassend das Schema des EMG-Arrays mit seinen Kanälen und mit der gewählten Beschaltung, wobei die bipolaren Kanäle parallel zur Haupttrichtung der Muskelfasern liegen.




Abbildung 3.2: EMG-Array mit Kanaluordnung und Orientierung

3.1.4 Verarbeitung des räumlichen EMG-Signals

Zur Verarbeitung der Messwerte des EMG-Arrays können Methoden der räumlichen Filterungen verwendet werden, wie sie aus der Bildverarbeitung oder Akustik bekannt sind. So wird ein zweidimensionales Laplace-Filter von Disselhorst-Klug u. a. (2000) dazu verwendet, um die Aktivität einer einzelnen Motor-Unit bei Verwendung eines EMG-Arrays zu extrahieren.

Aus der Akustik ist das Prinzip des Beamformers bekannt, der eine elektronische Fokussierung und Schwenkung der Empfangscharakteristik (Hauptkeule der Antenne) ermöglicht und somit das Zentrum des Muskelbauchs anvisieren kann. Staudenmann u. a. (2006) beschreiben ein weiteres Analyseprinzip, das die unipolaren EMG-Kanäle eines 10×13 -Arrays einer Hauptkomponentenanalyse unterzieht, welche die Eigenmoden des räumlichen EMG-Signals bestimmt, woraus sich die exakte Muskelfaserichtung mit dem dominanten EMG-Signal bestimmen lässt.

Im vorliegenden Fall der Willkürsteuerung ist die Lokalisierung einer Muskelfaser und Isolation ihres zugehörigen Aktionspotentials nicht von Vorteil für die Erkennung. Die Zerlegung des EMG-Signals in seine einzelnen Anteile, die mit einem räumlichen Ansatz möglich ist, setzt ein möglichst bekanntes und ungestörtes Muskelsignal voraus. Diese Annahmen sind im Prothesenschaft am Bein nicht erfüllt, weswegen das virtuelle EMG der Störerkennung, Störunterdrückung und Steigerung der Zuverlässigkeit mittels Redundanz dienen soll.

3.1.5 Virtuelles EMG

Damit die Vorteile aus dem EMG-Array nutzbar sind, müssen die einzelnen Kanäle hinsichtlich Signalqualität und Informationsinhalt bewertet werden, und es sollen nur

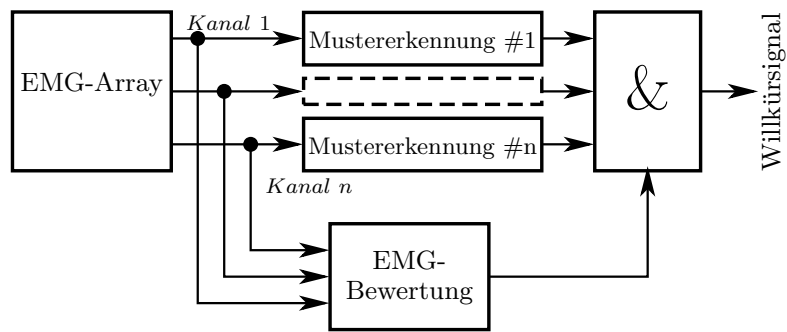


Abbildung 3.3: Architektur zum Zusammenführen der Einzelsignale zu einem Gesamtsignal, bei der die Ergebnisse der n Einzelkanäle fusioniert werden.




Abbildung 3.4: Architektur zum Zusammenführen der Einzelsignale zu einem Gesamtsignal, wobei die Kombination vor der Mustererkennung durchgeführt wird.

solche Kanäle einen Beitrag zum Ergebnis liefern, welche nicht durch Störungen, Ausfall, schlechte Signalkonditionierung oder Verschiebung des Arrays beeinträchtigt sind. Das Ziel des Konzepts „virtuelles EMG“ ist ein Signal, das gleichwertig oder besser als das beste EMG-Einzelsignal ist, wobei die Qualitätsbetrachtung der Einzelkanäle typischerweise nur im Postprocessing vorgenommen werden kann, wohingegen das virtuelle EMG ohne zusätzliche Latenz im Verarbeitungssystem gewonnen werden soll.

Für das stochastische EMG-Signal ergeben sich daraus zwei potentielle Ansätze, die im Folgenden diskutiert werden: In der Abbildung 3.3 ist an jeden Kanal n des Sensorarrays ein eigenständiges Mustererkennungssystem angeschlossen, welches die Merkmalsextraktion und Klassifikation ausführt. Parallel dazu wird über eine Bewertungslogik ein Stellsignal ermittelt, mit dem die einzelnen Ergebnisse der n Mustererkennungseinheiten zu einem einzelnen Ausgangssignal fusioniert werden.

Einen anderen Ansatz stellt die Abbildung 3.4 vor, in dem die n einzelnen EMG-Kanäle zuerst kombiniert werden, und erst dieses gemeinsame, virtuelle Signal einer Mustererkennungseinheit zugeführt wird.

Aus dem Vergleich ergeben sich für den zweiten Ansatz eine Reihe von Vorteilen, die insbesondere bei einer Anwendung an einer Prothese von Wichtigkeit sind: So muss die komplexe und rechenaufwändige Mustererkennung nicht mehrfach parallel ausgeführt werden, was den typischerweise limitierten Rechenleistungen in stromsparenden Embedded-Systemen entgegen kommt. Weiterhin ist diese Lösung flexibler und skaliert besser, da zwischen EMG-Array und Mustererkennung eine logische Schnittstelle implementiert wird. Somit kann unabhängig von der Mustererkennung das Sensorarray modifiziert werden, indem beispielsweise die Anzahl oder Geometrie der Elektroden verändert wird.

Auch aus Sicht der Systemtheorie ist dieser Ansatz zu präferieren, wie es Gan u. Harris (2001) in ihrer Arbeit darlegen. Demnach ist die Fusion der Messwerte vor dem Verarbeitungsschritt (Mustererkennung) der Fusion von Mustererkennungen auf den Einzelkanälen vorzuziehen. Dies wurde jedoch für ein System untersucht, das sich über ein Systemmodell beschreiben lässt und über einen Zustandsschätzer beschrieben werden kann. Im vorliegenden Fall der Mustererkennung müssen deshalb die vorgeschlagenen Ansätze und Methoden verfeinert und hinsichtlich des speziellen EMG-Signals bewertet werden.

Die untersuchten Ansätze und Methoden zur Generierung dieses virtuellen EMG-Signals aus dem EMG-Array werden in Abschnitt 5.2 näher vorgestellt.

3.2 Drucksensorik

Die Qualität des Messsignals, das durch nicht-aufgeklebte Oberflächen-Elektroden abgegriffen wird, hängt signifikant von dem Anpressdruck der Elektroden auf der Haut ab. Elektroden, die einen zu schwachen oder temporär gar keinen Kontakt haben, liefern kein verwertbares Nutzsignal und beinhalten nur Signalstörungen. Während der Bewegung des Prothesenträgers kann insbesondere im Gehen und beim Treppensteigen eine derartige partielle Kontaktschwächung auftreten, da in einzelnen Bewegungsphasen je nach Ort der Platzierung des Arrays innerhalb des Prothesenschafts die muskelkontrahierte Beingeometrie nicht mit der Prothesenschaft-Geometrie übereinstimmen muss und diese Unterschiede nicht komplett durch den flexiblen Silikon-Liner ausgeglichen werden können.




Abbildung 3.5: Prinzip des Aufbaus des EMG-Sensorarrays mit den Drucksensoren dargestellt als Schnittbild

Zur Erfassung des Anpressdrucks wurde eine Drucksensorik ausgewählt, welche mit dem EMG-Array einen Sensorverbund bildet, womit der Anpressdruck jeder einzelnen Elektrode bestimmt werden kann. Die Abbildung 3.5 zeigt den schematischen Aufbau im Schnittbild, bei dem jeder Elektrode des EMG-Arrays ein Drucksensor zugeordnet ist. Zwischen dem festen Prothesenschaft und dem Beinastumpf befindet sich der flexible Silikon-Liner.

3.3 Bewegungssensorik

Einen weiteren Bestandteil der Architektur des hybriden Sensorfusionsfilters stellt eine Bewegungssensorik dar, die auf dem Prinzip der Inertialsensorik basiert. Die Vorversuche, die im Rahmen der vorliegenden Arbeit durchgeführt und ausgewertet wurden, zeigten, dass insbesondere bei Beinprothesen die Kenntnis des aktuellen Bewegungszustands sehr nützlich ist und eine robustere Signalauswertung und Erkennung des Willkürsignals ermöglicht, da das EMG-Signal des Muskels wesentlich von der aktuellen Bewegungsform und damit von der Belastung auf den Muskel abhängt.

An dieser Stelle konnte auf früheren Entwicklungen aufgebaut werden, wobei das am Fraunhofer IPA entwickelte Inertiale Messsystem zur Ganganalyse von Rosenberg (2008) an die Anwendung im Prothesensystem angepasst und erweitert werden konnte.

Die Bewegungssensorik spiegelt dabei eine wesentliche Eigenschaft des entwickelten Steuerungssystems dar: An allen Stellen, an denen personenunabhängige und verallgemeinerbare Informationen und Zustandswerte ermittelt werden können, sollen diese präferiert herangezogen werden, da dadurch eine individuelle Anpassung an den einzelnen Prothesenträger vereinfacht und beschleunigt wird.

Diese Informationen lassen sich durch eine *äußere Sensorik*, zu der die Bewegungserfassung mittels Inertialsensorik gezählt werden kann, einfacher gewinnen als durch *innere Sensorik*, wie dem EMG-Signal. Die äußere Sensorik kann dabei jedoch nur die Reaktion der Stimulation oder des Bewegungswunsches erfassen, wohingegen das EMG-Signal einen direkten Wunsch (Willkürsignal) enthält. Ferner kann die *äußere Sensorik* einfacher in ein Prothesensystem integriert werden.

Hafner u. Bachmann (2008) stellen fest, dass mittels externer Sensorik bei Bewegungsmustern und Ganganalyse eine Vielzahl an Kenngrößen gewonnen werden kann, welche Gewicht, Geschlecht und sogar die Gefühlslage eines Probanden einschließen. Dies bestätigen Schauer u. a. (2009), die beschreiben, wie die Gangphasen in Echtzeit mittels Inertialsensorik detektiert werden können, wobei eine probandenunabhängige Erkennung ohne Anpassung der Algorithmen möglich ist.

3.4 Architekturen für EMG-Signalverarbeitung

Aus den Komponenten EMG-Array, Drucksensor-Array und Bewegungssensorik können verschiedene Architekturen für die Signalverarbeitung und Erkennung sowie Auswertung des Willkürsignals entworfen werden. Eine Variable stellt dabei die Anzahl der EMG-Druck-Sensor-Arrays dar, die für die sichere Detektion notwendig ist. Das System wurde so entworfen, dass zwei unabhängige Sensor-Arrays verwendet werden können, welche zwei Muskeln kontaktieren können, die ein antagonistisches System bilden. Dadurch kann ein größeres Eingabealphabet erreicht werden, und es ist ein größerer Freiraum bei der zeitlichen Muskelkontraktion bezüglich des Gangzyklusses möglich.

Die Abbildung 3.6 stellt eine Architektur vor, die zu Beginn der Entwicklung ausgearbeitet wurde und eine schrittweise Verfeinerung und Aufbereitung des EMG-Signals vorsieht. Bereits im frühen Stadium wurde bei der EMG-Filterung eine echtzeitfähige

3.4 Architekturen für EMG-Signalverarbeitung

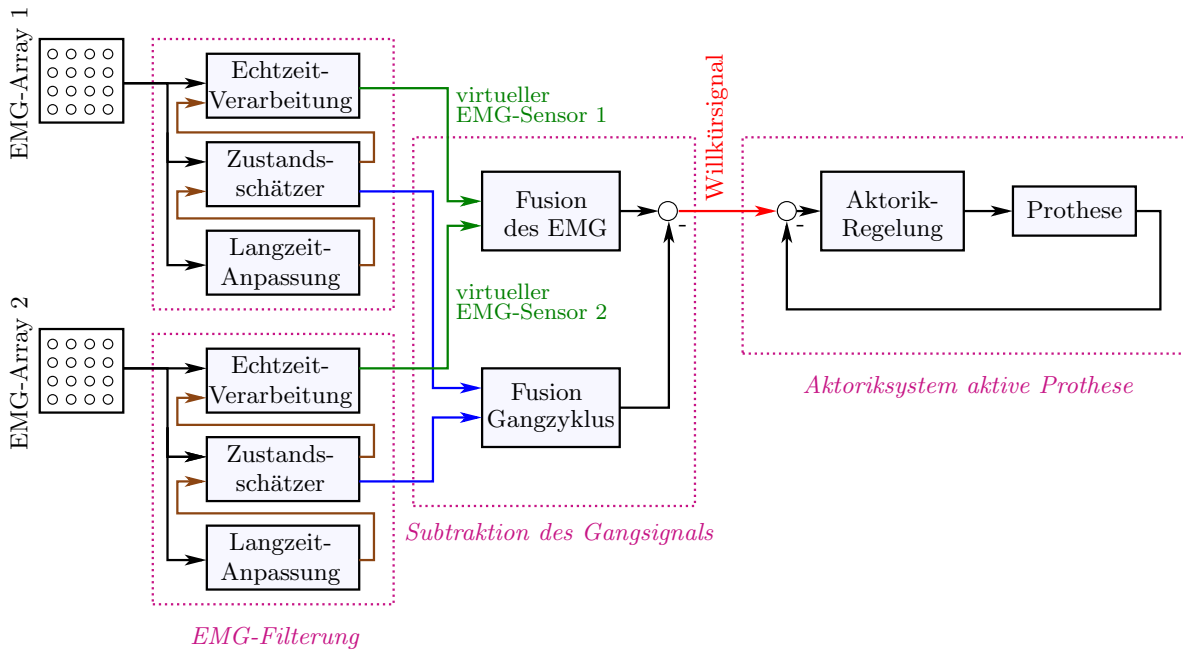


Abbildung 3.6: Architektur des Signalverarbeitungssystems, welche eine schrittweise Verfeinerung des EMG-Signals und eine aus diesem abgeleitete Bewegungsschätzung vorsieht.

Signalverarbeitung angestrebt, welche durch parallele Zustandsschätzer und Adaptionsglieder gestützt wird. Der Ansatz sah vor, dass das EMG-Signal, das gemäß Literatur und Simulation sich aus mehreren überlagernden Anteilen zusammensetzt, schrittweise um bekannte und ungewollte Anteile bereinigt und somit das eigentliche Willkürsignal isoliert wird, welches dem Aktoriksystem einer aktiven Prothese zugeführt werden kann.

Die von Szücs (2009) im Rahmen der vorliegenden Arbeiten durchgeführten und vom Autor betreuten Arbeiten ergeben, dass wesentliche Bestandteile des EMG-Signals, wie die bei der Beinprothese vorhandenen Bodenreaktionskräfte, im EMG-Signal erkannt und zugeordnet werden können. Sie können jedoch nicht exakt genug eliminiert werden, weshalb das gemessene EMG-Signal nicht mit einem Signal verglichen werden kann, das einem simulierten Muskel-Gewebe-Modell entstammt. Die benötigten Parameter für das Muskel-Gewebe-Modell sind beim realen Patienten nicht verfügbar oder sie sind zu großen Schwankungen unterworfen.

Ferner zeigte sich, dass das Bewegungsmodell, das in diesem Architekturf Entwurf nur den Bewegungszustand *Gehen* abdeckt, verfeinert und um weitere Zustände ergänzt werden musste, was sich mit der gewählten Architektur nicht sinnvoll abbilden lässt.

Aufgrund dieser Erkenntnisse wurde diese Architektur angepasst und erweitert, und es entstand das zielführende System, welches im Folgenden beschrieben werden soll und die Basis der vorliegenden Arbeit darstellt.

3.5 Architektur des Gesamtsystems

Zur Verarbeitung und Erkennung des Willkürsignals im mit Unsicherheiten behafteten EMG-Signal wird ein Ansatz aus Merkmalsextraktion und Klassifizierung gewählt, wie er von klassischen Mustererkennungsverfahren bereitgestellt wird. Dieser Funktionsblock stellt ein zentrales Element der in der Abbildung 3.7 gezeigten Systemarchitektur dar.

Somit hat sich die Architektur vom primären Zustandsschätzer mit Schwerpunkt auf der Signalrekonstruktion zum hybriden Sensorfusionsfilter gewandelt, in dem der Zustandsschätzer hauptsächlich die Funktion der Bewegungsdetektion und Generierung des virtuellen EMG-Signals übernimmt und die eigentliche EMG-Erkennung über ein an den Benutzer anpassbares und lernendes Mustererkennungssystem abgebildet wird.

Die EMG-Einzelkanäle jedes EMG-Arrays werden mit der in Abschnitt 5.2 vorgestellten Methode zu dem *virtuellen EMG* vereint, welches als logische Schnittstelle für unterschiedliche Sensor-Array-Konfigurationen betrachtet werden kann. Hier greift das Konzept der einfachen Schnittstellen innerhalb der Architektur, die jeweils ein komplexes Signal auf ein einfacher beschreibbares und handhabbares Signal abbildet, damit das Gesamtsystem flexibel an unterschiedliche Patienten anpassbar ist und einem Ansatz folgt, in dem Eigenschaften und Verhalten an den Schnittstellen bekannt und definiert sind. Im Rahmen dieser Arbeit soll dieser „Black-Box“-Ansatz erweitert werden, indem auch das Innere der einzelnen Funktionsblöcke untersucht wird, woraus sich ein echtes „White-Box“-System ergibt.

Eine Situationserkennung dient als Generator von diskreten Merkmalen, welche für die Schätzung des Bewegungszustands verwendet werden. Die Zustandsschätzung selbst kann dabei als Zustandsautomat betrachtet werden, in dem idealerweise zwischen den sicher erkannten Bewegungszuständen ξ_i , $i \in \{A, B, C, \dots\}$ mit einer Transition $c_{i,j}$, $i, j \in \{A, B, C, \dots\}$ umgeschaltet wird. Jedem Bewegungszustand wird dabei eine Wahrscheinlichkeit $p(\xi_i) = Z_i$ zugeordnet, die ein zum Bewegungszustand i gehörendes

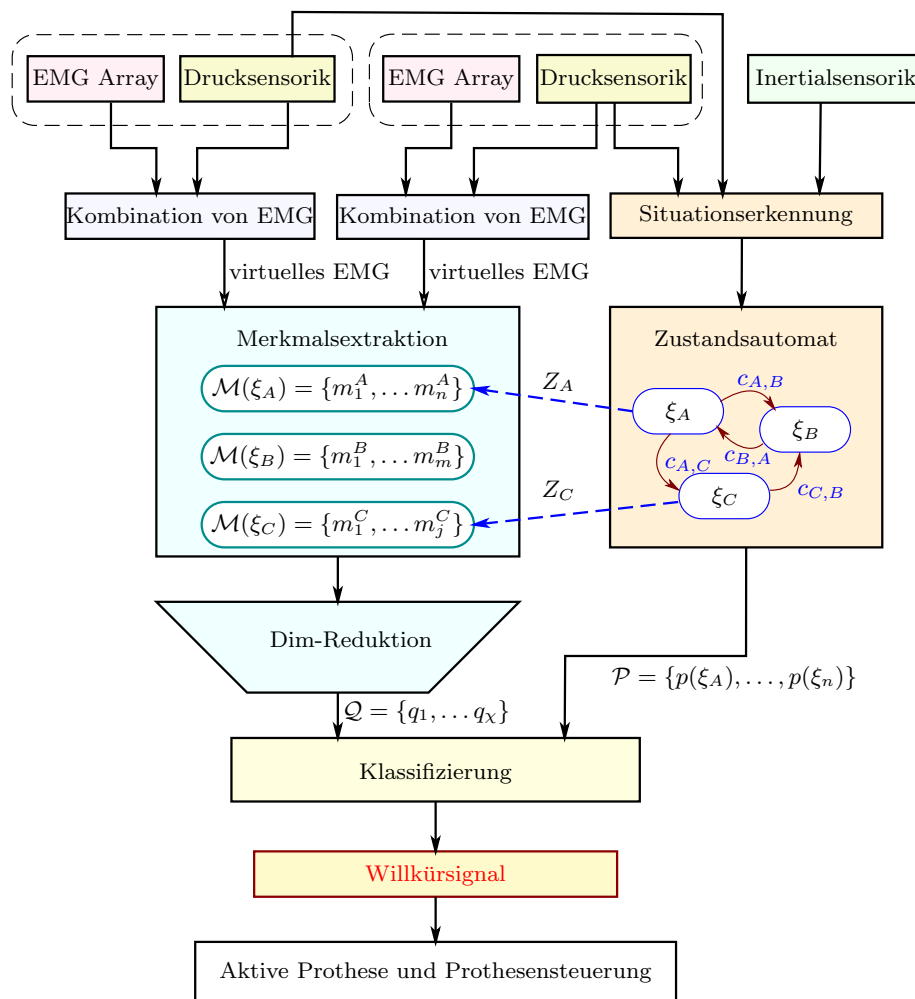


Abbildung 3.7: Architektur des Gesamtsystems des in dieser Arbeit beschriebenen Signalverarbeitungssystems.

Mustererkennungssystem mit Merkmalsextraktion $\mathcal{M}(\xi_i)$ aktiviert, sobald die Wahrscheinlichkeit für einen erkannten Bewegungszustand einen vordefinierten Schwellenwert übersteigt.

Die generierten Merkmale werden daraufhin einer Dimensionsreduktion zugeführt, in der nur jene Merkmale oder lineare Kombinationen aus Merkmalen ausgewählt werden, die wahrscheinlich einen Informationsgehalt aufweisen. In der anschließenden Klassifizierung werden die reduzierten Merkmale \mathcal{Q} vom Klassifikator dem gewünschten Ausgabealphabet zugeordnet, welches im vorliegenden Fall der binären Entscheidung entspricht, ob das Willkürsignal erkannt wurde. In diesen Entscheidungsprozess läuft zusätzlich die Information aus dem aktuellen Bewegungszustand \mathcal{P} ein, wodurch gangdynamisch und situationsabhängig eine robustere Entscheidung getroffen werden kann,

welche das zeitliche Auftreten des Willkürsignals auf Gangphasen beschränken kann, in denen eine Bewegung der aktiven Prothese zu keiner gefährlichen oder unerwarteten Situation für den Träger führt.

Im Gegensatz zur der in Abschnitt 3.4 vorgestellten Architektur wird hier die Gangphase und die Situationserkennung nicht für die Bestimmung des virtuellen EMGs verwendet, da die Kombination und Bewertung aus Situationserkennung (Bewegung und Gang) und Willkürerkennung erst nach der Mustererkennung in dieser Architektur vorgesehen ist.

Die Merkmalsextraktion ist Gegenstand von Abschnitt 6.1, nachdem in Abschnitt 5.1 die Merkmale des EMG-Signals untersucht wurden. Die Dimensionsreduktion (Abschnitt 6.2) und Klassifikation (Abschnitt 6.3) werden sowohl auf dem Einzelkanal, als auch auf dem virtuellen EMG-Signal (Abschnitt 8.1) angewendet. Die parallel laufende Zustandserkennung ist Gegenstand des Kapitels 7 und in Abschnitt 9.4 erfolgt die Ergebnisbetrachtung des Gesamtsystems.

4 Messungen und Messreihen

Dieses Kapitel beschreibt den Messaufbau und die verwendete Sensorik sowie Systeme zur Datenerfassung.

Für die Messungen und die Verifikation der in dieser Arbeit vorgestellten Methode wurde eine Testperson ausgewählt, die männlich und 28 Jahre alt ist und bei 72 kg Körpermasse eine Körpergröße von 182 cm hat. Die Testperson erlitt im August 1997 eine Unterschenkelamputation wegen eines bösartigen Knochentumors im linken Schienbeinknochen.

4.1 Messaufbau

4.1.1 EMG-Array

Zur Messung des EMG-Signals wird ein EMG-Array aus 16 Elektroden verwendet, welche in einer quadratischen Matrix zu je 4 Spalten und 4 Zeilen angeordnet sind. Die Silber/Silberchlorid-Stiftelektroden mit 2 mm Durchmesser und einer Höhe von $2,5\text{ mm}$ werden in einem Mittenabstand von 5 mm zueinander angeordnet, da sich dieser Abstand als optimal bezüglich räumlicher Signalauflösung gezeigt hat (Szücs, 2009) und dem räumlichen Samplingtheorem entspricht, welches einen maximalen Abstand der Elektroden fordert, der der Hälfte der Wellenlänge bei maximaler Frequenz entspricht. Mit einer oberen Frequenz von 400 Hz des EMG-Signals ergibt sich mit der Ausbreitungsgeschwindigkeit von 4 m/s (Lowery u. O'Malley, 2003) eine Wellenlänge zu 10 mm , deren Hälfte dem gewählten Elektrodenabstand von 5 mm entspricht.

In einer ersten Versuchsreihe wurde das in Abbildung 4.1 gezeigte Sensorarray verwendet, in dem die einzelnen Elektroden in einen Silikonträger eingebettet sind. Zur Verbesserung der Kontaktierung der Stift-Elektroden wurden diese innerhalb des Silikonträgers in umschließende Sockel eingegossen, deren freie Zwischenräume sich jedoch



Abbildung 4.1: Das EMG-Array aus der ersten Versuchsreihe (links). Die einzelnen Elektroden üben einen zu starken Druck auf die Hautoberfläche aus, und das umgebende Gewebe drückt sich lokal zu stark in die Zwischenräume der Elektroden-Sockel (rechts).




Abbildung 4.2: Aus GFK gefräster Träger für das EMG-Array mit Kabelführungen (links) und EMG-Array mit eingesetzten Elektroden und angelöteten Signalleitungen in der aus Plexiglas gefertigten Gießform (rechts).

zu stark in das Hautgewebe eindringen, weswegen insbesondere bei Bewegung an dieser Stelle binnen kurzer Zeit Blasen in der Hautoberfläche entstehen, die dem Ziel der Prothesensteuerung während des normalen Tragens der Prothese entgegenstehen.

Zur Steigerung des Tragekomforts und der Verbesserung der Signalableitungsqualität wurde ein weiteres EMG-Array aufgebaut. In der Abbildung 4.2 ist der aus einer GFK-Platte gefräste Grundträger dieses Sensorarrays dargestellt. Dieser GFK-Träger führt zu einer besseren mechanischen Stabilität und verteilt den Druck im Gegensatz zum Array aus Abbildung 4.1 besser. Die von der Haut abgewendete Seite enthält die Kabelführung und Lötstellen und wurde ausgegossen, damit eine plane Fläche für das Drucksensorik-Array entsteht. Die ausgefräste hautzugewandte Seite, welche in Abbil-




Abbildung 4.3: Mit Silikon ausgegossene Hautkontaktseite des EMG-Arrays mit dem abgehenden Flachbandkabel (links) und Hautbild nach einer zur Abbildung 4.1 vergleichbaren Tragedauer (rechts).

Abbildung 4.3 zeigt, wurde mit Silikon ausgegossen, wodurch zwischen den Stiftelektroden eine flexible Fläche zur Anpassung an die Haut von ca. 1 mm Dicke gebildet wird, die einen gleichmäßigeren Druck ausübt.

Weiterhin wurde bei dem neuen Sensorarray eine Referenzelektrode vorgesehen, die sich etwas abgesetzt vom eigentlichen Elektrodenfeld befindet. Diese Elektrode wird mit der Masse des Messgeräts zusammengeschaltet und dient als Bezugspotential für die weiteren analogen Verarbeitungen und Verstärkungen des EMG-Signals, bis dieses den Analog-Digital-Wandler erreicht. Für die Vorverstärkung, Signalwandlung und Aufzeichnung der EMG-Signale wird das integrierte Messsystem *TeleMyo 2400T G2* von Noraxon¹ verwendet. Dies ist ein mobiles EMG-Erfassungssystem, das seine Messwerte per WLAN-Funk an einen zentralen Datensammelpunkt sendet. Es kann direkt am Körper während der Versuche getragen werden.

4.1.2 Drucksensorik

In dem Messsystem werden zwei unterschiedliche Typen von Drucksensoren verwendet. Neben dem bereits in Abschnitt 3.2 vorgestellten Drucksensor-Array werden diskrete Drucksensoren verwendet, die unter dem Prothesenfuß befestigt werden.

¹Noraxon U.S.A. Inc., 15770 North Greenway-Hayden Loop, Suite 100, Scottsdale, Arizona




Abbildung 4.4: Sensor-Array Sandwich bestehend aus EMG-Array und hinterlegtem Drucksensor-Array, welches das Sensor-Array gegen den Silikon-Liner abstützt. Direkt auf der Haut sitzt das EMG-Array, dahinter das Drucksensor-Array.

Drucksensor-Array

Das Drucksensor-Array ist, wie auch das EMG-System, ein 4×4 -Array mit ebenfalls 5 mm Abstand der Messzellen zueinander. Mit dem Array vom Typ *S2001 pliance RLS sensor* wird der Anpressdruck des EMG-Arrays gemessen, wodurch eine Korrektur bei der Berechnung des EMG-Signals vorgenommen werden kann: Elektroden, die keinen Kontakt zur Haut haben, können erkannt und aus der Verarbeitung ausgeblendet werden. Artefakte im EMG-Signal, die durch einen zu großen Anpressdruck der EMG-Stiftelektroden hervorgerufen werden, können ebenfalls über dieses Drucksensor-Array bestimmt werden. Das Drucksensor-Array wird über das ebenfalls mobile Messsystem *Pedar* von Novel² eingelesen und aufgezeichnet.

Die Abbildung 4.4 zeigt das versuchsweise applizierte Sensorarray am Beinstumpf, wobei das EMG-Array und das Drucksensor-Array mittels des gezeigten Silikon-Liners gehalten und angepresst werden. Eine Integration des EMG- und Druckarrays in den Liner stellt eine weiterführende Thematik dar, die im Rahmen der vorliegenden Arbeit nicht vertieft wurde.

Diskrete Drucksensoren

Neben dem flächig messenden Drucksensor-Array hinter dem EMG-Array wurden zwei weitere Drucksensoren in das Messsystem integriert. In der Abbildung 4.5 sind die

²Novel GmbH, Ismaninger Str. 51, 81675 München



Abbildung 4.5: Drucksensoren unter der Fußsohle des Prothesenfusses

beiden Drucksensoren des Typs *FlexiForce A201* von *Tekscan Inc.* unter der Sohle des Prothesenfusses aufgeklebt, wobei diese den Druck an der Ferse und am Zeh messen. Aus diesen Sensoren werden neben der Inertialsensorik der Gangzyklus und die aktuelle Bewegungsform sowie der auf das Prothesenbein wirkende Gesamtdruck erfasst.

Im Folgenden stellen ρ_Z und ρ_F die auf das Körpergewicht normierten Drücke von Zehen-Drucksensor und Fersen-Drucksensor an der Prothese dar.

4.1.3 Inertialsensorik

Zur Erfassung der Bewegungsdynamik und Messung der Orientierungswinkel und Winkelgeschwindigkeiten der Prothese wird eine im Rahmen eines Fraunhofer-internen Forschungsprogramms entwickelte Inertiale Messeinheit (IMU) eingesetzt, die aus jeweils drei orthogonal zueinander stehenden Beschleunigungssensoren, Drehratensensoren und Magnetfeldsensoren besteht. In der Abbildung 4.6 ist das Sensorboard *MSens* dargestellt, dessen Messwerte über ein selbst entwickeltes Sensorfusionsfilter in eine Orientierungsrepräsentation überführt werden. Der dabei eingesetzte Zustandsschätzer berücksichtigt insbesondere dynamische Bewegungen und die dabei auftretenden Beschleunigungen, wodurch auch im Gangzyklus präzise Winkelmessungen möglich sind.

Für die Messung und Berechnung der Dynamik der Prothese wird folgendes Koordinatensystem definiert, in dem die x-Achse normal zur Frontalebene steht, die y-Achse steht senkrecht zur Sagittalebene, und die z-Achse ist orthogonal zur Transversalebene definiert.




Abbildung 4.6: Inertialsensorik-Sensorboard „MSens“

Die Beschleunigungen a_x , a_y und a_z sowie die Drehraten ω_x , ω_y und ω_z werden im körperfesten Koordinatensystem der Prothese gemessen. Der im Sensorfusionsfilter in der IMU daraus generierte Winkel θ , welcher der Auslenkung des Lots des Unterschenkels gegenüber dem horizontalen Untergrund entspricht, beschreibt im Weltkoordinatensystem den Nickwinkel der Prothese in der Sagittalebene.

4.1.4 Gesamtsystem

Das gesamte Messsystem ist in der Abbildung 4.7 gezeigt. Die IMU ist fest an dem Rohr der Unterschenkelprothese befestigt, und aus dem Prothesenschaft treten die einzelnen Messleitungen des EMG-Arrays hervor. Als Referenz, zur Dokumentation und für die spätere Auswertung wurden Marker eines Infrarot-Trackingsystems von Fa. Qualisys zusätzlich an der Beinprothese befestigt. Die Messwerte dieses Motion-Capture-Systems haben für die in dieser Arbeit vorgestellte Signalverarbeitung keine Relevanz und werden nicht verwendet.

An der Hüfte wurden die einzelnen Messgeräte und Messadapter vom EMG-System, vom Drucksensor-System und die notwendigen Komponenten zu deren Synchronisierung angebracht. Der gezeigte Messaufbau ermöglicht ein natürliches Bewegen auf der Gangstrecke und außerhalb von dieser, sofern auf das Infrarot-Tracking verzichtet wird, da das EMG-System seine Messdaten per WLAN-Funk und das Drucksensor-System seine Messdaten per Bluetooth-Funk überträgt.

Als Referenz für das zu erkennende Willkürsignal wurde an einem Eingang des EMG-Messsystems ein Handtaster angeschlossen, welchen die Versuchsperson zeitgleich mit dem Geben des Willkürsignals an der Beinmuskulatur betätigte.




Abbildung 4.7: Gesamtansicht des Versuchsaufbaus (links). An der Hüfte ist das Noraxon EMG-Datenloggersystem sowie das Novel-Druckmesssystem samt benötigter Synchronisierung-Elektronik fixiert. Rechts sind als Detail die IMU am Prothesenschaft und die Marker des Infrarot-Trackingsystems sowie die Signalableitungskabel des EMG-Arrays als Kabelstrang zu sehen.

Die Abbildung 4.8 stellt die Architektur des Messsystems dar. Das System kann in einen Datenerfassungs- und Postprocessing-Block unterteilt werden, dessen Verbindung die einzelnen Messdatensätze bilden. Das Motioncapture-System dient als Zeitgeber in dem Gesamtsystem, indem es an die anderen Systeme einen mit 100 Hz getakteten Trigger sendet. Während das EMG-Signal mit 1500 Hz erfasst wird, werden die anderen Sensoren mit 100 Hz eingelesen. Die Messdatensätze aus dem Motioncapture-System und dem EMG-System werden in einer gemeinsamen Datenstruktur gespeichert, wohingegen die IMU und das Druckarray ihre Daten in separate Dateien speichern.

Der mit aufgezeichnete 100 Hz -Trigger dient im Postprocessing-Block ferner zum Synchronisieren der Messdatensätze aus den drei Datenquellen, womit dem Postprocessing-Tool MATLAB eine einheitliche und zeitlich definierte und synchronisierte Datenbasis zur Verfügung steht.

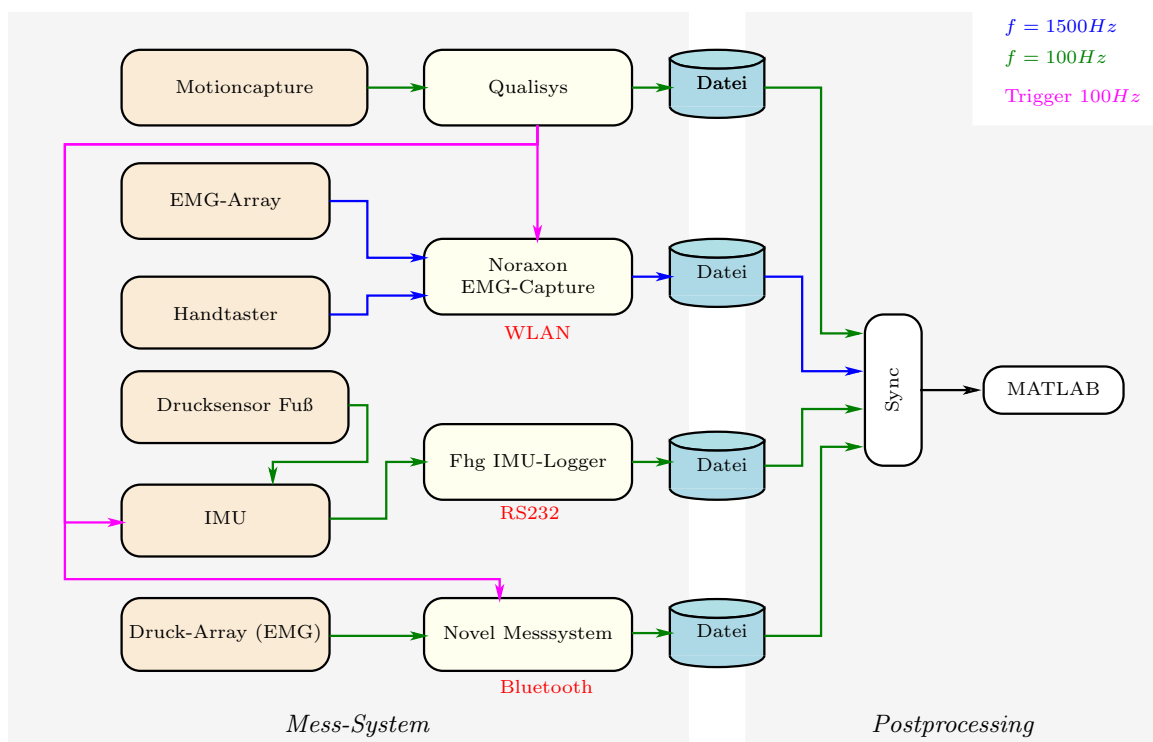


Abbildung 4.8: Architektur, Synchronisierung und Datenablage des Messsystems.

4.2 Beschreibung der Messreihen

Für die Messungen wurden Bewegungsformen und Bewegungstransienten bestimmt, welche besonders charakteristisch für die Willkürsteuerung einer Prothese sind. Jede Messreihe wurde insgesamt drei mal durchgeführt (bezeichnet mit „a“, „b“ und „c“), womit einzelne Fehlmessungen erkannt und eine Kreuzvalidierung zwischen den Messreihen möglich ist. Die Messreihen wurden jeweils an einem Tag mit zeitlichem Abstand von jeweils 10 Minuten durchgeführt, wodurch tagesabhängige Faktoren nicht in den Messungen berücksichtigt werden konnten. Veränderungen, wie sie durch die Schweißbildung und damit Änderung der Feuchtigkeit oder das Verrutschen des Sensorarrays entstehen, konnten jedoch mit diesem Ansatz berücksichtigt werden.

Die hausinternen Untersuchungen von Klasen (2008) zeigten, dass insbesondere der *Musculus gastrocnemius* und *Musculus tibialis anterior* sich für eine Willkürerfassung per EMG eignen, da diese gut zu erreichen sind, eine große Oberfläche aufweisen und auch bei kurzen Unterschenkelstümpfen zugänglich sind.

Das Sensor-Array wurde deshalb über dem Muskel *Gastrocnemius medialis* am linken Bein der Testperson positioniert und an dieser Stelle durch den in Abbildung 4.4

gezeigten Silikon-Liner fixiert, über welchem dann der Schaft der Prothese getragen wird.

Am *Musculus tibialis anterior* konnte bei der Testperson kein Sensorarray positioniert werden, weswegen die folgenden Messungen und Auswertungen im Gegensatz zur Systembeschreibung in Abschnitt 3.5 nur mit einem statt zwei EMG-Sensorarrays durchgeführt werden konnten.

Sitzen In der Messreihe *Sitzen* sitzt die Versuchsperson auf einem Stuhl, wobei die Füße unterschiedlich in Auftrittswinkel und Stärke den Boden berühren. Während des Sitzens gab die Versuchsperson mehrere Willkürsignale mit unterschiedlicher zeitlicher Dauer und Intervallabstand.

Stehen Für die Bewegungsform *Stehen* wurde zuerst das vorstehend beschriebene Sitzen aufgezeichnet. Nach einigen Sekunden erhob sich die Versuchsperson vom Stuhl und gab im folgenden Stehen wiederum mehrere Willkürsignale mit variierendem zeitlichen Verhalten.

Gehen Eine weitere Messreihe *Gehen* bildete das normale Gehen auf der Gangmessstrecke im Ganglabor ab, wobei jeweils eine Strecke von 6-7 Schritten zurückgelegt wurde und im dritten Schritt des linken Beins jeweils das Willkürsignal in der Schwungphase des Beins gegeben wurde. Insbesondere das Gehen ist neben dem nachfolgenden Bewegungsmuster der wichtigste Anwendungsfall für die Willkürsteuerung, da, wie in Abschnitt 2.1 dargelegt, ein mögliches Anheben des Fußes während der Vorschwungphase des Beins zu einem anatomisch günstigeren und natürlicheren Gang führt.

Hindernis und Treppe Ein weiterer wichtiger Anwendungsfall für eine willkürgesteuerte Beinprothese stellt das Überwinden von Hindernissen und das Steigen von Treppen dar. Um diese Bewegung zu simulieren, wurde die in der Abbildung 4.9 gezeigte Konstruktion im Ganglabor verwendet, welche den ersten Schritt über ein Hindernis oder eine erste Treppenstufe nachbildet. Die Versuchsperson geht normal auf das Hindernis zu und erreicht im siebten Schritt das Hindernis. Dabei wird am linken Bein das Willkürsignal gegeben, wenn das linke Bein den Kontakt zum Boden verloren hat und in der Schwungphase zur ersten Treppenstufe ist. In dieser Phase sollte eine aktive Prothese den Fuß anheben.




Abbildung 4.9: Versuch Hindernis und Treppe

Weitere Bewegungsformen Als weitere Bewegungsformen wurde das einbeinige Stehen jeweils auf dem gesunden Bein und der Prothese aufgezeichnet, wobei jeweils Willkürsignale gegeben wurden. Weiterhin wurde ein beidbeiniges vertikales Springen untersucht, wobei nach der beidbeinigen Landung ein Willkürsignal gegeben wurde.

Diese Versuche dienen primär zur Untersuchung der Willkürerkennungslgik und Bewegungszustandsschätzung, da hierbei die Adaption an schnelle Bewegungstransiente untersucht werden kann.

Die Tabelle 4.1 gibt einen Überblick über die Messreihen. Die Messreihen wurden jeweils sowohl für ein 3×3 als auch 4×4 -Sensorarray unter gleichen Mess- und Umgebungsbedingungen aufgenommen.

Tabelle 4.1: Übersicht über die Messreihen

Versuch	Beschreibung
1	Sitzen
2	Sitzen, dann Aufstehen von Stuhl und anschließend Stehen, wobei das Willkürsignal sowohl im Sitzen als auch Stehen gegeben wurde
3	nur Stehen
4	Stehen (Willkürsignal im Stehen gegeben), dann Gehen (Willkürsignal während Gehens gegeben)
5	Stehen, dann Gehen und nach siebtem Schritt Treppe/Hindernis
6	Weitere Bewegungsformen (einbeiniges Stehen, Springen)
7	Gehen, wobei häufiger und zu unterschiedlichen Gangphasen ein Willkürsignal gegeben wurde

5 EMG-Signalverarbeitung und Filterung

In dem Abschnitt 3.5 wurde dargelegt, warum das EMG-verarbeitende Signalverarbeitungssystem eine Mustererkennungskomponente enthalten muss. Dieses Kapitel widmet sich der Merkmalsextraktion aus dem EMG-Signal und der EMG-Vorverarbeitung inklusive der Generierung des virtuellen EMGs. Die Merkmale werden anschließend einer Dimensionsreduktion zugeführt, und der Klassifikator schließt das Mustererkennungssystem ab.

Bei Systemen zur Mustererkennung, die in der Spracherkennung angewendet werden, wird zwischen *isolierten* und *kontinuierlichen* Systemen unterschieden. Ein isoliertes System in der Spracherkennung kann nur Worte erkennen, welche durch eine Sprechpause getrennt sind. Die kontinuierlichen Systeme hingegen können einen unterbrechungsfreien Redefluss erkennen. Da insbesondere bei dynamischen Bewegungen wie im Gehen die Beinmuskulatur kontinuierlich mit unterschiedlichen Aktionspotentialen wirkt, kann die EMG-Mustererkennung zu den kontinuierlichen Systemen gezählt werden.

Eine weitere Unterscheidung bei den Mustererkennungssystemen besteht in der Aufteilung in *personen-unabhängig* und *personen-abhängig*. Ein personen-abhängiges System muss auf jeden einzelnen Benutzer gezielt trainiert und eingelernt werden, damit optimale Erkennungsergebnisse erzielt werden können. Das personen-unabhängige hingegen zeichnet sich durch seine Allgemeingültigkeit und Fähigkeit aus, dass gleiche Stimulationen von unterschiedlichen Benutzern mit vergleichbarer Genauigkeit erkannt werden. Eigenschaften der Muskeln und Haut wie Fettanteil beeinflussen sowohl in der Simulation als auch in konkreten Messungen signifikant das EMG-Signal, weswegen ein EMG-Mustererkennungssystem zur Klasse der benutzer-abhängigen Systeme gezählt werden muss.

5.1 Merkmale für Mustererkennung aus EMG

Die EMG-Signale weisen ein ausgeprägtes stochastisches Verhalten auf, was aus der in Unterabschnitt 2.2.3 dargestellten Entstehung resultiert. Die Mustererkennung benötigt jedoch reproduzierbare und eindeutige Merkmale, weswegen die Auswahl und die Methoden der Merkmalsextraktion eine entscheidende Rolle im Gesamtsystem übernehmen.

Die Merkmale können ihrerseits in den Zeitbereich und in den Frequenzbereich unterteilt werden. Die Merkmale aus dem Zeitbereich werden direkt aus dem Messdatensatz extrahiert. Hierfür wird der Datensatz mit Länge N in Sequenzen der Länge M unterteilt. Die Sequenzen können sich überlappen. Die dafür verwendeten Methoden werden in Unterabschnitt 5.1.1 behandelt. Unterabschnitt 5.1.2 widmet sich den Transformationen, welche das Signal aus dem Zeitbereich in den Frequenzbereich transformieren. Auch hier wird nicht auf dem gesamten Datensatz, sondern auf Sequenzen gearbeitet.

5.1.1 Merkmale im Zeitbereich

In der Literatur zur Extraktion von Willküraktivitäten bei EMG-Systemen finden sich zahlreiche Methoden der Merkmalsextraktion im Zeitbereich, von denen die meisten bisher primär für den Einsatz an Armprothesen untersucht wurden. Im Folgenden werden jene Merkmale aufgeführt, die im Rahmen der vorliegenden Arbeit verwendet werden und bereits von Dennerlein (2009) untersucht wurden.

In den Arbeiten von Hudgins u. a. (1993), Engelhart (1998), Hargrove u. a. (2007) und Huang u. a. (2008) werden die Merkmale *Mean Absolute Value* (MAV), *Mean Absolute Value Slope* (MAVS), *Zero Crossings* (ZC), *Slope Sign Changes* (SSC) und *Waveform Length* (WL) untersucht. Khezri u. Jahed (2007) befassen sich mit den Merkmalen MAV, SSC und den Koeffizienten eines Autoregressiven (AR) Modells. Ebenfalls mit dem AR-Modell befassen sich Park u. Lee (1998), die zusätzlich noch die Merkmale *Integrated Absolute Value*, *Difference Absolute Mean Value* und Varianz untersuchen, und Chan u. Englehart (2005), die neben dem AR-Modell noch das Merkmal *Root Mean Square Value* (RMS) betrachten, welches auch von Saponas u. a. (2009) verwendet wird. Ein weiteres Merkmal, die *Higher Order Statistics*, wird von Nazarpour u. a. (2005) untersucht. Zecca u. a. (2002) fassen die bis zu diesem Zeitpunkt verwendeten Merkmale in einer Veröffentlichung zusammen und liefern die mathematischen Definitionen der Merkmale.

Oskoei u. Hu (2008b) untersuchen einen Großteil dieser Merkmale auf ihre Qualität und Genauigkeit mit drei verschiedenen Klassifikationsverfahren. Die Untersuchung ergibt, dass eine Kombination von Merkmalen aus dem Zeitbereich, wie z. B. von MAV, WL, ZC und SSC oder von RMS und AR-Modell, sehr hohe Genauigkeiten bei der Klassifizierung ermöglicht.

Mittelwert

MAV und RMS sind beides Verfahren, die den Mittelwert einer Sequenz der Länge M berechnen. Der Unterschied zwischen ihnen liegt in der unterschiedlichen Bewertung von einzelnen Ausreißern, die stark von der Varianz abweichen.

Mean Absolute Value Der Mean Absolute Value \bar{x}_{MAV} beschreibt die Abschätzung des Mittelwerts der Absolutbeträge einer Sequenz der Länge M . Die Betragsbildung ist notwendig, da das Signal ohne Betragsbildung einen Mittelwert nahe Null aufweist und keine Aussagen über die Amplitude erlaubt. Er ist definiert durch (5.1).

$$\bar{x}_{\text{MAV}} = \frac{1}{M} \sum_{i=1}^M |x_i| \quad (5.1)$$

Root Mean Square Der RMS \bar{x}_{RMS} ist ebenfalls eine Abschätzung des Mittelwertes einer Sequenz der Länge M . Durch die Quadrierung ist hier keine Betragsbildung notwendig. Der Unterschied zum MAV liegt in der stärkeren Gewichtung von großen Signalwerten. Er ist definiert durch (5.2).

$$\bar{x}_{\text{RMS}} = \sqrt{\frac{1}{M} \sum_{i=1}^M x_i^2} \quad (5.2)$$

Zero Crossings

Das Merkmal Zero Crossings (ZC) beschreibt die Anzahl der Schnittpunkte des Signals mit der Signalnulllinie. Es erlaubt, aus dem Signal im Zeitbereich eine grobe Abschätzung der Frequenzen zu erhalten. Um jene Schnittpunkte mit der Nulllinie, die durch

das Rauschen des Signals hervorgerufen werden, zu unterdrücken, muss ein Schwellenwert s_{tres} definiert werden. Der Zähler für ZC wird nach Zecca u. a. (2002) erhöht, wenn für ein x_i gilt

$$\text{sgn}(-x_i \cdot x_{i+1}) \wedge (|x_i - x_{i+1}| > s_{\text{tres}}) \quad (5.3)$$

wobei $\text{sgn}(x) = 1$ für $x > 0$ und sonst 0 ist.

Slope Sign Changes

Ein Merkmal, das ebenfalls Hinweise auf die Frequenzanteile im Signal gibt, sind die Slope Sign Changes (SSCs). Auch hier ist ein Schwellenwert s_{tres} notwendig, um die vom Rauschen verursachten Verunreinigungen des Signals zu entfernen. Bei drei aufeinanderfolgenden Messwerten x_{i-1}, x_i, x_{i+1} wird der Zähler für SSC erhöht, wenn (5.4) gilt (Zecca u. a., 2002):

$$(x_i - x_{i-1}) \cdot (x_i - x_{i+1}) > s_{\text{tres}} \quad (5.4)$$

Waveform Length

Die Waveform Length (WL) l_0 beschreibt die kumulative Länge des Signals über eine Sequenz der Länge M . Sie ist gleichzeitig ein Merkmal für die Frequenz und die Amplitude. Sie ist nach Zecca u. a. (2002) definiert durch (5.5) mit $\Delta x_i = x_i - x_{i-1}$.

$$l_0 = \sum_{i=1}^M |\Delta x_i| \quad (5.5)$$

Autoregressives Modell

Das Autoregressive (AR) Modell beschreibt ein lineares Systemmodell, mit dem stochastische Prozesse modelliert und prädiziert werden können. Lombardi u. Godsill (2005) dokumentieren, dass sich dieses Modell besonders für verrauschte Signale eignet, wie sie typischerweise beim EMG vorliegen. Aus den Untersuchungen von Chen u. a. (2006b) ergibt sich ferner, dass sich das EMG-Signal mittels Autoregressivem Modell (AR) beschreiben lässt, da es bezüglich eines Sprachsignals Ähnlichkeiten aufweist.

Eine direkte Anwendung des AR-Modells für die EMG-Auswertung führen Luo u. a. (2006) auf: Bei sich ändernder Muskelkraft, welche insbesondere beim dynamischen Gang auftritt, weist das EMG-Signal im Zeitbereich eine Welligkeit auf, wohingegen im Frequenzbereich Parameter wie die AR-Koeffizienten annähernd konstant bleiben. Ferner stellen Luo u. a. (2006) fest, dass die Erkennungsrate von AR-Koeffizienten geringer ist als mit vergleichbaren Wavelet-Koeffizienten, jedoch erfordern die AR-Koeffizienten eine geringere Rechenleistung und haben eine schnellere Reaktionsgeschwindigkeit, was hinsichtlich der in Unterabschnitt 2.4.2 definierten Echtzeitbedingungen relevant ist.

Ein Prozess, der von einem AR-Modell abgebildet werden soll, muss stationär sein, wobei folgende Bedingungen erfüllt sein müssen:

$$\begin{aligned}
 \text{(i)} \quad & E(x_t^2) < \infty && \forall t \in N \\
 \text{(ii)} \quad & E(x_t) = \mu && \forall t \in N \\
 \text{(iii)} \quad & Cov(x_{t+h}, x_t) = Cov(x_h, x_0) && \forall t, h \in N
 \end{aligned} \tag{5.6}$$

Die erste Bedingung besagt, dass jeder Zufallswert eine endliche Varianz besitzt. Die zweite Eigenschaft legt fest, dass der Erwartungswert konstant über die Zeit ist. Die dritte Eigenschaft stellt sicher, dass die Kovarianzen zweier Zeitpunkte nicht von den Zeitpunkten selbst, sondern von deren Abständen abhängen. Das EMG-Signal erfüllt diese Eigenschaften nicht. Jedoch kann die Annahme getroffen werden, dass das EMG-Signal in einer genügend kleinen Sequenz die Stationaritätsbedingungen erfüllt. Dann kann der Messwert x_t zum Zeitpunkt t als Linearkombination der vorherigen n Werte mit den Koeffizienten φ_i und dem weißen Rauschen ϵ_t , welches mittelwertfrei ist und die Varianz σ^2 besitzt, gemäß (5.7) berechnet werden.

$$x_t = \sum_{i=1}^n \varphi_i x_{t-i} + \epsilon_t \tag{5.7}$$

Für die Schätzung der Koeffizienten des AR-Modells n -ter Ordnung wurden verschiedene Verfahren entwickelt. Sie werden entweder über die Methode der kleinsten Quadrate, über ein Maximum Likelihood Verfahren oder über die YULE-WALKER-Gleichungen bestimmt (Schlittgen, 2001). Luo u. a. (2006) verwenden ebenfalls die YULE-WALKER-Gleichung zur Berechnung der AR-Koeffizienten φ_i mittels des in (5.8) gezeigten Gleichungssystems, das nach Achilles (1987) und Eshel aufgestellt werden kann.

$$\begin{bmatrix} r_0 & r_1 & r_2 & \cdots & r_n \\ r_1 & r_0 & r_1 & \cdots & r_{n-1} \\ r_2 & r_1 & r_0 & \cdots & r_{n-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_n & r_{n-1} & r_{n-2} & \cdots & r_0 \end{bmatrix} \cdot \begin{bmatrix} 1 \\ \varphi_1 \\ \varphi_2 \\ \vdots \\ \varphi_n \end{bmatrix} = \begin{bmatrix} \sigma^2 \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (5.8)$$

Die TOEPLITZ-Autokorrelations-Matrix in (5.8) enthält dabei die Autokovarianzfolgen r_i von x_i aus (5.7).

5.1.2 Merkmale im Frequenzbereich

Mit den Merkmalen aus dem Frequenzbereich kann das EMG-Signal auf Frequenzanteile und periodische Charakteristika untersucht werden. Dazu wird die Messreihe mittels einer geeigneten Transformation in eine Darstellung im Frequenzbereich überführt. Englehart u. a. (1999, 2001) verwenden hierfür die Short Time Fourier Transformation (STFT) und benutzen die dabei generierten Koeffizienten zur Klassifizierung.

Von Englehart u. a. (2001) und Khezri u. Jahed (2007) wurde die diskrete Wavelet Transformation (DWT) bezüglich ihrer Eignung zur Klassifizierung untersucht. Oskoei u. Hu (2008b) und Saponas u. a. (2009) verwenden zur Klassifizierung die mit Hilfe der STFT erstellte spektrale Leistungsdichte des EMG-Signals. Diese Methode stellte sich alleine betrachtet aber mit einer Klassifikations-Genauigkeit von 60 % als unzureichend heraus. Aus diesem Grund wird in dieser Arbeit nur die Kombination aus STFT und DWT näher betrachtet.

Short Time Fourier Transformation

Die Fourier Transformation (FT) ermöglicht, ein Signal aus dem Zeitbereich in den Frequenzbereich zu transformieren, wobei das Signal in eine unendliche Anzahl von Sinus- und Kosinus-Funktionen zerlegt wird. Das Fourierspektrum $X(f)$ des transformierten Signals $x(t)$ liefert Informationen über den Energiegehalt einzelner Frequenzen im Signal und berechnet sich nach (5.9).

$$X(f) = \int_{-\infty}^{\infty} x(t)(\cos 2\pi ft - i \sin 2\pi ft)dt \quad (5.9)$$

Durch die Anwendung der Euler'schen Formel in (5.10) wird (5.9) in die gängige Darstellung der FT für ein kontinuierliches und nichtperiodisches Signal in (5.11) überführt.

$$e^{i\theta} = \cos \theta - i \sin \theta \quad (5.10)$$

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-i2\pi ft} dt \quad (5.11)$$

Handelt es sich bei der Funktion $x(t)$ um ein zeitdiskretes Signal mit N Messwerten und haben diese einen äquidistanten Abstand T , so lassen sich die unendlichen Integrationsgrenzen durch endliche ersetzen, wobei das Integral durch eine Summe ersetzt werden kann, aus der sich die diskrete Fourier Transformation (DFT) in (5.12) ergibt.

$$X(f) = \sum_{n=0}^{M-1} x(nT)e^{-inf2\pi/N} \quad (5.12)$$

Hierbei ist zu beachten, dass nur diejenigen Frequenzen korrekt dargestellt werden können, die unterhalb der NYQUIST-Frequenz liegen. Die NYQUIST-Frequenz ergibt sich aus dem NYQUIST-SHANNON-Abtasttheorem in (5.13), welches besagt, dass ein Signal nach einer Diskretisierung mit der Frequenz f_{abtast} nur dann fehlerfrei wiederhergestellt werden kann, wenn f_{abtast} mindestens doppelt so groß ist wie die größte im Signal enthaltene Frequenz f_{max} . Sind Frequenzen im Signal enthalten, die größer als die NYQUIST-Frequenz sind, werden diese durch die DFT fälschlicherweise als Frequenzen unterhalb der NYQUIST-Frequenz dargestellt.

$$f_{abtast} > 2 \cdot f_{max} \quad (5.13)$$

Da bei der DFT von N Messwerten N Werte der DFT berechnet werden, beträgt die Ordnung der DFT $\mathcal{O}(n^2)$. Es existiert jedoch ein Algorithmus, der die DFT in $\mathcal{O}(n \log_2 n)$ berechnet. Diese Implementierung wird Fast Fourier Transformation (FFT) genannt und wurde von Cooley u. Tukey (1965) veröffentlicht. Sie unterliegt der Einschränkung, dass die Anzahl der Messwerte eine Zweierpotenz sein muss. Da jedoch die Anzahl der Messwerte im Allgemeinen frei gewählt werden kann, stellt dies keinen Nachteil dar. Das Verfahren teilt die Menge der Messwerte rekursiv nach geraden und ungeraden Indizes auf und erzeugt somit zwei neue Mengen mit je der Hälfte an

Messwerten. Danach wird von beiden Teilmengen die DFT berechnet, und sie werden wieder zu einer Menge vereint.

Mit der DFT ist es nicht möglich, den Zeitpunkt, an dem bestimmte Frequenzen auftreten, zu bestimmen. Sie beschreibt immer alle Frequenzen, die im Signal vorkommen. Daher ist die DFT in dieser Form noch nicht für eine Willkürerkennung geeignet, da man zusätzlich zu der Information, dass eine Frequenz auftritt, auch noch den Zeitpunkt des Auftretens bestimmen muss. Hier schafft eine Erweiterung der DFT, die Short-time Fourier Transformation (STFT), Abhilfe. Hierbei wird das Signal, welches transformiert werden soll, mit einer Fensterfunktion $w(t - \tau)$ multipliziert, die nur in einem kurzen Intervall Werte ungleich Null annimmt. Dadurch ist es möglich, nur die Frequenzanteile dieses Ausschnitts zu berechnen und alle anderen Messwerte auszublenken. Wird nun die Fensterfunktion über die Zeitachse des Signals um den Betrag τ verschoben, so können die Frequenzanteile einzelnen Verschiebungen τ zugeordnet werden. Man erhält eine zweidimensionale Repräsentation der Messreihe, die für kontinuierliche Signale durch (5.14) definiert ist.

$$X(f, \tau) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-i2\pi ft} dt \quad (5.14)$$

Für zeitdiskrete Messreihen kann die STFT durch (5.15) berechnet werden.

$$X(f, \tau) = \sum_{n=0}^{M-1} x(nT)w(nT - \tau)e^{-inf2\pi/N} \quad (5.15)$$

Entspricht die Fenstergröße nicht der Periodendauer oder einem ganzzahligen Vielfachen der Periode einer im Signal auftretenden Frequenz, kommt es zu sogenannten Leck-Effekten. Diese verursachen im Frequenzspektrum das Auftreten zusätzlicher Frequenzen, die nicht im ursprünglichen Signal enthalten sind. Die Wahl der Fensterfunktion $w(t - \tau)$ bestimmt, wie stark dieser Effekt auftritt.

In der Abbildung 5.1 ist das Spektrogramm eines EMG-Signals dargestellt. Das Spektrogramm nach (5.16) veranschaulicht die Frequenzanteile zu verschiedenen Verschiebungen des Zeitfensters.

$$\text{spectrogram}\{x(t)\} = |X(f, \tau)|^2 \quad (5.16)$$




Abbildung 5.1: Elektromyographie-Signal (oben) und zugehöriges Spektrogramm (unten, Farblegende: grün = geringer, gelb = mittlerer und rot = hoher Frequenzanteil) (Bildquelle: Dennerlein (2009))

Es wird ein HANNING-Fenster mit 128 Messwerten benutzt, die Überlappung der Fenster beträgt 64 Messwerte und die DFT wird ebenfalls mit 128 Messwerten berechnet. Aus dem Spektrogramm ist ersichtlich, dass das EMG-Signal ein sehr breitbandiges Signal im Frequenzbereich 20 – 400 Hz ist, wobei einzelne Spitzen bis 500 Hz reichen. Zusätzlich ist das Netzbrummen von 50 Hz zu erkennen, was über ein separates Filter aus dem EMG-Signal entfernt werden muss.

Diskrete Wavelet Transformation

Während die STFT über der Zeit Frequenzblöcke mit gleichem Intervall bestimmt, wie in Abbildung 5.2 a) dargestellt, ermöglicht die Wavelet Transformation WT (Abbildung 5.2 b)) eine feinere Zeitauflösung bei höheren Frequenzen und genauere Frequenzauflösung bei kleinen Frequenzen. Die Wavelet Packet Transformation in Abbildung 5.2 c) erlaubt darüber hinaus eine beliebige Aufteilung der Kacheln (ein Bereich in der Frequenz-Zeit-Ebene in Abbildung 5.2), womit sie an das spezielle Problem angepasst werden kann.




Abbildung 5.2: Aufteilung der Zeit-Frequenz-Ebene in Kacheln (nach Englehart u. a. (1999))

Es erweist sich dabei als vorteilhaft, dass die MUAPs nach Zhou u. Rymer (2003) über einen kleinen Satz von Wellengrundformen und Wavelet-Funktionen beschrieben werden können. So verwenden Reaz u. a. (2006a,b) eine Wavelet Transformation mit verschiedenen Wavelet-Funktionen und Chu u. a. (2006) die Wavelet Packet Transformation, um ihre Merkmale aus dem EMG-Signal zu generieren. Sie verwenden dabei das *Haar-Wavelet* mit einer Skalierungsfunktion und den von Mallat (1989) vorgestellten Algorithmus, auf den im Folgenden eingegangen werden soll.

Obwohl die Wavelet Transformation ebenfalls eine Methode bietet, um das Signal bezüglich seines Frequenzinhalts zu untersuchen, weist es bezüglich der Fourier-Transformation einen entscheidenden Unterschied auf: Es entsteht eine Funktion der Skalierung und Translation. Die Funktion wird nicht in Sinus- und Kosinus-Funktionen zerlegt, sondern mit einem sogenannten Mutter-Wavelet $\psi(t)$ verglichen. Die Koeffizienten $W_\psi(a, b)$ der WT geben dann an, wie ähnlich das skalierte und translatierte Mutter-Wavelet einem Abschnitt im Signal ist. Als Mutter-Wavelet ist jede Funktion zulässig, die die Eigenschaft (5.17) erfüllt:

$$C_\psi = \int_0^\infty \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (5.17)$$

Hierbei bezeichnet $\Psi(\omega)$ die Fouriertransformierte des Wavelets und C_ψ die Calderon-Konstante. Aus der Konvergenzbedingung folgt, dass die Fouriertransformierte des Wavelets bei der Frequenz $\omega = 0$ verschwindet, und es lässt sich aus (5.18) ableiten, dass Wavelets mittelwertfrei sind. Die Abbildung 5.3 zeigt Wavelets, welche sich für die Analyse des EMG-Signals anbieten.

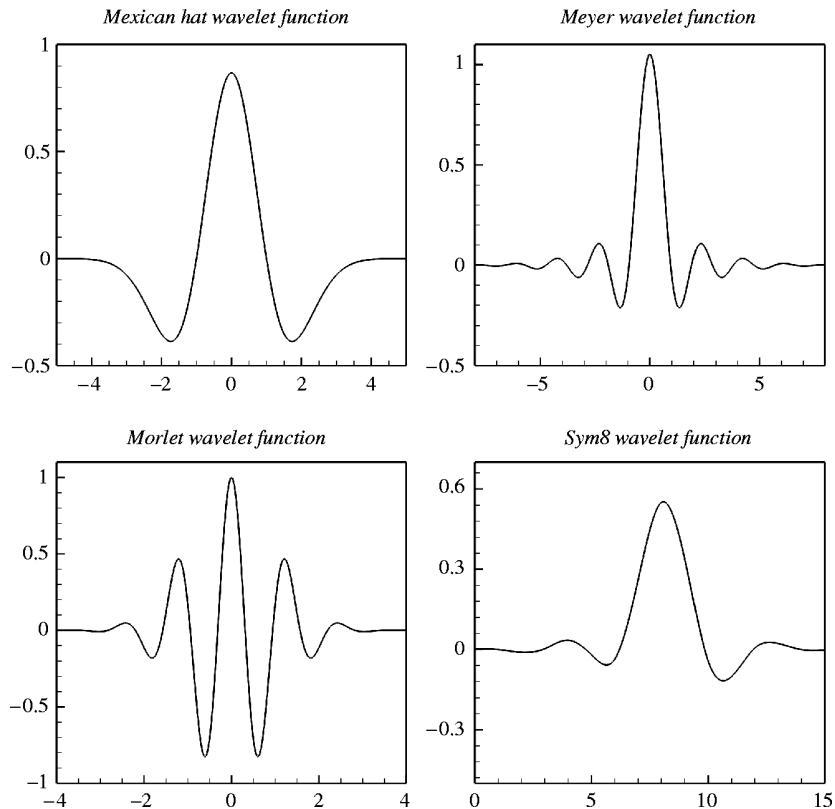


Abbildung 5.3: Beispiel für Wavelet-Funktionen. (Quelle: Hakkaki-Fard (2008))

$$\int_0^{\infty} \psi(t) dt = 0 \quad (5.18)$$

Aus dem Mutter-Wavelet werden durch verschiedene Skalierungen $a \in \mathbb{R}$ und Translationen $b \in \mathbb{R}$ durch (5.19) ein Satz von Basisfunktionen $\psi_{a,b}$ erzeugt, die sogenannten Tochter-Wavelets.

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \cdot \psi\left(\frac{t-b}{a}\right) \quad (5.19)$$

Somit lässt sich die kontinuierliche Wavelet Transformation (CWT) $W_{\psi}(a, b)$ aus dem inneren Produkt der Basisfunktionen $\psi_{a,b}$ und der kontinuierlichen Funktion $x(t)$ gemäß (5.20) berechnen, wobei * für die komplexe Konjugation steht. Die Wavelet-Koeffizienten beschreiben die Ähnlichkeit der jeweiligen Tochter-Wavelets mit dem Signal.

$$W_\psi(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi \left(\frac{t-b}{a} \right)^* \cdot x(t) dt \quad (5.20)$$

Da nicht nur das Signal $x(t)$ sondern auch der Skalierungs- und Translationsparameter a, b kontinuierlich ist, erhält man bei der Berechnung der CWT eine überabzählbare Menge an Tochter-Wavelets. Dies verhindert eine effiziente Berechnung der CWT. Des Weiteren sorgt die kontinuierliche Translation der Tochterwavelets für eine redundante Darstellung des Signals, da die Information eines Wavelet-Koeffizienten zu einem gewissen Teil auch in den benachbarten Koeffizienten enthalten ist. Die Lösung dieser Probleme stellt die diskrete Wavelet Transformation (DWT) dar. Sie diskretisiert die Skalierungs- und Translationsparameter a, b . Daraus folgt (5.21) zur Erzeugung der Tochter-Wavelets.

$$\psi_{j,k}(t) = \frac{1}{\sqrt{s_0^j}} \cdot \psi \left(\frac{t - k\tau_0 s_0^j}{s_0^j} \right) \quad (5.21)$$

Hierbei entspricht $a = s_0^j$ der Diskretisierung des Skalierungsparameters und $b = k\tau_0 s_0^j$ der Diskretisierung des Translationsparameters mit $j, k \in \mathbb{Z}$ und $s_0 \geq 1, \tau_0 > 0$.

Vollständigkeitshalber ist in (5.22) die Rücktransformation angegeben, aus der sich das Signal aus den Wavelet-Koeffizienten zurückgewinnen lässt.

$$x(t) = \sum_{j,k} W_\psi(j, k) \psi_{j,k}(t) \quad (5.22)$$

Bei der Analyse von zeitdiskreten Signalen wird ebenfalls eine Diskretisierung der Skalierungs- und Translationsparameter vorgenommen. Um ein Signal jedoch vollständig mit den Wavelet-Koeffizienten darzustellen, bedarf es weiterhin einer unendlichen Zahl an Skalierungen. Die Zahl der Translationen ist durch die endliche Länge der Messreihen begrenzt. Die Begrenzung der Skalierungen auf eine endliche Anzahl eröffnet den Weg zu einer sehr effizienten Berechnung der Wavelet-Koeffizienten mit einer Laufzeit von $\mathcal{O}(n)$. Dieses Verfahren wird schnelle Wavelet Transformation (FWT)¹ genannt und basiert auf einer Multiskalen-Analyse. Hierfür wird der Bandpasscharakter der Wavelets ausgenutzt. Dieser Charakter ergibt sich aus der Folge der Konvergenzbedingung in (5.17), so dass die Fouriertransformierte des Wavelets bei der Frequenz $\omega = 0$ verschwindet. Um die Multiskalen-Analyse vollständig durchführen zu können,

¹Fast Wavelet Transform

muss allerdings eine Funktion eingeführt werden, die einen Tiefpasscharakter besitzt. Hierfür wird das sogenannte Vater-Wavelet eingeführt (Mallat, 1989), dessen Spektrum diesen Charakter besitzt. Das Vater-Wavelet kann ebenfalls durch Wavelets dargestellt werden (5.23).

$$\varphi(t) = \sum_{j,k} W_{\psi}(j, k) \psi_{j,k}(t) \quad (5.23)$$

Durch die Einführung des Vater-Wavelets kann nun die Diskrete Wavelet Transformation mit Hilfe einer Filterbank ausgeführt werden, wobei mit Hilfe von Hoch- und Tiefpassfiltern das Signal in ein hoch- und niederfrequentes Subband aufgetrennt wird. Die Grenzfrequenz ist die Mittenfrequenz des Frequenzbandes und durch die Tiefpassfilterung werden die Approximations-Koeffizienten $S_{\varphi,j}(k)$ und Detail-Koeffizienten $W_{\psi,j}(k)$ generiert. Aus diesen lässt sich das Signal gemäß (5.24) reproduzieren.

$$x(t) = \sum_k S_{\varphi,j-1}(k) \varphi(2^{j-1}t - k) + \sum_k W_{\psi,j-1}(k) \psi(2^{j-1}t - k) \quad (5.24)$$

Sind das Vater-Wavelet und das Mutter-Wavelet orthonormal zueinander, so lassen sich die Approximations- und Detail-Koeffizienten direkt aus den Koeffizienten der vorangegangenen Skalierung nach (5.25) berechnen.

$$\begin{aligned} S_{\varphi,j-1}(k) &= \sum_i h(i - 2k) S_{\varphi,j}(k) \\ W_{\psi,j-1}(k) &= \sum_i g(i - 2k) W_{\psi,j}(k) \end{aligned} \quad (5.25)$$

Diese Gleichungen lassen sich nach Mallat (1989) als digitale Filter mit den Filterkoeffizienten $g(k)$ für den Hochpassfilter und $h(k)$ für den Tiefpassfilter umsetzen. Durch die gewählte Schrittweite zwei bei der Variablen k wird bei der Filterung jeder zweite Messwert aus den Subbändern entfernt (sogenanntes „Down-Sampling“, $\downarrow 2$). Die Approximations-Koeffizienten werden weiter mit Hoch- und Tiefpassfiltern solange analysiert, bis der gewünschte Detailgrad erreicht ist. In der Abbildung 5.4 ist das Verfahren schematisch dargestellt. Die durch die FWT erzeugten Approximations-Koeffizienten $S_{\varphi,j}(k)$ und Detail-Koeffizienten $W_{\psi,j}(k)$ werden nacheinander in einem Vektor abgelegt und als Merkmal m_j verwendet.




Abbildung 5.4: 3-Level-Fast-Wavelet-Transform (nach Mallat (1989))

5.2 Generierung des virtuellen EMG

Ein Bestandteil der Systemarchitektur in Abschnitt 3.5 ist die Auswahl und Kombination der einzelnen EMG-Kanäle des Sensorarrays zu einem einzelnen Signal, damit die nachgeschaltete Signalverarbeitung und Mustererkennung von der konkreten Auslegung des Arrays unabhängig wird. Auch aus systemtheoretischer Sicht weist dieser Ansatz Vorteile auf, da die vorhandene Redundanz möglichst auf die Eingangsseite eines Signalverarbeitungssystems gelegt werden sollte (Gan u. Harris, 2001). Dieses kombinierte Signal soll *virtuelles EMG* (vEMG) genannt werden.

Einfache Verfahren, wie die Mittelwertbildung über alle Kanäle, scheiden aus, da diese nur bei einer großen Anzahl von Elektroden funktionieren, wenn die überwiegende Mehrheit der Einzelkanäle ein fehlerfreies Messsignal liefert. Nachteilig ist dabei, dass Störungen auf Einzelkanälen im Signal verbleiben und Merkmale für die Mustererkennung durch die Mittelwertbildung zerstört werden.

Da einzelne Kanäle bedingt durch Störungen, Ausfall oder Kontaktverlust vollständig ausfallen können, und sich das Sensorarray über dem Muskel bedingt durch das weiche Hautgewebe verschieben kann, muss eine Bewertung des Signals vorgenommen werden, welche gültige und brauchbare Signale von ungültigen separieren kann. Deshalb wurden Methoden untersucht, die die Signale der Einzelkanäle direkt bewerten und daraus ihre Auswahl ableiten.

5.2.1 Ansätze und Verfahren

Aus der Akustik ist das Prinzip des *Beamformers* bei Mikrofonarrays bekannt, bei dem eine gezielte Verstärkung von akustischen Signalen aus einer gewünschten Richtung oder mit gewünschtem Frequenzverhalten erzielt werden kann (Drews, 1999). Für die Anwendung beim Muskel-EMG setzt dieser Ansatz voraus, dass von den Elektroden ein

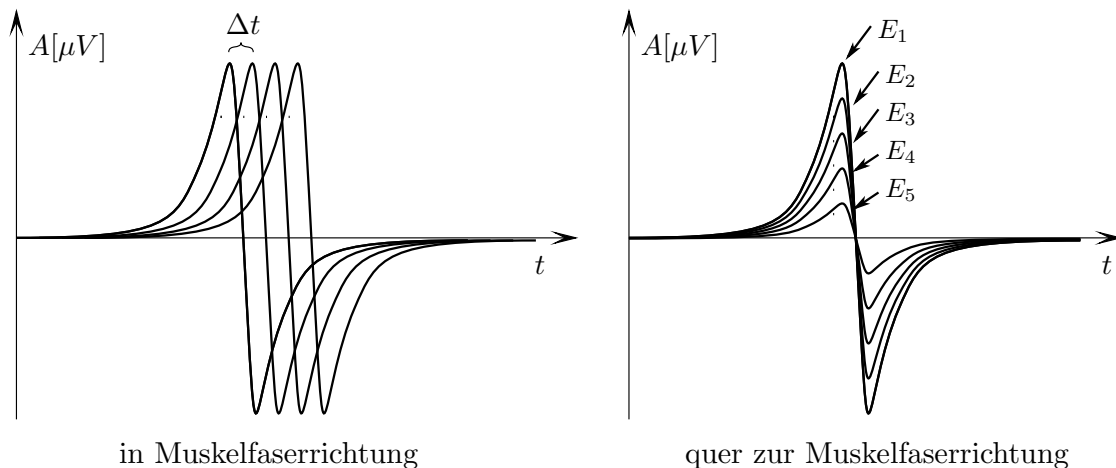


Abbildung 5.5: Amplitudenverlauf an den Array-Elektroden, wenn die Elektroden ein isoliertes und ideales MUAP erfassen (E_1 = nächste Elektrode am MUAP, E_5 = entfernteste Elektrode).

möglichst störungsfreies und vom gleichen Ursprung stammendes Signal vorliegt, was durch die räumliche Ausdehnung des Muskels und den relativ geringen Abstand des Arrays zu diesem nicht gewährleistet werden kann. Das Verfahren nach dem Prinzip des Beamformers wurde bisher von Farina u. Merletti (2000) für die Schätzung der Ableitgeschwindigkeit einer einzelnen muskulären motorischen Einheit (MU) verwendet und wird von Merletti u. Parker (2004) beschrieben.

Für die räumlich verteilten EMG-Signale ergeben sich bei einem Array gemäß den Simulationen von Fuglevand u. a. (1992) unter Verwendung von (3.1) auf Seite 24 die in Abbildung 5.5 dargestellten Amplituden A , wenn die räumlichen Elektroden das Potential eines einzelnen MUAPs messen. Die Verzögerungszeit Δt zwischen den Elektroden in Muskelfaserrichtung ergibt sich aus der Ausbreitungsgeschwindigkeit v im Muskel und dem räumlichen Abstand Δl der Elektroden. In Querrichtung zur Muskelfaser nimmt die Amplitude des Signals mit dem Abstand ab, wohingegen der qualitative Amplitudenverlauf gleich bleibt.

Dieser Zusammenhang kann bei der Generierung des virtuellen EMG-Signals ausgenutzt werden, wenn Vergleichsverfahren angewendet werden, die über eine Korrelation nur das qualitative Signal betrachten: Elektroden-Paare entlang der Muskelfaser in vertikaler Ausrichtung weisen, bedingt durch den Muskelbauch, ein gleichmäßigeres Signal auf als Elektrodenpaare, die quer dazu in horizontaler Richtung nebeneinander liegen.

Somit müssen vertikal übereinander liegende Elektrodenpaare eine größere Gemein-

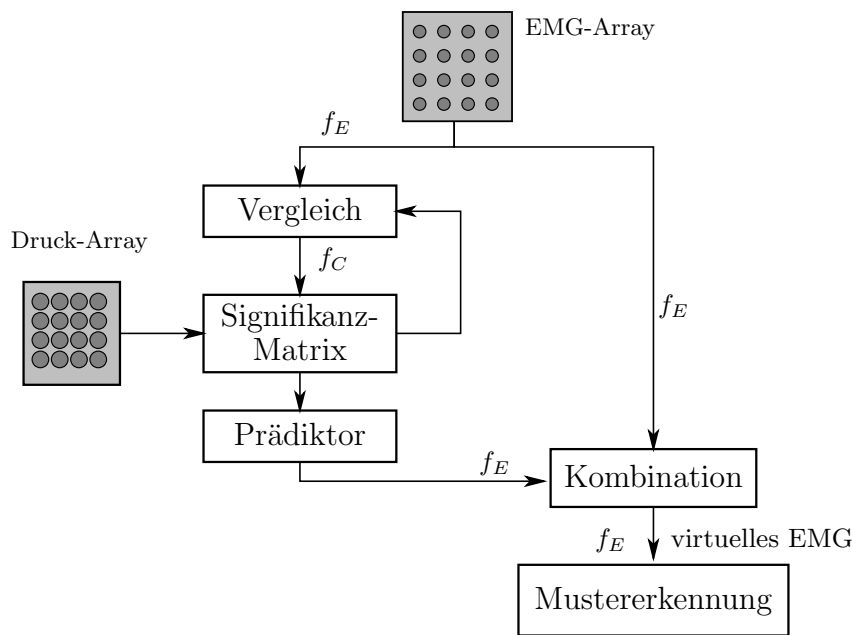


Abbildung 5.6: Blockschaltbild zur Berechnung des virtuellen EMG-Signals

samkeit aufweisen als horizontal liegende. Allerdings kann durch Beugung des Beins in vertikaler Richtung eine größere Veränderung in der Signalkonditionierung durch partielles Ablösen des Arrays von der Hautoberfläche entstehen als in horizontaler Richtung.

Bei einer mittleren Ausbreitungsgeschwindigkeit von $4 \frac{m}{s}$ (Lowery u. O'Malley, 2003) ergibt sich bei einem Elektrodenabstand von $5mm$ ein Δt von $1,25ms$, was bei $1500Hz$ Abtastfrequenz des EMG-Messsystems nur 2 Messwert-Samples entspricht und von Effekten wie Rauschen um Größenordnungen überlagert wird. Dieser Effekt der Verzögerungszeit in Muskelfaserichtung kann deshalb bei der Bestimmung des virtuellen EMG-Signals vernachlässigt werden.

Wie bereits im Abschnitt 2.4 beschrieben stellt die Echtzeitfähigkeit des Erkennungssystems eine wesentliche Komponente des Prothesensteuerungssystems dar. Zur Minimierung von Latenzen muss bei der Generierung des virtuellen EMGs deshalb ein möglichst direkter Durchgriff des Signals angestrebt werden, welcher als Echtzeitpfad bezeichnet werden soll.

Eine solche Struktur zur Gewinnung des virtuellen EMG-Signals ist in der Abbildung 5.6 gezeigt. Das EMG-Array-Signal mit der Samplingfrequenz von $f_E = 1500Hz$ wird in einen Vergleichs-Block geführt, welcher mit einer Frequenz von $f_C \ll f_E$ die Bewertung durchführt. Ergänzt wird die so gewonnene Signifikanz-Matrix $\mathbf{S} = [s_{i,j}]$,

$i \in \{1 \dots N_E^z\}$, $j \in \{1 \dots N_E^s\}$, die jedem Array-Kanal einen Vertrauenswert zuordnet, um die Informationen aus dem Drucksensor-Array $\rho_{EMG}^{i,j}$, $i \in \{1 \dots N_P^z\}$, $j \in \{1 \dots N_P^s\}$, wodurch bei Unter- oder Überschreitung eines partiellen Anpressdrucks die Kanalsignifikanz zusätzlich angepasst werden kann. Die Gesamtzahl L der bipolaren EMG-Kanäle in der folgenden Signalverarbeitung ergibt sich zu (5.26), wobei N_E^z die Anzahl der Sensor-Zeilen im EMG-Array, N_E^s die Anzahl der Sensor-Spalten im EMG-Array und N_E die Gesamtanzahl der EMG-Elektroden im EMG-Array bezeichnet.

$$L = \frac{N_E^z \cdot N_E^s}{2} = N_E/2 \quad (5.26)$$

Über einen Prädiktor, der als Bindeglied zum Echtzeitpfad dient und erkannte Trends innerhalb der Signifikanzverteilung berücksichtigen kann, werden schließlich die einzelnen EMG-Kanäle zum virtuellen EMG kombiniert. Die Frequenz f_C muss typische Signalveränderungen erfassen können, welche auch durch die Bewegungsdynamik des Prothesenträgers hervorgerufen werden können. Mit dieser Grenze ergibt sich ein sinnvoller Frequenzbereich für Beinprothesenträger von $10 \text{ Hz} \leq f_C \leq 100 \text{ Hz}$, wobei in dieser Arbeit $f_C = 100 \text{ Hz}$ gewählt wurden.

Vor dem Hintergrund der Effizienzsteigerung beim Vergleich der Kanäle ist eine Rückkoppelung von der Signifikanzmatrix vorgesehen, wodurch das Vergleichen, welches ein quadratisches Problem der Dimension n^2 darstellt, auf einen linearen Fall der Dimension n reduziert werden kann, indem die Kanäle nicht kreuzweise, sondern nur mit dem jeweils relevantesten verglichen werden.

Ein anderer Ansatz zur Generierung des virtuellen EMG stellt die Verwendung eines Zustandsschätzers dar, der das ideale EMG-Signal über ein dynamisches Systemmodell prädiziert und von den tatsächlichen EMG-Kanälen in Form einer Stützensensorik, welche als Beobachter fungiert, korrigiert und moduliert wird. Für das Systemmodell bieten sich das bereits für die Merkmalsextraktion herangezogene AR-Modell aus Abschnitt 5.1.1 oder ein vereinfachtes KALMAN-Filter an.

Die Methode der Fusion der Messungen, wie sie von Gan u. Harris (2001) beschrieben ist, weist dabei den Vorteil auf, dass der Eingang des statistisch arbeitenden Zustandsschätzers in Form eines KALMAN-Filters, der die Elektroden repräsentiert, beliebig skaliert werden kann, was die Anzahl der eingesetzten EMG-Sensoren flexibilisiert. Aspekte wie der schwankende und damit signalbeeinflussende Anpressdruck der EMG-Elektroden müssen in dieser Methode jedoch entsprechend berücksichtigt werden, was

über eine Vorfilterung der Beobachtungen realisiert werden könnte.

Für die weiteren Untersuchungen und Implementierungen im Rahmen der Arbeit wurde der Ansatz gewählt, welcher direkt Gemeinsamkeiten zwischen den EMG-Signalen und Störungen auf Einzelkanälen erkennt, da dem nachgeschalteten Mustererkennungssystem ein möglichst natürliches und reales EMG-Signal präsentiert werden sollte. Untermauert wird diese Design-Entscheidung von der Kenntnis, dass das EMG-Signal sich in charakteristischen Eigenschaften signifikant zwischen den einzelnen Bewegungszuständen unterscheidet, weswegen in der in Abschnitt 3.5 beschriebenen Systemarchitektur eine Erkennungslogik für jene Bewegungszustände hinzugefügt wurde. Dieser Zustandsschätzer müsste folglich zwei Zustände gleichzeitig schätzen: Das eigentliche EMG-Signal und die geänderte Ausprägung, die abhängig von der Belastung und Bewegung ist. Aus Gründen der Systemkapselung sollen deshalb keine Informationen aus der Zustandsschätzung für die Bestimmung des virtuellen EMG-Signals verwendet werden.

5.2.2 Vergleich der EMG-Kanäle

Damit innerhalb der EMG-Kanäle Gemeinsamkeiten im Signal gefunden werden können, müssen diese verglichen werden. Die gefundenen Gemeinsamkeiten werden verstärkt und extrahiert, wobei Störungen und Artefakte im virtuellen Signal entfernt werden.

Wie bereits oben beschrieben, treten bei der Berechnung des vEMG zwei verschiedene Frequenzen f_E und f_C auf, deren Signalströme voneinander abgeleitet und später wieder kombiniert werden. Die Indices k , welche den Wert zu einem Zeitpunkt repräsentieren, werden deswegen erweitert zu k_E und k_C , wobei zu jedem k_C eine Teilmenge aus den ursprünglichen Messwerten k_E mit einer Fensterbreite M genommen wird: $x(k_C) = \{x(k_E - M), \dots, x(k_E)\}$.

Zur Vereinfachung der Notation soll innerhalb dieses Abschnittes im Folgenden gelten: \mathbf{x} und \mathbf{y} sind zwei Vektoren mit EMG-Messwerten von zwei unterschiedlichen EMG-Kanälen i und j mit $i, j \in \{1, \dots, L\}$ aus dem EMG-Array mit Länge M , welche zum Zeitpunkt $t = k_C$ gewonnen wurden, also $\mathbf{x} = x_i(k_C)$ sowie $\mathbf{y} = x_j(k_C)$. Die beiden EMG-Signale \mathbf{x} und \mathbf{y} aus dem Zeitintervall $t \in \{(k_E - M), \dots, k_E\}$ sollen nun auf Ähnlichkeit verglichen werden.

Relative Energy Of Difference Die Energy of Difference (EOD) ist ein Maß für die Ähnlichkeit zweier Signale, das von Lee (2008) für den Vergleich von MUAPs verwendet wird. Es werden die Flächen unterhalb von Signalkurven berechnet und voneinander abgezogen und mit der Gesamtenergie im betrachteten Zeitfenster ins Verhältnis gesetzt. Daher ist die EOD relativ unempfindlich gegenüber der Wahl der Größe M des Zeitfensters. Je kleiner die EOD ist, desto ähnlicher sind sich die Signale. Da das Rauschen auf den EMG-Kanälen nicht gleich ist und der Verlust des Hautkontakts auf einem EMG-Kanal das Signal sehr stark verändert, ist die EOD gut geeignet, um die Signale zu bewerten. Nachteilig bei der EOD ist, dass Signale, welche sich ähneln, aber eine unterschiedliche Amplitude aufweisen, einen nachteilig hohen EOD-Wert generieren, weswegen die EOD als alleinige Vergleichsmethode nicht ausreichend ist.

Die EOD kann allgemein aufgestellt werden gemäß (5.27), wobei sich in der Diskretisierung die (5.28) ergibt.

$$EOD_{i,j} = \frac{\int_0^T (\mathbf{x} - \mathbf{y})^2 dt}{\int_0^T (\mathbf{x}^2 + \mathbf{y}^2) dt} \quad (5.27)$$

$$EOD_{i,j} = \frac{\sum_M (\mathbf{x} - \mathbf{y})^2}{\sum_M (\mathbf{x}^2 + \mathbf{y}^2)} \quad (5.28)$$

Die EOD-Berechnung (5.28) wird auf den dyadischen Raum der EMG-Kanäle $i \times j$ angewendet, wobei sich für den EMG-Kanal i der Vergleichskoeffizient $\beta_i^{EOD}(k_C)$ nach (5.29) ergibt

$$\beta_i^{EOD}(k_C) = \begin{cases} 1 - \left(\frac{\sum_{j=1}^L EOD_{i,j}}{\max_j EOD_{i,j}} \right) & , \text{für } i \neq j \\ 0 & , \text{für } i = j \end{cases} \quad (5.29)$$

Kovarianz der absoluten Werte Die Kovarianz gibt ebenfalls die Ähnlichkeit zweier Signale an. Da ein negativer Wert eine Übereinstimmung mit einem inversen Signal angibt, wird die Betragsfunktion angewendet, damit Polaritätszuordnungen innerhalb der EMG-Kanäle keinen Einfluss auf den Vergleichskoeffizienten haben, der sich nach (5.30) berechnet. Auch für die EMG-Messwerte \mathbf{x} und \mathbf{y} wird ebenfalls die Betragsfunktion angewendet, damit tendenziell eine Überabschätzung des Vergleichsergebnisses erzielt wird.

$$\beta_i^{CAS}(k_C) = \begin{cases} |Cov(|\mathbf{x}|, |\mathbf{y}|)| & , \text{für } i \neq j \\ 0 & , \text{für } i = j \end{cases} \quad (5.30)$$

Kreuzkorrelation Die Kreuzkorrelation vergleicht die beiden Messwertvektoren, während einer der Vektoren gegenüber dem anderen verschoben wird. Durch diese Verschiebung $\tau \in \{-M/2, \dots, 0, \dots, M/2\}$ können auch Gemeinsamkeiten detektiert werden, welche nicht exakt phasengleich vorliegen, was bedingt durch die räumliche Ausdehnung des EMG-Arrays und die unterschiedliche Lokalisierung der MUAPs mit dem superpositionierenden EMG-Summensignal² notwendig ist. Der Vergleichskoeffizient $\beta_i^{XCS}(k_C, \tau)$ bestimmt sich gemäß (5.31).

$$\beta_i^{XCS}(k_C, \tau) = \begin{cases} \sum_{n=0}^{M/2-\tau-1} \mathbf{x}_{n+\tau} \mathbf{y}_n & , \text{für } (i \neq j) \wedge (\tau \geq 0) \\ \beta_i^{XCS}(k_C, -\tau) & , \text{für } (i \neq j) \wedge (\tau < 0) \\ 0 & , \text{für } i = j \end{cases} \quad (5.31)$$

Das Ergebnis der Kreuzkorrelation wird mit der in (5.32) gezeigten und statischen GAUSS-Verteilung $\mathbf{w} = [w_1, \dots, w_M]^T$ mittels Skalarprodukt multipliziert, wobei nur Korrelationswerte mit kleinem τ in das Ergebnis einfließen, was einer nahen zeitlichen Korrelation der EMG-Messwerte entspricht und Effekte, die nicht aus der EMG-Array-Geometrie oder aus den MUAP resultieren, unterdrückt.

$$w_i = \exp\left(-\frac{1}{2} \left(\frac{i}{0,005M}\right)^2\right), \quad i \in \{1, \dots, M\} \quad (5.32)$$

Somit ergibt sich für $\beta_i^{XCS}(k_C)$ der in (5.33) gezeigte Zusammenhang.

$$\beta_i^{XCS}(k_C) = \langle \beta_i^{XCS}(k_C, \tau), \mathbf{w} \rangle \quad (5.33)$$

²vgl. Abbildung 2.1 in Abschnitt 2.2.3

5.2.3 Kombination und Prädiktion des vEMG

Skalierung der Koeffizienten Die Vergleichskoeffizienten β_i^{XCS} , β_i^{EOD} und β_i^{CAS} müssen auf den Wertebereich $[0 \dots 1]$ skaliert werden, wobei drei verschiedene Ansätze untersucht wurden: Die erste Methode war eine lineare Skalierung gemäß (5.34). Weiterhin wurde eine quadratische Skalierung nach (5.35) untersucht, die kleine β_i geringer gewichten soll als große β_i , welche für eine größere Gemeinsamkeit stehen. Da auch beim quadratischen Skalieren nicht das gewünschte Verhalten erzielt werden konnte, wurde schließlich eine logarithmische Skalierung vorgesehen, welche die Koeffizienten β_i gemäß (5.37) unter Verwendung von (5.36) skaliert.

$$\tilde{\beta}_i(k_C) = \begin{cases} 0 & \text{für } \max_i \beta_i = 0 \\ \frac{\beta_i}{\max_i \beta_i} & \text{sonst} \end{cases} \quad (5.34)$$

$$\tilde{\beta}_i(k_C) = \begin{cases} 0 & \text{für } \max_i \beta_i = 0 \\ \frac{\beta_i^2}{(\max_i \beta_i)^2} & \text{sonst} \end{cases} \quad (5.35)$$

$$\hat{\beta}_i = \log \left(\frac{\beta_i}{\max_i \beta_i} \right) \quad (5.36)$$

$$\tilde{\beta}_i(k_C) = \frac{\hat{\beta}_i + \max_i |\hat{\beta}_i|}{\max_i (\hat{\beta}_i + \max_i |\hat{\beta}_i|)} \quad (5.37)$$

Die Vergleichskoeffizienten, die mit den oben genannten Ansätzen berechnet werden, werden mit (5.38) zu einem Vergleichsindex kombiniert, wobei eine Gewichtung der einzelnen Parameter vorgenommen wird: Die Gewichtungsfaktoren $d_{EOD} = 0,1$ für die Energy of Difference, $d_{CAS} = 0,5$ für die Kovarianz der absoluten Werte und $d_{XCS} = 0,4$ für die Kreuzkorrelation wurden experimentell ermittelt. Sie ergeben ein ausgewogenes Verhältnis zwischen den Vorteilen und Nachteilen der Vergleichsmethoden.

$$C_i(k_C) = d_{EOD} \cdot \tilde{\beta}_i^{EOD}(k_C) + d_{XCS} \cdot \tilde{\beta}_i^{XCS}(k_C) + d_{CAS} \cdot \tilde{\beta}_i^{CAS}(k_C) \quad (5.38)$$

Prädiktion der Koeffizienten Der Vergleichsindex $C_i(k_C)$ zum EMG-Kanal i entspricht dem Block „Vergleich“ in der Abbildung 5.6 auf Seite 66. Im nächsten Schritt wird daraus die Signifikanzmatrix \mathbf{S} gebildet, in welche auch die Informationen aus dem Drucksensor-Array einfließen. Wie bereits bei den Vergleichskoeffizienten β_i wird auch hier zugunsten einer besseren Notation von der Array-Zeilen/Spalten-basierten Notation $\mathbf{S}(k_E) = [s_{i,j}(k_E)]$ auf eine vektorielle Notation gewechselt, indem nur die EMG-Kanäle gemäß der in Abbildung 3.2 auf Seite 29 eingeführten Kanalzuordnung $(1, 2, \dots, L)$ indiziert werden: $\mathbf{S}(k_E) = [s_1(k_E), s_2(k_E), \dots, s_L(k_E)]$.

Da bei Inbetriebnahme keine Informationen über die Qualität der EMG-Kanäle verfügbar sind, wird die Signifikanzmatrix folgendermaßen initialisiert (5.39):

$$\mathbf{S}(0) = [1/L, \dots, 1/L] \quad (5.39)$$

Die Berechnung und Prädiktion von $\mathbf{S}(k_E)$ setzt sich aus einem Korrekturschritt, der mit der Frequenz f_C zum Zeitpunkt k_C ausgeführt wird und einem Systemdynamik-Update-Schritt zusammen, welcher mit der Frequenz f_E zu jedem neu eintreffenden Satz von EMG-Messwerten ausgeführt wird.

Im Korrekturschritt wird der synthetische Eingangswert \mathbf{u} berechnet (5.40):

$$\mathbf{u}(k_C) = \frac{[C_1(k_C), \dots, C_L(k_C)] - \mathbf{S}(k_E - 1)}{M} \quad (5.40)$$

Der Systemdynamik-Update-Schritt setzt sich danach aus (5.41) und (5.42) zusammen, wobei $\mathbf{z}(k_E)$ hier den Ausgang des Zustandsschätzers von $\mathbf{S}(k_E)$ beschreibt.

$$\mathbf{S}(k_E + 1) = \mathbf{S}(k_E) + \mathbf{u}(k_C) \quad (5.41)$$

Der Ausgang $\mathbf{z}(k_E + 1) = [z_1(k_E + 1), \dots, z_L(k_E + 1)]$ berechnet sich danach gemäß (5.42), wobei $\bar{\mathbf{S}}(k_E)$ den Mittelwert der Signifikanzmatrix beschreibt.

$$z_i(k_E + 1) = \begin{cases} z_i(k_E) + 0,05 \cdot (s_i(k_E) - z_i(k_E)) & \text{wenn } s_i(k_E) > \bar{\mathbf{S}}(k_E) \\ 0,95 \cdot z_i(k_E) & \text{sonst} \end{cases}, \quad i \in \{1, \dots, L\} \quad (5.42)$$

Mit diesem Ansatz für die Systemdynamik werden zwei Ziele erreicht: Als relevant erkannte EMG-Kanäle werden verstärkt für die Bildung des vEMG herangezogen, da die Signifikanz des Einzelkanals über der mittleren Signifikanz liegen muss. Zum anderen wird einem Verharren von großen Signifikanzwerten entgegengewirkt, da sich die Kanäle ohne neuen, relevanten Eingang einander angleichen bzw. sich große Signifikanzwerte exponentiell reduzieren, sobald der jeweilige EMG-Kanal keine Signifikanz gemäß dem Vergleichsindex $C_i(k_C)$ aufweist. Die Parameter 0,05 und 0,95 in (5.42) wurden über eine experimentelle Betrachtung der angesetzten Systemdynamik gewonnen.

Kombination zum vEMG Das skalare vEMG-Signal $\hat{x}(k_E)$ mit der Frequenz f_E wird schließlich über das in (5.43) gezeigte Skalarprodukt aus dem Ausgang $\mathbf{z}(k_E)$ der Schätzung und dem ursprünglichen EMG-Signal $\mathbf{x}(k_E) = [x_1(k_E), \dots, x_L(k_E)]^T$ berechnet.

$$\hat{x}(k_E) = \langle \mathbf{z}(k_E), \mathbf{x}(k_E) \rangle \quad (5.43)$$

5.3 Vergleich EMG und vEMG

Als Zwischenergebnis und Visualisierung der in den vorigen Abschnitten beschriebenen Methode zur Gewinnung des virtuellen EMG-Signals ist in der Abbildung 5.7 ein Vergleich der einzelnen EMG-Kanäle $\{1, \dots, L = 8\}$ des Arrays sowie des virtuellen EMG-Signals dargestellt. Im unteren Bereich der Abbildung sind die Gewichtungskoeffizienten des Ausgangs \mathbf{z} der Signifikanzmatrix-Schätzung dargestellt, welche dort als „CI“ bezeichnet sind.

Bei der gezeigten Sequenz handelt es sich um eine Messung aus der Messreihe 2 „Sitzen und Aufstehen“, bei der der Proband bis zum Zeitpunkt $t = 12 \text{ s}$ saß und dann bis zum Zeitpunkt $t = 15 \text{ s}$ durch Aufstehen in den Zustand *Stehen* überging. Während des *Sitzens* ($t < 12 \text{ s}$) und während des *Stehens* ($t > 15 \text{ s}$) gab der Proband jeweils zwei Mal ein Willkürsignal, das durch den sich in Ruhe befindenden Muskel bereits optisch im Diagramm erkennbar ist. Während des Aufstehens im Intervall $t \in [12 \text{ s}, \dots, 15 \text{ s}]$ treten auf den einzelnen EMG-Kanälen Störungen auf, die mehrere Ursachen haben: So ist der gemessene Muskel während des Aufstehens etwas in den Aufstehprozess involviert, jedoch wirken sich Störungen durch mechanische Belastungen auf das EMG-Array und

5.3 Vergleich EMG und vEMG

die Verschiebung des Arrays wesentlich stärker im Signal der einzelnen EMG-Kanäle aus, was durch Spikes auf einzelnen Kanälen bestätigt werden kann.

In dem berechneten virtuellen EMG-Signal treten diese Störungen nicht mehr auf, und es wird die natürliche und erwartete Muskelaktivität angezeigt. Ferner ist zu erkennen, dass dem EMG-Kanal 6 und 7 während der ganzen Messung eine Signifikanz zwischen 75% - 100% mit Mittelwert 89,5% für Kanal 6 und 90,1% für Kanal 7 zugewiesen wird, was dem erwarteten Verhalten, dass benachbarte Kanäle ein ähnliches Signal liefern sollen, entspricht. Andererseits wurde der Kanal 1 für die Berechnung des vEMG gar nicht verwendet.

Die Tabelle 5.1 fasst die Ergebnisse der Signifikanzwerte zusammen, wobei die Mittelwerte je Kanal über die betrachtete Messung angegeben sind. Das Zentrum der unteren




Abbildung 5.7: Vergleich der EMG-Einzelkanäle mit dem generierten „virtuellen EMG“-Signal (Der Systemausgang z_i aus (5.42) ist in dem unteren Diagramm als „CI i“ angegeben).

Tabelle 5.1: Mittelwerte der Signifikanzwerte „CI i“ aus der Abbildung 5.7

EMG-Kanal	1	2	3	4	5	6	7	8
gemittelte Signifikanz [%]	0,0	1,4	14,8	23,4	48,8	89,5	90,1	61,4

Reihe des EMG-Arrays aus der Abbildung 3.2 auf Seite 29 liefert somit das relevante EMG-Signal.

5.4 Beeinflussung der Merkmale für Mustererkennung durch virtuelles EMG

Das vEMG-Signal berechnet sich gemäß (5.43) als Linearkombination der einzelnen EMG-Kanäle. Im Folgenden soll untersucht werden, wie sich diese Linearkombination auf die in Abschnitt 5.1 beschriebenen Merkmale auswirkt. Insbesondere muss vermieden werden, dass durch die Kombination informationsgebende Merkmale im vEMG-Signal zerstört werden, die der nachfolgende Klassifikator für eine hohe Erkennungsrate benötigt.

Die Methoden, die die einzelnen EMG-Signale vor Berechnung des vEMG vergleichen, wurden darauf hin ausgewählt, dass sie die Phasengleichheit der Signale bewerten und wahren. So stellt die Korrelation in Kombination mit dem GAUSS-Fenster (5.32) sicher, dass die Phasenlage zwischen den Einzelsignalen erhalten bleibt und nur phasengleiche Kanäle kombiniert werden, wodurch die Frequenzmerkmale erhalten bleiben. Andernfalls würde eine Beeinträchtigung des Signals induziert, die sich als Verzerrung beschreiben lässt (Drews, 1999). Für die Energy of Difference dokumentiert Lee (2008), dass die Amplitude der Wellenform und die Dauer des Aktionspotentials eine Auswirkung auf die Energy of Difference haben.

Eine Prüfung der Merkmale des EMG-Signals auf Superposition ist in der Tabelle 5.2 zusammengefasst, wobei für die Superposition gelten muss (5.44):

$$f(ax + by) = af(\mathbf{x}) + bf(\mathbf{y}), \quad a, b \in \mathbb{R}, \quad \mathbf{x}, \mathbf{y} \in \mathbb{R}^n \quad (5.44)$$

Die überwiegende Mehrheit der Merkmale stellt folglich lineare Systeme dar, die die Merkmale im Signal nicht zerstören. Für Zero Crossings und Slope Sign Changes gilt

Tabelle 5.2: Untersuchung der Merkmale auf Superposition

Merkmal	Superposition
Mean Absolute Value	ja
Root Mean Square	nein
Zero Crossings	bedingt
Slope Sign Changes	bedingt
Waveform Length	ja
Autoregressives Modell	ja
Short Time Fourier Transformation	ja
Wavelet Transformation	ja

das Superpositionsprinzip, wenn die Signale ausreichend groß sind und ausreichend steile Flanken aufweisen. Durch den in Abschnitt 5.3 demonstrierten Wirkmechanismus, dass das vEMG primär einzelne und relevante Kanäle aussucht, die ein sehr ähnliches Signal aufweisen, wird die Superposition nur relevant, wenn kein eindeutiger EMG-Kanal bestimmt werden kann, und wenn sich das Array-Signal nach einer Bewegung durch Verschiebung oder geänderten Anpressdruck verändert.

6 Mustererkennung und Klassifizierung des EMG

Das im vorangehenden Kapitel generierte virtuelle EMG-Signal, aus dem die Merkmale extrahiert werden, soll klassifiziert werden, wobei die Merkmale bzw. Merkmalskombinationen den gewünschten Ausgangsgrößen *kein Willkürsignal* und *Willkürsignal erkannt* (WKS) zugeordnet werden sollen. Somit kann die Menge \mathcal{V} der Klassen V_i , die v unterschiedliche Klassen enthält, nach (6.1) definiert werden.

$$\mathcal{V} = \{V_1, \dots, V_v\} = \{\overline{WKS}, WKS\} = \{0, WKS\} \quad (6.1)$$

Während die Merkmalsextraktion sehr stark signalgetrieben ist und die ausgewählten und verwendeten Merkmale eng mit der Natur des EMG-Signals zusammenhängen, besteht bei der Auswahl des Klassifikators eine größere Freiheit. Von verschiedenen Autoren wurden bereits eine Vielzahl an Klassifikationsverfahren für EMG-Systeme theoretisch betrachtet und in realen Versuchen angewendet und untersucht.

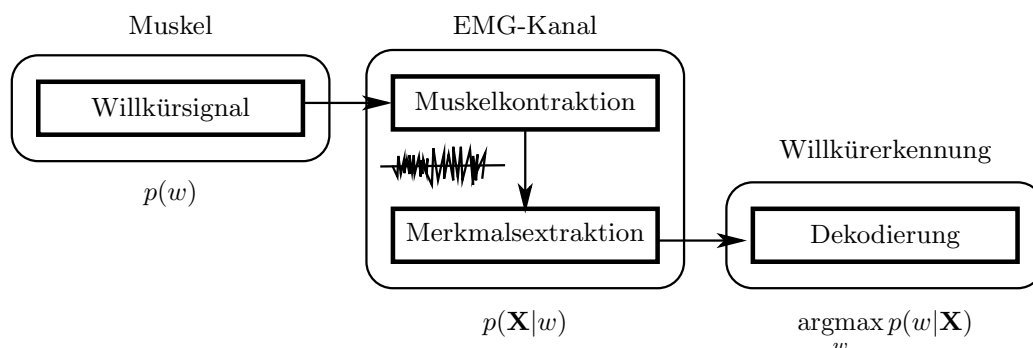


Abbildung 6.1: Informationstheoretisches Kanalmodell von Willkürerzeugung und Erkennung

Das der Klassifikation zugrunde liegende Problem kann nach Fink (2003) als Kanalmodell formuliert werden, welches in der Abbildung 6.1 dargestellt ist: Der Muskel erzeugt mit der Wahrscheinlichkeit $p(w)$ das vom Prothesenträger initiierte Willkürsignal w . In den Merkmalen \mathbf{X} , die durch die gemessene Muskelkontraktion erfasst und generiert werden, ist mit der Wahrscheinlichkeit $p(\mathbf{X}|w)$ das Willkürsignal enthalten. Für das zu identifizierende Willkürsignal \hat{w} kann demnach (6.2) aufgestellt werden.

$$\hat{w} = \operatorname{argmax}_w p(w|\mathbf{X}) = \operatorname{argmax}_w \frac{p(w)p(\mathbf{X}|w)}{p(\mathbf{X})} \quad (6.2)$$

Hierbei stellt $p(\mathbf{X})$ bezüglich der Maximierung eine Konstante dar, weshalb (6.2) zu (6.3) vereinfacht werden kann.

$$\hat{w} = \operatorname{argmax}_w p(w|\mathbf{X}) = \operatorname{argmax}_w p(w)p(\mathbf{X}|w) \quad (6.3)$$

Die Lösung von (6.3), und damit die Maximierung der Erkennungswahrscheinlichkeit \hat{w} bei vorliegendem Willkürsignal w und Zuordnung von \hat{w} zu $V = \{WKS|0\}$, stellt somit die Aufgabe des Klassifikators und des mit ihm verbundenen Parametrisierungs- und Lernprozesses dar.

6.1 Merkmalsextraktion

In einem Mustererkennungssystem folgt der Merkmalsextraktion, die bereits in Abschnitt 5.1 für das EMG beschrieben wurde, die Merkmalsauswahl und -aggregation, wobei zwischen der räumlichen und zeitlichen Auswahl und Aggregation unterschieden werden muss:

Räumlich Die räumliche Auswahl bestimmt, in wie weit der Merkmalsraum für die Klassifikation verwendet wird. Zur Reduktion des Merkmalsraumes bieten sich die Methoden der Dimensionsreduktion aus dem Abschnitt 6.2 an.

Zeitlich Die zeitliche Aggregation beschreibt das Zusammenfassen von mehreren, zeitlich aufeinander folgenden Merkmalen zu einer Einheit, auf die der Klassifikator angewendet wird. Dies wird von Saponas u. a. (2009) umgesetzt, die die EMG-Messwerte

in ihrem Echtzeitsystem in 32 Segmente je Sekunde unterteilen, was zu einer Sequenzlänge von 31,25 *ms* führt.

Im vorliegenden Fall wurden in Abschnitt 5.1 bereits Merkmale generiert, die eine Sequenz von Messwerten umfassen, weswegen dem im Folgenden untersuchten Klassifikator jeweils ein Satz Merkmale zu einem Abtastzeitpunkt zugeführt wird.

6.2 Dimensionsreduktion

Insbesondere während eines Lernvorgangs und der Parametrisierung kann $p(\mathbf{X}|w)$ nicht optimal bezüglich seiner Kompaktheit sein, was sich in einer großen Anzahl an Merkmalen und damit einer großen Dimension des Merkmalsvektors \mathbf{m} ausdrückt.

Durch die große Anzahl an Merkmalen ist das Training eines Klassifikators aufwendiger, da dieser Prozess in der Regel auf einem Optimierungsproblem aufbaut, welches ein globales Extremum iterativ ermittelt. Merkmale, die keinen Informationsgehalt bezüglich der Willkürerkennung beinhalten, sollen identifiziert und entfernt werden, so dass das Signalverarbeitungssystem im mobilen Echtzeiteinsatz an der Prothese möglichst schlank und effizient ist.

Die Dimensionsreduktion stellt somit eine Merkmalsprojektion dar, die den hochdimensionalen Merkmalsraum mit Dimension n in einen niedrig dimensionalen Unterraum mit Dimension χ ($\chi < n$) abbildet, so dass ein Gütekriterium optimiert wird. Dieses Gütekriterium stellt dabei die zu maximierende Separation der zu klassifizierenden Klassen dar, wodurch der Klassenabstand wächst.

6.2.1 Hauptkomponentenanalyse (PCA)

Die Hauptkomponentenanalyse (Principle Component Analysis, PCA) ist ein Verfahren aus der multivariaten Statistik, das über einem Satz \mathcal{M} von Merkmalen m_i Korrelationen identifizieren kann, wobei neue und dekorrelierte Merkmale q_i gebildet werden, die die Menge \mathcal{Q} definieren.

Hierbei wird angenommen, dass die Varianz der Merkmale ein Maß für deren Informationsgehalt darstellt. Die Abbildung 6.2 veranschaulicht das Vorgehen: In den Schwerpunkt der Punktwolke \blacklozenge , welche aus den ursprünglichen Merkmalen $\mathbf{m} = (m_1, m_2)$ gebildet wird, wird ein neues kartesisches Koordinatensystem eingepasst, so dass die




Abbildung 6.2: Beispiel für PCA: in den Merkmalsraum (m_1, m_2) mit der Probe \blacklozenge wird der Merkmalsraum (q_1, q_2) gelegt, so dass die Merkmale q_i in Richtung der größten Varianzen zeigen.

Hauptrichtung q_1 entlang der größten Varianz zeigt. Orthogonal zur Hauptrichtung werden entlang der weiteren Varianz-Maxima schließlich zusätzliche Achsen q_i , $i \in \{2, \dots, \chi\}$ gelegt, bis die gewünschte Dimension χ des Unterraums erreicht ist.

Mathematisch kann die Transformationsvorschrift des Koordinatensystems des Merkmalsraums mit Hilfe der Eigenwerte λ_i und Eigenvektoren γ_i der Kovarianzmatrix der r Merkmalsvektoren berechnet werden. Die Merkmalsvektoren werden in einer $n \times r$ Matrix $\mathbf{M} = (\mathbf{m}_1, \dots, \mathbf{m}_r)$ zusammengefasst. Dann werden die Mittelwerte in Richtung der einzelnen Dimensionen gemäß (6.4) berechnet und in einem Mittelwertsvektor $\bar{\mathbf{m}}$ gesammelt.

$$\bar{\mathbf{m}} = \frac{1}{r} \sum_{i=1}^r \mathbf{M}(n, r) \quad (6.4)$$

Dieser Mittelwertsvektor wird in (6.5) genutzt, um eine mittelwertfreie Merkmalsmatrix \mathbf{B} zu erzeugen, wobei der Operator \otimes das dyadische Produkt zwischen $\bar{\mathbf{m}}$ und $\mathbf{h} = [1, \dots, 1]$ angibt. Die Mittelwertfreiheit sorgt dafür, dass der Ursprung des neuen Koordinatensystems in den Schwerpunkt der Punktwolke gelegt wird.

$$\mathbf{B} = \mathbf{M} - (\bar{\mathbf{m}} \otimes \mathbf{h}) \quad (6.5)$$

Nach der Translation folgt die Rotation des Koordinatensystems. Dies geschieht durch die Bestimmung der Eigenwerte λ_i und den zugehörigen Eigenvektoren γ_i der Kovarianzmatrix \mathbf{Cov} . Diese wird mit Hilfe der neuen Merkmalsmatrix \mathbf{B} nach (6.6) berechnet.

$$\mathbf{Cov} = \begin{pmatrix} \text{Var}(\mathbf{B}_1) & \text{Cov}(\mathbf{B}_1, \mathbf{B}_2) & \cdots & \text{Cov}(\mathbf{B}_1, \mathbf{B}_n) \\ \text{Cov}(\mathbf{B}_2, \mathbf{B}_1) & \text{Var}(\mathbf{B}_2) & \cdots & \text{Cov}(\mathbf{B}_2, \mathbf{B}_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(\mathbf{B}_n, \mathbf{B}_1) & \text{Cov}(\mathbf{B}_n, \mathbf{B}_2) & \cdots & \text{Var}(\mathbf{B}_n) \end{pmatrix} \quad (6.6)$$

Hierbei bezeichnet \mathbf{B}_i die i -te Zeile der Merkmalsmatrix \mathbf{B} . $\text{Var}(\mathbf{B}_i)$ ist die Varianz in Richtung der i -ten Koordinate und wird mit Hilfe des Mittelwerts $\mu_{\mathbf{B}_i}$ gemäß (6.7) berechnet. Die Kovarianz ist ein Maß für die Abhängigkeit von zwei Koordinaten i, j und ist in (6.8) aufgeführt.

$$\text{Var}(\mathbf{B}_i) = E[\mathbf{B}_i^2] - (E[\mathbf{B}_i])^2 = \frac{1}{r-1} \sum_{k=1}^r (\mathbf{B}_i(k) - \mu_{\mathbf{B}_i})^2 \quad (6.7)$$

$$\text{Cov}(\mathbf{B}_i, \mathbf{B}_j) = \frac{1}{r} \sum_{k=1}^r (\mathbf{B}_i(k) - \mu_{\mathbf{B}_i}) \cdot (\mathbf{B}_j(k) - \mu_{\mathbf{B}_j}) \quad (6.8)$$

Die Kovarianzmatrix ist eine quadratische und symmetrische Matrix, die zur Diagonalmatrix Λ transformiert werden kann, die auf ihrer Diagonalen die Eigenwerte der Kovarianzmatrix beinhaltet. Mit der orthogonalen Matrix Γ , deren Spalten den Eigenvektoren der Kovarianzmatrix entsprechen, gilt die Ähnlichkeitsbedingung (6.9).

$$\Lambda = \Gamma^T \cdot \mathbf{Cov} \cdot \Gamma \quad (6.9)$$

Durch Lösen dieses Eigenwertproblems werden die Eigenvektoren berechnet. Aus den sortierten Eigenwerten $\lambda_1 > \lambda_2 > \cdots > \lambda_n$, wobei λ_1 mit γ_1 die erste Hauptkomponente bildet, wird die gewünschte Ziel-Anzahl χ von Eigenwerten ausgewählt, deren zugehörige Eigenvektoren $\gamma_1, \dots, \gamma_\chi$ die Transformationsmatrix Γ_χ^T bilden. Die ursprünglichen Merkmalsvektoren \mathbf{m} werden schließlich durch die in (6.10) gezeigte Transformation in den χ -dimensionalen Unterraum zum Merkmalsvektor \mathbf{q} transformiert.

$$\mathbf{q} = \Gamma_\chi^T \cdot \mathbf{m} \quad (6.10)$$

6.2.2 Weitere Dimensionsreduktionsverfahren

Bei diskreten Merkmalen bietet sich eine Clusterung von mehreren Merkmalen zu einer Einheit an, welche ein neues Merkmal formt. So können bei der FFT mehrere Spektralbereiche einem Merkmal zugeordnet werden. Die Methode der diskreten Wavelet-Transformation in Abschnitt 5.1.2 zeigt jedoch, dass dieses Vorhaben bereits auf der Merkmalsextraktionsebene selbst berücksichtigt werden können.

Die Lineare Diskriminanten-Analyse (LDA), welche in Unterabschnitt 6.3.3 näher beschrieben wird, stellt eine Kombination aus Dimensionsreduktion und Klassifikator dar, welche jedoch nur bei linear trennbaren Klassen angewendet werden kann. Sie ist weniger flexibel in der Anpassung als eine Kombination aus PCA und nachgeschaltetem Klassifikator, da bei der LDA bereits bei der Merkmalsreduktion die Klassenzugehörigkeit der Merkmale einfließt.

Chu u. a. (2006) verwenden eine *Self-Organizing Feature Map* (SOFM). Sie ist eine Abwandlung eines künstlichen Neuronales Netzes, das einen hochdimensionalen Merkmalsraum in eine zweidimensionale Ebene, die *Feature Map*, transformiert. Wie die LDA beinhaltet die SOFM bereits Elemente eines Klassifikators, weswegen im folgenden Abschnitt das künstliche Neuronale Netz als Klassifikator betrachtet werden soll.

Nachteilig erweist sich bei der SOFM, dass sie einen wesentlich höheren Rechenbedarf als die PCA und LDA aufweist (Chu u. a., 2006), weswegen sie hinsichtlich der spezifizierten Echtzeitanforderungen auf einem Embedded-System nicht vorteilhaft ist und nicht weiter verfolgt wurde.

6.3 Klassifikatoren

Im Folgenden werden die Klassifikatoren dargestellt, die im Rahmen der vorliegenden Arbeit betrachtet und in der Literatur zu EMG-Systemen bisher erfolgreich angewendet wurden. Es zeigt sich, dass sich je nach Aufgabenstellung, Messumgebung und Zielsetzung ein uneinheitliches Bild bezüglich der Aussagekraft „bester Klassifikator“ ergibt, weswegen aus dem Stand der Technik zu den EMG-Klassifikatoren nur Anhaltspunkte und Tendenzen abgeleitet werden können, die für den konkreten Fall jeweils diskutiert werden müssen.

6.3.1 Künstliche Neuronale Netze

Bereits in frühen Arbeiten wurden Künstliche Neuronale Netze (KNN) für die Klassifizierung des EMG-Signals verwendet. Hudgins u. a. (1993) dokumentieren die Erkennung der initialen Phase der Muskelkontraktion am Arm, welcher aus einer Ruhephase heraus bewegt wird. Diese Ergebnisse können auf den hier behandelten Fall der Beinprothese mit der Bewegungsform *Gehen* nicht übertragen werden.

Das KNN ist dabei direkt von der Biologie inspiriert, indem es künstliche Neuronen modelliert, die ein Netz ausbilden. An einer Seite des Netzes gibt es eine Eingabeschicht, an die die *äußeren Reize* (hier Signal-Merkmale) angelegt werden, und an der anderen Seite eine Ausgabeschicht, an der das Ergebnis vorliegt. Die zwischen der Eingabe- und Ausgabeschicht liegenden künstlichen Neuronen bilden eine Übertragungsfunktion ab, welche durch Gewichte, die auf die Verbindungskanten des Netzes gelegt werden, beeinflussbar sind. Durch Lernverfahren werden diese Gewichte bestimmt, so dass bei angelegtem Muster an der Eingabeschicht die gewünschte Ausgabe erzielt wird.

Ein derartiges überwachtes Lernverfahren wird von Chu u. a. (2006) beschrieben, die ein Multilayer-Perceptron (MLP) verwenden, was einem vereinfachten KNN entspricht: Die Merkmale, die nach der Dimensionsreduktion mittels LDA gebildet werden, bilden die Eingangsschicht eines neuronalen Netzes, welches aus zwei versteckten Schichten besteht. Die Ausgabeschicht entspricht nun direkt den zu klassifizierenden Mustern.

Das Einlernen eines KNN ist ein aufwendiger Schritt, da der Gradient des Lernerfolgs von der Qualität der Eingangsdatensätze abhängt. Au u. a. (2005) schlagen deshalb ein KNN vor, das vom Prothesenträger selbst über ein visuelles Feedbacksystem mittels Back-Propagation eingelernt wird, wodurch eine breitere Datenbasis erzielt wird.

Matsumura u. a. (2002) verwenden ein KNN, an dessen Eingang diskrete Spektren aus der FFT-Transformation angelegt werden, welche das KNN einlernt und somit klassifizieren kann. Auch Oyama u. a. (2006) verwenden die FFT als Merkmalsextraktion, wobei mittels PCA und LDA zuerst eine Dimensionsreduktion der Spektren durchgeführt wird, damit die Anzahl der Neuronen in der Eingabeschicht minimiert wird. Einen anderen Weg zur Reduktion der Merkmale aus der FFT-Transformation schlagen Reaz u. a. (2006b) vor, indem sie die Merkmale mit der Methode *Fuzzy C-Means* in Cluster unterteilen, die dem KNN präsentiert werden.

Englehart u. a. (1999) setzen ebenfalls ein MLP ein und erzielen ein vergleichbares, wenn nicht besseres, Ergebnis bei der Klassifikation als bei Verwendung der LDA. Sie führen

dies darauf zurück, dass das KNN einen höherdimensionalen Eingangsmerkmalsvektor verarbeiten und nichtlineare Klassenseparationsgrenzen bilden kann. Diesen Vorteilen stehen jedoch auch Nachteile gegenüber: Das MLP muss eingelernt und trainiert werden, wobei das Einlernen nur empirisch gesteuert werden kann, damit keine Überanpassung oder Unteranpassung eintritt. Weiterhin ist die innere Struktur in Gestalt der Anzahl der versteckten Ebenen nicht festgelegt, was die praktische Anwendung und Anpassung an ein konkretes Problem erschwert.

6.3.2 Fuzzy-Systeme

Die Fuzzy-Systeme stellen einen Ansatz dar, mit dem Systeme modelliert werden können, die Unsicherheiten und Unschärfen beinhalten, die sich durch fließende Übergänge zwischen Beschreibungs- und Zuordnungs-Klassen oder durch eine verbale Merkmalsdefinition ergeben. Das Problem wird dabei über eine Reihe von linguistischen Bedingungen formuliert, welche exemplarisch lauten:

*WENN(Merkmal A **groß**) UND (ein **bisschen** Merkmal B) DANN (C ist **klein**)*

Die *Wenn-Dann-Bedingungen* werden einer anschließenden Inferenzschicht zugeführt, in der die Schlussfolgerung ermittelt wird, was einem detektierten Willkürsignal entsprechen kann.

Chan u. a. (2000) kommen zu dem Schluss, dass das Training und das Klassifikationsergebnis des Fuzzy-Systems dem KNN überlegen ist. Weiterhin könne beim Fuzzy-System kein *Over-Training* vorkommen, bei dem das KNN die Trainingsdaten schlicht „auswendig lernt“, und das Fuzzy-System kann durch seine auf linguistischen Ausdrücken basierende Funktionsweise leichter als ein KNN auf spezifische Klassifikationsprobleme angepasst oder erweitert werden.

6.3.3 Lineare Diskriminanten-Analyse

Die lineare Diskriminanten-Analyse (Linear Discriminant Analysis, LDA) ist ebenfalls ein Verfahren der multivariaten Statistik. Bei Chu u. a. (2006) liefert sie die beste Erkennungsrate bei gleichzeitig geringstem Rechenbedarf. Auch von Huang u. a. (2008) und Hargrove u. a. (2009) wird die LDA als Klassifikator, dem die Merkmale MAV, ZC, WL und SSC aus dem Zeitbereich zugeführt werden, eingesetzt.




Abbildung 6.3: Visualisierung der maximierten Inter- und minimierten Intra-Varianz

Der wesentliche Unterschied zwischen der LDA und PCA ist die Einbeziehung der Klassenzugehörigkeit V_i der einzelnen Merkmalsvektoren $\mathbf{m}(k)$ bei der LDA. Die LDA bestimmt eine Transformation des Merkmalsraums, so dass die Mittelwerte der Merkmalsvektoren der jeweiligen Klassen die größtmögliche Distanz zueinander besitzen. Gleichzeitig minimiert die Transformation die Abstände der Merkmalsvektoren innerhalb einer Klasse, wodurch die Klassenseparabilität erhöht und somit die Fehlerrate bei der anschließenden Klassifikation minimiert wird.

Das zu maximierende Kriterium der LDA stellt die Klassenseparabilität dar, für deren Beschreibung die Intravarianz-Matrix¹ \mathbf{S}_w , welche in (6.11) die Abweichung der Merkmalsvektoren \mathbf{m}_i von dem jeweiligen Klassenmittelwert μ_c beschreibt, und die Intervarianz-Matrix² \mathbf{S}_b , welche die Abweichung der jeweiligen Klassenmittelwerte μ_c vom globalen Mittelwert $\bar{\mathbf{m}}$ in (6.12) beschreibt, eingeführt werden. Die Intra- und Intervarianz sind in Abbildung 6.3 exemplarisch gezeigt.

$$\mathbf{S}_w = \sum_c \sum_{i \in c} (\mathbf{m}_i - \mu_c)(\mathbf{m}_i - \mu_c)^T \quad (6.11)$$

$$\mathbf{S}_b = \sum_c (\mu_c - \bar{\mathbf{m}})(\mu_c - \bar{\mathbf{m}})^T \quad (6.12)$$

Die Klassenseparabilität kann maximiert werden, indem entlang der Projektionsrichtung \mathbf{w} des Merkmalsraums die Intravarianz minimiert und die Intervarianz maximiert wird, was als FISHER'sches-Kriterium in (6.13) formuliert ist, wobei $|\cdot|$ die Bildung der Determinante bezeichnet (Fisher, 1936).

¹Within-Class Scatter Matrix

²Between-Class Scatter Matrix

$$J(w) = \frac{|\mathbf{w}^T \mathbf{S}_b \mathbf{w}|}{|\mathbf{w}^T \mathbf{S}_w \mathbf{w}|} \quad (6.13)$$

Dieses Maximierungsproblem kann mit Hilfe des generalisierten Eigenwertproblems in (6.14) gelöst werden. Der Rang der Intervarianz-Matrix \mathbf{S}_b kann maximal mit der Anzahl an Klassen v übereinstimmen, weswegen es maximal $v - 1$ von Null verschiedene Eigenwerte λ_i und deren korrespondierende Vektoren \mathbf{w}_i gibt. Somit kann der n -dimensionale Merkmalsraum maximal auf einen $v - 1$ -dimensionalen Unterraum mittels (6.15) transformiert werden.

$$\mathbf{S}_b \mathbf{w}_i = \lambda_i \mathbf{S}_w \mathbf{w}_i \quad (6.14)$$

$$\mathbf{q} = \mathbf{w}^T \mathbf{m} \quad (6.15)$$

Da im vorliegenden Fall nur zwei Klassen $\{0, WKS\}$ definiert wurden, existiert nur ein Eigenwert λ mit zugehörigem Vektor \mathbf{w} , und der Merkmalsvektor \mathbf{q} bildet einen eindimensionalen Unterraum.

6.3.4 Hidden Markov Modell

Ein *Hidden Markov Modell* (HMM) ist ein stochastisches Modell, bei dem auf Basis einer Folge von äußeren Beobachtungen auf einen inneren, unzugänglichen (hidden) Zustand geschlossen werden soll. Der innere Zustand entspricht dabei der detektierten Klasse $V = \{0|WKS\}$, und die Beobachtungen werden durch die Merkmale m_i definiert.

HMMs werden in der Spracherkennung und Bioinformatik eingesetzt und sind ein wahrscheinlichkeitsbasiertes Verfahren. Dabei stellen Chan u. Englehart (2005) bei der Anwendung des HMM auf ein EMG-Problem fest, dass sich das HMM wegen seiner geringen Berechnungs-Komplexität gut für Echtzeitsysteme eignet.

Lee u. Choi (2003) verwenden ein HMM zur Klassifizierung, wobei sie ein HMM als Zwischenschicht zwischen der PCA-Dimensionsreduktion und einem nachgeschalteten Zusatz-Klassifikator in Form einer Support Vector Machine (SVM) schalten.




Abbildung 6.4: Trennung der Bereiche \circ und \star durch mehrere mögliche Hyperebenen H , wobei H_3 eine optimale Separation mit größtmöglichem Abstand erzielt.

6.3.5 Support Vector Machines

Das Multilayer-Perceptron (MLP) in Unterabschnitt 6.3.1 führte bereits den Vorteil der nichtlinearen Trennebenen zwischen den Klassen ein. Die SVM ermöglicht ebenso nichtlineare Trennebenen und vermeidet das iterative Einlernen des MLP.

Das Training der SVM gestaltet sich dabei sehr effizient, was die Versuche von Saponas u. a. (2009) ergeben: Für eine EMG-Klassifizierung mittels SVM genügen bereits Messdatensätze von 70 Sekunden zur Erzielung von eindeutigen Ergebnissen. Die SVM erzielt darüber hinaus bei Boschmann u. a. (2009) im Anwendungsfall der Armprothesen eine hohe Erkennungsrate und kann bei gegebener diskreter und räumlicher EMG-Elektrodenkonfiguration verschiedene Eingabebefehle unterscheiden.

Die von Vapnik u. Chervonenkis (1974) eingeführte SVM stellt ein lineares Klassifikationsverfahren dar, bei der eine Zuordnungsfunktion $f(\mathbf{q}_i)$ die Merkmalsvektoren \mathbf{q}_i einer Klasse V_i zuweist. Der Klasse „Willküraktivität“ wird hier der Wert $+1$ zugeordnet, der Klasse „keine Willküraktivität“ der Wert -1 . Die Zuordnung erfolgt durch die Bestimmung einer Hyperebene H , die die Klassen mit einem größtmöglichen Abstand separiert, wie es in der Abbildung 6.4 exemplarisch für H_3 gezeigt ist. Merkmalsräume, in denen die Merkmalsvektoren so verteilt sind, dass keine lineare Trennung möglich ist, können von der SVM in einen Raum höherer Dimension transformiert werden, in dem dann wiederum eine lineare Trennung durch eine Hyperebene realisierbar ist und somit die Merkmalsvektoren klassifiziert werden. Die Hyperebene kann durch den Normalenvektor \mathbf{n} und den Abstand vom Ursprung b gemäß (6.16) aufgestellt werden.




Abbildung 6.5: Darstellung der optimalen Hyperebene mit den Stützvektoren \bullet und \star und dem Margin-Bereich.

$$\langle \mathbf{n}, \mathbf{q}_i \rangle - b = 0 \quad (6.16)$$

Merkmalsvektoren, die auf derjenigen Seite der Hyperebene liegen, in die der Normalenvektor zeigt, besitzen ein positives Vorzeichen, Merkmalsvektoren auf der anderen Seite entsprechend ein negatives Vorzeichen. Somit kann die Beschreibung der Hyperebene direkt für die Klassifikation verwendet werden. Dadurch kann die Klassifikationsregel durch die Zuordnung $f(\mathbf{q})$ mit Hilfe der Vorzeichenfunktion $sgn()$ wie in (6.17) beschrieben werden, wobei \mathbf{n}_0 den Normalenvektor und b_0 den Abstand der optimalen Hyperebene bezeichnen.

$$f(\mathbf{q}) = sgn(\langle \mathbf{n}_0, \mathbf{q}_i \rangle - b_0) \quad (6.17)$$

Die Hyperebene wird so in den Raum gelegt, dass der minimale Abstand der Merkmalsvektoren zur Hyperebene, der sogenannte Margin, maximiert wird. Hierfür reicht es aus, nur diejenigen Vektoren zu betrachten, die den geringsten Abstand zur Hyperebene besitzen. Diese werden als Stützvektoren (Support Vectors) bezeichnet und sind in der Abbildung 6.5 exemplarisch markiert.

Die Ebenen, auf denen sich die Stützvektoren befinden, können damit gemäß (6.18)

aufgestellt werden.

$$\begin{aligned}\langle \mathbf{n}, \mathbf{q}_i \rangle - b &= +1 \\ \langle \mathbf{n}, \mathbf{q}_i \rangle - b &= -1\end{aligned}\tag{6.18}$$

Der Abstand dieser beiden Ebenen zueinander beträgt $\frac{2}{\|\mathbf{n}\|}$. Zusätzlich muss garantiert sein, dass sich kein Merkmalsvektor zwischen diesen beiden Ebenen befindet, was durch (6.19) erzielt wird.

$$\begin{aligned}\langle \mathbf{n}, \mathbf{q}_i \rangle - b &\geq +1 \quad \text{falls } V_i = +1 \\ \langle \mathbf{n}, \mathbf{q}_i \rangle - b &\leq -1 \quad \text{falls } V_i = -1\end{aligned}\tag{6.19}$$

Die Ermittlung der optimalen Hyperebene stellt somit ein Minimierungsproblem von $\|\mathbf{n}\|$ unter der Nebenbedingung von (6.19) dar, was durch die Einführung von LAGRANGE-Multiplikatoren $\alpha_i \geq 0$ gelöst werden kann. Dadurch kann das Optimierungsproblem als LAGRANGE-Funktion $L(\mathbf{n}, b, \alpha)$ in (6.20) umformuliert werden, welche bezüglich \mathbf{n} und b minimiert wird. Dies kann durch (6.21) erreicht werden, wobei die partiellen Ableitungen zu Null gesetzt werden. Die Anzahl an Trainings-Merkmalsvektoren q_i ist durch r gekennzeichnet.

$$L(\mathbf{n}, b, \alpha) = \frac{1}{2} \|\mathbf{n}\| - \sum_{i=1}^r \alpha_i (V_i (\langle \mathbf{n}, \mathbf{q}_i \rangle + b) - 1)\tag{6.20}$$

$$\begin{aligned}\frac{\partial}{\partial \mathbf{n}} L(\mathbf{n}, b, \alpha) = 0 &\Rightarrow 0 = \sum_{i=1}^r \alpha_i V_i \\ \frac{\partial}{\partial b} L(\mathbf{n}, b, \alpha) = 0 &\Rightarrow \mathbf{n} = \sum_{i=1}^r \alpha_i V_i \mathbf{q}_i\end{aligned}\tag{6.21}$$

Unter Verwendung von (6.21) kann (6.20) zu dem dualen Optimierungsproblem $Q(\alpha)$ in (6.22) transformiert werden, das bezüglich α maximiert wird.

$$Q(\alpha) = \sum_{i=1}^r \alpha_i - \frac{1}{2} \sum_{j=1}^r \alpha_i \alpha_j V_i V_j \langle \mathbf{q}_i, \mathbf{q}_j \rangle \quad (6.22)$$

Die Erweiterung der SVM auf nicht linear separierbare Klassen wird durch die Einführung einer Kernel-Funktion κ implementiert, wobei das Skalarprodukt $\langle \mathbf{q}_i, \mathbf{q}_j \rangle$ durch eine Kernel-Funktion $\kappa(\mathbf{q}_i, \mathbf{q}_j)$ ersetzt wird (Boser u. a., 1992), welche einen höherdimensionalen Raum abbilden kann.

Es existiert eine Reihe von Kernel-Funktionen, die durch Parameter an eine Problemstellung angepasst werden können. Der Parametersatz für jede Kernel-Funktion besteht aus einem Straf-Parameter C und den Gewichten w_i des Straf-Parameters für jede Klassenzugehörigkeit V_i . Die einfachste Kernel-Funktion stellt der lineare Kernel κ_{lin} dar, der in (6.23) definiert ist und bereits in (6.22) verwendet wurde.

$$\kappa_{lin}(\mathbf{q}_i, \mathbf{q}_j) = \langle \mathbf{q}_i, \mathbf{q}_j \rangle \quad (6.23)$$

Der Radial-Basis-Funktion-Kernel (RBF) κ_{RBF} ist ein Kernel, der sich in der Literatur durch gute Ergebnisse bei unterschiedlichen Problemstellungen auszeichnet (Cherkassky u. Ma, 2002; Burges, 2004; Oskoei u. Hu, 2008a,b). Dieser besitzt neben den bisher erwähnten Parametern einen weiteren Parameter γ_{kernel} und ist in (6.24) definiert.

$$\kappa_{RBF}(\mathbf{q}_i, \mathbf{q}_j) = \exp(-\gamma_{kernel} \|\mathbf{q}_i - \mathbf{q}_j\|^2) \quad (6.24)$$

Eine weitere nichtlineare Kernel-Funktion stellt der in (6.25) gezeigte polynomielle Kernel κ_{poly} dar, der durch zwei weitere Parameter d , der den Grad des Polynoms bestimmt und η , der als additive Konstante im Polynom dient, beschrieben ist.

$$\kappa_{poly}(\mathbf{q}_i, \mathbf{q}_j) = (\gamma_{kernel} \cdot \langle \mathbf{q}_i, \mathbf{q}_j \rangle + \eta)^d \quad (6.25)$$

Schließlich kann eine sigmoidale Kernel-Funktion κ_{sig} gemäß (6.26) aufgestellt werden, die ebenfalls den Parameter η besitzt, der hier als additive Konstante verwendet wird.

$$\kappa_{sig}(\mathbf{q}_i, \mathbf{q}_j) = \tanh(\gamma_{kernel} \cdot \langle \mathbf{q}_i, \mathbf{q}_j \rangle + \eta) \quad (6.26)$$

Die oben vorgestellten Kernelfunktionen wurden in den Vorarbeiten von Dennerlein (2009) jeweils auf eine Messreihe³ eines EMG-Einzelkanals angewendet und hinsichtlich ihres Rechenbedarfs und der erzielten Klassifikations-Genauigkeit untersucht, wobei der Radial-Basis-Funktion-Kernel den besten Kompromiss zwischen Erkennungsrate und Rechenaufwand darstellte. Deshalb wird im Folgenden innerhalb der vorliegenden Arbeit bei der SVM nur noch der RBF-Kernel betrachtet.

6.3.6 Weitere Ansätze für Klassifikatoren

Glette u. a. (2008b) stellen einen Klassifikator für eine EMG-Prothesen-Steuerung vor, der auf der Idee von *Evolvable Hardware* basiert und verschiedene primitive Logikgatter verknüpft. Als Vorteil wird die hardwarenahe Auslegung gesehen, welche eine rasche Implementierung auf einem FPGA⁴ ermöglicht, wobei dieser Ansatz bei der eigentlichen Klassifikationsaufgabe nicht die Leistungsfähigkeit einer SVM erreicht.

6.4 Diskussion der Klassifikations-Verfahren

In der im Rahmen der vorliegenden Arbeit von Dennerlein (2009) durchgeführten Untersuchung zeigte sich, dass eine Kombination aus PCA und SVM bei der Mustererkennung auf dem EMG-Signal der zielführendste Ansatz ist. Die SVM wurde mit der LDA verglichen, und es zeigte sich, dass die SVM bessere Ergebnisse als die LDA liefert, weswegen in der vorliegenden Arbeit der Fokus auf der SVM liegt.

Die PCA bietet den Vorteil, dass die einzelnen Transformations-Matrizen, die aus verschiedenen Messreihen und von verschiedenen Patienten stammen können, auf Gleichheit und Ähnlichkeit numerisch überprüft werden können, was in Abschnitt 9.3 näher gezeigt werden soll.

Der Ansatz mittels KNN wurde nicht gewählt, weil ein KNN nicht genügend Einblicke in das System für eine Verallgemeinerung ermöglicht. Insbesondere die Rückschlüsse aus dem eintrainierten System auf innere Funktionsmechanismen fallen beim KNN schwer. Ein weiterer Nachteil der KNN liegt im problematischen Lern- und Trainingsverhalten,

³Messreihe bei konstantem Bewegungszustand ξ . Keine Verwendung von vEMG, sondern EMG-Kanal manuell aus EMG-Array ausgewählt.

⁴Field Programmable Gate Array: Integrierter Schaltkreis der Digitaltechnik, in den eine logische Schaltung programmiert werden kann.

welches vom Umfang der präsentierten Trainingsdaten und der Wahl der Initialisierung der Gewichte des Netzes abhängt und zum Over-Training führen kann.

Eine derartige Überanpassung und Abhängigkeit vom modellierten System tritt bei SVMs in viel geringerem Maß auf, da sie das größte Potential zur sicheren Trennung der Merkmale durch nichtlineare Hyperebenen bietet. Der Abstand der Trennebene und damit die Sicherheit und Robustheit bei der Klassifikation kann bestimmt werden, was einen nachvollziehbaren und systematischen Blick auf das Gesamtsystem ermöglicht.

Damit eröffnen die Parameter der SVM ein Vergleichspotential und können für eine Auslegung des Gesamtsystems verwendet werden, so dass eine Art „Grundtraining“ in das Willkürerkennungssystem einprogrammiert werden kann, welches auf den konkreten Prothesenträger noch abgestimmt und verfeinert wird, wohingegen bei KNN und anderen Ansätzen eine komplett neue Grund-Einlernung stattfinden muss.

Das HMM wird in dieser Arbeit ebenfalls nicht für die EMG-Mustererkennung verwendet, jedoch ergibt sich bei der Bewegungsschätzung im Folgenden Kapitel ein Potential, das in Unterabschnitt 7.4.1 untersucht wird.

7 Bewegungszustandsschätzung

In diesem Kapitel werden die Ansätze und Methoden vorgestellt, mit denen die aktuelle Bewegungssituation des Prothesenträgers ermittelt werden soll. Für jeden der Zustände wird dann ein angepasstes Mustererkennungssystem aus dem vorherigen Kapitel bereitgestellt und an die Anforderungen angepasst.

7.1 Gang und Bewegungsformen

Der physiologische Gang kann nach Perry (2003) in eine Stand- und Schwungphase für jedes Bein unterteilt werden, wobei 60 % des Gangzyklusses auf die Standphase und 40 % auf die Schwungphase entfallen. Ein Gangzyklus enthält folglich einen Doppelschritt, dessen Anfang und Ende durch das Auftreten der Ferse am rechten oder linken Bein definiert werden kann.

Neben dem Gehen treten nach Oehler u. a. (2009) noch weitere Bewegungsformen auf, welche für einen Amputierten große Relevanz aufweisen. Die Bewegungsmuster können dabei in statische und dynamische aufgeteilt werden, wobei zu den statischen das *Sitzen*, das *Stehen* und das *Liegen* zählen. In die Gruppe der dynamischen Bewegungsformen, welche ein zyklisches Muster beinhalten, gehören neben dem bereits erwähnten *Gehen* auch das *Treppensteigen* (sowohl hinauf als auch hinunter) sowie das Begehen von Rampen und unebenen Untergründen. Diese Liste muss für eine Beinprothese noch um das Überwinden eines *Hindernisses* erweitert werden. Dies stellt beim aktiven Fußgelenk einen Sonderfall des Besteigens einer Treppe dar, da die Bewegung bei der ersten Treppe mit der Hindernisüberwindungsbewegung in guter Näherung übereinstimmt.

Die statischen Bewegungsformen können weitgehend probandenunabhängig ermittelt werden, während die dynamischen stärker vom jeweiligen Bewegungsstil der Testperson abhängen. Aus diesen Bewegungszuständen, welche insbesondere für die Willkürsignalsteuerung relevant sind, wurden vier für die Untersuchung in der vorliegenden Arbeit ausgewählt: *Sitzen*, *Stehen*, *Gehen* und *Hindernis*.

Sie definieren im Folgenden den Bewegungszustand der Testperson. Weitere Zustände wie *Laufen*, *Rennen*, *Liegen*, *Fahrradfahren* oder das Bewegungsmuster *rückwärts Gehen*, welche von Hafner u. Bachmann (2008) neben den oben aufgeführten identifiziert werden, können für den Prothesengang vernachlässigt werden und sollen hier nicht untersucht werden. Darüber hinaus spielen sie bezüglich Willkürsignal nur eine untergeordnete Rolle, da das Willkürsignal primär bei langsamer Dynamik vom Prothesenträger gegeben wird. Übergänge wie das Aufstehen (Transition von *Sitzen* zu *Stehen*) werden primär hinsichtlich der korrekten EMG-Signalverarbeitung¹ während des Übergangs betrachtet, in dem typischerweise kein Willkürsignal gegeben wird.

7.2 Identifikation von Bewegungsmustern

Bei der Bewegungserkennung und insbesondere in der Gangerkennung können nach Chen u. a. (2006a) zwei grundlegende Methoden unterschieden werden: Zum einen die modellbasierte Erkennung und zum Anderen jene nach dem Erscheinungsbild. Die modellbasierte Methode versucht, den Gang zu modellieren und Wissen über die Dynamik und Form in den Erkennungsprozess einzubringen. Zu dieser Klasse kann der von Albrecht-Laatsch (2009) vorgeschlagene *Matrix-Controller* gezählt werden, der Parameter des Ganges erkennt und identifizieren kann. Die Erkennungslogik dieses Systems ist jedoch nur intervallartig aktiv, da sie ausschließlich die Standphase während eines Gangzyklusses zur Identifikation verwendet. Somit können nur Rückschlüsse nach einem erfolgten Schritt geschlossen werden, nicht jedoch bereits während des aktuellen Schritts.

Die Methoden, die das Erscheinungsbild des Ganges verwenden, sind klassische Mustererkennungsverfahren, wobei sich das Hidden-Markov-Modell (HMM) etabliert hat (Chen u. a., 2006a; Sundaresan u. a., 2003). Das HMM, das bereits in Unterabschnitt 6.3.4 bei den Klassifikatoren für das EMG eingeführt wurde, weist dabei nach Fink (2003) den Vorteil auf, dass sowohl eine Segmentierung der Eingangsdaten als auch Klassifikation in einem integrierten Formalismus möglich sind. Jedoch stellt Meyer (1997) fest, dass zum Einlernen eines HMM zur Bewegungsdetektion eine ausreichend große Datenbasis vorhanden sein muss, damit die statistischen Voraussetzungen erfüllt sind. Die Segmentierung des Gangbildes stellt dabei das Aufteilen in einzelne Gangzyklen bzw. die Unterteilung eines Gangzyklusses in seine Phasen dar. Auch das KNN wurde bereits für die Bewegungsschätzung von Lee u. Lee (2005) eingesetzt, die damit den

¹vgl. Untersuchung und Ergebnis in Abschnitt 9.1




Abbildung 7.1: Signalverläufe beim Übergang von *Stehen* zu *Gehen* (bei $t = 4\text{ s}$) mit den beiden Drücken ρ_F (Druck Ferse) und ρ_Z (Druck Zeh) sowie Nickwinkel θ (skaliert auf $1/20$) und $\dot{\theta} = \frac{d\theta}{dt}$ sowie den zu ρ_F und ρ_Z gehörenden gleitenden Standardabweichungen STD-Ferse und STD-Zeh.

Winkelverlauf an den Beingelenken schätzen, aus dem sich eine Gangphasenerkennung ergibt.

7.3 Merkmalsgenerierung aus Bewegungsdaten

Wie bereits bei den EMG-Merkmalen und der Generierung des virtuellen EMG in Kapitel 5 soll möglichst viel explizites Systemwissen extrahiert werden, das für die Problemmodellierung verwendet werden kann. Dies beinhaltet Merkmale aus Mess- und Zustandsgrößen, welche personenunabhängig und generalisierbar sind.

Solche Merkmale generieren Hafner u. Bachmann (2008) aus der Energiebetrachtung des Beschleunigungssignals eines Beschleunigungssensors und Oehler u. a. (2009) betrachten ein System aus Korrelation, Wavelets und neuronalem Netz. Aus Performancegründen wird hier eine Mustererkennung auf Basis von Parametern im Zeitbereich implementiert.

Da die Bewegungsmuster und die Transitionen zwischen den Bewegungszuständen sehr schnell erkannt werden müssen, und da neben den reinen Beschleunigungssignalen $[a_x, a_y, a_z]^T$ der Inertialsensorik auch die mittels Sensorfusionsfilter berechneten Orientierungswinkel verfügbar sind, wird ein parametrischer Ansatz verfolgt, der sich primär auf die Orientierungswinkel und die Rotationsdynamik stützt.

Von den Orientierungswinkeln wird der Nickwinkel θ des Unterschenkels verwendet, der den absoluten Winkel zwischen Unterschenkel und dem horizontalen Lot angibt, wobei im senkrechten Stand gilt $\theta \approx 0^\circ$. Aus dem Nickwinkel ergibt sich die Drehrate $\omega_y = \dot{\theta} = \frac{d\theta}{dt}$.

Weiterhin werden die Drücke an Ferse ρ_F und Zeh ρ_Z und deren gleitende Standardabweichungen herangezogen.

In der Abbildung 7.1 ist exemplarisch ein Datensatz gezeigt, welcher für die iterative Abstimmung der Merkmalsextraktion verwendet wurde. Dazu wird nach einem modellbasierten Ansatz eine Reihe von Merkmalen ζ_n generiert, die die Grundlage für die Entscheidungsfindung im Bewegungsschätzer darstellen:

- ζ_1 Auftreten des Fußes auf dem Boden bei Fersenkontakt.
- ζ_2 Rückschwungphase des Beins bezüglich des sich nach vorne bewegenden Körpers nach der Bodenstand-Phase.
- ζ_3 Vorschwungphase I, welche sich an die Rückschwungphase ζ_2 anschließt und bis zum Durchschwingen des Beins am unteren Lotpunkt ($\theta = 0^\circ$) reicht.
- ζ_4 Vorschwungphase II, welche sich an die Vorschwungphase I anschließt und im kontinuierlichen Gehen vom Auftreten ζ_1 gefolgt wird.

Für die Erkennung und Modellierung des Übersteigens eines Hindernisses oder Ersteigens einer Treppenstufe werden noch zwei weitere Merkmale definiert:

- ζ_5 ähnelt der Schwungphase II, beschreibt jedoch die Vorschwungphase, wenn das Bein vor einem Hindernis oder einer Treppenstufe gehoben wird.
- ζ_6 stellt das Auftreten auf eine Treppenstufe dar und bildet einen Sonderfall von ζ_1 .

Die bereits in Abschnitt 5.1.1 eingeführte Zerocrossing-Funktion kann bei der Merkmalsgenerierung auf die beiden Fälle eines positiven (\uparrow) und negativen Nulldurchgangs




Abbildung 7.2: Flussdiagramm zur Merkmalsgenerierung mit den im Text aufgeführten Pseudocode-Sequenzen. Dem Einlesen eines neuen Messwert-Satzes von den Sensoren geht ein Ausführungsschritt des in Abschnitt 7.4 beschriebenen Zustandsschätzers voraus.

(\downarrow) für eine beliebige Folge von Werten y_k erweitert werden, welche folgendermaßen definiert werden sollen:

$$\uparrow y_k = \begin{cases} true & , \text{für } y_{k-1} < 0 \quad \wedge \quad y_k > 0 \\ false & \text{sonst} \end{cases} \quad (7.1)$$

$$\downarrow y_k = \begin{cases} true & , \text{für } y_{k-1} > 0 \quad \wedge \quad y_k < 0 \\ false & \text{sonst} \end{cases} \quad (7.2)$$

Zur Steigerung der Übersichtlichkeit der nachfolgend beschriebenen Bestimmung der Merkmale ζ_i wird jedem Merkmal i ein Merker \diamond_i zugeordnet, welcher das Eintreten eines Ereignisses markiert, das zeitlich unkorreliert zum Merkmal ζ_i ist. Durch dieses zweistufige Vorgehen mit Merker und Merkmal wird der kontinuierliche Signalraum diskretisiert, wobei die zeitliche Varianz eliminiert wird.

Die Abbildung 7.2 stellt den Ablauf des Einlesens von Sensormesswerten, den einzelnen Schritten der Merkmalsgenerierung von ζ_i und den anschließenden Zustandsschätzer dar. Der erste Schritt in Algorithmus 7.1 besteht im Setzen des Merkers \diamond_1 , wenn die Nickwinkelgeschwindigkeit bei negativem Nickwinkel einen positiven Nulldurchgang aufweist.

```

if ( $\uparrow \dot{\theta}_k$ )  $\wedge$  ( $\theta_k < -5^\circ$ ) then
   $\diamond_1 \leftarrow true$ 
end if
  
```

Algorithmus 7.1: Prüfe Bedingung zum Setzen von \diamond_1

Die nächste Stufe ist das Erkennen des Auftretens, welches in Algorithmus 7.2 aufgeführt ist. Dabei steht S für eine Datenstruktur „Schritt“. Der auf das Körpergewicht

normierte Fersendruck ρ_F muss 0,5 übersteigen und der Merker \diamond_1 musste bereits gesetzt sein. Für den ersten Schritt wird dabei eine Dauer von 1,4 s angesetzt, bis ein gültiger Schätzwert vorliegt.

```

if ( $\rho_F(k) > 0,5$ )  $\wedge$  ( $\diamond_1 = true$ ) then
   $\zeta_1 \leftarrow true$ 
   $\diamond_1 \leftarrow false$ 
   $\diamond_2 \leftarrow true$ 
   $S.time(S.counter) \leftarrow t$ 
  if  $S.counter > 1$  then
     $S.duration(S.counter) \leftarrow S.time(S.counter) - S.time(S.counter - 1)$ 
  else
     $S.duration(S.counter) \leftarrow 1,4 s$ 
  end if
   $S.counter \leftarrow S.counter + 1$ 
end if

```

Algorithmus 7.2: Erkennen des Auftretens

Der Algorithmus 7.3 ist als Sicherheitsabfrage nach Algorithmus 7.2 eingefügt, falls kein Schritt erkannt werden konnte und damit das Eintrittsereignis für \diamond_1 ungültig geworden ist.

```

if ( $\downarrow \dot{\theta}_k$ ) then
   $\diamond_1 \leftarrow false$ 
end if

```

Algorithmus 7.3: Zurücksetzen von \diamond_1

Wenn im Algorithmus 7.2 ein Auftreten erkannt wurde, dann wird im folgenden Algorithmus 7.4 geprüft, ob zusätzlich ein Rückschwingen ζ_2 des Beins vorliegt.

```

if ( $\dot{\theta}_k > 0,3^\circ/s$ )  $\wedge$  ( $\diamond_2 = true$ ) then
   $\zeta_2 \leftarrow true$ 
end if

```

Algorithmus 7.4: Erkennung Rückschwingen ζ_2

Der Algorithmus 7.5 prüft bei erfolgreich erkanntem Rückschwung ζ_2 , ob ein Vor-schwingen des Beins vorliegt und setzt die Merker passend, damit in den folgenden

Detektionsstufen die einzelnen Vorschwing-Phasen sicher detektiert werden können.

```

if  $(\dot{\theta}_k < 0^\circ/s) \wedge (\diamond_2 = true)$  then
   $\diamond_2 \leftarrow false$ 
   $\diamond_3 \leftarrow true$ 
end if

```

Algorithmus 7.5: Erkennung des Umschaltens zwischen Rückschwung und Vorschwingung

Der Algorithmus 7.6 erfüllt zwei Aufgaben: Zum einen wird der Vorschwing I (ζ_3) markiert und zum zweiten wird der Merker \diamond_4 gesetzt, mit dem die Unterscheidungslogik angestoßen wird, welche zwischen einem weiteren Schritt im Gangzyklus und einem Schritt über ein Hindernis/Treppe unterscheidet.

```

if  $(\diamond_3 = true) \wedge (\theta_k > 0^\circ)$  then
   $\zeta_3 \leftarrow true$ 
else
   $\diamond_3 \leftarrow false$ 
   $\diamond_4 \leftarrow true$ 
end if

```

Algorithmus 7.6: Erkennung Vorschwingphase I und Vorbereitung zur Unterscheidung zwischen *normalem Schritt* und *Hindernis/Treppe*

Der Algorithmus 7.7 prüft neben dem gesetzten Merker \diamond_4 die weitere Vorschwingphase des Beins. Sollte gleichzeitig ein Auftreten ζ_1 erkannt worden sein, so wird die aktuelle Schwungphasenerkennung abgebrochen.

```

if  $(\diamond_4 = true) \wedge ((\dot{\theta}_k < 0,1^\circ/s) \vee (\theta_k < -5^\circ))$  then
  if  $|\omega_y(k)| > 0,3 rad^{-1}$  then
     $\zeta_4 \leftarrow true$ 
     $\diamond_5 \leftarrow true$ 
  end if
  if  $\zeta_1 = true$  then
     $\diamond_4 \leftarrow false$ 
  end if
end if

```

Algorithmus 7.7: Erkennung Vorschwingphase II

Wie bereits im Algorithmus 7.3 wird im Algorithmus 7.8 eine Plausibilität zwischen Winkel θ des Beins und dem gesetzten Merker \diamond_4 durchgeführt.

```

if ( $\theta_k > 10^\circ$ ) then
     $\diamond_4 \leftarrow false$ 
end if

```

Algorithmus 7.8: Plausibilitätsprüfung für Schwungphase

Anschließend erfolgt eine Abschätzung der Schrittphase, welche dem später beschriebenen Zustandsschätzer als Stützgröße zugeführt wird. Der Algorithmus 7.9 prüft, ob ein Auftreten bei gleichzeitig vorhandener minimaler Schrittdauer von 0,5 s erkannt wurde oder ob ein neuer Phasenzklus, markiert durch *phase.start*, vorliegt.

```

if ( $(\zeta_1 = true) \wedge (S.duration(S.counter - 1) > 0,5s) \vee (phase.start = true)$ ) then
    phase.start  $\leftarrow true$ 
    phase.length  $\leftarrow S.duration(S.counter - 1)$ 
    phase.inittime  $\leftarrow S.time(S.counter - 1)$ 
     $S.phase_k \leftarrow \left( \frac{t - phase.inittime}{phase.length} \right)$ 
    if  $S.phase_k > 1$  then
         $S.phase_k \leftarrow 0$ 
        phase.start  $\leftarrow false$ 
    end if
end if

```

Algorithmus 7.9: Abschätzung der Schrittphase

Im abschließenden Algorithmus 7.10 wird ein Auftreten auf die Treppenstufe bzw. ein Hindernis erkannt, wobei eine Reihe von Druck- und Winkel-Bedingungen erfüllt sein muss: Der normierte Zehen-Druck ρ_Z muss größer 0,6 und größer als der Fersendruck ρ_F sein. Ferner darf $\dot{\theta}_k$ bei positivem Winkel θ_k nur in einem begrenzten Intervall liegen.

Weiterhin wird für die Merkmalsgenerierung die gleitende Standardabweichung $\tilde{\sigma}_\theta(k)$ über den von der Inertialsensorik bestimmten Nickwinkel $\theta(k)$ mit der Fensterbreite 150 aus dem Intervall $[k - 150 \dots k]$ benötigt, welche rückwärtsgerichtet ist, damit eine kausale Berechnung im Echtzeitsystem möglich ist.

Die Abbildung 7.3 zeigt exemplarisch das Ergebnis dieser Merkmalsgenerierung angewendet auf einen Datensatz aus der Messreihe *Hindernis und Treppe* aus Abschnitt 4.2, wobei zur besseren Unterscheidbarkeit die detektierten Merkmale mit unterschiedlichen Amplituden dargestellt werden. Das Auftreten kann sicher detektiert werden, und auch

```

if ( $\theta_k > 0^\circ$ )  $\wedge$  ( $\rho_Z(k) > \rho_F(k)$ )  $\wedge$  ( $\rho_Z > 0,6$ ) then
  if ( $\dot{\theta}_k > -0,2^\circ/s$ )  $\wedge$  ( $\dot{\theta}_k < 10^\circ/s$ ) then
    if ( $\zeta_2 = false$ )  $\wedge$  ( $\tilde{\sigma}_\theta(k) > 5^\circ$ ) then
       $\zeta_6 \leftarrow true$ 
    end if
  end if
end if

```

Algorithmus 7.10: Erkennung Auftreten Treppenstufe

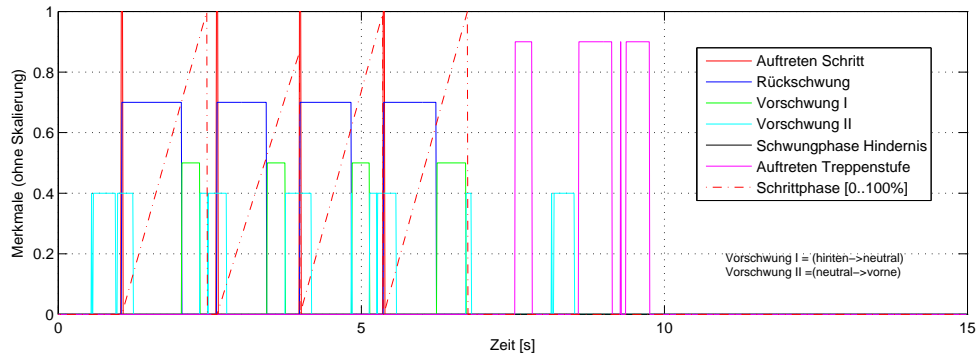


Abbildung 7.3: Anwendung der Merkmalsextraktion für ζ_i auf einen Datensatz mit folgendem Bewegungsablauf: *Stehen* \rightarrow *Gehen* ($t \in [1, 6]s$) \rightarrow *Hindernis* ($t \in [6, 10]s$) \rightarrow *Stehen*

die Sequenz der einzelnen Schwungphasen wird detektiert. Aus den Zeitpunkten des Auftretens kann bereits eine Abschätzung für die Schrittphase gewonnen werden.

Neben den Merkmalen ζ_n fließt gemäß Abbildung 3.7 auf Seite 36 auch der Druck $\rho_{EMG}^{i,j}$ des EMG-Arrays in die Zustandsermittlung mit ein, wobei hier der Mittelwert (7.3) über das ganze Druckarray gebildet wird.

$$\bar{\rho}_{EMG}(k) = \frac{1}{N_P} \sum_{i=1}^{N_P^z} \sum_{j=1}^{N_P^s} \rho_{EMG}^{i,j}(k) \quad (7.3)$$

Aus diesem räumlichen Mittelwert wird weiterhin ein gleitender zeitlicher Mittelwert mit einer Fensterbreite von 11 Werten² in (7.4) gebildet, welcher dem Zustandsschätzer als Merkmal zugeführt wird.

²entspricht bei 100 Hz Scanrate der Inertialsensorik einem Zeitfenster von 11ms, siehe Echtzeitanforderungen




Abbildung 7.4: Zustandsautomat

$$\tilde{\rho}_{EMG}(t_k) = \sum_{i=k-11}^k \bar{\rho}_{EMG}(t_i) \quad (7.4)$$

Im folgenden Abschnitt wird die Methode entwickelt, welche, basierend auf diesen Merkmalen, den Bewegungszustand schätzt.

7.4 Schätzung und Prädiktion des Bewegungszustands

Der Anfangszustand ξ_0 kann unter der Annahme, dass nur Stehen und Sitzen als Initialisierungszustand in Frage kommen, einfach gemäß (7.5) bestimmt werden, wobei ein entlastetes Bein als *Sitzen* angenommen wird.

$$\xi_0 = \begin{cases} \xi_{stehen} & \rho_F > 0,5 \quad \vee \quad \rho_Z > 0,5 \\ \xi_{sitzen} & sonst \end{cases} \quad (7.5)$$

Aufbauend auf diesen Initialzuständen kann ein Zustandsautomat gebildet werden, wie er in der Abbildung 7.4 gezeigt ist. Hierbei wird jede Zustandstransition $c_{i,j}$ mit einer Wahrscheinlichkeit für den Übergang von Zustand ξ_i nach ξ_j belegt. Dies erfolgt vor dem Hintergrund, dass es beispielsweise unwahrscheinlich ist, dass auf *Sitzen* direkt *Gehen* ohne zwischenzeitliches *Stehen* folgt. Andererseits kann der Zustand *Hindernis* sowohl aus dem Zustand *Gehen* als auch aus dem Zustand *Stehen* folgen. Der Zustand „*Hindernis*“ ist somit auch der erste Schritt zu dem Zustand „*Treppe hoch*“, da eine Treppe hier wie eine Folge von Hindernissen behandelt wird.

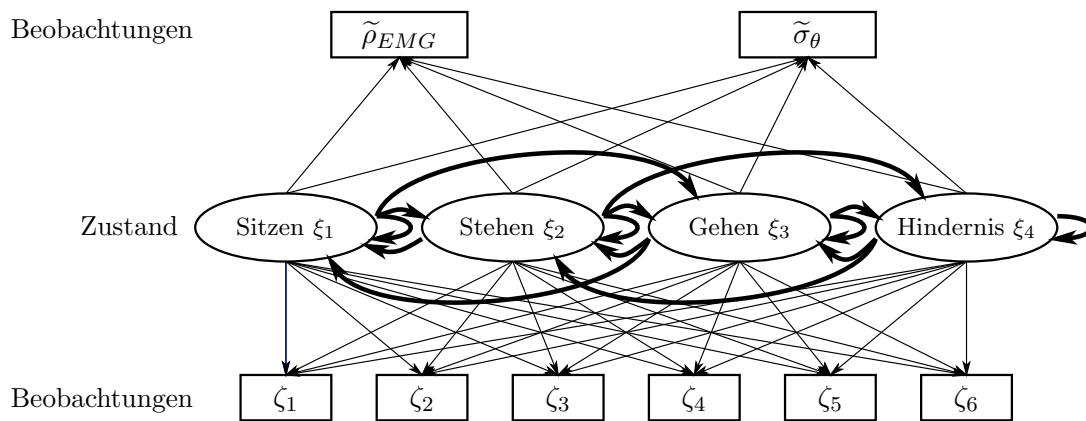


Abbildung 7.5: Hidden-Markov-Modell für die Bewegungszustandsschätzung mit den Merkmalen ζ_i , welche als Beobachtungen für die Zustände ξ_i dienen. Die Übergangswahrscheinlichkeiten und Beobachtungswahrscheinlichkeiten sind der Übersicht wegen nicht notiert.

7.4.1 Hidden-Markov-Modell

In Unterabschnitt 6.3.4 wurde beschrieben, dass ein Hidden-Markov-Modell auf Basis von äußeren Beobachtungen einen inneren Zustand schätzt. Chen u. a. (2009) verwenden ein HMM zur Erkennung der Gangbewegung einer Person, wobei sie den Gang in einzelne, unabhängige Merkmale untergliedern.

Im Rahmen dieser Arbeit wurde untersucht, ob das in Abbildung 7.5 skizzierte HMM diese Zustandsschätzung durchführen kann. Als Beobachtungen wurden sowohl die oben definierten Merkmale ζ_i als auch der EMG-Druck $\tilde{\rho}_{EMG}$ aus (7.4) verwendet. Zusätzlich wurde über dem Nickwinkel θ eine gleitende Standardabweichung $\tilde{\sigma}_\theta$ berechnet, welche als weiteres Merkmal dient.

Als Ergebnis läßt sich festhalten, dass das HMM bedingt durch die zeitliche Aufeinanderfolge und teilweise Überlagerung der gangdefinierenden Merkmale ζ_i signifikante Falschklassifizierungen generierte. Ferner zeigte sich, dass Änderungen am geschätzten Bewegungszustand gegenüber der realen Bewegungsform zu langsam erfolgten, wobei eine Änderung der internen Parameter zu Gunsten einer größeren Dynamik zu häufigeren Fehlklassifizierungen führte.

Als weiterer Nachteil ergab sich, dass die Gangphase, welche für die Vorhersage der auftretenden Bodenreaktionskraft-Störungen im EMG-Signal hilfreich ist, mit dem HMM

nicht geschätzt werden kann. Schließlich findet beim HMM ein hartes Umschalten zwischen den Zuständen statt, wodurch Unsicherheiten in der Erkennung nur unzureichend abgebildet werden können. Aus diesen Gründen wurde eine abgewandelte Form eines kontinuierlichen Zustandsschätzers entworfen und evaluiert.

7.4.2 Kontinuierlicher Zustandsschätzer

Mit dem Ansatz aus dem Zustandsautomaten und dem HMM wird ein Zustandsschätzer auf Basis eines KALMAN-Filters entwickelt, der sich in die beiden Teile *Vorhersage* und *Korrektur* gliedert (Wagner, 2003).

Vorhersage Der Zustandsvektor \mathbf{x} des im Folgenden betrachteten Zustandsschätzers besitzt den in (7.6) definierten Aufbau, wobei δ die Gangslope, Z_i die Wahrscheinlichkeit der einzelnen zu bestimmenden Bewegungszustände *Sitzen*, *Stehen*, *Gehen* und *Hindernis* und ϕ die Phase des aktuellen Gangzyklusses definieren. Die Gangslope stellt die zeitliche Ableitung der Gangphase dar: $\delta = \dot{\phi}$.

$$\mathbf{x} = [\delta, Z_{sitzen}, Z_{stehen}, Z_{gehen}, Z_{hind}, \phi]^T \quad (7.6)$$

Die dem Zustandsschätzer zugrunde liegende Dynamikfunktion $\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u})$ ist in (7.7) angegeben.

$$\underbrace{\begin{bmatrix} \dot{\delta} \\ Z_{sitzen} \dot{} \\ Z_{stehen} \dot{} \\ Z_{gehen} \dot{} \\ Z_{hind} \dot{} \\ \dot{\phi} \end{bmatrix}}_{\dot{\mathbf{x}}} = \underbrace{\begin{bmatrix} -0,9 \delta \\ -0,4 Z_{sitzen} \\ -0,4 Z_{stehen} \\ -0,4 Z_{gehen} \\ -0,4 Z_{hind} \\ \delta \end{bmatrix}}_{\mathbf{A}\mathbf{x}} + \underbrace{\begin{bmatrix} 0 \\ (1 - \tanh(\tilde{\rho}_{EMG})) - 0,1 \tilde{\sigma}_{\theta} \\ \tanh(\tilde{\rho}_{EMG}) - 0,1 \tilde{\sigma}_{\theta} \\ 20 \zeta_1 - 20 \zeta_6 + 2 \zeta_2 + 2 \zeta_3 + 2 \zeta_4 + 0,3 \tilde{\sigma}_{\theta} \\ 10 \zeta_5 + 20 \zeta_6 \\ 0 \end{bmatrix}}_{\mathbf{b}(\mathbf{u})} \quad (7.7)$$

Dieses Differentialgleichungssystem in Zustandsraumdarstellung lässt sich aufteilen in $\dot{\mathbf{x}} = \mathbf{A} \mathbf{x} + \mathbf{b}(\mathbf{u})$. Der Teil $\mathbf{A} \mathbf{x}$ führt bei fehlendem Eingang $\mathbf{b}(\mathbf{u})$ mit der in jedem Schritt durchgeführten Normierung in (7.8) zu einem Angleichen der Wahrscheinlichkeiten Z_i , was der gestiegenen Unsicherheit entspricht, wenn keine neuen Messwerte bzw.

Merkmale vorliegen. Auch die Gangslope δ nimmt ohne Eingang und Stützung ab, was einer Verlangsamung des Prothesenträgers entspricht. Vor der Normierung werden die Wahrscheinlichkeiten auf das Intervall $[0 \dots \infty[$ begrenzt, da der Eingang $\mathbf{b}(\mathbf{u})$ zu negativen Werten führen kann, die einer negativen Wahrscheinlichkeit entsprechen. Ferner wird die Phase δ auf das Intervall $[0 \dots 1]$ limitiert.

$$Z'_i = \frac{Z_i}{\sum_i Z_i} \quad (7.8)$$

Der Ausdruck $\tanh(\tilde{\rho}_{EMG})$ in (7.7) bildet ein differenzierbares Konstrukt für eine Minimum-Funktion $\min(x, 1)$, die die Druckkraft aus dem EMG-Array im Intervall $[0 \dots \infty[$ in das Intervall $[0 \dots 1[$ abbildet, wobei durch den Tangens-Hyperbolicus bereits geringe Drücke für das maximale Ansprechen der Funktion ausreichend sind.

Die konstanten Faktoren in (7.7) wurden in einem iterativen Optimierungsprozess, der über alle vorliegenden Messreihen durchgeführt wurde, bestimmt, wobei ein Hauptaugenmerk auf schnelles Ansprechverhalten bei Zustandsübergängen und konservatives Verhalten bei fehlenden oder unplausiblen Messwerten gelegt wurde.

Jedem Merkmal in (7.7) wurde ein Rauschen ϵ_i zugewiesen, wodurch sich die Kovarianzmatrix \mathbf{Q} des Systemrauschens im KALMAN-Filter gemäß (7.9) aufstellen lässt, die mit den Werten in (7.10) parametrisiert wurde (*diag* definiert eine Diagonalmatrix aus den angegebenen Elementen).

$$\mathbf{Q} = \text{diag}(\epsilon_\delta; \epsilon_{\zeta_1}; \epsilon_{\zeta_2}; \epsilon_{\zeta_3}; \epsilon_{\zeta_4}; \epsilon_{\zeta_5}; \epsilon_{\zeta_6}; \epsilon_{\tilde{\sigma}_\theta}; \epsilon_{\tilde{\rho}_{EMG}}; \epsilon_\phi) \quad (7.9)$$

$$\mathbf{Q} = \text{diag}(0, 01; 0, 01; 0, 01; 0, 01; 0, 01; 0, 01; 0, 01; 0, 01; 0, 01; 10^{-3}; 10^{-6};) \quad (7.10)$$

Mit der Jacobimatrix \mathbf{G} in (7.11), die sich aus dem modellierten Prozessrauschen in (7.7) bestimmt, ergibt sich somit die Differentialgleichung für die Kovarianz \mathbf{P} , welche in (7.12) angegeben ist und den Vorhersage-Schritt des KALMAN-Filters vervollständigt.

$$\mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & -0,1 & -1 + \tanh(\tilde{\rho}_{EMG})^2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 - \tanh(\tilde{\rho}_{EMG})^2 & 0 & 0 \\ 0 & 20 & 2 & 2 & 2 & 0 & -20 & 0,3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 10 & 20 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (7.11)$$

$$\dot{\mathbf{P}} = \mathbf{A}\mathbf{P} + \mathbf{P}\mathbf{A}^T + \mathbf{G}\mathbf{Q}\mathbf{G}^T \quad (7.12)$$

Korrektur Im Korrektur-Schritt erfolgt die Aktualisierung des Zustands durch die vorliegenden Messwerte, wobei hier vom klassischen KALMAN-Filter in Wagner (2003) abgewichen wird: Wenn der Druck $\tilde{\rho}_{EMG}$ vorliegt oder ein Auftreten ζ_1 oder ein Hindernis nach ζ_6 oder $Z_{gehen}(k) > 75\%$ gilt, dann wird ein Korrektur-Schritt innerhalb des Messupdates durchgeführt, welcher in (7.13) definiert ist.

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{K} \left(\begin{bmatrix} (phase.length)^{-1} \\ S.phase_k \end{bmatrix} - \mathbf{H}\mathbf{x} \right) \quad (7.13)$$

Die Stützung findet über die Gangslope, die als Kehrwert aus der Phasenlänge $phase.length$ folgt, und der Schrittphase $S.phase_k$ statt. Die Update-Matrix \mathbf{K} berechnet sich dabei nach (7.14), wobei die Jacobimatrix \mathbf{H} in (7.15) angegeben ist. Die Matrix \mathbf{R} des Messrauschens ergab sich nach dem Optimierungsprozess zu (7.16).

$$\mathbf{K} = \mathbf{P}\mathbf{H}^T (\mathbf{H}\mathbf{P}\mathbf{H}^T + \mathbf{R})^{-1} \quad (7.14)$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (7.15)$$

$$\mathbf{R} = \text{diag}(10^{-4}; 1) \quad (7.16)$$




Abbildung 7.6: Ergebnis für das Bewegungsprofil „*Sitzen* → *Aufstehen*“. (oben: Messwerte, Mitte: Merkmale, unten: Wahrscheinlichkeit für erkannten Zustand)

7.5 Ergebnisse der Bewegungszustandsschätzung

In diesem Abschnitt sollen exemplarische Ergebnisse für die Bewegungszustandsschätzung gezeigt werden. Die Abbildung 7.6 zeigt das Ergebnis aus der Messreihe 2 mit dem Bewegungsprofil „*Sitzen* → *Aufstehen*“. Bis $t = 12\text{ s}$ saß der Proband und ab $t = 14\text{ s}$ stand er. Während des Aufstehens kann im unteren Diagramm ein kurzzeitiges Erkennen des Zustands *Gehen* beobachtet werden, was aus der Winkelbewegung des Beins während des Aufstehens rührt. Das *Sitzen* und das *Stehen* werden korrekt erkannt.

Die Abbildung 7.7 zeigt das Ergebnis für einen komplexen Bewegungsablauf aus der Versuchsreihe 5, bei dem aus dem Stand bei $t = 3\text{ s}$ begonnen wurde zu laufen. Nach mehreren Schritten wurde bei $t = 9\text{ s}$ das in der Abbildung 4.9 auf Seite 48 gezeigte Podest mittels 2 Stufen bestiegen, auf dem der Proband bis zum Ende der Messaufzeichnung stehen blieb. Da der Proband das Prothesenbein ab $t = 12,5\text{ s}$ vollständig

7.5 Ergebnisse der Bewegungszustandsschätzung




Abbildung 7.7: Ergebnis für Versuch aus Messreihe 5 „*Stehen* → *Gehen* → *Hindernis* (Treppe) → *Stehen*“ (oben: Messwerte, Mitte: Merkmale, unten: Wahrscheinlichkeit für erkannten Zustand)

im Stand entlastete, wurde ab diesem Zeitpunkt durch die fehlende Druckbelastung fälschlicherweise der Zustand *Sitzen* erkannt.

Im Zeitintervall $t = [9,5 \text{ s} \dots 11 \text{ s}]$ ist bereits in den oben in der Abbildung gezeigten Messwerten der unterschiedliche und charakteristische Winkel- und Druckverlauf beim Treppensteigen zu erkennen, welcher sich als korrekt identifiziertes Merkmal (magenta „Auftreten Treppenstufe“) ausdrückt, aus dem der mit hoher Flankensteilheit unverzüglich erkannte Zustand *Hindernis* (cyan in unterem Diagramm) folgt.

Abschließend soll die Schätzung und Prädiktion der Gangphase in Abbildung 7.8 mit dem Messdatensatz aus der Messreihe 7 „*Stehen* → *Gehen* → *Stehen*“ gezeigt werden: Der letzte Schritt, für den kein Auftrittsmerkmal generiert werden konnte, wird über den Zustandsschätzer („Phase aus KaFi“ im Diagramm) korrekt vorhergesagt. Ferner ist zu erkennen, dass die geschätzte Gangphase gegenüber der aus den Auftritten be-




Abbildung 7.8: Ergebnis für Versuch aus Messreihe 4 „*Stehen* \rightarrow *Gehen* \rightarrow *Stehen*“ (oben: Wahrscheinlichkeit für erkannten Zustand, darunter: Gangslope, darunter: berechnetes diskretes Merkmal aus dem EMG-Druck-Array, unten: Gangphase)

stimmt leicht zeitlich versetzt ist, da sie kontinuierlich geschätzt wird, wobei auch die gegenüber dem reinen Fersenkontakt zeitlich anders verlaufende Druckverteilung im EMG-Array (Kurve „Druck“) beiträgt.

Beim Übergang von *Gehen* zu *Stehen* bei $t = 14 - 15$ s bleibt die geschätzte Gangphase auf einem mittleren Wert stehen, da das Nachziehen des Schwungbeins aus dem Gang hin zum Stand einem halben Gangzyklus entspricht.

Zusammenfassend bleibt zu betonen, dass sämtliche Merkmale und auch die Zustände in Echtzeit geschätzt werden, und dass das Besteigen einer Treppenstufe bereits erkannt wird, noch bevor der Fuß die Treppenstufe erreicht hat. Dadurch ist eine sehr schnelle Bewegungszustands-Umschaltung möglich, die nicht erst eine Anzahl an zurückliegenden Schritten für das Erkennen des Bewegungszustands benötigt.

8 Implementierung des hybriden Sensorfusionsfilters

Das hier beschriebene Identifikationssystem für Willkürsignale an Beinprothesen wurde als Postprocessing-System in MATLAB™ implementiert. Ein Hauptaugenmerk war dabei der spätere Echtzeit-Charakter sowie eine leichte Portierung des Programm-Codes auf ein Embedded-System, weswegen alle MATLAB-Scripte und Funktionen so umgesetzt wurden, dass sie nicht auf dem vollständigen Datensatz arbeiten, sondern jeweils nur einen neuen Messwertsatz innerhalb einer großen *FOR*-Schleife verarbeiten, was der Funktionsweise mit realen Sensoren entspricht. Auch das Zusammenspiel und die Synchronisierung der unterschiedlichen Frequenzen f_E und f_C sowie der asynchronen Zustandsschätzer wurde dabei berücksichtigt.

Die Bewegungszustandsschätzung wurde gemäß der Dokumentation im vorausgehenden Kapitel implementiert. Im Folgenden sollen deshalb insbesondere die untersuchte und gewählte Parametrisierung des EMG-Systems dargelegt und die bisher nicht besprochenen Funktionsblöcke aus der Systemarchitektur in Abbildung 3.7 auf Seite 36 beschrieben werden.

8.1 Klassifizierung des vEMG

Die Generierung des virtuellen EMGs wurde gemäß den Ausführungen in Abschnitt 5.2 implementiert. Für Vergleichszwecke wurden jedoch auch alle einzelnen EMG-Kanäle parallel durch das Mustererkennungssystem geführt.

Aufgrund der in Abschnitt 6.4 aufgeführten Entscheidungskriterien wurde für das Dimensionsreduktionsverfahren die PCA und für die Klassifikation des EMG-Signals die SVM ausgewählt.

Merkmalsvektor Für das Merkmal *Mean Absolute Value* wurde eine Fensterbreite von 128 Werten verwendet. Die Merkmale *Zero Crossings* und *Slope Sign Changes* wurden mit einem Schwellenwert von jeweils 3 belegt. Die *Waveform Length* wurde für eine Fensterbreite von 256 Werten ausgelegt und das AR-Modell wurde als Modell fünfter Ordnung über einem Zeitfenster von 512 Werten umgesetzt. Für das AR-Modell wurde die MATLAB-eigene Implementierung über die *System Identification Toolbox* gewählt.

Die Diskrete Wavelet Transformation wurde ebenfalls über die MATLAB-eigene Implementierung mittels *Wavelet Toolbox*¹ umgesetzt, wobei das Wavelet *Daubechies D3* verwendet wurde, das auf ein Fenster der Breite 512 Werte angewendet wird.

Für jeden Merkmalsextraktionsschritt wurde ein gleitendes Fenster verwendet, das um jeweils 64 Werte verschoben wurde, wodurch sich für die oben aufgeführten Merkmale mit einer größeren Fensterbreite eine gleitende Berechnung ergibt.

Der generalisierte Merkmalsvektor für das EMG-Signal ist in (8.1) angegeben.

$$\mathbf{m} = \left[\text{MAV}, \text{RMS}, \text{ZC}, \text{SSC}, \text{WL}, \underbrace{\varphi_1, \dots, \varphi_n}_{\text{AR-Koeffizienten}}, \underbrace{W_{\psi,j}(k), \dots, W_{\psi,j-n}(k)}_{\text{Wavelet-Koeffizienten}} \right]^T \quad (8.1)$$

Der Merkmalsvektor wurde bewegungszustandsunabhängig während der Entwicklung für das Training des SVM-Klassifikators und für die Beurteilung der PCA-Dimensionsreduktion verwendet.

Dimensionsreduktion PCA Die Implementierung der Dimensionsreduktion wurde durch die *Dimension Reduction Toolbox*² von van der Maaten (2007) umgesetzt, die in MATLAB eingebunden wurde.

Als Zieldimensionen χ wurden dabei für jeden Versuch aus Abschnitt 4.2 jeweils 3, 6 und 9 gewählt. Dies ist deutlich mehr als die LDA in Unterabschnitt 6.3.3 ermöglicht und erfolgte vor dem Hintergrund, dass die minimale reduzierte Dimension χ je Bewegungszustand identifiziert werden sollte, bei der eine akkurate Klassifizierung möglich ist.

¹Version R2010, benutzt den Algorithmus von Mallat (1989), vgl. Abbildung 5.4 auf Seite 64

²Version v0.7b

Die Merkmale des dimensionsreduzierten Merkmalvektors \mathbf{q} wurden durch eine Skalierungsfunktion auf einen Wertebereich $[0 \dots 1]$ bzw. $[-1 \dots 1]$ skaliert, bevor sie dem Klassifikator zum Training oder zur eigentlichen Klassifikation übergeben wurden.

Klassifikator SVM Als Implementierung der SVM wurde die *LibSVM*³ von Chang u. Lin (2001) eingesetzt, da diese gegenüber der MATLAB-eigenen SVM-Toolbox mehr Freiheiten bei der Modellierung und insbesondere beim Training ermöglicht. So kann mit frei definierbaren Parametern y_i zu jeder Klasse V_i ein Gewicht festgelegt werden, mit dem falsche Klassifizierungen gewichtet werden können. Dadurch kann eine allgemeingültigere und einfachere Hyperebene H gefunden werden, in der einzelne Falschklassifizierungen toleriert werden. Als Kernelfunktion wurde der in (6.24) aufgeführte RBF-Kernel verwendet.

Für jeden Bewegungszustand ξ_i wurde eine eigene SVM vorgesehen, so dass im vorliegenden Fall vier SVMs parallel existieren. Aus Vergleichsgründen wurden auch SVMs für die EMG-Einzelkanäle implementiert, deren Ergebnisse in Abschnitt 9.1 mit dem vEMG verglichen werden.

Für das Training der einzelnen SVMs wurde zu jeder der in Abschnitt 4.2 aufgeführten Messreihe manuell der Bewegungszustand definiert, so dass ein akkurates und bewegungszustandsspezifisches Lernen möglich war. Im späteren Einsatz am Prothesenträger erfüllt diese Aufgabe das in Kapitel 7 vorgestellte System.

Als Referenzsignal für das zu erkennende Willkürsignal diene dabei das in Unterabschnitt 4.1.4 beschriebene Signal des synchron zum Muskel aktivierten Handtasters. Die Messdaten wurden je Bewegungszustand zufällig in Trainingsdaten und Verifikationsdaten unterteilt, wodurch eine Kreuz-Validierung möglich war.

Die Abbildung 8.1 und Abbildung 8.2 vergleichen exemplarisch das virtuelle EMG-Signal, wie es im Bewegungszustand *Stehen* und im *Gehen* vorliegt. Während es beim *Stehen* in Abbildung 8.1 eine eindeutige Übereinstimmung zwischen der Aktivität des vEMG-Signals und dem Referenz-Handtaster gibt, kann in der Abbildung 8.2 nicht mehr mit einfachen Mitteln auf das WKS geschlossen werden. Weiterhin sei auf die unterschiedlichen Amplituden und Signalformen des EMG-Signals zwischen *Stehen* und *Gehen* im direkten Vergleich hingewiesen.

³Version 3.1




Abbildung 8.1: vEMG-Signal und WKS-Referenz im *Stehen*




Abbildung 8.2: vEMG-Signal und WKS-Referenz im *Gehen*

Die iterative Parametersuche für die Gewichte y_i der SVM und die mit diesen zusammenhängenden weiteren Parameter wurde in der Implementierung aus den Vorarbeiten von Dennerlein (2009) übernommen.

8.2 Kombination Bewegungszustand und Willkürerkennung

Die Kombination des Bewegungszustands und der Willkürerkennung muss aus Signalströmen zweier Wahrscheinlichkeitsgruppen, die von separaten Klassifikatoren und Zustandsschätzern stammen, ein Gesamtergebnis berechnen, das dem wahrscheinlichsten erkannten Willkürsignal entspricht und an die Aktorik der aktiven Prothese geleitet wird.

Burmeister u. a. (2006) beschreiben eine Methode, um Ergebnisse unterschiedlicher Klassifikatoren zu fusionieren, wobei die Ergebnisse, die zu unterschiedlichen Zeitpunkten bereitstehen, mit einer Klassifikationsgüte versehen werden.

Im vorliegenden Fall arbeiten die SVM-Klassifikatoren jedoch zeitsynchron, weswegen eine Synchronisierung nicht notwendig ist. Durch die gewählten Fensterbreiten bei der Mustererkennung des EMG-Signals können die Signalströme der Willkürerkennung \hat{w}_i je Bewegungszustand und der Bewegungszustand Z_i direkt kombiniert werden.

Der Aspekt der Klassifikationsgüte kann im vorliegenden Fall als Produkt der Bewegungswahrscheinlichkeit und Willkürwahrscheinlichkeit beschrieben werden, der insbesondere bei wechselnden Bewegungszuständen relevant ist: So kann einerseits hart zwischen den erkannten Bewegungszuständen umgeschaltet oder zwischen diesen überblendet werden. Ferner kann sich das Gesamtsignal gemäß (8.2) berechnen, in der die lineare Kombination der beiden Wahrscheinlichkeiten Z_i und \hat{w}_i berechnet wird, wobei beide Wahrscheinlichkeiten gleich gewichtet werden.

$$\hat{w}_{gesamt} = \sum_i Z_i \hat{w}_i \quad (8.2)$$

Insbesondere wenn der Bewegungszustand nicht eindeutig geschätzt werden kann (z. B. $Z_{gehen} = 55\%$ und $Z_{stehen} = 45\%$) ergibt sich ein Zuordnungsproblem: Soll der Zustand höher gewichtet werden oder soll die Willkürerkennung höher gewichtet werden?

Im vorliegenden Fall wurde die Priorität auf den Bewegungszustand ξ_i mit seiner Wahrscheinlichkeit Z_i gelegt, wobei \hat{w}_{gesamt} die normierte Summe aller Willkürwahrscheinlichkeiten \hat{w}_i ist, deren Bewegungswahrscheinlichkeit größer gleich 50 % ist, was durch (8.3) ausgedrückt werden soll.

$$\hat{w}_{gesamt} = \min \left(\sum_i \begin{cases} \hat{w}_i & , \text{ wenn } Z_i \geq 0,5 \\ 0 & \text{sonst} \end{cases} , 1 \right) \quad (8.3)$$

8.3 Zeitliche Filterung

Bei der Willkürsignal-Erkennung ist hauptsächlich die Erkennung der steigenden Flanke des Erkennungssignals wesentlich, da das eigentliche Anheben des Fußes vom Prothesenträger nicht proportional gesteuert wird. Somit vollzieht die Prothese das Anheben als eigenständigen Prozess.

Die Dauer des erkannten WKS kann hierbei zweierlei Einflussgrößen auf das Anheben haben:

- Dauert das WKS länger, als die Prothesenaktorik für das Anheben des Fußes benötigt, so wird der Fuß in der angehobenen Stellung gehalten, bis das WKS nicht mehr vorliegt.
- Wird das WKS deaktiviert, noch während der Fuß angehoben wird, so kann dies entweder einem ungewollten oder falsch erkannten WKS entsprechen oder der Wunsch des Prothesenträgers lag nur eine entsprechend kurze Zeit vor.

Deshalb muss das zeitliche Verhalten der WKS-Erkennung betrachtet und berücksichtigt werden:

Sitzen Im *Sitzen* kann das WKS ohne Berücksichtigung eines Zeitverhaltens an die Prothese geleitet werden.

Stehen Für das *Stehen* kann dieser Fall nicht angenommen werden, weswegen hier eine minimale Aktivitätsdauer des WKS verlangt wird, bevor die Prothese die Aktion ausführt. Dieser Zeitverzug, der der Erhöhung der Sicherheit dient, hat im *Stehen* keine Auswirkung, da im *Stehen* die Echtzeitbedingungen nur eingeschränkt gelten und Verzögerungen von 0,25 s, während denen konstant das WKS vorlag, keinen Einfluss




Abbildung 8.3: Gangzyklus 0%–100% mit Zeitfenstern für Willkürerkennung und Willküraktion. In der Schwungphase soll der Fuß angehoben werden (\uparrow).

auf die Bewegung haben. Kurzzeitige Falscherkennungen, beispielsweise durch unkoordiniertes Muskelzucken, können somit ausgeschlossen werden.

Gehen und Hindernis Für die in dieser Arbeit untersuchten Bewegungsformen *Gehen* und *Hindernis* kann das in der Abbildung 8.3 skizzierte Zeitverhalten spezifiziert werden. Es werden zwei Zeitfenster definiert, wobei eines das Erkennungs-Intervall und das andere das Aktions-Intervall beschreibt. Mit der in Unterabschnitt 7.4.2 ermittelten und prädizierten Gangphase ϕ kann bereits während eines Schrittes die Zuordnung zu den Zeitfenstern geschehen. Somit ist ein System möglich, welches nur dann innerhalb des Aktionszeitfensters den Fuß anhebt, wenn im Erkennungs-Zeitfenster das WKS detektiert wurde. Es muss dabei in späteren Arbeiten unter Verwendung einer aktiven Prothese untersucht werden, ob die zeitliche Koordination des Fußanhebens nach einem erkannten WKS rein auf Basis der geschätzten Gangphase ϕ erfolgen soll, oder ob die Anhebebewegung so lange andauern soll, wie das WKS präsent ist.

Auf jeden Fall soll mit der zeitlichen Filterung im Zustand *Gehen* ein Abknicken des Fußes in Situationen wie der Standphase, wo dies nicht gewünscht und sogar gefährlich ist, unterbunden und blockiert werden, selbst wenn der Prothesenträger ein explizites WKS geben würde.

9 Ergebnisse

In diesem Kapitel sollen einzelne exemplarische und typische Ergebnisse vorgestellt und erläutert werden. Auf prozentuale Angaben zur Erkennungsgenauigkeit wird hier verzichtet, da, wie in den vorausgehenden Kapiteln geschildert, neben der eigentlichen muskelbasierten Willkürerkennung zusätzliche Faktoren in das Endresultat einfließen. Schwerpunktmäßig soll die innere Struktur des EMG-Mustererkennungssystems untersucht werden, aus der sich über Analysen zur Verallgemeinerung auf eine mögliche Klassifizierungsgüte schließen lässt und Ursachen für eine Fehlklassifizierung identifizieren lassen.

Da die zeitlich korrekt erkannten steigenden Flanken des WKS das Hauptgütemerkmal repräsentieren, würde eine Ergebnisdarstellung, die die Klassenzugehörigkeit $\{0, WKS\}$ über die gesamte Messdauer einer Messreihe betrachtet und mit dieser ins Verhältnis setzt, das Ergebnis verzerren und nicht den besonderen Anforderungen und Randbedingungen des Gesamtsystems gemäß Abschnitt 8.3 gerecht werden. Die Dauer des korrekt erkannten Willkürsignals stellt somit nur ein sekundäres Gütekriterium dar.

Zur besseren visuellen Unterscheidung sind in diesem Kapitel die Kurven in den Diagrammen, die das Klassifikationsergebnis zu einer Klasse V_i , $i \in \{0, WKS\}$ angeben, leicht vertikal versetzt gezeichnet.

9.1 Vergleich Mustererkennung EMG und vEMG

In diesem Abschnitt soll die Klassifikation zwischen dem in Abschnitt 5.2 generierten virtuellen EMG (vEMG) und der Variante, die auf den einzelnen EMG-Kanälen arbeitet, verglichen werden. Im Fall der EMG-Einzelkanäle wurde gemäß der Abbildung 3.3 auf Seite 30 für jeden Kanal eine eigene SVM bereitgestellt, die speziell auf diesen einzelnen Kanal trainiert wurde. Für ein resultierendes und als erkannt gewertetes Will-

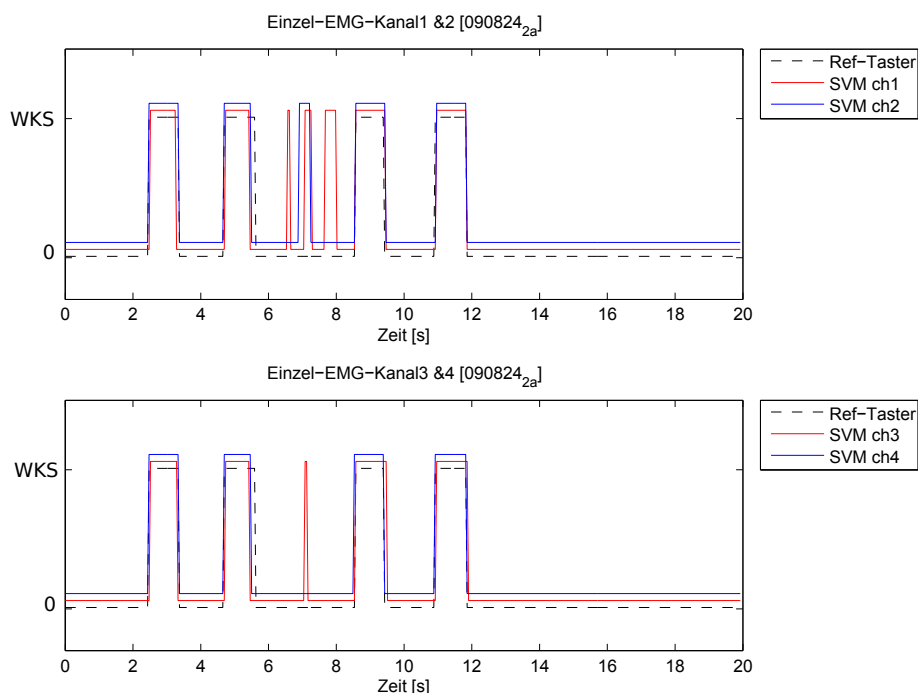


Abbildung 9.1: Klassifikationsergebnis auf den EMG-Einzelkanälen für das Bewegungsprofil *Sitzen* \rightarrow *Stehen* (Datensatz aus Versuch 2)

kürsignal wird in diesem Abschnitt bei den Einzelkanälen eine Mehrheitsentscheidung der Einzelkanal-Ergebnisse angenommen.

Die Abbildungen 9.1 und 9.2 zeigen exemplarisch den Vergleich zwischen Mustererkennung auf den vier EMG-Einzelkanälen eines 3×3 -EMG-Arrays mit dem virtuellen EMG. Es ist das Ergebnis für einen Versuch aus der Messreihe 2 (*Sitzen* \rightarrow *Stehen*, Aufstehen bei $t = 7\text{ s}$). Vergleichbar zu dem in Abschnitt 5.3 aufgeführten Vergleich zwischen EMG und vEMG treten bei $t = [6,5\text{ s} \dots 8,0\text{ s}]$ auf den Einzelkanälen Störungen auf, die in Abbildung 9.1 zu partiellen Fehlklassifikationen führen. Beim vEMG-Signal in Abbildung 9.2 sind diese Fehlklassifikationen nicht zu beobachten. Würde bei den EMG-Einzelkanälen eine Mehrheitsentscheidung gemäß der obigen Definition durchgeführt, so hätte dies bei $t = 7\text{ s}$ zu einer unerwünschten Fußbewegung der Prothese während des Aufstehens geführt, da hier bei drei von vier Kanälen kurzzeitig ein WKS erkannt wurde.

Aus dem Vergleich mit dem Klassifikationsergebnis auf den EMG-Einzelkanälen im Fall des 3×3 und 4×4 EMG-Arrays kann festgehalten werden:

- Bei Zustandsübergängen, wie dem gezeigten Aufstehen, verhindert das vEMG




Abbildung 9.2: Klassifikationsergebnis vEMG für Bewegungsprofil *Sitzen* \rightarrow *Stehen* (gleicher Datensatz wie in Abbildung 9.1)

Fehlklassifizierungen, die beim Einzel-EMG durch ein inkonsistentes Sensorsignalsbild entstehen würden.

- Eine Klassifizierung des vEMGs scheitert, wenn nicht auf der vergleichsweise durchgeführten Auswertung der EMG-Einzelkanäle mindestens 25 % – 35 % der Kanäle korrekt klassifiziert werden. Dieser Zusammenhang ist darauf zurückzuführen, dass in diesem Fall der Vergleich der EMG-Kanäle keine korrekten Ergebnisse mehr liefert. Hier sei auf die als relevant markierten EMG-Kanäle in Tabelle 5.1 auf Seite 75 hingewiesen, in der ebenfalls 3 von 8 Kanälen (= 37,5 %) als relevant betrachtet wurden.

Durch die in Folge der Messtechnik limitierte Anzahl von 16 für das EMG-Signal nutzbaren unipolaren Messkanälen kann hier keine abschließende Aussage getroffen werden, ob bei einem Array mit mehr als 4×4 Elektroden ebenfalls 3-4 gute und vom vEMG-System als relevant eingestufte EMG-Kanäle für die korrekte Funktionsweise der vEMG-Erkennung benötigt werden und sicher ausreichend sind.

Alle folgenden Auswertungen und Ergebnisse wurden ausschließlich mittels virtuellem EMG durchgeführt und ermittelt. Die EMG-Einzelkanäle werden nicht weiter untersucht.

9.2 Dimensionsreduktion

Die Abbildung 9.3 zeigt die Willkürsignal-Erkennung im *Stehen*, wobei als Zieldimension χ der PCA 3 gewählt wurde. Es werden sowohl lange als auch kurze WKS-Sequenzen korrekt detektiert.




Abbildung 9.3: WKS-Erkennung auf vEMG im *Stehen* mit PCA und $\chi = 3$ (Datensatz aus Messreihe 3)




Abbildung 9.4: Ergebnis der WKS-Erkennung im *Gehen* mit den reduzierten Dimensionen $\chi = 3$ (oben), $\chi = 6$ (Mitte) und $\chi = 9$ (unten) in der PCA und bewegungszustandszugehörigem SVM-Klassifikator (Datensatz aus Messreihe 7)

Tabelle 9.1: Eigenwerte $\lambda_1 - \lambda_6$ der PCA-Matrix Γ^T zu Messreihe 1 *Sitzen*

Versuch	1a		1b		1c	
	EW	λ_i/λ_1	EW	λ_i/λ_1	EW	λ_i/λ_1
λ_1	23406740	1,000	21220592	1,000	18024838	1,000
λ_2	96086	0,004	91823	0,004	74261	0,004
λ_3	60718	0,002	55125	0,003	35711	0,002
λ_4	57660	0,002	48613	0,002	31838	0,002
λ_5	55956	0,002	46748	0,002	31092	0,002
λ_6	53187	0,002	44183	0,002	30330	0,002

Die Abbildung 9.4 zeigt die Ergebnisse für einen Versuch aus der Messreihe 7 (*Gehen*), der für die PCA-Dimensionen $\chi = 3$, $\chi = 6$ und $\chi = 9$ ausgewertet wurde und exemplarisch zeigt, dass mit der Anzahl der PCA-Dimensionen die Fehlklassifizierungen beim Gehen abnehmen und schließlich bei $\chi = 9$ keine Fehlklassifizierung mehr auftritt. Somit enthalten die zusätzlichen Dimensionen im Gehen Informationen, aus denen von der SVM eine bessere Hyperebene H bestimmt werden kann, die zu einer höheren Genauigkeit führt. Im Folgenden soll deshalb der Informationsgehalt der einzelnen reduzierten Merkmalsdimensionen untersucht werden.

In den Tabellen 9.1 bis 9.4 sind die Eigenwerte (EW) λ_i der PCA-Dimensionsreduktionsmatrix Γ^T aus (6.10) für die jeweils ersten 6 bzw. 12 reduzierten Dimensionen angegeben. Aus den Eigenwerten und deren Vergleich zwischen den Versuchen lassen sich folgende Eigenschaften ablesen: Absoluter Betrag von λ_i , der bei den gleichen Wiederholungsversuchen „a“, „b“ und „c“ innerhalb einer Messreihe möglichst gleich sein sollte, da dies auf eine ähnliche Varianz innerhalb des Merkmalsraums hindeutet und somit ein Anzeichen für die Ähnlichkeit der Merkmalsausprägung ist. Weiterhin sind die auf den Eigenwert λ_1 normierten Eigenwerte von λ_i angegeben, die das Verhältnis der geometrischen Ausdehnung der Punktwolke im n -dimensionalen Merkmalsraum widerspiegeln, woraus sich der potentielle Informationsgehalt der reduzierten Dimensionen χ ableiten lässt.

Aus der Tabelle 9.1 ist ersichtlich, dass sich im *Stehen* die Merkmale im Wesentlichen auf einen linearen Fall reduzieren lassen. Bereits der zweite Eigenwert λ_2 hat nur noch 0,4% Ausdehnung gegenüber λ_1 . Die folgenden Eigenwerte λ_3 bis λ_6 weisen nur noch 0,2% auf, was auf Messrauschen zurückgeführt werden kann.

Im *Stehen* in der Tabelle 9.2 kann beobachtet werden, dass, ebenso wie im *Sitzen*, der

Tabelle 9.2: Eigenwerte $\lambda_1 - \lambda_6$ der PCA-Matrix Γ^T zu Messreihe 3 *Stehen*

Versuch	3a		3b		3c	
	EW	λ_i/λ_1	EW	λ_i/λ_1	EW	λ_i/λ_1
λ_1	73900810	1,000	33537432	1,000	38180758	1,000
λ_2	615668	0,008	274384	0,008	264615	0,007
λ_3	362783	0,005	149728	0,004	208270	0,005
λ_4	342927	0,005	143468	0,004	174556	0,005
λ_5	329571	0,004	139380	0,004	164332	0,004
λ_6	317948	0,004	127334	0,004	157815	0,004

Tabelle 9.3: Eigenwerte $\lambda_1 - \lambda_{12}$ der PCA-Matrix Γ^T zu Messreihe 7 *Gehen*

Versuch	7a		7b		7c	
	EW	λ_i/λ_1	EW	λ_i/λ_1	EW	λ_i/λ_1
λ_1	188275599	1,000	189936479	1,000	299764808	1,000
λ_2	116401120	0,618	102066724	0,537	245999469	0,820
λ_3	113212017	0,601	100902935	0,531	207903623	0,693
λ_4	105959985	0,563	96823245	0,509	159565168	0,532
λ_5	102987400	0,547	93425525	0,491	136440435	0,455
λ_6	89533821	0,475	89435540	0,470	129244373	0,431
λ_7	71227396	0,378	81151131	0,427	113972403	0,380
λ_8	58170434	0,308	78297943	0,412	102663947	0,342
λ_9	40627260	0,215	66921545	0,352	76453725	0,255
λ_{10}	38423714	0,204	48569648	0,255	65283333	0,217
λ_{11}	36113278	0,191	43245483	0,227	56153782	0,187
λ_{12}	32053600	0,170	40308981	0,212	47248796	0,157

erste Eigenwert λ_1 dominiert, wobei der Eigenwert λ_2 mit 0,8% und die folgenden mit 0,4% geringfügig mehr Einfluss aufweisen. Dies kann darauf zurückgeführt werden, dass im *Stehen* die Muskeln nicht so entspannt sind wie im *Sitzen*.

Ein anderes Bild zeigt sich beim *Gehen* in der Tabelle 9.3: Selbst der Eigenwert λ_5 weist in allen drei Wiederholungsversuchen einen Wert nahe 50% auf, was auf einen deutlich komplexeren Merkmalsraum hinweist. Die folgenden Eigenwerte λ_6 bis λ_{12} nehmen gleichmäßig monoton ab, wobei kein deutlicher Wertesprung wie im Fall *Sitzen* und *Stehen* (λ_1 zu λ_2) beobachtet werden kann.

Die Eigenwertverteilung von *Gehen mit Hindernis* ist in der Tabelle 9.4 dargestellt: Die

Tabelle 9.4: Eigenwerte $\lambda_1 - \lambda_{12}$ der PCA-Matrix Γ^T zu Messreihe 5 *Gehen mit Hindernis*

Versuch	5a		5b		5c	
	EW	λ_i/λ_1	EW	λ_i/λ_1	EW	λ_i/λ_1
λ_1	106572333	1,000	128103070	1,000	147811817	1,000
λ_2	53900433	0,506	44212130	0,345	73948748	0,500
λ_3	50827951	0,477	40218924	0,314	69889004	0,473
λ_4	35578363	0,334	37352207	0,292	56516721	0,382
λ_5	33145535	0,311	35157068	0,274	51359689	0,347
λ_6	26146963	0,245	27884992	0,218	46814553	0,317
λ_7	24846313	0,233	25432762	0,199	43427262	0,294
λ_8	20957666	0,197	23990658	0,187	38326239	0,259
λ_9	19471595	0,183	22233385	0,173	27876924	0,186
λ_{10}	14445790	0,136	17861712	0,139	15068447	0,102
λ_{11}	14261170	0,134	14158517	0,111	14819280	0,100
λ_{12}	12396975	0,116	10978660	0,086	12132793	0,082

Dimensionen sind weniger stark ausgeprägt im Vergleich zur Tabelle 9.3, da während der gesamten Messung nur ein einziges Willkürsignal beim Betreten der Treppenstufe erfolgte, während es in Tabelle 9.3 mehrmals während der Gangzyklen gegeben wurde.

In den Tabellen 9.5 und 9.6 sind die Beiträge der verschiedenen Merkmale m_i zu den reduzierten Merkmalsvektoren $\mathbf{q} = [q_i]$ angegeben. Daraus ergibt sich die qualitative Verteilung der Merkmale innerhalb der reduzierten Merkmalsvektoren. Hierbei wurden Merkmale berücksichtigt, die zu mindestens 10 % in den reduzierten Merkmalsvektor eingehen. Aus der Tabelle ergeben sich die relevanten und dominierenden Merkmale je Bewegungszustand, aufgeschlüsselt jeweils für die durchgeführten Wiederholungsversuche. Ein alleinstehender Zahlenwert gibt an, dass dieses Merkmal ausschließlich verwendet wird (± 1) oder seinen zugehörigen Eintrag in der PCA-Matrix Γ_X^T auf Seite 81. Die Markierung \blacklozenge gibt an, dass die unterschiedlichen Koeffizienten aus dem Merkmal in das reduzierte Merkmal einfließen, wobei in Klammern der Wert der größten Komponente angegeben ist.

Auffallend ist, dass die PCA innerhalb der einzelnen Versuche „a“, „b“ und „c“ einzeln bei ungefähr gleichem Betrag des Merkmalseinflusses unterschiedliche Vorzeichen (z. B. WL bei Versuch „3a“ und „3b“, WT hat jeweils gleiches Vorzeichen) für die jeweilige Merkmalskomponente bestimmte. Daraus folgt, dass die SVM, die für diese PCA-Transformation trainiert wurde (z. B. „3a“), nicht mit dem Parametersatz des Vorzeichen-ungleichen Versuchs (z. B. „3b“) verglichen werden kann. Die ermittelten

Tabelle 9.5: Zusammensetzung und Anteile (größer 10%) der Merkmale innerhalb des reduzierten Merkmalsvektors $\mathbf{q} = [q_1, \dots, q_9]$ über die Versuche *Sitzen* (1) und *Stehen* (3)

Messreihe		1			3		
Merkmal		a	b	c	a	b	c
q_1	WL	-1	-1	-1	1	-1	1
	WT						
q_2	WT	♦(-0,46)	♦(0,47)	♦(0,48)	♦(-0,47)	♦(-0,47)	♦(-0,41)
q_3	WT	♦(0,2)	♦(0,15)	♦(0,10)	♦(0,18)	♦(0,11)	♦(0,21)
$q_4 - q_9$	WT	♦	♦	♦	♦	♦	♦

Tabelle 9.6: Zusammensetzung und Anteile (größer 10%) der Merkmale innerhalb des reduzierten Merkmalsvektors $\mathbf{q} = [q_1, \dots, q_9]$ über die Versuche *Gehen mit Hindernis* (5) und *Gehen* (7)

Messreihe		5			7		
Merkmal		a	b	c	a	b	c
q_1	WL	1	-1	-1	-0,94	-0,94	0,88
	WT				♦(0,12)	♦(0,12)	♦(0,13)
q_2	WT	♦(0,21)	♦(0,26)	♦(0,25)	♦(0,27)	♦(0,25)	♦(-0,30)
q_3	WT	♦(0,14)	♦(0,16)	♦(0,19)	♦(0,30)	♦(0,21)	♦(0,25)
$q_4 - q_9$	WT	♦	♦	♦	♦	♦	♦

und trainierten SVM-Parametersätze können somit nur bei fest vorgegebener PCA-Transformationsmatrix verglichen werden.

Der Vergleich der Tabellen 9.3 und 9.4 zeigt bereits, dass das einzelne WKS-Signal in Messreihe 5 nur eine geringe Auswirkung im Merkmalsraum der PCA-Transformation aufweist, während Messreihe 7 zu einer unterschiedlichen internen Struktur führt. Dieses Verhalten kann ebenfalls in der Tabelle 9.6 beobachtet werden. Die Messreihe 7 unterscheidet sich hier signifikant von den Messreihen 1, 3 und 5, da bei ihr bereits bei q_1 die Wavelet-Transformation einfließt. Auch bei den betrachteten q_2 und q_3 haben hier die WT-Faktoren ein höheres Gewicht. Dies deckt sich mit dem Ergebnis der Klassifikation für *Gehen* in der Abbildung 9.4, in der die höheren Dimensionen von q_i für eine korrekte Klassifizierung benötigt werden.

Die in der Tabelle 9.5 aufgeführten Merkmale ermöglichen eine korrekte und robu-

te Klassifizierung des Willkürsignals für die Zustände *Sitzen* und *Stehen*, weswegen im Folgenden insbesondere für *Gehen* und *Hindernis* die weiteren Merkmalsanteile betrachtet werden sollen: Das Merkmal MAV geht beim Versuch 5 zu 5% in q_1 ein. Die AR-Koeffizienten liegen darunter und erreichen teilweise nur Promillewerte. Ein ähnliches Bild zeigt sich bei Versuch 7, wobei hier MAV bis zu 7% erreicht. Die AR-Koeffizienten sind auch hier nur gering in ihrem Anteil, der nicht abschließend von einem Rauschen des Merkmals selbst unterschieden werden kann. Die weiteren Merkmale werden ebenfalls nur im Promillebereich in der automatisch bestimmten PCA-Transformationsmatrix berücksichtigt.

Wenn diese Merkmale einen wesentlichen Anteil an dem Klassifikationsergebnis haben sollen, dann muss entweder die Skalierung dieser Merkmale vor der PCA-Transformation angepasst werden, so dass diese eine größere Varianz im Eingangsmerkmalsraum aufweisen, oder sie müssen manuell einem bereits reduzierten Merkmalsvektor angefügt werden, auf dem dann der Klassifikator trainiert und verglichen wird.

9.3 Generalisierbarkeit der PCA-Dimensionsreduktion

Aus den Tabellen 9.5 und 9.6 lässt sich unter Berücksichtigung der vorangehenden Überlegungen keine generelle Aussage zur Generalisierbarkeit der ermittelten PCA-Transformation ableiten, da die Orientierung der Eigenvektoren der PCA-Transformationsmatrix im ursprünglichen n -dimensionalen Merkmalsraum nicht betrachtet wird.

In niedrig dimensionalen Vektorräumen lässt sich über das Skalarprodukt gemäß (9.1) der Winkel zwischen Vektoren \mathbf{x} und \mathbf{y} bestimmen.

$$\langle \mathbf{x}, \mathbf{y} \rangle = \|\mathbf{x}\| \|\mathbf{y}\| \cos \angle (\mathbf{x}, \mathbf{y}) \quad (9.1)$$

Übertragen auf einen höher dimensionalen Raum kann das Skalarprodukt ähnlich verwendet werden, wodurch ein Prähilbertraum definiert wird. Hierbei gilt, dass ein Skalarprodukt von 1 eine Orientierungs- und Richtungsübereinstimmung der Vektoren anzeigt, während 0 ein orthogonales Vektorpaar charakterisiert. Im Fall -1 weisen die Vektoren in entgegengesetzte Richtung, haben jedoch die gleiche Orientierung. Hierdurch kann das in den Tabellen 9.5 und 9.6 beschriebene Verhalten der unterschiedli-

Tabelle 9.7: Skalarprodukt der Eigenvektoren (EV) der PCA-Transformation zu den Versuchen *Sitzen* (1) und *Stehen* (3)

Messreihe	1			3		
	a vs. b	a vs. c	b vs. c	a vs. b	a vs. c	b vs. c
EV 1	1,000	1,000	1,000	-0,999	1,000	-0,999
EV 2	-0,882	-0,847	0,874	0,871	0,801	0,732
EV 3	0,021	0,279	0,191	-0,250	-0,226	-0,334
EV 4	0,080	-0,048	0,410	0,048	-0,066	-0,221
EV 5	-0,011	-0,076	0,225	0,105	0,064	-0,127
EV 6	0,112	-0,071	-0,175	-0,027	-0,148	-0,088

chen Koordinatensystemdefinitionen nach der automatischen PCA-Transformation genauer betrachtet und die Dimensionsreduktion untersucht werden.

Aus Sicht der Analyse der PCA-Transformation ist der Betrag des Skalarprodukts relevant, da nicht die Richtung, sondern die Orientierung der Varianzverteilung bedeutsam ist, wodurch ein Wertebereich für das Skalarprodukt $[0 \dots 1]$ entsteht. Für den sich an die PCA anschließenden SVM-Klassifikator ist die Richtung jedoch relevant, da aus den Abbildungen 6.2 auf Seite 80 und 6.5 auf Seite 88 ersichtlich ist, dass unterschiedliche Richtungen der Merkmalsvektoren zu unterschiedlichen Trennebenen H führen würden.

Durch den in (9.1) aufgezeigten Winkelzusammenhang über die Kosinus-Funktion muss für das Skalarprodukt ein Wert nahe 1 oder -1 verlangt werden, damit der Winkel zwischen den Vektoren ausreichend klein ist, so dass daraus die Generalisierbarkeit gefolgert werden kann.

In den Tabellen 9.7 und 9.8 sind die Skalarprodukte der Eigenvektoren $EV(i)$ zu den Eigenwerten λ_i der PCA-Transformation Γ_χ^T aus den Tabellen 9.1 bis 9.4 angegeben. Es wurden jeweils die Eigenvektoren aus dem Versuch „a“ mit „b“, „a“ mit „c“ und „b“ mit „c“ verglichen.

In der Tabelle 9.7 ist das Skalarprodukt der Eigenvektoren zu *Sitzen* und *Stehen* angegeben. Der erste Eigenvektor besitzt für Versuch 1 und 3 die jeweils identische Orientierung. Der Wechsel des Merkmals-Vorzeichens in q_1 aus der Tabelle 9.5 für den Versuch 3 führt im Skalarprodukt der Eigenvektoren erwartungsgemäß zu einem negativen Vorzeichen. Dieses Verhalten kann für q_2 des Versuchs 1 hier ebenfalls konsistent nachvollzogen werden. Obwohl die Eigenwerte λ_2 im Versuch 1 und 3 in der Tabelle 9.1

Tabelle 9.8: Skalarprodukt der Eigenvektoren (EV) der PCA-Transformation zu den Versuchen *Gehen mit Hindernis* (5) und *Gehen* (7)

Messreihe	5			7		
	a vs. b	a vs. c	b vs. c	a vs. b	a vs. c	b vs. c
EV 1	-0,982	-0,978	0,988	0,995	-0,997	-0,997
EV 2	0,807	0,765	0,865	0,955	-0,964	-0,972
EV 3	0,879	0,725	0,835	0,947	0,960	0,960
EV 4	0,143	0,104	0,850	0,207	0,484	0,906
EV 5	0,130	-0,010	0,910	0,159	-0,474	-0,890
EV 6	0,062	0,351	-0,799	-0,241	0,516	0,125
EV 7	0,130	-0,899	-0,367	0,072	-0,661	0,288
EV 8	0,347	0,371	-0,083	-0,425	-0,725	0,267
EV 9	0,088	0,767	-0,047	-0,197	-0,613	0,191

und 9.2 stark gegenüber λ_1 abfallen, besitzen die zugehörigen Eigenvektoren eine relativ ähnliche Orientierung, woraus geschlossen werden kann, dass die zweite reduzierte Dimension verwertbare Nutzinformationen beinhaltet und nicht nur durch Rauschen ihre Ausprägung erfährt.

Die Untersuchung der Orientierung der Eigenvektoren für die Zustände *Gehen* und *Hindernis* ist in der Tabelle 9.8 dargestellt. Auch hier sind die Vorzeichen der Merkmale in Tabelle 9.6 mit dem aus dem Skalarprodukt bestimmten Vorzeichen zu den Eigenvektoren konsistent. Bis zum Eigenvektor 3 weisen die reduzierten Merkmale eine gute Übereinstimmung in ihrer Orientierung auf. Insbesondere bei den Eigenvektoren 4 und 5 im Versuch 7 kann beobachtet werden, dass der reduzierte Merkmalsraum des Versuchs „a“ sich von jenen von „b“ und „c“ unterscheidet, die ihrerseits ähnliche Orientierungen aufweisen.

Bei den Eigenvektoren 6 bis 9 zeigt sich ein uneinheitlicheres Bild, das sich jedoch mit den Ergebnissen aus der Tabelle 9.3 deckt und ein weiteres Anzeichen ist, dass die Merkmale, die für die WKS-Erkennung¹ im *Gehen* verwendet werden, nur schwach ausgeprägt sind und sich in ihrer inneren Struktur unterscheiden. Somit kann für diese Merkmale keine Verallgemeinerbarkeit festgestellt werden.

¹vgl. benötigte reduzierte Dimension $\chi = 9$ in Abbildung 9.4


9.4 Willkürerkennung des hybriden Systems

Dieser Abschnitt soll exemplarische und typische Ergebnisse des in Abschnitt 8.2 beschriebenen Gesamtsystems zeigen. Die in Abschnitt 8.3 beschriebene zeitliche Filterung wird hier nicht angewendet, da die direkte Erkennungsgenauigkeit des Willkürsignals gegenüber dem als Referenz dienenden Handtaster demonstriert werden soll.

Die Abbildungen 9.5 und 9.6 zeigen die Ergebnisse zum Bewegungszustand *Stehen* und *Gehen* und haben folgenden Aufbau: Im obersten Diagramm je Abbildung ist das Klassifikationsergebnis der einzelnen SVMs dargestellt, die auf einen der vordefinierten Bewegungszustände eintrainiert wurden. Dabei wurden die SVM-Klassifikatoren ungeachtet des darunter angezeigten Bewegungszustands und somit ungeachtet des in der Abbildung 3.7 auf Seite 36 definierten Aktivierungssignals auf den Datensatz angewendet, damit die Klassifikationsgüte bei nicht passendem Bewegungszustand beurteilt werden kann. Der Bewegungszustand wurde gemäß Kapitel 7 ermittelt, und für eine Abschätzung und Anwendbarkeit der in Abschnitt 8.3 aufgeführten zeitlichen Filterung ist unterhalb des Bewegungszustands die prädizierte Gangphase ϕ angegeben. Das unterste Diagramm je Abbildung stellt das kombinierte Gesamtergebnis der Willkürerkennung dar, so wie es mittels (8.3) auf Seite 116 aus Bewegungszustand und EMG-Verarbeitung bestimmt wird.

Die Abbildung 9.5 zeigt das Ergebnis für den konstanten Bewegungszustand *Stehen*, der während der gesamten Messdauer mit annähernd 100% korrekt erkannt wird. Durch das *Stehen* liegt die Gangphase bei konstant Null. Es ist zu beobachten, dass alle SVM-Klassifikatoren auf das Willkürsignal ansprechen, wobei SVM_{Gehen} und $SVM_{\text{Hindernis}}$ beträchtliche Fehlklassifikationen aufweisen. Dies ist in dem in Abschnitt 9.2 gezeigten internen Unterschied der SVMs begründet. Lediglich die auf den Bewegungszustand optimierte SVM_{Stehen} führt zu einem korrekten Klassifikationsergebnis, das sich über den sehr eindeutig erkannten Bewegungszustand in das Endergebnis überführt, in dem alle steigenden Flanken des WKS-Signals korrekt detektiert werden. Lediglich bei $t = 13\text{ s}$ wird das Ende des WKS-Signals kurzfristig falsch erkannt, was jedoch durch die in Abschnitt 8.3 aufgeführten Überlegungen keine Auswirkung auf die Ansteuerung der Prothesenfunktion hätte.

In der Abbildung 9.6, die vom Zustand *Stehen* aus die Erkennung im Zustand *Gehen* zeigen soll, wurde vom Probanden bewusst zu unterschiedlichen Zeitpunkten innerhalb der Gangphase das WKS gegeben. Dies umfasst auch Zeitintervalle, in denen die in

Abbildung 9.5: Ergebnisse des Gesamtsystems zum Versuch *Stehen*

Abschnitt 8.3 geschilderte zeitliche Filterung aktiviert würde, die hier nicht berücksichtigt werden soll. Durch das unbelastete Prothesenbein wird zu Beginn der Messung kurzzeitig der falsche Bewegungszustand *Sitzen* detektiert, wobei zügig in den korrekten Zustand *Stehen* gewechselt wird, bevor das Loslaufen korrekt erkannt wird, was an den ebenfalls angegebenen prädierten Gangphasen ersichtlich ist.

Bei Betrachtung der einzelnen SVM-Klassifikatoren fällt auf, dass die SVM_{sitzen} und SVM_{stehen} während des *Gehens* versagen und kein verwertbares Klassifikationsergebnis liefern. Auch bei diesem Versuch liefert lediglich die auf den Bewegungszustand angepasste SVM_{gehen} ein korrektes Ergebnis in der Klassifikation. Die Hinderniserkennung beim Betreten der Treppe in der Bewegungsidentifikation korreliert korrekt mit der geschätzten Gangphase, da in der Schwungphase des Beins die Transition des Bewegungszustands stattfindet.

Wie bereits in der Abbildung 9.5 gezeigt, führt auch hier der eindeutige Bewegungszustand und das korrekte Ergebnis der SVM_{gehen} dazu, dass das Endergebnis der Will-

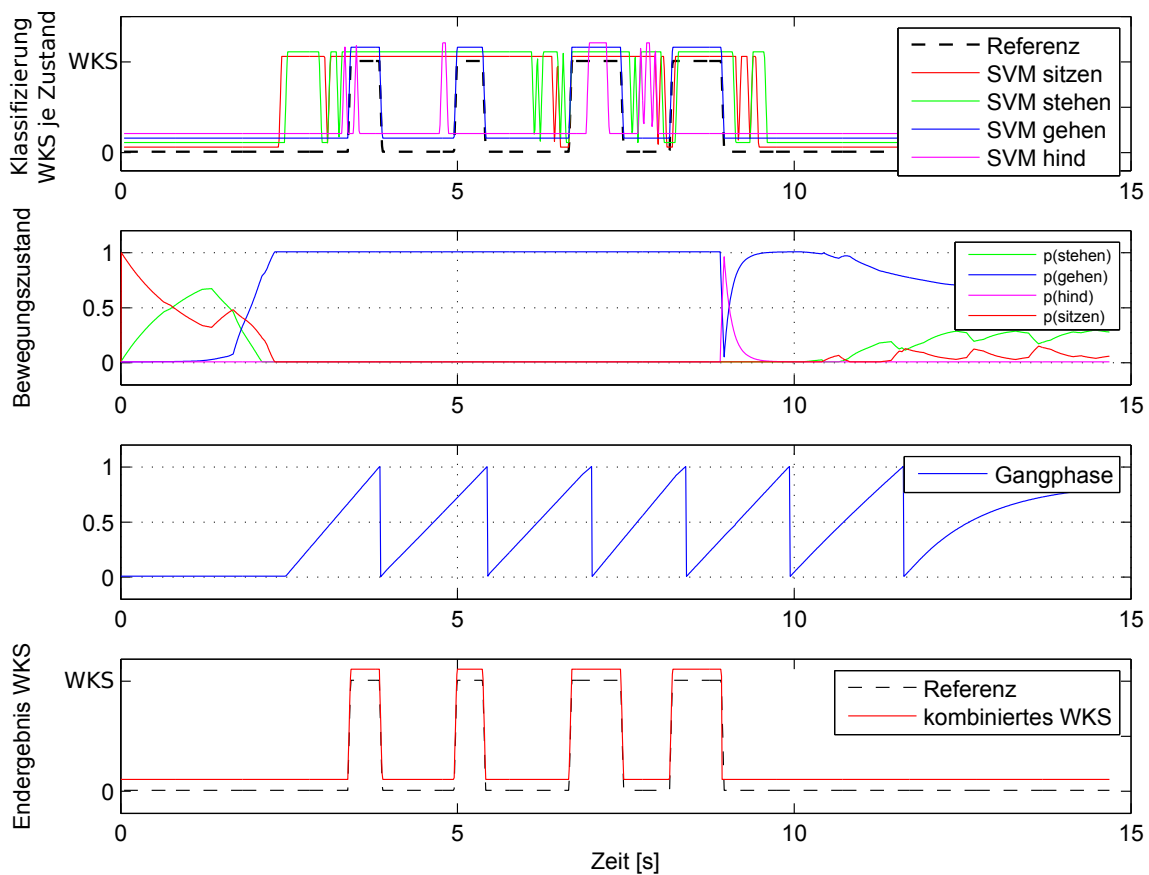


Abbildung 9.6: Ergebnisse des Gesamtsystems zum Versuch *Gehen und Hindernis*

küridentifikation mit der Referenz übereinstimmt.

9.5 Generalisierbarkeit der Support-Vector-Machine

Für die Bewegungszustände *Sitzen* und *Stehen* ergeben sich verallgemeinerbare Parametersätze, was aus den Tabellen 9.1, 9.2 und 9.5 sowie den Ergebnissen aus Tabelle 9.7 folgt.

Bei Betrachtung der Eigenwertverteilung in Tabelle 9.3 und der Merkmalsverteilung in Tabelle 9.6 zum Bewegungszustand *Gehen* und *Hindernis* kann im Zusammenhang mit der Abbildung 9.4 (korrekte Klassifikation erst bei $\chi = 9$) und den Ergebnissen aus der Tabelle 9.8 festgehalten werden, dass der von der PCA mittels Varianzanalyse angenommene Informationsgehalt der Merkmale sich nicht mit dem von der SVM

auf Basis der reduzierten Merkmale gewonnenen Trainings- und Klassifikationsergebnis deckt: Die für die Willkürsignal-Erkennung herangezogenen reduzierten Merkmale liegen somit in einem wenig ausgeprägten Unterraum² des ursprünglichen n-dimensionalen Merkmalsraums. Sie können somit nicht mit vergleichbarer Robustheit wie im Falle der Bewegungszustände *Sitzen* und *Stehen* bestimmt und isoliert werden, was zwangsläufig ein fein angepasstes und wiederholendes Nachlernen des SVM-Klassifikators für diese Bewegungszustände impliziert.

Die in Abbildung 6.5 auf Seite 88 eingezeichneten Support-Vektoren können für einen verallgemeinerten Parametersatz somit nicht direkt an den Randbereich der Margin gelegt werden, da dies zu Fehlklassifizierungen durch den schmalen Merkmalsunterraum führen kann. Sie müssen konservativ gewählt werden und dann durch ein gezieltes und inkrementelles Lernverfahren an den Randbereich herangeführt werden, wodurch sich die SVM-bestimmende Klassifikationsregel in (6.19) ergibt. Mit diesem Ansatz wird ein vollständiges Neu-Parametrisieren der SVM vermieden und der Initialisierungsprozess beschleunigt. In der folgenden Diskussion werden Ansätze und Methoden, die dies ermöglichen, aufgeführt.

²durch kleine λ_i in Tabelle 9.3 und ungleichförmige Orientierung in Tabelle 9.8 charakterisiert

10 Diskussion

In diesem Kapitel sollen die untersuchten und verwendeten Methoden und die mit ihnen gewonnenen Ergebnisse diskutiert und bewertet werden. Da diese Arbeit die Entwicklung und Evaluierung eines neuartigen Ansatzes für ein Willkürsteuerungssystem für Beinprothesen zum Gegenstand hat, werden nicht die erzielten Genauigkeiten betrachtet, sondern es wird untersucht, ob sich die theoretisch angenommenen und modellierten Systemeigenschaften in den Ergebnissen widerspiegeln.

Ferner sollen weitere Ansätze und Methoden für einzelne Module und Funktionsblöcke des Gesamtsystems dargestellt und angerissen werden, die im Rahmen der vorliegenden Arbeit nicht untersucht wurden und Anknüpfungspunkte für weiterführende Arbeiten darstellen können.

Eine Feldstudie stellt die logische Fortsetzung dieser Arbeit dar. In dieser könnte das Prinzip der Signalverarbeitung an einem größeren Personenkreis angewendet und untersucht werden, damit eine statistisch belastbare Auswertung möglich ist.

10.1 Bewegungserkennung

Wie in Kapitel 7 geschildert, baut die Bewegungserkennung hauptsächlich auf externen Merkmalen und Messgrößen auf. Parallel durchgeführte Experimente zur Bewegungserkennung am nicht-amputierten Probanden zeigten, dass dabei am Unterschenkel bei der mittels Gurtband befestigten Inertialsensorik wesentlich geringere Auftrittsbeschleunigungen gemessen werden und auch die Druckverteilung zwischen Ferse und Zeh sich anders gestaltet, da der Fuß über das Fußgelenk abknickt und damit den Auftritt dämpft. Bei der in den Messungen verwendeten Prothese erzeugte das Auftreten im Signal des Beschleunigungssensors einen sehr kurzzeitigen Spike durch die mechanische Steifigkeit, weswegen der Drucksensor an der Ferse notwendig wurde.

Das Erkennungssystem wurde daraufhin derart modifiziert, dass die Auftrittserkennung auch beim nicht-amputierten Probanden sicher erfolgt. Die Auftrittserkennung beim nicht-amputierten Probanden konnte über eine spektrale Analyse des vertikalen Beschleunigungssignals äquivalent durchgeführt werden, die bei der steifen Prothese durch den kurzen Spike nicht robust genug ausführbar ist.

Die anderen Winkelverlaufs-Merkmale bleiben davon unberücksichtigt. Somit kann dieses System auch bei einer Prothese mit aktivem Fußgelenk, welches beim Auftreten analog zum menschlichen Fußgelenk ausgelenkt wird, ebenfalls eingesetzt werden. Die Ziele des aktiven Fußgelenks, das durch das Willkürsignal angehoben werden kann, widersprechen sich somit nicht, und beide Funktionen können in eine Prothesen-Fuß-Einheit integriert und parallel ausgeführt werden. Für den Einsatz an einer aktiven Fußprothese kann dadurch die Komplexität des Sensorsystems reduziert werden, da der Fersen-Drucksensor entfallen könnte.

Die Winkelverlaufs-Merkmale wurden aus den Messungen bestimmt und auf den untersuchten Probanden angepasst. Durch die nur kurze mögliche Gangstrecke im Ganglabor konnten folgende Aspekte nicht untersucht werden: Abhängigkeit der Merkmale von der Ganggeschwindigkeit der Person und Abhängigkeit von probandenabhängigen Parametern wie der Beinlänge, die sicherlich eine Auswirkung darauf zeigen werden. Dies kann nur durch eine Vermessung einer größeren Anzahl von Personen ermittelt werden, sofern sich die gangspezifischen Charakteristika, die sich auf die Merkmale auswirken, nicht aus einem parametrisierbaren Biomechanik-Modell des Menschen extrahieren lassen (Schauer u. a., 2009).

Die Bestimmung der Merkmale ζ_i kann auch über eine automatisierte Merkmalsgenerierung durchgeführt werden, wobei jedoch keine Berücksichtigung der explizit modellierbaren Eigenschaften vorgenommen werden kann. Auch die Parameter des KALMAN-Filters, die in (7.7) iterativ bestimmt werden, können bei einer Erweiterung des Zustandsschätzers und Kenntnis des aktuell anliegenden Zustandes automatisch gelernt werden (von Rosenberg, 2006), indem der Zustandsvektor gemäß (10.1) um die Parameter α_i ergänzt wird, die die Konstanten in (7.7) ersetzen.

$$\tilde{\mathbf{x}} = [\mathbf{x}, \alpha_1, \dots, \alpha_n]^T \quad (10.1)$$

Zur Schätzung von α_i muss dann neben dem Zustandsvektor die Systemdynamik in (7.7) analog um eine Dynamikfunktion für α_i erweitert, und es muss die erlaubte Fle-

xibilität der α_i über die Definition eines virtuellen Parameter-Rauschens abgestimmt werden.

Der Vektor \mathbf{z} , der in (7.13) als Stützsystem eingeht, wird dann gemäß (10.2) erweitert, so dass bei bekanntem Bewegungszustand über (7.13) mit passend gewählten Lernfaktoren in der passend erweiterten (7.16) die automatische Bestimmung von α_i über (7.14) möglich ist. In (10.2) definiert $Z_i^{(ref)}$ den extern bestimmten Referenzzustand, wobei die Differenz minimiert werden soll, so dass $(Z_i^{(ref)} - Z_i) \rightarrow 0$ verlangt wird.

$$\tilde{\mathbf{z}} = \left[\mathbf{z}, Z_{sitzen}^{(ref)}, Z_{stehen}^{(ref)}, Z_{gehen}^{(ref)}, Z_{hind}^{(ref)} \right]^T \quad (10.2)$$

Diese automatisierte Parameterschätzung setzt jedoch länger andauernde Bewegungszustände voraus, damit ein guter Kompromiss zwischen Robustheit und Lernrate gefunden werden kann. Die Messungen im Ganglabor des Fraunhofer IPA lieferten dafür keine ausreichend langen Messreihen.

10.2 EMG-Signalverarbeitung

In Unterabschnitt 2.2.3 und in Abschnitt 3.1 wurde erörtert, dass das EMG-Signal prinzipiell personenabhängig ist und sich bereits bei einer einzelnen Person durch sich ändernde äußere und innere Faktoren unterscheiden kann. Die Ergebnisse zur EMG-Signalverarbeitung in dieser Arbeit zeigen, dass versuchsübergreifend die personenspezifischen Eigenschaften mit guter Näherung als konstant angenommen werden können. Eine Langzeit-Untersuchung am Probanden müsste dies abschließend klären.

10.2.1 Weiterentwicklung EMG-Array

Aktuelle weiterführende Arbeiten in der Projektgruppe haben eine Optimierung des EMG-Sensor-Arrays zum Ziel. Damit der Tragekomfort und die Qualität des EMG-Signals weiter gesteigert werden können, und die Integrationsfähigkeit in bestehende Prothesensysteme erhöht wird, wurde das in der Abbildung 10.1 gezeigte Folien-Array¹ aufgebaut, das aus einem zwischen zwei Folien geführten Leiterbahnsystem besteht

¹In Zusammenarbeit mit der Contag GmbH aufgebaut.




Abbildung 10.1: Flexibles EMG-Array auf Basis von Folien-Leiterbahnen

und einen hohen Grad an Flexibilität aufweist. Die isolierende Folie ist partiell durchbrochen, wodurch an diesen Stellen eine metallische Beschichtung durch Bedampfen aufgebracht werden konnte, die als quadratische Elektrode mit einer Kantenlänge von 5 mm dient. Aktuell stehen dabei folgende Fragen im Vordergrund:

- Auswahl des Beschichtungsmaterials für die Elektrode. Es muss die Bio-Kompatibilität nachgewiesen werden, und dieses Material muss im gewählten Beschichtungsprozess aufgebracht werden können.
- Entwurf und Abschirmung der Signalleitungen von Elektrode zu Signalverstärker.
- Integration von Signalverstärkern und AD-Wandlern, welche als Bare-Die direkt in die Folie hinter die Elektrode integriert werden, so dass die ungeschirmte und unverstärkte Signalstrecke möglichst kurz ist bzw. direkt digitale gemultiplixte Signale am Array zur Verfügung stehen.
- Kabelführung, da der scharfkantige Folienleiter nicht direkt auf der Haut geführt werden und den Silikon-Liner beschädigen kann.
- Integration der Drucksensorik in dieses EMG-Array, da der relative Anpressdruck geringer ist als bei den in dieser Arbeit untersuchten Arrays.
- Beschichtung der Elektroden mit einem elektrisch leitfähigen, dauerelastischen nichtklebenden Gel, das eine bessere und vor allem druckunabhängigere Signalkontaktierung ermöglicht und gleichzeitig den Tragekomfort erhöhen könnte, bei dem jedoch kein Kurzschluss zwischen den Elektroden durch das Gel auftreten darf.

Dieses Array sollte sich nicht mehr in die Haut eindrücken, weswegen sich die in dem Abschnitt 3.1 aufgeführten Effekte des Verschiebens auf der Hautoberfläche zeigen sollten.

Da dieses Array noch nicht einsatzbereit ist, konnte es im Rahmen der vorliegenden Arbeit nicht mehr berücksichtigt, untersucht und mit den in Unterabschnitt 4.1.1 vorgestellten EMG-Arrays verglichen werden.

10.2.2 Generierung virtuelles EMG

Der Ansatz aus Abbildung 3.4 auf Seite 30 zur Generierung eines skalaren virtuellen EMG-Signals zeigt gegenüber dem alternativen Ansatz aus Abbildung 3.3 die erwarteten Vorteile, die sich in einem einfacheren und einheitlicheren Mustererkennungssystem, geringerer benötigter Rechenleistung und insgesamt verbesserter Signalqualität und somit besserem Klassifikationsergebnis, wie in Abbildung 9.1 gezeigt, widerspiegeln.

Wenn die EMG-Einzelkanäle statt dem vEMG verwendet worden wären, dann müssten in der vorliegenden Konfiguration für die vier Bewegungszustände mit den 8 EMG-Kanälen somit 32 SVM-Klassifikatoren implementiert und parametrisiert werden. Es konnte gezeigt werden, dass mit dem vEMG die Komplexität der Signalverarbeitungsarchitektur reduziert werden kann bei gleichzeitiger Steigerung der Identifikationsleistung.

Die in den Tabellen 9.5 und 9.6 auf Seite 126 aufgeführten Merkmale, die hauptsächlich den reduzierten EMG-Merkmalsvektor bilden, setzen sich primär aus den Merkmalen zusammen, für die in der Tabelle 5.2 auf Seite 76 die Superposition gezeigt werden konnte. Somit tritt keine hinsichtlich der Mustererkennung qualitative Verschlechterung des Signals durch die Generierung des virtuellen EMG auf.

Andererseits konnte beobachtet werden, dass die Berechnung des virtuellen EMG von der Qualität der EMG-Einzelkanäle abhängt: Wenn auf allen EMG-Einzelkanälen kein Willkürsignal korrekt erkannt wurde, dann scheiterte auch das vEMG an der Erkennung. In diesem Fall ergeben sich jedoch trotzdem die Vorteile der sicheren Transitionsübergänge, in denen Fehlklassifizierungen verhindert werden, und die signifikant reduzierte Anforderung an die benötigte Rechenleistung auf dem Embedded-System. In den Auswertungen konnte der Effekt, dass sich das qualitative Signifikanzzentrum unterhalb des EMG-Arrays verschiebt, nicht beobachtet werden. Dies liegt daran, dass die verwendeten EMG-Arrays einen starken Anpressdruck innerhalb des Silikon-Liners

auf die Haut ausübten, der an dem in der Abbildung 4.3 auf Seite 41 gezeigten Abdruck in der Haut ersichtlich ist.

Für die Generierung des virtuellen EMG-Signals konnten alternative Ansätze und Erweiterungen formuliert werden, welche sich von dem in Abschnitt 5.2 beschriebenen System unterscheiden und im Folgenden skizziert werden sollen:

- Neben der klassischen Korrelation stellt eine abgewandelte und gewichtete HÄMMING-Ähnlichkeit einen Ansatz dar, bei der grob quantisierte EMG-Messwerte und weitere Merkmale zur Ähnlichkeitsbestimmung herangezogen werden. Die absolute Amplitude des EMG-Signals kann hierbei als relative Größe berücksichtigt werden, wenn eher der qualitative Signalverlauf und die aus ihm folgende Ähnlichkeit gefordert wird. Als Vorteil ergibt sich hier, dass kein Systemmodell und keine Annahmen über das Signal erforderlich sind.
- Statt der in Unterabschnitt 5.2.2 aufgeführten Korrelation kann die Signalähnlichkeit über eine Faltung der Signale bestimmt werden.
- Bei der Zustandsschätzung für vEMG-Signifikanz in (5.42) könnte die Geometrie zusätzlich berücksichtigt werden, wodurch die horizontale und vertikale Geschwindigkeit für die Verlagerung des EMG-Zentrums jeweils separat limitiert werden können.
- Anstatt das vollständige EMG-Signal untereinander zu vergleichen, kann auch das Leistungsspektrum der einzelnen EMG-Kanäle in verschiedenen Frequenzbändern verglichen werden (Mikut u. a., 2006). Hierbei bietet es sich an, Frequenzbänder zu wählen, in denen keine oder nur geringe Störungen erwartet werden.
- Der Signal-zu-Rauschabstand kann für die Selektion der EMG-Kanäle ebenfalls herangezogen werden, wenn beispielsweise die Signalspektren in den Intervallen $A = [25 \text{ Hz} \dots 100 \text{ Hz}]$, $B = [100 \text{ Hz} \dots 250 \text{ Hz}]$ und $C = [250 \text{ Hz} \dots 500 \text{ Hz}]$ bestimmt werden, und das Verhältnis A/B und C/B gebildet wird.
- Die in Unterabschnitt 5.2.1 aufgeführte Methode kann ebenfalls verwendet werden. Sie schätzt mittels Zustandsschätzer und Beobachtungen das EMG-Signal direkt und müsste im Rahmen der weiterführenden Forschungsarbeit untersucht werden. Auch die dann nötige Dynamik in der Schätzung des EMG-Signals bei Bewegungszustandsänderungen muss dabei berücksichtigt und evaluiert werden.

- Schließlich bietet sich ein Ansatz an, der nicht die EMG-Signale untereinander, sondern mit einem erwarteten Referenz-EMG-Signal vergleicht, wobei der Vergleich derart gestaltet sein muss, dass das zu detektierende Willkürsignal nicht als Störung identifiziert wird, da es im simulierten Referenzsignal naturgemäß nicht enthalten sein kann. Neben dieser Herausforderung ergibt sich eine weitere Schwierigkeit bei diesem Ansatz: Es muss das personenabhängige Referenzsignal definiert werden, welches sich tagesabhängig und bewegungszustandsabhängig verändern und nicht als langzeitstabil angenommen werden kann.

10.2.3 EMG-Merkmalsgenerierung und Klassifikation

Die Merkmale für die Mustererkennung des EMG-Systems wurden auf Basis der durchgeführten Literaturrecherche ausgewählt. Hierbei zeigte sich, dass der gewählte Ansatz zielführend war: Es wurde mit einer breiten Basis an EMG-Merkmalen begonnen, aus denen über die automatische Hauptachsentransformation relevante Merkmale von nicht relevanten getrennt oder linear kombiniert werden sollen.

Für die Merkmale des EMG-Signals aus Abschnitt 3.1 kann zusammengefasst werden, dass grobe Informationen allgemeingültig extrahiert werden können. Die Ergebnisse dieser Arbeit haben gezeigt, dass die verallgemeinerbaren Signalmerkmale für eine zuverlässige Erkennung insbesondere im *Gehen* nicht ausreichend sind, da hier bereits bei Messreihen von einer einzelnen Person der Merkmalsunterraum in Tabelle 9.6 und 9.8 nur schwach und uneinheitlich ausgeprägt ist.

Nach der automatisierten PCA-Analyse bleiben, wie in Abschnitt 9.2 geschildert, lediglich die Merkmale WL und WT mit nennenswertem Anteil an dem reduzierten Merkmalsvektor übrig. Mittels dieses Merkmalsvektors konnte für jeden Bewegungszustand ein SVM-Trainingssatz ermittelt werden, so dass eine korrekte Klassifizierung möglich ist.

Sollten die anderen Merkmale ebenfalls berücksichtigt werden, so müssten diese manuell an den Vektor \mathbf{q} angefügt werden (also ohne PCA), oder es müsste vor der PCA-Transformation eine Skalierung derart gewählt werden, dass diese Merkmale sich nicht erst in reduzierten Dimensionen größer 12 auswirken.

Der Schwerpunkt der Analyse der EMG-Verarbeitung und Erkennung wurde auf den Merkmalsraum gelegt, da durch eine feste Topologie mit ausgeprägten Trennbereichen

ein allgemein besseres Klassifikationsergebnis, eine reduzierte Komplexität des Klassifikators und eine bessere Verallgemeinerbarkeit folgt. Denn wenn sich bereits der Merkmalsraum strukturell von Versuch zu Versuch unterscheidet, dann kann daraus kein verallgemeinerter Klassifikator gewonnen werden.

In weiterführenden Untersuchungen und in einer eventuellen Feldstudie wäre zu prüfen, ob die anderen Merkmale, die im vorliegenden Fall im Merkmalsvektor \mathbf{q} nicht eingeflossen sind, zu einem personenunabhängigen Erkennungssystem führen bzw. welchen Einfluss die Testpersonen-Gruppe auf die Ausprägung und Gewichtung dieser Merkmale hat.

Aus den Auswertungen der Messreihen ergibt sich, dass für die Willkürsignal-Erkennung im *Sitzen* und im *Stehen* generell eine PCA mit reduzierter Dimension $\chi = 3$ eine sichere Erkennung ermöglicht. Für die Bewegungsformen *Gehen* und *Hindernis* musste eine reduzierte Dimension $\chi = 9$ gewählt werden, damit das Willkürsignal innerhalb des Gangs sicher erkannt werden kann. Bei einzelnen Messreihen konnte bereits mit $\chi = 6$ ein korrektes Klassifikationsergebnis erzielt werden, wobei sich bei Verwendung einer PCA mit $\chi = 9$ keine weitere Veränderung ergab.

In der Arbeit wurde bei dem SVM-Klassifikator generell der RBF-Kernel verwendet. Auch hier bietet es sich an zu untersuchen, ob die anderen in Unterabschnitt 6.3.5 vorgestellten Kernel bei einzelnen Bewegungszuständen ξ eine noch bessere Erkennungsrate bzw. eine geringere Rechenleistung bei vergleichbarer Erkennungsrate wie der RBF-Kernel haben oder den uneinheitlichen Merkmalsraum beim *Gehen* besser separieren können. Auch der notwendige individuelle Einlern- und Parametrisierungsaufwand wird hierdurch beeinflusst, da die weniger komplexen SVM-Kernel weniger Parameter besitzen, die an den jeweiligen Patienten in den nicht verallgemeinerbaren Zuständen angepasst werden müssen.

Es konnte in den Abbildungen 9.5 und 9.6 gezeigt werden, dass die implementierten SVM-Klassifikatoren nur in dem für sie ausgelegten Bewegungszustand ein verwertbares Klassifikationsergebnis liefern, weswegen die Bewegungszustandsschätzung für die Entscheidung zur Auswahl der jeweiligen SVM benötigt wird, wenn die Beinprothese in möglichst vielen Bewegungssituationen erwartungsgemäß funktionieren soll.

In der vorliegenden Arbeit wurden bei der EMG-Klassifikation gemäß (6.1) nur die Klassen „kein Willkürsignal“ und „Willkürsignal erkannt“ unterschieden. In Unterabschnitt 3.1.1 wurde die von Englehart u. a. (1999) gewonnene Erkenntnis aufgeführt, dass transiente EMG-Signale wertvolle Informationen beinhalten können. Somit könnte

eine Erweiterung der Anzahl der zu identifizierenden Klassen innerhalb des Mustererkennungssystems für das vEMG-Signal vorgenommen werden, wobei die Klassen *Willkür* (WKS), *Willkür steigend* (\uparrow), *Willkür fallend* (\downarrow) und *kein Willkür* (0) definiert werden könnten.

Diese Erweiterung ist ferner inspiriert durch das in der Abbildung 8.2 auf Seite 114 gezeigte Signalbild des virtuellen EMGs, in dem bei dem Willkürsignal im Zeitintervall $t = [3,3 s \dots 3,9 s]$ zu erkennen ist, dass sich das vEMG während des WKS signifikant ändert. Dies kann zwei Ursachen haben: nachlassende Muskelkraft oder destruktive Überlagerung des WKS mit der Gangbewegung. Mit den zusätzlich zu detektierenden Klassen kann eine logische und wahrscheinlichkeitsbasierte Kette aufgebaut werden, mit der in einem separaten Prozess die Klassifikation überwacht wird. Wie bereits geschildert, ist wegen der Echtzeitanforderungen die erkannte steigende Flanke des WKS relevant, weswegen die Sequenz an erkannten Klassen „0, \uparrow , WKS, \downarrow , 0“ nicht für die Ausgabe des WKS an die aktive Prothese herangezogen werden kann. Ausnahmen davon stellen Bewegungszustände wie das *Stehen* oder das *Gehen* dar, in denen durch nicht überlappende Zeitfenster für WKS-Erkennung und WKS-Aktion diese Sequenz die Falsch-Positiv-Rate der Erkennung reduzieren kann.

Für das Training und die Plausibilisierung könnte auch hier die in Kapitel 7 vorgestellte Gangphasenerkennung unterstützend wirken. Damit könnte das System erweitert werden zu einem „nachlernenden“ System.

Nach Au u. a. (2005) sollen zukünftige EMG-Prothesensysteme über ein echtzeitfähiges und selbst lernendes Erkennungssystem verfügen. Hierbei bleiben jedoch zwei zentrale Punkte ungelöst, welche in dieser Arbeit behandelt wurden: Automatische und ausreichend schnelle Anpassung an die verschiedenen Bewegungszustände und insbesondere das ausreichend sichere Merkmal, welches dem automatisch lernenden System das WKS anzeigt, sofern keine weiteren Hilfsmittel wie der zeitlich parallel betätigte Handtaster verwendet werden.

Hierbei bietet sich das in Unterabschnitt 2.2.4 vorgestellte Ultraschall-System an. Es kann insbesondere für das automatische Nachlernen interessant sein, da eine unabhängige und objektive Beobachtung des Muskels durchgeführt werden kann. Eine Strategie zur Vermeidung der in Unterabschnitt 2.2.4 aufgeführten Nachteile besteht darin, dass das Willkürsignal hauptsächlich mittels Oberflächen-EMGs gemessen wird, aber zum täglichen Einrichten oder bei Unsicherheit in dem Klassifikationsergebnis oder zyklischer Validierung temporär das Ultraschall für die Signalerkennung und das Nachtrai-

ning der Mustererkennung herangezogen werden kann, wodurch die Schallenergieeinträge in das Gewebe auf kurze Zeitintervalle begrenzt bleiben.

Durch die Schaffung von Signalpfaden mit minimaler Latenz und die Verwendung von überlappenden Signalverarbeitungsfenstern konnte gezeigt werden, dass die geforderte Echtzeitfähigkeit eingehalten werden kann, wobei die in Abschnitt 8.3 geschilderten Randbedingungen und Überlegungen zeigen, dass zwischen dem Echtzeitverhalten bei Arm- und Beinprothesen generell unterschieden werden muss.

10.2.4 Implementierung

In dieser Arbeit wurde aufgezeigt, wie eine ressourcenschonende Implementierung auf einem echtzeitfähigen Embedded-System realisiert werden kann. Für die konkrete Implementierung und Anwendung am Patienten können ferner folgende Aspekte berücksichtigt werden:

- Bei der Berechnung des virtuellen EMGs kann ergänzend zu Unterabschnitt 10.2.2 Rechenbedarf gespart werden, wenn nicht alle Kanäle kreuzweise in jedem Zyklus-schritt verglichen werden, sondern nur jene Kanäle, die bereits eine wesentliche Signifikanz erreicht haben. Somit findet ein Vergleich der $L - 1$ EMG-Kanäle mit dem besten EMG-Kanal, welcher als „Master-Kanal“ und Referenz dient, statt. Hierbei ist die Berücksichtigung einer Ansprechschwelle zur Übernahme anderer Kanäle als „Master-Kanal“ wichtig, da andernfalls Störungen auf dem „Master-Kanal“ nicht erkannt und herausgefiltert werden können.
- Die PCA-Matrix Γ_χ^T in (6.10) wird nicht aufgrund der gewonnenen Messwerte dynamisch berechnet, sondern statisch vorgegeben. Damit können ebenfalls Merkmale in der Berechnung entfallen, die durch Γ_χ^T keine Berücksichtigung erfahren, was den übergreifenden Aufwand in der Berechnung zusätzlich reduziert.
- Die sich an die PCA-Transformation anschließende Skalierung der reduzierten Merkmale q_i im Echtzeiteinsatz muss ebenso über einen vorbestimmten Betrag \tilde{q}_i erfolgen. Hierbei kann \tilde{q}_i das Ergebnis einer tagesaktuellen Initialisierung sein oder durch einen parallel ablaufenden Prozess abgebildet werden, der anhand der über einen längeren Zeitraum aufgezeichneten Messwerte das \tilde{q}_i dynamisch berechnet und nachführt, wobei es bezüglich der Identifikation eines konkreten Willkürsignals als statische Größe betrachtet wird.

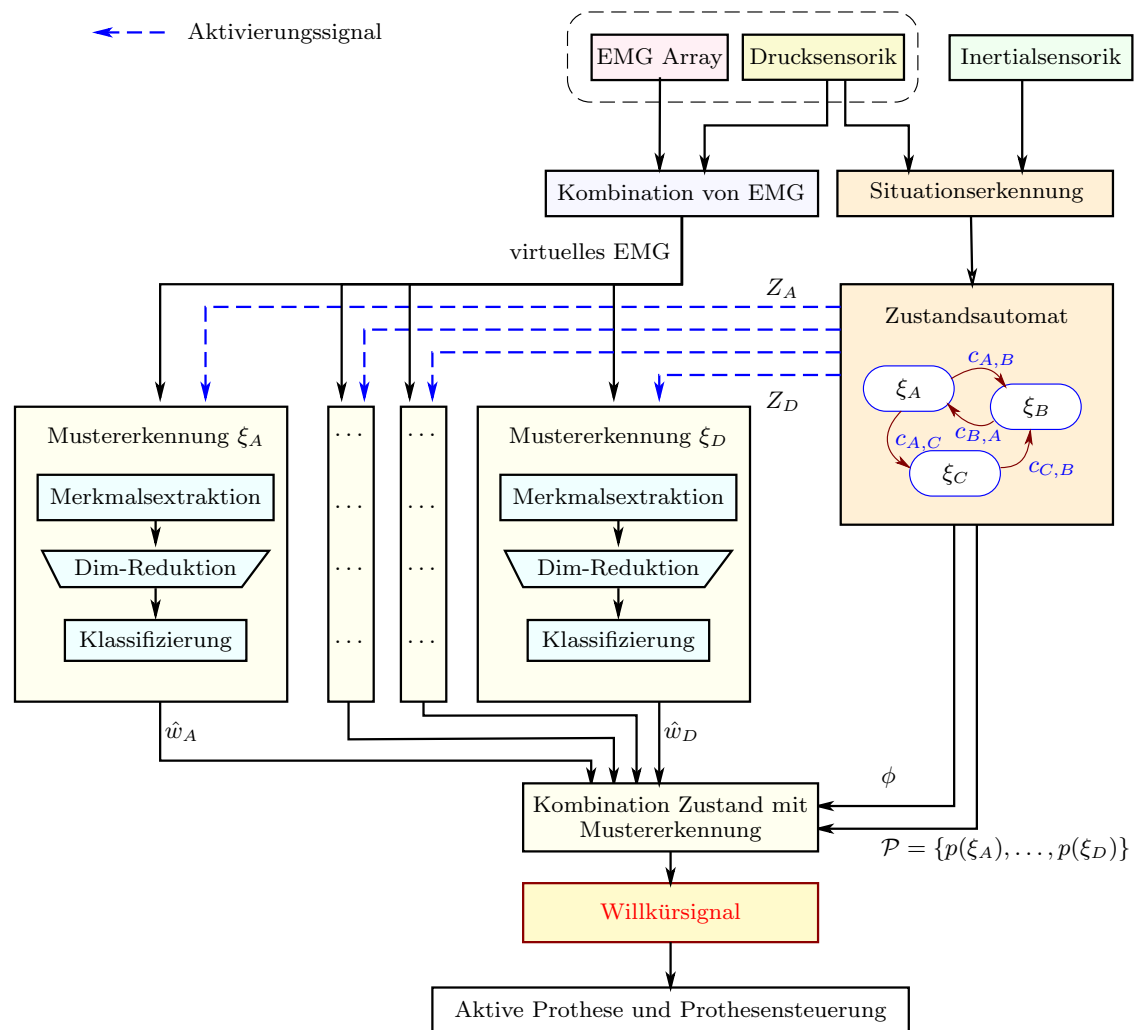


Abbildung 10.2: Final umgesetzte Architektur des Gesamtsystems

- Die Ansprechschwelle, anhand der ein zu einem Bewegungszustand gehörender Klassifikator aktiviert wird, kann erhöht werden, so dass maximal zwei gleichzeitige EMG-Mustererkennungssysteme parallel laufen, was durch die in (8.3) im Abschnitt 8.2 gezeigte Kombinationslogik begründet werden kann.

10.3 Gesamtsystem

Die Abbildung 10.2 zeigt abschließend die Systemarchitektur, wie sie letztendlich im Rahmen der vorliegenden Arbeit implementiert wurde. Die einzelnen Mustererkennungsblöcke ξ_i sind vollständig isoliert, da sie über Z_i individuell aktiviert werden. Zwar

könnte wie in der Abbildung 3.7 auf Seite 36 eine gemeinsame Merkmalsextraktions-Einheit verwendet werden, jedoch zeigte sich im Zusammenspiel der Merkmalsextraktion und Dimensionsreduktion, dass für einfach zu beschreibende Zustände wie *Sitzen* eine wesentlich einfachere Merkmalsextraktion gegenüber dem Zustand *Gehen* ausreichend ist, weswegen die Merkmalsextraktion formell aufgegliedert und den separaten Mustererkennungseinheiten ξ_i zugeordnet wird.

Je Bewegungszustand ξ_i wurde ein angepasster Satz von SVM-Parametern verwendet, und die SVM-Klassifikatoren wurden auf Merkmalsvektoren unterschiedlicher Dimension angewendet, was bereits in der angepassten Architektur in Abbildung 3.7 prinzipiell berücksichtigt wurde.

Das Signalverarbeitungssystem in Abbildung 10.2 enthält drei unabhängige Merkmalsextraktions-Systeme (Bewegungszustand in Abschnitt 7.3, Generierung virtuelles EMG in Unterabschnitt 5.2.2 und Mustererkennung EMG in Abschnitt 5.1) sowie drei unabhängige Zustandsschätzer auf Grundlage eines erweiterten KALMAN-Filters (Orientierungs- und Lagewinkelberechnung innerhalb der IMU aus Unterabschnitt 4.1.3, Schätzung und Prädiktion von Bewegungszustand in Unterabschnitt 7.4.2 und Generierung virtuelles EMG in Unterabschnitt 5.2.3). Jeder EMG-Mustererkennungsblock baut auf einer Support-Vector-Machine als Klassifikator (Unterabschnitt 6.3.5) auf.

10.4 Fazit

Diese Arbeit zeigt, dass die Bewegungskontrolle der Beinprothese erst durch die Kombination der eigentlichen Willkürsignal-Identifikation auf Basis des EMG-Signals und der Bewegungszustandserkennung inklusive Echtzeitgangphasenabschätzung zu einem funktionalen und sicheren Gesamtsystem wird.

Bei einer mit dem vorgestellten Sensorsystem ausgerüsteten aktiven Beinprothese dürfte insbesondere im *Gehen* bezüglich des wiederholenden Fußanhebens den Informationen aus der Bewegungserkennung eine höhere Bedeutung als jenen aus dem EMG-Willkürsignal zukommen, da sich die Prothesenregelung im Gang auf ein zyklisches Regelungsprofil analog der Gangbewegung einregeln soll. Der Prothesenträger kann dadurch vom wiederholenden Geben des Willkürsignals entlastet werden.

Durch den vorgestellten Ansatz ist das Gesamtsystem nicht mehr auf einen speziellen Bewegungszustand limitiert und es benötigt auch keine definierte Anzahl an bereits zurückgelegten Schritten des Prothesenträgers, bevor eine Aktion erfolgt.

Auch wenn im *Gehen* die kontinuierliche und zyklische Prothesen-Regelung verstärkt die Gangphasenerkennung verwendet, so bleibt der Vorteil bestehen, dass im Rahmen der in Abschnitt 8.3 eingeführten Limitierungen jederzeit ein Willkürsignal vom Prothesenträger gegeben werden kann, das vom Willkür-Erkennungssystem detektiert und ausgewertet wird. Dies weist insbesondere für den untersuchten Fall des Hindernisses beziehungsweise der ersten Treppenstufen größte Relevanz auf.

Durch den modularen Ansatz mit einfachen Schnittstellen können die einzelnen Teilfunktionalitäten bei anstehenden Weiterentwicklungen und einem notwendigen Feldversuch, der mehr als einen Probanden einschließt, getestet und weiter optimiert werden, so dass die Verallgemeinerbarkeit und einfache Adaptierbarkeit an den jeweiligen Prothesenträger einen Grad erreicht, welcher für ein Seriengerät geeignet und Voraussetzung ist. Auch EMG-Willkürsteuerungen für Handprothesen können durch die in dieser Arbeit vorgestellten Ansätze wie dem virtuellen EMG oder der integrierten Bewegungsdynamikerfassung robuster gemacht werden.

Durch aktuelle modulare Prothesensysteme, aus denen baukastenartig individuelle Lösungen erstellt werden können, können bereits existierende Systeme (z. B. aktiver Fuß *Proprio* aus Unterabschnitt 2.3.5) mit dem in dieser Arbeit vorgestellten Erkennungssystem, das in den Prothesenschaft integriert wird, kombiniert werden.

Dies setzt jedoch voraus, dass es einheitliche und standardisierte Schnittstellen zwischen den Prothesen-Modulen gibt. Während in mechanischer Hinsicht diese Schnittstellen bereits existieren, so besteht bei den elektrischen Signalverbindungen und den darüber laufenden Kommunikationsprotokollen noch Forschungs- und Entwicklungsbedarf, wobei einige Hersteller durch proprietäre Lösungen ihr Produktsortiment gegenüber Konkurrenten abzuschirmen versuchen. Durch die Standardisierung und Normung der Kommunikationsschnittstellen und Kommunikationsprotokolle könnten in Zukunft einzelne Prothesenelemente über einen „Prothesen-Bus“ Sensormesswerte, Zustandsgrößen und Aktuatorsignale austauschen, so dass aus Prothesen-Einzelkomponenten ein optimal abgestimmtes Gesamtsystem für den Prothesenträger aufgebaut werden kann.

Dadurch werden die Marktakzeptanz und die Einsatzmöglichkeiten von aktiven Prothesensystemen gesteigert. Lösungsvorschläge, wie das in dieser Arbeit beschriebene Sensorsystem, das in den Prothesenschaft integriert ist und Aktorsignale an den Fuß sendet und von diesem im Gegenzug Sensorwerte erhält, lassen sich dann als Seriengerät besser realisieren.

Literaturverzeichnis

- [Achilles 1987] ACHILLES, M.:
Zur Lösung der Yule-Walker-Gleichungen.
In: *Metrika* 34 (1987), S. 237–251.
<http://dx.doi.org/10.1007/BF02613155>. –
DOI 10.1007/BF02613155
- [Albrecht-Laatsch 2009] ALBRECHT-LAATSCH, Erik:
Matrix-Controller-Method for Adjusting a System that is modified in a
Cycle to a non-constant cyclical Target Profile.
In: *ECas news - The European Adaptronics Network* 02 (2009), S. 2–6
- [Au u. a. 2006] AU, S. K. ; DILWORTH, P. ; HERR, H.:
An ankle-foot emulation system for the study of human walking biome-
chanics.
In: *Proc. IEEE International Conference on Robotics and Automation
ICRA 2006*.
Orlando, Florida, USA, 15–19 May 2006, S. 2939–2945
- [Au u. a. 2005] AU, Samuel K. ; BONATO, Paolo ; HERR, Hugh:
An EMG-position controlled system for an active ankle-foot prosthesis:
an initial experimental study.
In: *Proc. 9th Int. Conf. Rehabilitation Robotics ICORR 2005*.
Chicago, Illinois, 2005, S. 375–379
- [Boschmann u. a. 2009] BOSCHMANN, Alexander ; KAUFMANN, Paul ; PLATZNER, Mar-
co ; WINKLER, Michael:
Towards Multi-movement Hand Prostheses: Combining Adaptive Classi-
fication with High Precision Sockets.
In: *Proceedings of the 2nd European Conference on Technically Assisted
Rehabilitation (TAR'09)*.
Berlin, Germany, 2009
- [Boser u. a. 1992] BOSER, Bernhard E. ; GUYON, Isabelle M. ; VAPNIK, Vladimir N.:
A training algorithm for optimal margin classifiers.
In: *COLT '92: Proceedings of the fifth annual workshop on Computational
learning theory*.
New York, NY, USA : ACM Press, 1992. –
ISBN 089791497X, 144–152

- [Burck u. a. 2009] BURCK, James ; ZEHER, Michael J. ; ARMIGER, Robert ; BEATY, James D.:
Entwicklung der modernsten Armprothese der Welt mit Model-Based Design / Applied Physics Laboratory der Johns Hopkins University.
Version: 2009.
<http://www.mathworks.de/mason/tag/proxy.html?dataid=12443>.
2009. –
Forschungsbericht
- [Burges 2004] BURGES, Christopher J.:
A Tutorial on Support Vector Machines for Pattern Recognition.
Boston: Kluwer Academic Publishers, 2004
- [Burmeister u. a. 2006] BURMEISTER, Ole ; REISCHL, Markus ; GRÖLL, Lutz ; MIKUT, Ralf:
Zeitvariante Klassifikatoren zur Steuerung von Brain Machine Interfaces und Neuroprothesen (Time-variant Classifiers to Control Brain Machine Interfaces and Neuroprostheses).
In: *Automatisierungstechnik* 54 (2006), Nov., S. 537–545
- [Chan u. Englehart 2005] CHAN, Adrian D C. ; ENGLEHART, Kevin B.:
Continuous myoelectric control for powered prostheses using hidden Markov models.
In: *IEEE Trans Biomed Eng* 52 (2005), Nr. 1, S. 121–124.
<http://dx.doi.org/10.1109/TBME.2004.836492>. –
DOI 10.1109/TBME.2004.836492
- [Chan u. a. 2000] CHAN, F. H. Y. ; YANG, Yong-Sheng ; LAM, F. K. ; ZHANG, Yuan-Ting ; PARKER, P. A.:
Fuzzy EMG classification for prosthesis control.
In: *IEEE Transactions on Rehabilitation Engineering* 8 (2000), Nr. 3, S. 305–311.
<http://dx.doi.org/10.1109/86.867872>. –
DOI 10.1109/86.867872
- [Chang u. Lin 2001] CHANG, Chih-Chung ; LIN, Chih-Jen:
LIBSVM: a library for support vector machines, 2001. –
Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- [Chen u. a. 2006a] *Kapitel Gait Recognition Using Hidden Markov Model*.
In: CHEN, Changhong ; LIANG, Jimin ; ZHAO, Heng ; HU, Haihong:
Advances in Natural Computation.
Berlin, Heidelberg : Springer, 2006, S. 399–407
- [Chen u. a. 2009] CHEN, Changhong ; LIANG, Jimin ; ZHAO, Heng ; HU, Haihong ; TIAN, Jie ; TIAN, Jie:
Factorial HMM and Parallel HMM for Gait Recognition.

- In: *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews* 39 (2009), Nr. 1, S. 114–123.
<http://dx.doi.org/10.1109/TSMCC.2008.2001716>. –
DOI 10.1109/TSMCC.2008.2001716
- [Chen u. a. 2006b] CHEN, Yu-Jen ; WANG, Chin-Chang ; JONG, Gwo-Jia ; WANG, Boi-Wei:
The Separation System of the Speech Signals Using Kalman Filter with Fuzzy Algorithm.
In: *Innovative Computing, Information and Control, 2006. ICICIC '06. First International Conference on* Bd. 1.
Beijing, 30-01 Aug. 2006, S. 603–606
- [Cherkassky u. Ma 2002] CHERKASSKY, Vladimir ; MA, Yunqian:
Practical selection of SVM parameters and noise estimation for SVM regression.
[http://dx.doi.org/10.1016/S0893-6080\(03\)00169-2](http://dx.doi.org/10.1016/S0893-6080(03)00169-2).
Version: 2002
- [Chu u. a. 2006] CHU, Jun-Uk ; MOON, Inhyuk ; MUN, Mu-Seong:
A supervised feature projection for real-time multifunction myoelectric hand control.
In: *Conf Proc IEEE Eng Med Biol Soc* 1 (2006), 2417–2420.
<http://dx.doi.org/10.1109/IEMBS.2006.259659>. –
DOI 10.1109/IEMBS.2006.259659
- [Cooley u. Tukey 1965] COOLEY, James W. ; TUKEY, John W.:
An algorithm for the machine calculation of complex Fourier series.
In: *Math. Comput* 19 (1965), S. 297–301
- [Dennerlein 2009] DENNERLEIN, Florian:
Merkmalsextraktion und Klassifizierung des EMG-Signals im Beinprothesenshaft zur adaptiven Willkürsteuerung.
Fraunhofer IPA, Nobelstraße 12, 70569 Stuttgart, Eberhard Karls Universität Tübingen, Diplomarbeit, 2009. –
Betreuer: Harald von Rosenberg
- [Disselhorst-Klug u. a. 2000] DISSELHORST-KLUG, C. ; BAHM, J. ; RAMAEKERS, V. ; TRACHTERNA, A. ; RAU, G.:
Non-invasive approach of motor unit recording during muscle contractions in humans.
In: *Eur J Appl Physiol* 83 (2000), Nr. 2-3, S. 144–150
- [Drews 1999] DREWS, Martin:
Mikrofonarrays und mehrkanalige Signalverarbeitung zur Verbesserung gestörter Sprache.
Berlin, Technische Universität, Diss., 1999.
<http://elvera.nue.tu-berlin.de/files/0010Drews1999.pdf>

- [Engelhart 1998] ENGELHART, Kevin B.:
Signal Representation for Classification of the Transient Myoelectric Signal.
Fredericton und Saint John, Canada, University of New Brunswick, Diss., 1998
- [Englehart u. a. 2001] ENGLEHART, K. ; HUDGIN, B. ; PARKER, P. A.:
A wavelet-based continuous classification scheme for multifunction myoelectric control.
In: *IEEE Transactions on Biomedical Engineering* 48 (2001), March, Nr. 3, S. 302–311.
<http://dx.doi.org/10.1109/10.914793>. –
DOI 10.1109/10.914793
- [Englehart u. a. 1999] ENGLEHART, K. ; HUDGINS, B. ; PARKER, P. A. ; STEVENSON, M.:
Classification of the myoelectric signal using time-frequency based representations.
In: *Med Eng Phys* 21 (1999), Nr. 6-7, S. 431–438
- [Eshel] ESHEL, Gidon:
The Yule Walker Equations for the AR Coefficients, <http://www-stat.wharton.upenn.edu/~steele/Courses/956/Resource/YWSourceFiles/YW-Eshel.pdf>
- [Farina u. Merletti 2000] FARINA, D ; MERLETTI, R:
Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions.
In: *J Electromyogr Kinesiol* 10 (2000), Nr. 5, S. 337–349
- [Fink 2003] FINK, Gernot A.:
Mustererkennung mit Markov-Modellen.
Stuttgart : Vieweg+Teubner Verlag, 2003
- [Fisher 1936] FISHER, Ronald A.:
The use of multiple measurements in taxonomic problems.
In: *Annals of Eugenics* 7 Nr. 2 (1936), S. 179–188
- [Fuglevand u. a. 1992] FUGLEVAND, A. J. ; WINTER, D. A. ; PATLA, A. E. ; STASHUK, D.:
Detection of motor unit action potentials with surface electrodes: influence of electrode size and spacing.
In: *Biol Cybern* 67 (1992), Nr. 2, S. 143–153
- [Gan u. Harris 2001] GAN, Q. ; HARRIS, C.J.:
Comparison of two measurement fusion methods for Kalman-filter-based multisensor data fusion.
In: *IEEE Transactions on Aerospace and Electronic Systems* 37 (2001), Nr. 1, S. 273–279.

<http://dx.doi.org/10.1109/7.913685>. –
DOI 10.1109/7.913685

- [Gesch 2000] GESCH, G.:
Computer-assisted evaluation of surface electromyograms of 8 different arm muscles.
In: *Biomed Tech* 45 (2000), Nr. 1-2, S. 2–5
- [Glette u. a. 2008a] GLETTE, Kyrre ; GRUBER, Thiemo ; KAUFMANN, Paul ; TORRESEN, Jim ; SICK, Bernhard ; PLATZNER, Marco:
Comparing Evolvable Hardware to Conventional Classifiers for Electromyographic Prosthetic Hand Control.
In: *Proceedings 3rd NASA/ESA Conference on Adaptive Hardware and Systems (AHS)*.
Noordwijk, The Netherlands : IEEE Computer Society, 2008, S. 32–39
- [Glette u. a. 2008b] GLETTE, Kyrre ; TORRESEN, Jim ; KAUFMANN, Paul ; PLATZNER, Marco:
A Comparison of Evolvable Hardware Architectures for Classification Tasks.
In: *Evolvable Systems: From Biology to Hardware (ICES)*.
Prague, Czech Republic : Springer, 2008. (LNCS)
- [Gray 1918] GRAY, Henry:
Anatomy of the Human Body, by Henry Gray. 20th ed., thoroughly rev. and re-edited by Warren H. Lewis.
Philadelphia: Lea & Febiger, 1918
- [Hafner u. Bachmann 2008] HAFNER, V. V. ; BACHMANN, F.:
Human-Humanoid walking gait recognition.
In: *Proc. 8th IEEE-RAS International Conference on Humanoid Robots Humanoids 2008*.
Daejeon, Republic of Korea, 1–3 Dec. 2008, S. 598–602
- [Hakkaki-Fard 2008] HAKKAKI-FARD, H. Ahmadi-Noubari; A. Pourshaghaghay; F. Kowsary; A.:
Wavelet application for reduction of measurement noise effects in inverse boundary heat conduction problems.
In: *International Journal of Numerical Methods for Heat & Fluid Flow* 18 (2008), S. 217–236
- [Hargrove u. a. 2007] HARGROVE, L. ; LOSIER, Y. ; LOCK, B. ; ENGLEHART, K. ; HUDGINS, B.:
A real-time pattern recognition based myoelectric control usability study implemented in a virtual environment.
In: *Conf Proc IEEE Eng Med Biol Soc 2007* (2007), 4842–4845.
<http://dx.doi.org/10.1109/IEMBS.2007.4353424>. –
DOI 10.1109/IEMBS.2007.4353424

- [Hargrove u. a. 2009] HARGROVE, L. J. ; HUANG, H. ; SCHULTZ, A. E. ; LOCK, B. A. ; LIPSCHUTZ, R. ; KUIKEN, T. A.:
Toward the development of a neural interface for lower limb prosthesis control.
In: *Proc. Annual Int. Conf. of the IEEE Engineering in Medicine and Biology Society EMBC 2009*.
Minneapolis, Minnesota, USA, 2009, S. 2111–2114
- [Huang u. a. 2008] HUANG, He ; ZHOU, Ping ; LI, Guanglin ; KUIKEN, Todd A.:
An Analysis of EMG Electrode Configuration for Targeted Muscle Reinnervation Based Neural Machine Interface.
In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 16 (2008), Nr. 1, S. 37–45.
<http://dx.doi.org/10.1109/TNSRE.2007.910282>. –
DOI 10.1109/TNSRE.2007.910282
- [Hudgins u. a. 1993] HUDGINS, B. ; PARKER, P. ; SCOTT, R. N.:
A new strategy for multifunction myoelectric control.
In: *IEEE Transactions on Biomedical Engineering* 40 (1993), Nr. 1, S. 82–94.
<http://dx.doi.org/10.1109/10.204774>. –
DOI 10.1109/10.204774
- [Isakov u. a. 2000] ISAKOV, E. ; KEREN, O. ; BENJUYA, N.:
Trans-tibial amputee gait: time-distance parameters and EMG activity.
In: *Prosthet Orthot Int* 24 (2000), Nr. 3, S. 216–220
- [Johansson u. a. 2005] JOHANSSON, Jennifer L. ; SHERRILL, Delsey M. ; RILEY, Patrick O. ; BONATO, Paolo ; HERR, Hugh:
A clinical comparison of variable-damping and mechanically passive prosthetic knee devices.
In: *Am J Phys Med Rehabil* 84 (2005), Nr. 8, S. 563–575
- [Kealy u. a. 2007] KEALY, Allison ; RETSCHER, Günther ; WINTER, Stephen:
Strategies for Development – Next Generation Mobile Mapping Systems.
In: *European Journal of Navigation* 5 (2007), Nr. 3, S. 6–13
- [Khezri u. Jahed 2007] KHEZRI, Mahdi ; JAHED, Mehran:
Real-time intelligent pattern recognition algorithm for surface EMG signals.
In: *Biomed Eng Online* 6 (2007), S. 1–12.
<http://dx.doi.org/10.1186/1475-925X-6-45>. –
DOI 10.1186/1475-925X-6-45
- [Klasen 2008] KLASSEN, Sebastian:
Sensorsystemintegration zur Erkennung von Bewegungsmustern zur aktiven Steuerung eines Prothesenfußes und methodische Konstruktion geeigneter Prüfschäfte.

Fraunhofer IPA, Nobelstraße 12, 70569 Stuttgart, Fachhochschule Münster, Diplomarbeit, 2008

- [Konrad 2005] KONRAD, Peter:
ABC of EMG.
<http://www.velamed.com/downloads/EMG-Fibel.pdf>.
Version: 2005
- [Koyama u. a. 2005] KOYAMA, T. ; TANAKA, T. ; KANEKO, S. ; MOROMUGI, S. ; FENG, M. Q.:
Integral ultrasonic muscle activity sensor for detecting human motion.
In: *Proc. IEEE International Conference on Systems, Man and Cybernetics* Bd. 2, 2005, S. 1669–1674
- [Kuiken u. a. 2009] KUIKEN, Todd A. ; LI, Guanglin ; LOCK, Blair A. ; LIPSCHUTZ, Robert D. ; MILLER, Laura A. ; STUBBLEFIELD, Kathy A. ; ENGLEHART, Kevin B.:
Targeted Muscle Reinnervation for Real-time Myoelectric Control of Multifunction Artificial Arms.
In: *JAMA* 301 (2009), Nr. 6, 619–628.
<http://dx.doi.org/10.1001/jama.2009.116>. –
DOI 10.1001/jama.2009.116
- [Kumar u. Mital 1996] KUMAR, S. ; MITAL, A.:
Electromyography in Ergonomics.
London : Taylor&Francis, 1996
- [Laubach u. a. 2008] LAUBACH, Hans J. ; MAKIN, Inder R S. ; BARTHE, Peter G. ; SLAYTON, Michael H. ; MANSTEIN, Dieter:
Intense focused ultrasound: evaluation of a new treatment modality for precise microcoagulation within the skin.
In: *Dermatol Surg* 34 (2008), Nr. 5, 727–734.
<http://dx.doi.org/10.1111/j.1524-4725.2008.34196.x>. –
DOI 10.1111/j.1524-4725.2008.34196.x
- [Lee u. Choi 2003] LEE, Hyekyung ; CHOI, Seungjin:
PCA+HMM+SVM for EEG pattern classification.
In: *Signal Processing and Its Applications, 2003. Proceedings. Seventh International Symposium on* Bd. 1.
Paris, France, 1-4 July 2003, S. 541–544
- [Lee u. Lee 2005] LEE, Ju-Won ; LEE, Gun-Ki:
Gait Angle Prediction for Lower Limb Orthotics and Prostheses Using an EMG Signal and Neural Networks.
In: *International journal of control automation and systems* 3 (2005), Nr. 2, S. 152–158

- [Lee 2008] LEE, Ki-Seung:
SNR-adaptive stream weighting for audio-MES ASR.
In: *IEEE Trans Biomed Eng* 55 (2008), Nr. 8, 2001–2010.
<http://dx.doi.org/10.1109/TBME.2008.921094>. –
DOI 10.1109/TBME.2008.921094
- [Lombardi u. Godsill 2005] LOMBARDI, Marco J. ; GODSILL, Simon J.:
On-line Bayesian estimation of AR signals in symmetric alpha-stable noise.
<http://dx.doi.org/10.1186/1475-925X-6-45>.
Version: 2005
- [Lowery u. O'Malley 2003] LOWERY, M. M. ; O'MALLEY, M. J.:
Analysis and Simulation of changes in EMG amplitude during high-level fatiguing contractions.
In: *IEEE Transactions on Biomedical Engineering* 50 (2003), Nr. 9, S. 1052–1062.
<http://dx.doi.org/10.1109/TBME.2003.816078>. –
DOI 10.1109/TBME.2003.816078
- [Lowery u. a. 2004] LOWERY, M. M. ; STOYKOV, N. S. ; DEWALD, J. P. A. ; KUIKEN, T. A.:
Volume conduction in an anatomically based surface EMG model.
In: *IEEE Transactions on Biomedical Engineering* 51 (2004), Nr. 12, S. 2138–2147.
<http://dx.doi.org/10.1109/TBME.2004.836494>. –
DOI 10.1109/TBME.2004.836494
- [Lowery u. a. 2002] LOWERY, M. M. ; STOYKOV, N. S. ; TAFLOVE, A. ; KUIKEN, T. A.:
A multiple-layer finite-element model of the surface EMG signal.
In: *IEEE Transactions on Biomedical Engineering* 49 (2002), Nr. 5, S. 446–454.
<http://dx.doi.org/10.1109/10.995683>. –
DOI 10.1109/10.995683
- [Luo u. a. 2006] LUO, Zhizeng ; WANG, Fei ; MA, Wenjie:
Pattern Classification of Surface Electromyography Based on AR Model and High-order Neural Network.
In: *Mechatronic and Embedded Systems and Applications, Proceedings of the 2nd IEEE/ASME International Conference on*.
Beijin, China, Aug. 2006, S. 1–6
- [van der Maaten 2007] MAATEN, L.J.P. van d.:
An Introduction to Dimensionality Reduction Using Matlab.
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.107.1327&rep=rep1&type=pdf>.
Version: July 2007

- [Mallat 1989] MALLAT, S. G.:
A Theory for Multiresolution Signal Decomposition: The Wavelet Representation.
In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* 11 (1989), Nr. 7, S. 674–693.
<http://dx.doi.org/10.1109/34.192463>. –
DOI 10.1109/34.192463. –
ISSN 0162–8828
- [Matsumura u. a. 2002] MATSUMURA, Y. ; FUKUMI, M. ; MITSUKURA, Y. ; AKAMATSU, N. ; YAMAMOTO, Y. ; NAKAURA, K.:
Recognition system of EMG patterns by neural networks.
In: *Proc. 41st SICE Annual Conf. SICE 2002* Bd. 3.
Naples, Italy, 2002, S. 1613–1617
- [Merletti u. Parker 2004] MERLETTI, Roberto ; PARKER, Philip ; IEEE PRESS SERIES ON BIOMEDICAL ENGINEERING (Hrsg.):
Electromyography: Physiology, Engineering and Non-Invasive Applications.
Piscataway : Wiley-IEEE Press, 2004 <http://dx.doi.org/10.1016/j.clinph.2008.10.160>
- [Meyer 1997] MEYER, Dorthe:
Human Gait Classification Based on Hidden Markov Models.
In: *3D Image Analysis and Synthesis '97*.
Erlangen, Germany : Infix, 1997, S. 139–146
- [Michaud 1993] MICHAUD, Thomas C.:
Foot Orthoses and Other Forms of Conservative Foot Care.
Philadelphia : Lippincott, Williams & Wilkins, 1993
- [Mikut u. a. 2006] MIKUT, Ralf ; KRÜGER, Thilo ; REISCHL, Markus ; BURMEISTER, Ole ; RUPP, Rüdiger ; STIEGLITZ, Thomas:
Regelungs- und Steuerungskonzepte für Neuroprothesen am Beispiel der oberen Extremitäten (Closed- and Open-Loop Control Concepts for Neuroprostheses of Upper Extremities).
In: *Automatisierungstechnik* 54 (2006), S. 523–536
- [Miller u. a. 2010] MILLER, Kai J. ; GERWINSCHALK ; FETZ, Eberhard E. ; NIJS, Marcel den ; OJEMANN, Jeffrey G. ; RAO, Rajesh P. N.:
Cortical activity during motor execution, motor imagery, and imagery-based online feedback.
In: *Proceedings of the National Academy of Sciences, PNAS*.
Washington, 2010, 1–6. –
www.pnas.org/cgi/doi/10.1073/pnas.0913697107
- [Nat 2005] NATIONAL AMPUTEE STATISTICAL DATABASE (NASDAB). (Hrsg.):
National Amputee Statistical Database Annual Report 2004/2005.

- Edinburgh: National Amputee Statistical Database (NASDAB)., 2005.
<http://www.nasdab.co.uk>
- [Nazarpour u. a. 2005] NAZARPOUR, K. ; SHARAFAT, A. ; FIROOZABADI, S. P.:
Surface EMG Signal Classification Using a Selective Mix of Higher Order
Statistics.
In: *Conf Proc IEEE Eng Med Biol Soc* 4 (2005), 4208–4211.
<http://dx.doi.org/10.1109/IEMBS.2005.1615392>. –
DOI 10.1109/IEMBS.2005.1615392
- [Oehler u. a. 2009] OEHLER, S. ; PUSCH, M. ; KRAFT, M.:
Mobilitäts- und Belastungsmessungen an Oberschenkelamputierten.
In: *Orthopädie-Technik* 7 (2009), S. 464–470
- [Oskoei u. Hu 2008a] OSKOEI, M. A. ; HU, Huosheng:
Myoelectric based virtual joystick applied to electric powered wheelchair.
In: *Proc. IEEE/RSJ International Conference on Intelligent Robots and
Systems IROS 2008*.
Nice, France, 22–26 Sept. 2008, S. 2374–2379
- [Oskoei u. Hu 2008b] OSKOEI, Mohammadreza A. ; HU, Huosheng:
Support vector machine-based classification scheme for myoelectric control
applied to upper limb.
In: *IEEE Trans Biomed Eng* 55 (2008), Nr. 8, 1956–1965.
<http://dx.doi.org/10.1109/TBME.2008.919734>. –
DOI 10.1109/TBME.2008.919734
- [Össur a] Össur Europe, Augustinusstrasse 11A, 50226 Frechen, Deutschland
- [Össur b] ÖSSUR:
RHEO KNEE.
Ekkersrijt 4106-4114, Son en Breugel, The Netherlands: Össur Europe
BV, <http://www.ossur.com>
- [Oyama u. a. 2006] OYAMA, T. ; MATSUMURA, Y. ; KARUNGARU, S. ; MITSUKURA,
Y. ; FUKUMI, M.:
Recognition of Wrist Motion Pattern by EMG.
In: *Proc. Int SICE-ICASE Joint Conf*.
Bexco, Busan, 2006, S. 599–603
- [Park u. Lee 1998] PARK, Sang-Hui ; LEE, Seok-Pil:
EMG pattern recognition based on artificial intelligence techniques.
In: *IEEE Transactions on Rehabilitation Engineering* 6 (1998), Nr. 4, S.
400–405.
<http://dx.doi.org/10.1109/86.736154>. –
DOI 10.1109/86.736154
- [Perry 2003] PERRY, Jacquelin ; URBAN & FISCHER (Hrsg.):
Ganganalyse, Norm und Pathologie des Gehens.

München : Elsevier, 2003

- [Reaz u. a. 2006a] REAZ, M. B. I. ; HUSSAIN, M. S. ; MOHD-YASIN, F.:
EMG analysis using wavelet functions to determine muscle contraction.
In: *Proc. 8th Int. Conf. e-Health Networking, Applications and Services HEALTHCOM 2006*.
New Delhi, India, 2006, S. 132–134
- [Reaz u. a. 2006b] REAZ, M. B. I. ; HUSSAIN, M. S. ; MOHD-YASIN, F.:
Techniques of EMG signal analysis: detection, processing, classification
and applications (Correction).
In: *Biol Proced Online* 8 (2006), 163.
<http://dx.doi.org/10.1251/bpo124>. –
DOI 10.1251/bpo124
- [Reucher u. a. 1987a] REUCHER, Harald ; RAU, Gunter ; SILNY, Jiri:
Spatial Filtering of Noninvasive Multielectrode EMG: Part I - Introduc-
tion to Measuring Technique and Applications.
In: *IEEE Transactions on Biomedical Engineering* 34 (1987), Nr. 2, S.
98–105.
<http://dx.doi.org/10.1109/TBME.1987.326034>. –
DOI 10.1109/TBME.1987.326034
- [Reucher u. a. 1987b] REUCHER, Harald ; SILNY, Jiri ; RAU, Gunter:
Spatial Filtering of Noninvasive Multielectrode EMG: Part II - Filter
Performance in Theory and Modeling.
In: *IEEE Transactions on Biomedical Engineering* 34 (1987), Nr. 2, S.
106–113.
<http://dx.doi.org/10.1109/TBME.1987.326035>. –
DOI 10.1109/TBME.1987.326035
- [von Rosenberg 2006] ROSENBERG, Harald von:
Sensorfusion zur Navigation eines Fahrzeugs mit low-cost Inertialsensoren.
Stuttgart, Institut für Statik und Dynamik der Luft- und Raumfahrtkon-
struktionen, Universität Stuttgart, Diplomarbeit, Juli 2006. –
Fraunhofer Technologie-Entwicklungsgruppe TEG
- [von Rosenberg 2007] ROSENBERG, Harald von:
Zustandsinformationen aus Sensorfusionssystemen – der virtuelle Beob-
achter.
In: *Tagungsband: Industrielles Symposium Mechatronik*.
Linz : Clusterland Oberösterreich GmbH / Mechatronik Cluster, Oktober
2007
- [von Rosenberg 2008] ROSENBERG, Harald von:
Vorstellung eines inertialen Messsystems für die medizinische Ganganalyse.

- In: *Tagungsband: Internationales Forum Mechatronik*.
Stuttgart : Kompetenznetzwerk Mechatronik BW e.V., September 2008
- [Saponas u. a. 2009] SAPONAS, T. S. ; TAN, Desney S. ; MORRIS, Dan ; BALAKRISHNAN, Ravin ; TURNER, Jim ; LANDAY, James A.:
Enabling Always-Available Input with Muscle-Computer Interfaces.
Version: 2009.
<http://research.microsoft.com/en-us/um/redmond/groups/cue/publications/SaponasUIST2009EMG.pdf>. –
Computer Science and Engineering, DUB Group, University of Washington
- [Schauer u. a. 2009] SCHAUER, T. ; NEGARD, N.-O. ; NAHRSTAEDT, H. ; RAISCH, J.:
Regelung von Peroneus-Stimulatoren zur Kompensation von Fußheberschwäche nach Schlaganfall.
In: *Orthopädie-Technik 2* (2009), S. 78–83
- [Schlittgen 2001] SCHLITTTGEN, Rainer:
Angewandte Zeitreihenanalyse.
München : Oldenbourg Wissenschaftsverlag, 2001
- [Schmalz u. a. 2002] SCHMALZ, Thomas ; BLUMENTRITT, Siegmund ; JARASCH, Rolf:
Energy expenditure and biomechanical characteristics of lower limb amputee gait: the influence of prosthetic alignment and different prosthetic components.
In: *Gait Posture* 16 (2002), Nr. 3, S. 255–263
- [Soetanto u. a. 1998] SOETANTO, Kawan ; KOBAYASHI, Masahiro ; OKUJIMA, Motoyoshi:
Fundamental Examination of Cattle Red Blood Cells Damage with Ultrasound Exposure Microscopic System (UEMS).
In: *Japanese Journal of Applied Physics* 37 (1998), Nr. 5B, S. 3070–3073.
<http://dx.doi.org/10.1143/JJAP.37.3070>. –
DOI 10.1143/JJAP.37.3070
- [Spiegel Online 2009] SPIEGEL ONLINE:
Chirurgen transplantieren Roboter-Hand.
<http://www.spiegel.de/fotostrecke/fotostrecke-49393-2.html>.
Version: Dec. 2009
- [Staudenmann u. a. 2006] STAUDENMANN, Didier ; KINGMA, Idsart ; DAFFERTSHOFER, Andreas ; STEGEMAN, Dick F. ; DIEËN, Jaap H.:
Improving EMG-based muscle force estimation by using a high-density EMG grid and principal component analysis.
In: *IEEE Trans Biomed Eng* 53 (2006), Nr. 4, 712–719.
<http://dx.doi.org/10.1109/TBME.2006.870246>. –
DOI 10.1109/TBME.2006.870246

- [Sundaresan u. a. 2003] SUNDARESAN, Aravind ; CHOWDHURY, Amit R. ; CHELLAPPA, Rama:
A Hidden Markov Model Based Framework For Recognition Of Humans From Gait Sequences.
In: *PROC. ICIP*.
Barcelona, Spain, 2003, S. 93–96
- [Szücs 2009] SZÜCS, Rita:
Identifikation von Nutzsignalen aus myelektrischen Sensorarrays zur adaptiven Willkürsteuerung für Prothesen.
Fraunhofer TEG, Nobelstraße 12, 70569 Stuttgart, Universität Stuttgart, Diplomarbeit, Januar 2009. –
Betreuer: Harald von Rosenberg
- [Tamura u. a. 1982] TAMURA, Y. ; HATTA, I. ; MATSUDA, T. ; SUGI, H. ; TSUCHIYA, T.:
Changes in muscle stiffness during contraction recorded using ultrasonic waves.
In: *Nature* 299 (1982), Nr. 5884, S. 631–633
- [Tsutsui u. a. 2005] TSUTSUI, Y. ; TANAKA, T. ; KANEKO, S. ; FENG, M. Q.:
Duplex ultrasonic muscle activity sensor.
In: *Proc. IEEE Sensors*, 2005, S. 310–313. –
DOI 10.1109/ICSENS.2005.1597698
- [Vapnik u. Chervonenkis 1974] VAPNIK, V. ; CHERVONENKIS, A.:
Theory of Pattern Recognition.
Nauka, 1974. –
Deutsche Übersetzung: W. Wapnik & A. Tscherwonenkis, Theorie der Zeichenerkennung, Akademie- Verlag, Berlin, 1979
- [van Vugt u. van Dijk 2001] VUGT, J. P. P. ; DIJK, J. G.:
A convenient method to reduce crosstalk in surface EMG.
In: *Clinical Neurophysiology* 112 (2001), Nr. 4, 583 - 592.
[http://dx.doi.org/10.1016/S1388-2457\(01\)00482-5](http://dx.doi.org/10.1016/S1388-2457(01)00482-5). –
DOI 10.1016/S1388-2457(01)00482-5. –
ISSN 1388–2457
- [Wagner 2003] WAGNER, Jörg F.:
Zur Verallgemeinerung integrierter Navigationssysteme auf räumlich verteilte Sensoren und flexible Fahrzeugstrukturen.
Düsseldorf : VDI, 2003
- [Wirth u. Zichner 2002] WIRTH, Carl J. ; ZICHNER, Ludwig:
Orthopädie und orthopädische Chirurgie. Fuß.
Stuttgart : Thieme, 2002 (Orthopädie und orthopädische Chirurgie). –
ISBN 9783131262417

- [Zecca u. a. 2002] ZECCA, M. ; MICERA, S. ; CARROZZA, M. C. ; DARIO, P.:
Control of multifunctional prosthetic hands by processing the electromyographic signal.
In: *Crit Rev Biomed Eng* 30 (2002), Nr. 4-6, S. 459–485
- [Zhou u. Rymer 2003] ZHOU, Ping ; RYMER, W. Z.:
Motor unit action potential number estimation in the surface electromyogram: wavelet matching method and its performance boundary.
In: *Proc. First International IEEE EMBS Conference on Neural Engineering*.
Capri Island, Italy, 20–22 March 2003, S. 336–339

Die Arbeit stellt ein Verfahren zur adaptiven Steuerung und Regelung von Prothesen vor, wobei an einem Muskel eines Prothesenträgers eine Vielzahl von Muskelaktivitätssignalen gemessen wird. Parallel werden Zustandsinformationen aus der Bewegung des Prothesenträgers ermittelt, aus denen der aktuelle Bewegungszustand bestimmt wird. Mit diesen Informationen werden aus den Muskelaktivitätssignalen mit Hilfe eines Verfahrens zur Detektion von Signalmustern Muskelaktivitätsmerkmale extrahiert.

ISBN 978-3-8396-0435-9



FRAUNHOFER VERLAG