

Klassifikation von EMG-Signalen unter Berücksichtigung des zeitlichen Verlaufs

Vollständiger Abdruck der von der Fakultät für Informatik für die Universität der Bundeswehr
München zur Erlangung des akademischen Grades eines

Doktors der Naturwissenschaften (Dr. rer. nat.)

angenommenen Dissertation.

Gaßner Philip, M.Sc.

23. Juni 2024

Gutachter:

1. Univ.-Prof. Klaus Buchenrieder, Ph.D. (OSU)
2. Univ.-Prof. Dr.-Ing. habil. Helmut Mayer

Die Dissertation wurde am 11.12.2023 bei der Universität der Bundeswehr München eingereicht und
durch die Fakultät für Informatik am 26.03.2024 angenommen. Die mündliche Prüfung fand am
07.05.2024 statt.

Widmung

Mein Dank gilt meinen Eltern, Edelgard und Markus.
Ihre stetige Unterstützung und Liebe haben mir den Rücken gestärkt und
mich dazu ermutigt, die Entscheidungen zu treffen, die letztendlich zu
dieser Arbeit geführt haben.

Ein herzliches Dankeschön geht auch an meine wunderbare Tochter Svea.
Deine stetige Freude und uneingeschränkte Liebe haben diese
akademische Reise noch bedeutungsvoller gemacht.

Abstract

Prosthetics play a crucial role in supporting individuals with physical impairments resulting from functional loss or limb amputation. A significant number of people live with severe disabilities, often due to general illnesses. Active prostheses, which possess their own drives and complex functions, require precise signals for movement control. Traditional classification methods are often inefficient and can only reliably distinguish a limited number of gestures. This dissertation develops a new method for classifying EMG signals to improve the control of active hand prostheses.

The goal is to accelerate prosthesis response and enable natural handling by significantly increasing the number of distinguishable activation gestures and maintaining classification accuracy over extended periods. This is achieved through improved preprocessing of activation signals, allowing the use of the temporal course of a signal. To this end, EMG signals from five subjects were recorded over a period of six days, distributed over at least three weeks. Using 25 different classifiers, an F_1 -score of up to 99% was achieved for nine different gestures, with a feedforward neural network and a convolutional neural network particularly standing out. This improvement in classification accuracy has the potential to significantly enhance the control of active hand prostheses and, thereby, the quality of life for people with severe disabilities.

Kurzfassung

Prothesen spielen eine wichtige Rolle bei der Unterstützung von Personen mit körperlichen Einschränkungen, wie sie durch Funktionsverlust oder den Verlust einer Gliedmaße entstehen können. Eine erhebliche Zahl von Menschen lebt mit schweren Behinderungen, die häufig auf allgemeine Erkrankungen zurückzuführen sind. Aktive Prothesen, die über eigene Antriebe und komplexe Funktionen verfügen, benötigen präzise Signale zur Bewegungssteuerung. Traditionelle Klassifikationsmethoden sind oft ineffizient und können nur eine begrenzte Anzahl von Gesten sicher unterscheiden. Diese Dissertation entwickelt eine neue Methode zur Klassifikation von Elektromyographie (EMG)-Signalen, um die Ansteuerung aktiver Handprothesen zu verbessern.

Ziel ist es, die Prothesenreaktion zu beschleunigen und eine natürliche Handhabung zu ermöglichen, indem die Anzahl der unterscheidbaren Aktivierungsgesten deutlich erhöht und die Klassifikationsergebnisse über längere Zeiträume stabil gehalten werden. Dies wird durch eine verbesserte Vorverarbeitung der Aktivierungssignale erreicht, die es erlaubt, den zeitlichen Verlauf eines Signals zu nutzen. Zu diesem Zweck wurden EMG-Signale von fünf Probanden über einen Zeitraum von sechs Tagen, verteilt über mindestens drei Wochen aufgezeichnet. Unter Verwendung von 25 unterschiedlichen Klassifikatoren konnte für neun unterschiedliche Gesten ein F_1 -Score von bis zu 99% erzielt werden, wobei insbesondere ein vorwärtsgerichtetes neuronales Netz und ein Convolutional Neural Network herausragen. Diese Verbesserung der Klassifikationsgenauigkeit hat das Potenzial die Steuerung aktiver Handprothesen und damit die Lebensqualität von Menschen mit schweren Behinderungen signifikant zu erhöhen.

Inhaltsverzeichnis

Abbildungsverzeichnis	xi
Tabellenverzeichnis	xv
Abkürzungen	xvii
1 Einleitung	1
1.1 Zielsetzung	3
1.2 Aufbau der Arbeit	3
2 Steuerung von Handprothesen	5
2.1 Arten von Prothesen in ihrer geschichtlichen Entwicklung	5
2.2 Ansteuerung von Griffmustern aktiver Handprothesen	8
2.3 Steuersignale für Handprothesen	14
2.3.1 Electroencephalography (EEG)	15
2.3.2 Electrocorticography (ECoG)	16
2.3.3 Near Infrared Spectroscopy (NIRS)	17
2.3.4 Elektromyographie (EMG)	17
2.4 Vorverarbeitung der Signale zur Steuerung von Handprothesen	21
2.4.1 Filterung von EMG-Signalen	21
2.4.2 Merkmalsberechnung für Handprothesen	21
2.4.3 Fensterfunktionen	27
2.4.4 Schnitt von EMG-Signalen	28
2.4.5 Distanzmaße	30
2.5 Klassifikation von Steuersignalen	32
2.5.1 Datenmengen	32
2.5.2 Überwachtes Lernen	32
2.5.3 Unüberwachtes Lernen	33
2.5.4 Bestärkendes Lernen	33
2.5.5 Bewertung von Klassifikationsergebnissen	33
2.5.6 Verwendete Klassifikatoren	38
2.6 Bisherige Lösungen	47

3	Verbesserte Klassifikation von elektromyographischen Signalen	53
3.1	Zeitabhängigkeit der Signale	53
3.2	Zeitnormierung von EMG-Signalen	55
3.2.1	Betrachtung mehrerer Signalpfade in Zeitscheiben	60
3.2.2	Bewegungskörper für EMG-Signale	62
3.2.3	Zeitabhängige Änderung der Bewegungskörper	64
3.2.4	Klassifikation von EMG-Signalen mit Signalpfaden und Bewegungskörpern	67
3.3	Fortlaufende Zeitnormierung von EMG-Signalen	68
4	Experimentelle Klassifikation zeitnormierter elektromyographischer Signale	73
4.1	Verwendete Aktivierungsmuster	73
4.2	Aufnahme von EMG-Signalen	75
4.2.1	Filterung von EMG-Signalen	76
4.2.2	Schnitt der Signale	78
4.3	Normierung der Signale zur Merkmalsberechnung	80
4.4	Verwendete Klassifikatoren	81
5	Verifikation und Validierung	91
5.1	Vorgehensweise und Versuchsaufbau	91
5.2	Untersuchung der vorgestellten Klassifikationsverfahren	93
5.2.1	Klassifikationsgüte der Standardmethode	93
5.2.2	Klassifikationsgüte der normierten Methoden	99
5.2.3	Klassifikationsgüte der fortlaufenden Normierungsmethode	107
5.2.4	Frühzeitige Klassifikation bei fortlaufender Normierung	115
5.3	Probanden	117
5.3.1	Drei Gesten mit zwei Merkmalen pro Proband	118
5.3.2	Drei Gesten mit vier Merkmalen pro Proband	119
5.3.3	Neun Gesten mit zwei Merkmalen pro Proband	121
5.3.4	Neun Gesten mit vier Merkmalen pro Proband	123
5.3.5	Zwischenfazit für Probanden	124
5.4	Zeiträume	125
5.4.1	Zeitliche Stabilität von drei Gesten mit zwei Merkmalen	126
5.4.2	Zeitliche Stabilität von drei Gesten mit vier Merkmalen	127
5.4.3	Zeitliche Stabilität von neun Gesten mit zwei Merkmalen	129
5.4.4	Zeitliche Stabilität von neun Gesten mit vier Merkmalen	131
5.4.5	Zwischenfazit zeitliche Stabilität	132
5.5	Gesten	133
5.6	Diskussion	139
5.7	Abgrenzung zum Zeitstempelmerkmal	140
6	Zusammenfassung	141
7	Ausblick	143

8 Anhang	145
8.1 Parameter der Klassifikatoren	145
8.2 Metriken in tabellarischer Form für die Verifikation und Validierung	150
8.2.1 Pro Verfahren	150
8.2.2 Pro Proband	152
8.2.3 Pro Tagesset	155
Literaturverzeichnis	157

Abbildungsverzeichnis

1.1	Struktur und Aufbau der Arbeit mit möglichen Lesepfaden	4
2.1	Einteilung von Prothesen in Anlehnung an Baumgartner et al. [8]	6
2.2	Die eiserne Hand des Götz von Berlichingen mit beweglichen Fingern sowie den Lederriemen zur Befestigung [106]	7
2.3	Zustandsautomat einer Armprothese mit nur einem Griff und einer Aktivierungsgeste	9
2.4	Zustandsautomat einer Armprothese mit zwei Griffen und drei Aktivierungsgesten	10
2.5	Der Zustandsübergangsautomat der <i>VINCENT evolution3</i> [102]	11
2.6	Schematischer Verarbeitungsablauf von Signalen zur Ansteuerung von Prothesen, von der Aktivierungsgeste bis zur ausgeführten Geste	15
2.7	Internationales <i>10-20-System</i> zur Aufzeichnung von EEG-Signalen [34]	16
2.8	Schematischer Aufbau eines Skelettmuskels [58]	19
2.9	Tetanische Kontraktion bei hoher Aktivierungsfrequenz [58]	19
2.10	Ein <i>motor unit action potential</i> (MUAP) [59]	20
2.11	Ausschnitt eines EMG-Signals bei beginnender Muskelaktivität.	20
2.12	Ungeschnittenes EMG-Signal der Geste Faust mit zwei Sensoren (oben), Root Mean Square (RMS) für beide Sensoren (unten)	22
2.13	Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörendes Zero Crossing (ZC)-Signal mit Schwellwert (unten)	24
2.14	Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörende Autokorrelationskoeffizienten der Ordnung 1 bis 4 (unten)	25
2.15	Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörende Approximate Entropys (ApEns) (unten)	26
2.16	Darstellung der Hanning- und Hammingfunktion für die jeweiligen Fensterfunktionen	28
2.17	Ein ungeschnittenes EMG-Signal von zwei Sensoren	29
2.18	Verfahren zum automatischen Schneiden von EMG-Signalen und der Berechnung der Schwellwerte zur Erkennung von Anfang und Ende	30
2.19	Vier unterschiedliche Receiver Operating Characteristic (ROC)-Kurven mit dazugehörigem Area Under Curve (AUC)-Wert [18]	37
2.20	Hyperebene einer Support Vector Machine (SVM) im zweidimensionalen Raum mit maximierten Support-Vektoren	39
2.21	Beispiel für einen Entscheidungsbaum	40
2.22	Darstellung eines einfachen, vorwärts betriebenen Netzes mit einer Eingangs-, einer verborgenen und einer Ausgabeschicht.	43
2.23	Faltung einer Matrix für Convolutional Neural Networks (CNNs) [18]	44
2.24	Max-Pooling für Convolutional Neural Networks (CNNs) [18]	45
2.25	Streudiagramm von zwei Merkmalen über drei unterschiedliche Gesten	49

Abbildungsverzeichnis

2.26	Streudiagramm von zwei Merkmalen über neun unterschiedliche Gesten	49
2.27	Korrelation zwischen der Anzahl an Klassen und der Korrekturklassifikationsrate (KKR) unter Berücksichtigung der Anzahl der verwendeten Sensoren	50
2.28	Verlauf des Root Mean Square (RMS)-Merkmals einer Bewegung der Geste Extension	51
3.1	Zeitverlauf zweier Merkmale für die Bewegungen Flexion und Extension, dargestellt mit Signalpfaden	54
3.2	Normierung von zwei EMG-Signalen mit vier Zeitscheiben	56
3.3	Normierte dreidimensionale EMG-Signale von den zwei Gesten Extension und Flexion	57
3.4	Linkes Teilbild: Alle Wiederholungen des Probanden 2 vom Aufnahmetag 2 ohne Aufnahmefehler, Rechtes Teilbild: Alle Wiederholungen des Probanden 2 vom Aufnahmetag 6 mit zwei fehlerhaften Aufnahmen	58
3.5	Die Punkteverteilung der Geste Extension für Proband 1. Alle Wiederholungen: blau Tag 1 und rot Tag 3	59
3.6	Bildung von Umhüllenden auf Datenpunkte von 90 Bewegungswiederholungen der fünften Zeitscheibe aus der Geste Extension von Proband 2	61
3.7	Hüllkörper von Bewegungsaufnahmen dreier Gesten von einem und sechs Tagen .	63
3.8	Unterschiedliche Ansichten der Bewegungskörper Extension für sechs Tage	65
3.9	Unterschiedliche Ansichten der Bewegungskörper Flexion für sechs Tage	66
3.10	Schrittweiser Aufbau des Bewegungskörpers für die Geste Flexion durch Normierung zu markanten Zeitpunkten	69
4.1	Die Muskeln Extensor digitorum und Flexor carpi radialis ¹	76
4.2	Beispielhafte Darstellung eines EMG-Signals mit und ohne Filterung	77
4.3	Amplitudengänge der entworfenen Hoch- und Tiefpassfilter	78
4.4	Support Vector Machine (SVM) mit einem Radial Basis Function (RBF)-Kernel	82
4.5	KNNCosine-Klassifikator, welcher als Distanz eine Kosinus-Funktion nutzt	86
4.6	Schichten-Modell des recur6-Klassifikators	88
4.7	Schichten-Modell des Convolutional Neural Network (CNN)-Klassifikators	90
5.1	Boxplot des erreichten F_1 -Scores der Klassifikationsergebnisse mit drei Bewegungsklassen und zwei Merkmalen für die Gesten Flexion, Faust und Extension .	95
5.2	F_1 -Score mit drei Bewegungsklassen und zwei bzw. vier Merkmalen	96
5.3	Der Boxplot vergleicht die erreichten F_1 -Scores der Klassifikatoren für zwei Merkmale sowie drei und neun Gesten.	98
5.4	F_1 -Scores der Klassifikatoren von drei Gesten mit zwei Merkmalen und neun Gesten mit vier Merkmalen.	99
5.5	F_1 -Score der Standard- und der normierten Methode für zwei Merkmale über alle Probanden und Testsets der drei Gesten Faust, Flexion und Extension	101
5.6	F_1 -Score der Standard- und der normierten Methode. Klassifiziert wurden drei Gesten mit Hilfe von vier Merkmalen und daraus der Boxplot über alle Probanden, alle Testsets und die drei Gesten Faust, Flexion und Extension erstellt.	102
5.7	F_1 -Scores der Standard- und der normierten Methode für neun Gesten mit zwei Merkmalen für fünf Probanden und alle Testsets	103

5.8	Vergleich des F_1 -Scores der Standard- und der normierten Methode für neun Gesten und vier Merkmale über fünf Probanden und alle Testsets	105
5.9	Vergleich des F_1 -Scores der drei vorgestellten Methoden für drei Gesten und zwei Merkmalen über fünf Probanden und alle Testsets	108
5.10	Vergleich des F_1 -Scores der drei vorgestellten Methoden über drei Gesten und vier Merkmale über fünf Probanden und alle Testsets	110
5.11	Vergleich des F_1 -Scores der drei vorgestellten Methoden über neun Gesten und zwei Merkmale über fünf Probanden und alle Testsets	112
5.12	Vergleich des F_1 -Scores der drei vorgestellten Methoden über neun Gesten, vier Merkmale, fünf Probanden und alle Testsets	113
5.13	Anzahl der zu klassifizierenden Zeitbasen	116
5.14	Kerndichtefunktion der richtig und falsch klassifizierten Gesten im Verlauf über die Zeitbasen	117
5.15	Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über drei Gesten, zwei Merkmale und alle Tages-Testsets. Berücksichtigt sind die Ergebnisse der besten fünf Klassifikatoren CNN, NN, BaggedTree, SVMFineGaussian und BoostedTree	119
5.16	Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über drei Gesten, vier Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren BaggedTree, SVMCubic, SVMQuadratic, NN und CNN.	121
5.17	Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über neun Gesten, zwei Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren CNN, BaggedTree, KNNWeighted, KNNCubic und KNNMedium.	122
5.18	Erreichte F_1 -Scores der drei unterschiedlichen Methoden über neun Gesten, vier Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren BaggedTree, SVMCubic, Recur6, SVMQuadratic und CNN.	123
5.19	Erreichte F_1 -Scores mit drei unterschiedlichen Methoden für drei Gesten, zwei Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: SVMQuadratic, BaggedTree, SVMFineGaussian, NN und CNN	127
5.20	Erreichter F_1 -Score mit drei unterschiedlichen Methoden für drei Gesten, vier Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: CNN, BaggedTree, SVMCubic, SVMFineGaussian und SVMMediumGaussian	129
5.21	Erreichter F_1 -Score mit drei unterschiedlichen Methoden für neun Gesten und zwei Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: SVMFineGaussian, SVMQuadratic, SVMMediumGaussian, Recur6 und CNN.	130
5.22	Erreichter F_1 -Score mit drei unterschiedlichen Methoden für neun Gesten und vier Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: CNN, BaggedTree, SVMCubic, SVMFineGaussian und SVMMediumGaussian.	131

Abbildungsverzeichnis

5.23	Gegenüberstellung der erreichten F_1 -Scores von drei unterschiedlichen Methoden, für drei Gesten mit zwei bzw. vier Merkmalen. Verwendete Klassifikatoren: SVM-Cubic, SVMQuadratic, BaggedTree, NN und CNN.	134
5.24	Erreichter F_1 -Score der Probanden mit den drei unterschiedlichen Methoden. Klassifiziert wurden neun verschiedene Gesten.	136

Tabellenverzeichnis

2.1	Vergleich der technischen Daten von Prothesen [4, 65–67, 69, 99–103]	13
2.2	Vergleich der technischen Daten von alternativen Systemen zur Abnahme von EMG-Signalen und der Klassifikation zur Steuerung von Prothesen [68–70, 72]	13
2.3	Vergleich der unterstützten Prothesengriffe [66, 67, 99, 102, 103]	14
2.4	Ergebnisse einer binären Konfusionsmatrix	34
2.5	Beispiel für eine Multi-Klassen-Konfusionsmatrix mit 100 Beobachtungen pro Klasse (Richtig-Positiv (RP) in Grün; Falsch-Negativ (FN) in Grau; Falsch-Positiv (FP) in Blau; Richtig-Negativ (RN) in Orange)	36
3.1	Beispielmatrix für eine fortlaufende Normierung mit einer Normierungsgröße von drei und vier resultierenden Zeitbasen	71
4.1	Beschreibung der Aktivierungsmuster mit der dazugehörigen Identifikationsnummer	74
4.2	Parameter der Hoch- und Tiefpassfilter	78
5.1	Grunddaten der fünf Probanden	92
5.2	Vergleich des F_1 -Scores der Normierungsmethode mit drei Gesten sowie zwei und vier Merkmalen. Es sind nur Klassifikatoren berücksichtigt, welche sowohl Daten der Standardmethode als auch der normierten Methode klassifizieren können.	106
5.3	Vergleich von Korrekturklassifikationsrate (KKR), Sensitivität und Spezifität der beiden Verfahren Standard und Normiert. Es wurden drei Gesten berücksichtigt und zwischen zwei und vier Merkmalen unterschieden.	107
5.4	Der Median aus der Kombination von Methode, Anzahl Gesten und Anzahl Merkmale der fünf besten Klassifikatoren	114
5.5	Der Median des besten Klassifikators für die jeweilige Methode. Verglichen wird das Ergebnis des Stands der Technik mit dem F_1 -Score der Normierungsmethoden je Proband.	125
5.6	Median der besten fünf Klassifikatoren, verglichen mit dem Ergebnis der Standardmethode und dem F_1 -Score der Normierungsmethoden je Tagestestset.	132
5.7	Durchschnittswerte der Metriken Sensitivität, Spezifität und Genauigkeit sowie dem Δ zur Standardmethode von einem Aufnahme-tag und sechs Aufnahme-tag jeweils über alle Probanden. Ergebnisse der fünf besten Klassifikatoren für die Permutation aus Anzahl Gesten und Merkmalen	133
5.8	Vergleich des Medians des besten Klassifikators und des Standes der Technik nach F_1 -Score für verschiedene Normierungsmethoden	137
8.1	Vergleich des erreichten F_1 -Scores der drei Vorverarbeitungsmethoden. Es werden drei sowie neun Gesten und sowohl zwei als auch vier Merkmale berücksichtigt. Nicht berücksichtigt sind die beiden Klassifikatoren CNN und Recur6, welche keine Daten für die Standardmethode geliefert haben.	150

Tabellenverzeichnis

8.2	Vergleich der Korrektklassifikationsrate (KKR), der Sensitivität und der Spezifität der drei Verfahren. Es wurden drei sowie neun Gesten berücksichtigt und zwischen zwei und vier Merkmalen unterschieden.	151
8.3	Durchschnittlicher F_1 -Score in Prozent der jeweils fünf besten Klassifikatoren aus den Permutationen von Geste und Anzahl an Merkmalen	152
8.4	Durchschnittlich erreichte True Positiv Rate (TPR), True Negative Rate (TNR), sowie Korrektklassifikationsrate (KKR). Der Durchschnitt wurde jeweils mit den für die Permutation aus Anzahl Gesten und Anzahl Merkmale besten fünf Klassifikatoren gebildet. Das Delta der Metrik wird jeweils in Bezug auf den Wert der Standardmethode gebildet.	153
8.5	Durchschnittlicher F_1 -Score von einem Aufnahmetag über alle Probanden gegen sechs Aufnahmetage über alle Probanden. Berechnet jeweils aus den fünf besten Klassifikatoren der Permutationen von Geste und Anzahl an Merkmalen. Angegeben ist der Median und die Standardabweichung.	155

Abkürzungen

%P	Prozent Punkte	93
ACC	Accuracy	34
AD-Wandler	Analog-Digital-Wandler	75
Adam	Adaptive moments	150
ANN	Artificial Neural Network	41
ApEn	Approximate Entropy	25
AR	Autoregressive Coefficient	23
AUC	Area Under Curve	36
BCI	Brain-Computer-Interface	15
BNC	Bayonet Neill Concelman	75
CNN	Convolutional Neural Network	41
DC	Direct Control	47
EC_oG	Electrocorticography	15
EEG	Electroencephalography	15
EMG	Elektromyographie	v
FIR	Finit Impulse Response	76
FN	Falsch-Negativ	33
fn	false negative	33
FP	Falsch-Positiv	33
fp	false positive	33
FPR	Falsch-Positiv-Rate	34
GdB	Grad der Behinderung	1
GDI	Gini's Diversity Index	147
ID	Identifikationsnummer	70
k-NN	<i>k</i> -Nächste Nachbarn	40
KKR	Korrektklassifikationsrate	16
KNN	Künstliche-Neuronale-Netze	41
LDA	Lineare Diskriminanzanalyse	38
LSTM	Long Short-Term Memory	41
MFL	Maximum Fractal Length	80
MKQ	Methode der kleinsten Quadrate	38
MSAP	Muskelsummenaktionspotential	17
MUAP	<i>motor unit action potential</i>	17
NIRS	Near Infrared Spectroscopy	15
NNK	Nächste-Nachbarn-Klassifikation	81
PR	Pattern Recognition	14
RBF	Radial Basis Function	82
ReLU	rectified linear unit	45

Abkürzungen

RFID	Radio-Frequency-Identification	8
RMS	Root Mean Square	14
RMSProb	Root Mean Square Propagation	149
RN	Richtig-Negativ	33
RNN	Recurrent Neural Network	45
RNR	Richtig-Negativ-Rate	35
ROC	Receiver Operating Characteristic	33
RP	Richtig-Positiv	33
RPR	Richtig-Positiv-Rate	34
RUS-Boosting	Random Undersampling Boosting	84
SVM	Support Vector Machine	38
TMR	Targeted Muscle Reinnervation	50
tn	true negative	33
TNR	True Negative Rate	35
tp	true positive	33
TPR	True Positiv Rate	34
TS	Time Stamp	50
WDF	Wahrscheinlichkeitsdichtefunktion	59
WL	Waveform Length	80
ws	Window Size	26
ZC	Zero Crossing	14

1 Einleitung

Prothesen finden häufig Einsatz, um Personen mit körperlichen Einschränkungen den Alltag zu erleichtern, wie sie durch eine Einschränkung der Funktionalität oder den Verlust einer Gliedmaße auftreten. Häufig wird hierbei von einer schweren Behinderung gesprochen. Diese wird durch den Grad der Behinderung (GdB) definiert und von einem Versorgungsamt nach der Beantragung bestimmt. Personen welche auf der von 20 bis 100 reichenden Skala, einen GdB von mindestens 50 erreichen, gelten dabei als schwerbehindert im Sinne des § 2 SGB IX [17]. Diese Behinderungen können auf verschiedene Faktoren zurückzuführen sein, wie beispielsweise Unfälle am Arbeitsplatz, im Verkehr oder im häuslichen Bereich. In den meisten Fällen jedoch entsteht eine schwere Behinderung aufgrund einer allgemeinen Erkrankung. Angeborene Fehlbildungen oder bestimmte Krankheitsverläufe können ebenfalls zu schweren Behinderungen führen. Ein weiterer, wenn auch geringer Anteil, entfällt auf Kriegs-, Wehrdienst- oder Zivildienstbeschädigungen. Laut Statistischem Bundesamt gab es bis zum 31.12.2019 in Deutschland 7,9 Millionen Menschen mit einer schweren Behinderung. Das entspricht einem Anteil von etwa 9,5% der damaligen Bevölkerung. Etwa 1,35 Millionen Menschen mit einer schweren Behinderung leiden unter einer Einschränkung der Gliedmaßen. Eine Funktionseinschränkung trat dabei bei etwa 890 Tausend Menschen auf. Die Wirbelsäule ist als Ursache für etwa 420 Tausend Menschen festzustellen und bei ca. 53 Tausend Menschen ist es der Verlust von einer oder mehreren Gliedmaße(n). [23]

In Anbetracht der großen Anzahl betroffener Personen ist es nicht überraschend, dass die Prothetik auch einen wichtigen Wirtschaftsfaktor darstellt. Der Deutsche Industrieverband für Optik, Photonik, Analysen- und Medizintechnik e.V. beziffert den Umsatz mit Prothesen und Zubehör auf 4,955 Milliarden Euro jährlich. Hierzu zählt jedoch auch die Zahnprothetik und ihr Zubehör. Der Umsatz für künstliche Gelenke, andere orthopädische Apparate und Vorrichtungen, Prothesen und Waren der Prothetik, Vorrichtungen zum Beheben von Funktionsschäden sowie Teile und Zubehör für Prothesen werden mit einem Jahresumsatz von 3,130 Milliarden Euro angegeben [88].

Prothesen lassen sich im allgemeinen durch die von ihnen bereitgestellte Funktionalität in drei Arten unterteilen. So gibt es passive, aktive und hybride Prothesen.

Passive Prothesen erfüllen meistens kosmetische Anforderungen, wobei zu diesen auch Prothesen zählen, die das Einsetzen von Hilfsmitteln ermöglichen, um spezielle Tätigkeiten auszuführen. Wie beispielsweise Arbeitsarme mit Steckaufsätzen wie Schraubenschlüsseln. Passive Prothesen sind jedoch zumeist starr und nur wenige lassen sich auch durch Muskelkraft anwinkeln oder drehen.

Aktive Prothesen sind im Gegensatz zu passiven Prothesen sehr komplexe Geräte, welche meist über einen eigenen Antrieb verfügen und eine Vielzahl unterschiedlicher Funktionen ausführen können. Hierfür benötigt die aktive Prothese einen Signalgeber. Dieser leitet die Bewegungsaktion ein, während ein zusätzlicher Sensor detektiert, ob eine Aktion ausgelöst wurde. Der konkrete Signalgeber ist für den jeweiligen Anwendungsfall ausgelegt und erhält die Daten von einem kontrahierenden Muskel, angeregten Nerven oder leitet diese von Gehirnaktivitäten ab.

1 Einleitung

Zur Detektierung können rein mechanische oder elektrische Sensoren Verwendung finden. Soll eine aktive Prothese über eine größere Funktionalität verfügen, so ist es notwendig, einzelne Signale voneinander zu unterscheiden und einer spezifischen Aktion durch Klassifikation zuzuordnen. Ein Problem der Klassifizierung ist, dass mit steigender Anzahl an möglichen Aktionen, die eine Prothese unterstützen soll, die einzelnen Aktionen zunehmend schwieriger voneinander zu unterscheiden sind.

Moderne Handprothesen sind Beispiele für hybride Prothesen. Sie kombinieren die Möglichkeiten hochentwickelter Mechanik und leistungsstarker Elektroantriebe mit denen von innovativen Kunststoffen, um kosmetische Ziele zu erreichen. Hybride Prothesen verbinden unterschiedliche Eigenschaften passiver und aktiver Prothesen miteinander.

Die für aktive Prothesen notwendigen Signale zum Aktivieren einer Aktion der Prothese werden im Folgenden Aktivierungssignale genannt. Sie entstehen beispielsweise durch das Bilden einer Faust, dem Ausstrecken des Zeigefingers oder auch nur durch den aktiven Gedanken daran. Diese Tätigkeiten, welche ein Aktivierungssignal erzeugen, werden im Folgenden Aktivierungsmuster genannt. Gesten wie das Bilden der Faust sind dabei eine Untermenge der Aktivierungsmuster, welche als Aktivierungsgesten bezeichnet werden.

Das Aktivierungssignal ist das daraus resultierende und von der Prothesensteuerung aufgenommene mechanische oder bei modernen Prothesen elektrische Signal. Die verschiedenen Arten ein elektrisches Aktivierungssignal auszuführen und dieses zu messen sind in Abschnitt 2.3 beschrieben. Die meisten Prothesen unterstützen dabei ein bis vier unterschiedliche Aktivierungssignale [4, 65–67, 69, 99–103], siehe auch Abschnitt 2.2, aus denen moderne Mehrfinger-Handprothesen bis zu 36 unterschiedliche Griffmuster ableiten können. Dies verdeutlicht die Diskrepanz zwischen der Anzahl der Aktivierungsmuster, die dem Benutzer zur Steuerung der Prothese zur Verfügung stehen und den Griffmustern, die die Prothese letztlich ausführen kann. Diese deutliche Abweichung zwischen Aktivierungsmustern und Griffmustern beruht auf der historischen Vorgehensweise bei der Signalklassifikation. Traditionell werden für gemessene Signale zu einem bestimmten Zeitpunkt Merkmale berechnet. Im einfachsten Fall wird nur geprüft, ob das einzelne Merkmal einen Schwellwert überschreitet. Ist dies der Fall, so wird eine Aktion ausgelöst und ein Griffmuster ausgeführt. Hierbei besteht eine ein-Muskel-ein-Griffmuster Zuordnung [108].

Eine wesentliche Verbesserung bestand folglich darin, diese eins-zu-eins Zuordnung aufzulösen und die Aktivierung unterschiedlicher Muskelgruppen sowie deren Stärke für die Ansteuerung von Prothesen zu berücksichtigen [108]. Die dabei zum Einsatz kommenden Klassifikationsverfahren verwenden dafür Merkmale, die zueinander in Beziehung gesetzt werden. Daraus entsteht ein mindestens zweidimensionaler Merkmalraum. Die Anzahl an Dimensionen ist dabei von der Anzahl verwendeter Sensoren sowie der Anzahl berechneter Merkmale abhängig. Das Problem bei diesem standardmäßig verwendeten Verfahren zur Klassifikation ist, dass sich die errechneten Merkmale für die einzelnen Zeitpunkte bereits bei nur wenigen zu unterscheidenden Gesten überlagern. Daher können mit diesem Verfahren nur geringe Anzahl an Gesten sicher voneinander unterschieden werden. Eine mögliche, jedoch kaum beachtete Lösung besteht darin, die berechneten Merkmalspunkte der einzelnen Zeitpunkte in Relation zueinander zu setzen. Ein dabei bisher auftretender Nachteil ist, dass eine Klassifikation erst nach Beendigung des Aktivierungsmusters möglich ist und die Prothese somit erst mit einer deutlichen Verzögerung reagiert.

1.1 Zielsetzung

Das Ziel dieser Arbeit besteht darin, die Steuerung von aktiven Handprothesen zu verbessern. Dies beinhaltet eine schnelle Reaktion der Prothese mit geringer Verzögerungszeit, eine Erhöhung der Anzahl von Aktivierungsgesten und die Verbesserung der Klassifikationsgenauigkeit dieser Gesten. Das Umschalten zwischen verschiedenen Griffmustern soll somit dem natürlichen Verhalten weitestgehend entsprechen. Darunter ist zu verstehen, dass die Prothese auf ein Signal zeitnah reagiert und dass sie eine Vielzahl an Signalen unterscheiden kann, damit die Aktion des Nutzers und die Reaktion der Prothese in einem direkten Zusammenhang stehen. Hierfür soll die Ansteuerung der Prothese ohne Voraktivierung erfolgen und die Klassifikation des aufgenommenen Aktivierungsmusters so frühzeitig abgeschlossen sein, dass für den Nutzer ein unmittelbarer Steuereindruck entsteht. Die Klassifikationsergebnisse der Aktivierungsgesten sollen dabei über den Zeitraum von mehreren Tagen ohne erneutes Training des Klassifikators stabil sein.

1.2 Aufbau der Arbeit

Für Leser ohne Vorkenntnisse im Bereich der Prothetik, der Prothesenansteuerung sowie der Signalaufnahme und Verarbeitung empfiehlt sich der Leseplan in ordinaler Reihenfolge. Hierbei bietet Kapitel 2 eine Einführung in die benötigten Grundlagen und die Gewinnung von Steuersignalen für aktive Prothesen. Die notwendige Vorverarbeitung sowie die erstrebte Klassifikation der Signale werden in den weiteren Abschnitten dargestellt. Das Kapitel schließt mit einem Überblick über bisherige Lösungsansätze und der Diskussion der resultierenden Defizite.

Leser mit Vorkenntnissen im Bereich der Klassifikation, insbesondere von Signalen der EMG, können dem blauen Leseplan in Abbildung 1.1 folgen. Dieser beginnt in Abschnitt 3.1 mit der Einführung in die Zeitabhängigkeit von EMG-Signalen. Im Anschluss werden zwei Methoden zur Vorverarbeitung mit dem Ziel einer verbesserten Klassifikation vorgestellt. Der Abschnitt 5.6 empfiehlt sich dabei als Abschluss, da er eine Zusammenfassung der Klassifikationsergebnisse beider Methoden bietet.

Für Leser, denen bereits die Veröffentlichungen mit Bezug auf Klassifikation unter Berücksichtigung von zeitabhängigen Signalen [3, 30, 31] bekannt sind, die aber einen tieferen Einblick in die in dieser Arbeit vorgestellten Methoden sowie die dazugehörigen Ergebnisse erhalten möchten, wird der grüne Leseplan empfohlen. Der Pfad beginnt mit Abschnitt 4.1 und der Definition der verwendeten Aktivierungsmuster. Die darauffolgenden Abschnitte 4.2 - 4.4 beschreiben die Signalaufnahme, die Durchführung der Normierung sowie die verwendeten Klassifikatoren. Nachdem damit die notwendigen Grundlagen für den späteren Versuchsaufbau beschrieben und definiert sind, finden sich die Ergebnisse im Kapitel 5. Der Abschnitt 5.1 beschreibt die unterschiedlichen Versuche, die dann in den Abschnitten 5.2 - 5.5 ausgewertet werden. Nach dem Diskussionsabschnitt 5.6 empfiehlt es sich den Abschnitt 5.7 zu lesen, in dem eine Abgrenzung zum Zeitstempelmerkmal stattfindet.

1 Einleitung

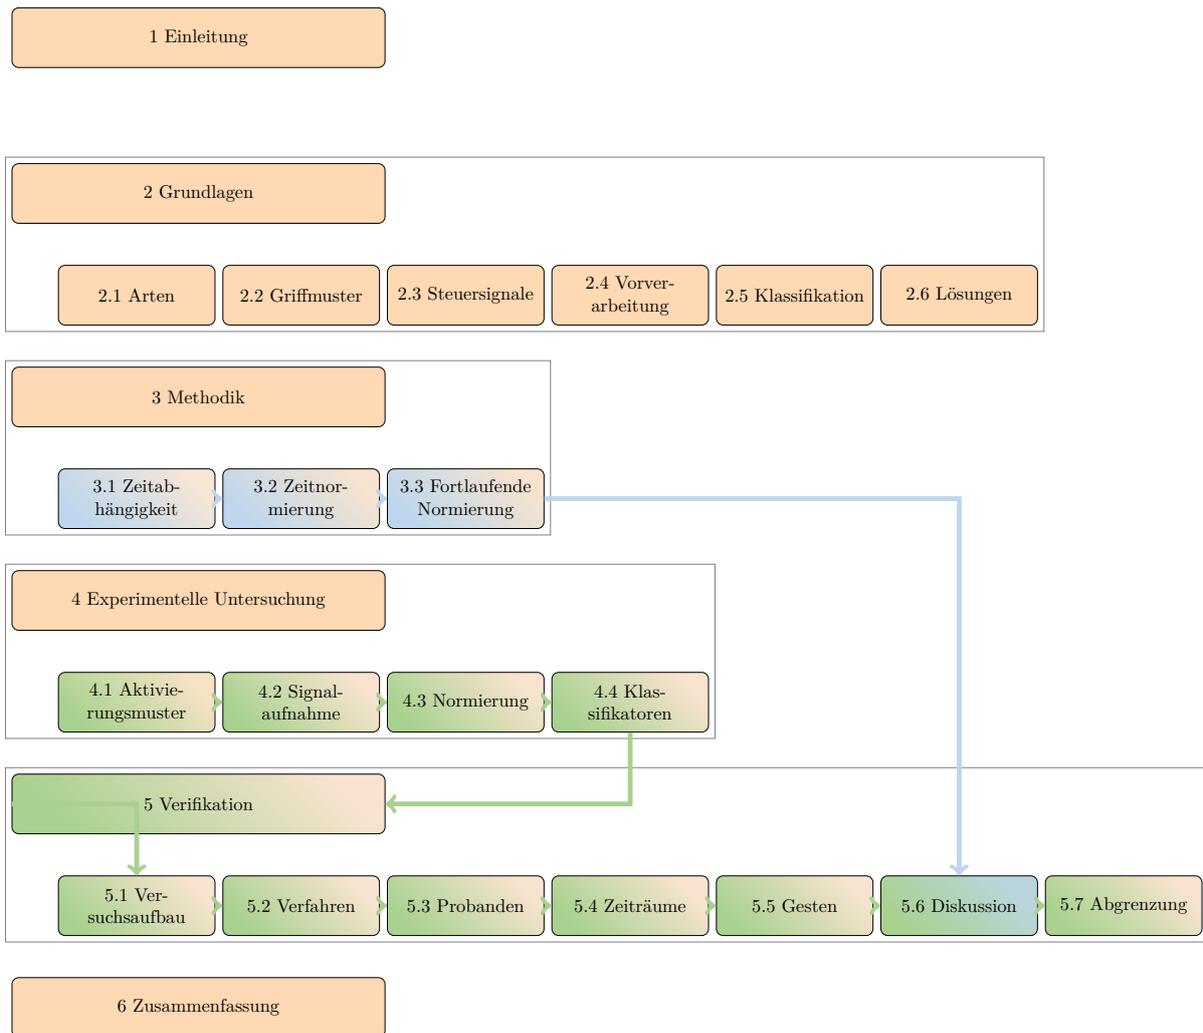


Abbildung 1.1: Struktur und Aufbau der Arbeit mit möglichen Lesepfaden

2 Steuerung von Handprothesen

Die grundsätzliche Aufgabe einer Prothese ist es, das verlorene oder in seiner Funktion eingeschränkte Glied zu ersetzen. Seit Anbeginn der Entwicklungen auf diesem Gebiet haben sich viele neue technische Möglichkeiten ergeben. Die Aufgabenstellung als solche ist jedoch gleich geblieben. So hat sich das Hilfsmittel „Handprothese“ nicht nur mechanisch weiterentwickelt, sondern erfuhr durch die Möglichkeit einer gezielten Ansteuerung eine massive Weiterentwicklung.

Um dies zu veranschaulichen, stellt dieses Kapitel die geschichtliche Entwicklung sowie eine Auswahl unterschiedlicher Prothesen vor. Zu diesem Zweck werden zunächst die verschiedenen Arten von Handprothesen beschrieben und ein Schema präsentiert, welches es ermöglicht, Handprothesen zu gruppieren und in Unterkategorien einzuteilen. Darauf erfolgt die Vorstellung und Erläuterung von ansteuerbaren Prothesen und der von ihnen unterstützten Griffmuster sowie ein Überblick über die zur Steuerung notwendigen dazugehörigen Zustandsautomaten. Dem schließt sich die Beschreibung der hierfür nötigen Steuersignale und der dazugehörigen unterschiedlichen Methoden zur Erfassung mit Sensoren an. Daraus leitet sich ein weitgehend allgemeiner Ansatz zur Ansteuerung einer Prothese ab. Unter der Prämisse, dass die Ansteuerung mit Hilfe eines zu erfassenden Signals erfolgt, wird der derzeitige Stand der Technik detailliert betrachtet, analysiert und Defizite aufgezeigt. Aus diesen leitet sich die bereits vorgestellte Zielsetzung der vorliegenden Arbeit ab.

2.1 Arten von Prothesen in ihrer geschichtlichen Entwicklung

Laut dem deutschen Duden [26] leitet sich das Wort Prothese von dem griechischen prósthesis ab, was soviel wie Hinzufügen oder Ansetzen bedeutet. Unter einer Prothese versteht sich somit ein Hilfsmittel für den künstlichen Ersatz eines fehlenden, amputierten oder unvollständig ausgebildeten Körperteils, besonders der Gliedmaßen oder der Zähne.

Nach Baumgartner et al. [8] lassen sich Prothesen in drei Haupttypen einteilen, passive, aktive und Hybridprothesen. Abbildung 2.1 verdeutlicht die Einteilung nach Baumgartner et al.

Wie eingangs bereits dargelegt findet die wesentliche Unterscheidung zwischen aktiven und passiven Prothesen statt. Letztere lassen sich in kosmetische Prothesen und Arbeitsprothesen untergliedern. Kosmetische Prothesen dienen hauptsächlich dazu, den Anschein der körperlichen Unversehrtheit zu erzeugen. Sie sind zumeist starr, unbeweglich und lassen sich nur für unterstützende Tätigkeiten einsetzen. So kann beispielsweise mit einer kosmetischen Armprothese ein Gegenstand dadurch fixiert werden, dass dieser unverrückbar gegen eine Tischplatte gedrückt wird. Insofern können kosmetische Prothesen bei der Bewältigung des Alltags helfen. Eine zeitlich frühe passive und kosmetische Prothese war der *Digitus pedis I*, der an einer ägyptischen Mumie aus der Zeit 1500 v. Chr. gefunden wurde [97]. Ein weiteres Beispiel für frühe passive Prothesen ist das Holzbein. Erste Erwähnungen dazu stammen schon aus dem frühen 5. Jahrhundert v. Chr. [49]. Aus dem 2. Jahrhundert v. Chr. ist bekannt, dass der römische General

2 Steuerung von Handprothesen

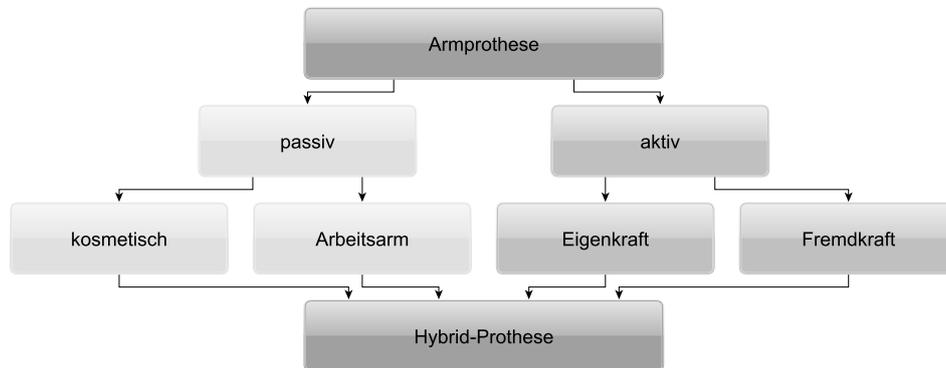


Abbildung 2.1: Einteilung von Prothesen in Anlehnung an Baumgartner et al. [8]

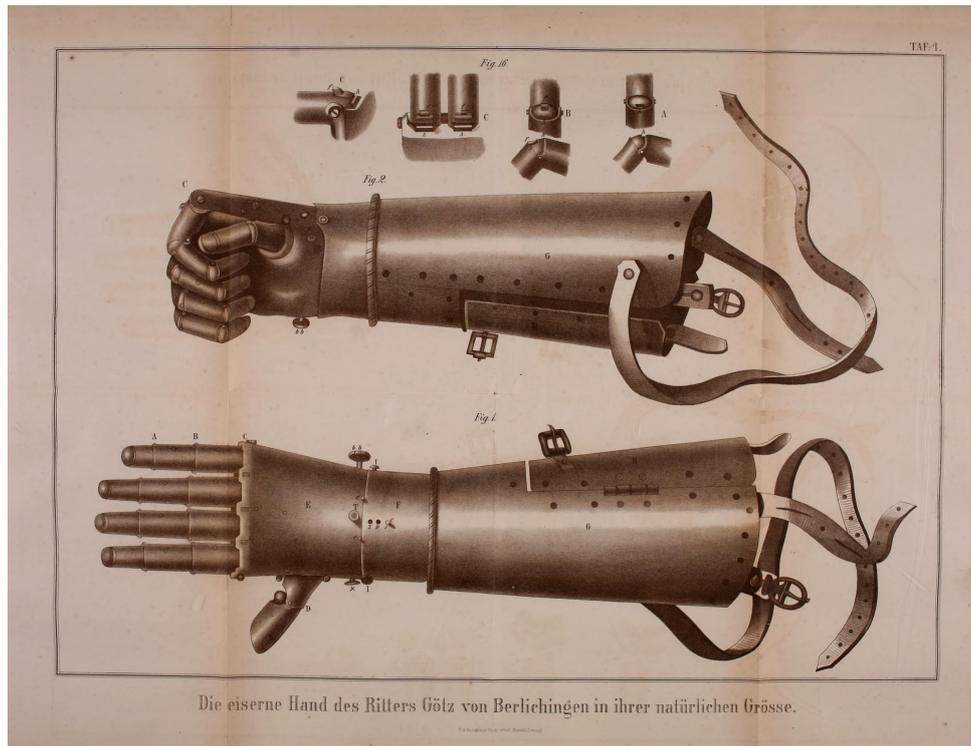
Marcus Sergius über eine Armprothese verfügte, welche er im Kampf einsetzen konnte [114]. Über diese Prothese sind jedoch nur wenige Details bekannt. Wenn für die Prothese der ästhetische Aspekt gegenüber dem funktionalen Aspekt eine untergeordnete Rolle spielt, so können Arbeitsarme eingesetzt werden. Darunter sind Arm- oder Handprothesen zu verstehen, welche für eine bestimmte Tätigkeit optimiert sind. Das kann zum Beispiel ein an der Spitze der Prothese befestigter Haken für das Tragen von Lasten oder das Anbringen von verschiedenen Werkzeugen wie Schraubendreher oder Säge für handwerkliche Tätigkeiten sein.

Infolge zahlreicher Kriege und der damit verbundenen Verletzungen sowie der Weiterentwicklung der Mechanik im 15. Jahrhundert n. Chr. kam es zu einem Bedeutungsgewinn der Handprothesen. Eine der bekanntesten Handprothesen aus dem Beginn des 16. Jahrhunderts ist die eiserne Hand des Götz von Berlichingen [114]. Über diese Prothese ist bekannt, dass sie bereits über bewegliche Finger verfügte, welche in eine gewünschte Position gedrückt werden konnten. Anschließend verharrten die Glieder fixiert in dieser Stellung. Abbildung 2.2 zeigt zwei Zustände der Prothese, sowie deren Gelenke. Zudem verfügte die Apparatur über zwei Knöpfe, mit denen die Finger gelöst und in die extendierte Lage zurück versetzt werden konnten. Die Prothese des Götz von Berlichingen verfügte über einen solchen Auslöseknopf für die Finger zwei bis fünf und einen für den Daumen [80]. Über den Armstumpf konnten diese Knöpfe betätigt werden.

Die Weiterentwicklung einer beweglichen passiven Prothese, wie es die eiserne Hand des Götz von Berlichingen ist, wird als aktive Prothese bezeichnet. Generell fallen unter diesen Begriff Prothesen, welche durch Eigen- oder durch Fremdkraft bewegt werden können. Bei Eigenkraftprothesen wendet der Benutzer selbst die Kraft für die Änderung der Gliedmaßenposition auf, während diese bei Fremdkraftprothesen aus externen Quellen kommt.

Eine der ersten Eigenkraftprothesen entwickelte Peter Baliff am Anfang des 19. Jahrhunderts. Die Prothese von Baliff verfügte über drei aktiv gesteuerte Finger, welche über Seilzüge mit Hilfe der Schulter eine Beugung, auch Flexion genannt, ausführen konnten. Alle fünf Finger wurden durch Federn zurück gestreckt und somit extendiert [49]. Eine weitere frühe aktive Eigenkraftprothese ist die Sauerbruch-Hand. Sauerbruch unterteilt in seinen Arbeiten die Kraftquellen nach der auszuführenden Bewegung in die der Beuger (*Flexionen*) und Strecker (*Extender*) [80]. Er identifiziert und nutzt für seine Vorrichtung verschiedene Muskelgruppen, durch die er einen Stiftkanal legt. Bei Anspannung der Muskelgruppe wird ein hindurchgeschobenes Elfenbeinstäbchen durch den Muskel bewegt. An dessen Ende werden über einen Zügel die beweglichen Fingerglieder der Prothese bewegt [107]. Die beiden Prothesen von Baliff und Sauerbruch zählen

2.1 Arten von Prothesen in ihrer geschichtlichen Entwicklung



Die eiserne Hand des Ritters Götze von Berlichingen in ihrer natürlichen Grösse.

Abbildung 2.2: Die eiserne Hand des Götze von Berlichingen mit beweglichen Fingern sowie den Lederriemen zur Befestigung [106]

somit auch zu den ersten hybriden Prothesen, da sie sowohl kosmetische Eigenschaften besitzen als auch mit Eigenkraft betrieben sind.

Als Weiterentwicklung der Eigenkraftprothesen entstanden Mitte des 20. Jahrhunderts die Fremdkraftprothesen. Diese verfügen meist über Aktoren, welche, um beispielsweise einen Greifer zu schließen, elektrisch angesteuert werden. Seit Erforschung der Elektromyographie und dem Aufkommen der Transistortechnik mit zunehmender Integration in der Mitte des letzten Jahrhunderts bietet es sich an, auch die Steuersignale für die Aktoren elektrisch mit integrierten Sensoren zu erfassen.

Moderne Handprothesen sind häufig Hybrid-Prothesen. Sie vereinen das kosmetische Ziel der Unversehrtheit mit der Möglichkeit austauschbarer Hände und Endeffektoren. Somit fallen moderne Handprothesen in die Bereiche der kosmetischen, Arbeitsarm- und Fremdkraft-Prothesen. In Abschnitt 2.2 werden vier häufig verwendete und technisch weit fortgeschrittene Prothesen vorgestellt und näher beschrieben.

2.2 Ansteuerung von Griffmustern aktiver Handprothesen

Mit modernen, myoelektrisch gesteuerten Handprothesen sind Nutzer in der Lage, verschiedene Griffmuster auszuführen. Ein Griffmuster ist hierbei als die Endposition definiert, welche die einzelnen Fingerglieder der Prothese einnehmen. Durch die unterschiedlichen Permutationen der Positionen der verschiedenen beweglichen Glieder kann so eine Vielzahl von Griffmustern ausgeführt werden. Der Begriff *Griff* steht dabei synonym für einige nützliche Permutationen, bei welchen aber nicht zwingend etwas gegriffen wird. Ein Griffmuster kann auch die Extension des Zeigefingers bei gleichzeitiger Flexion aller anderen Fingerglieder sein. Die daraus resultierende Geste des Zeigens oder des selektierten Betätigens z. B. eines Tasters ist ebenfalls ein Griffmuster. Um ein Griffmuster auszuführen, das heißt, dieses zu schließen oder zu öffnen sowie um zu einem weiteren Griffmuster zu wechseln, muss die Prothese Informationen erhalten. Hierfür stehen verschiedene Möglichkeiten zur Verfügung, wie beispielsweise ein Knopf, der sich auf der Prothese befindet und betätigt wird oder auch Radio-Frequency-Identification (RFID)-Karten, welche in der Nähe von Gegenständen platziert werden können, um somit ein bestimmtes Griffmuster zu selektieren. Weitere Möglichkeiten bestehen darin, dass der Benutzer eine körpereigene Tätigkeit ausübt, wie beispielsweise das Anspannen von Muskeln oder auch lediglich durch das Konzentrieren auf bestimmte Abläufe sowie der bloße Gedanke daran. Wird eine solche Aktivität ausgeführt und von der Prothese erkannt, so können Funktionen wie das Schließen, Öffnen oder ein bestimmtes Griffmuster ausgeführt werden. Eine solche Aktivität, welche auf eine Funktion der Prothese verweist und diese somit aktiviert, wird im Folgenden Aktivierungsgeste genannt. Moderne Prothesen sind in der Lage eine Vielzahl von Griffmustern auszuführen. So unterstützt die kommerziell erhältliche Prothese *Quantum* von touch bionics bis zu 36 verschiedene Griffmuster [65]. Das Gerät kann jedoch lediglich maximal vier Aktivierungsmuster unterscheiden (Abschnitt 2.6). Die meisten myoelektrischen Prothesen unterstützen lediglich ein einziges Aktivierungsmuster [35]. Da es zu einer deutlichen Diskrepanz zwischen der vergleichbar geringen Anzahl an Aktivierungsmustern und der hohen Anzahl an Griffmustern kommt, ist die Steuerung für den Benutzer häufig nicht intuitiv. Das ausgeführte Aktivierungsmuster entspricht oft auch nicht der Geste, welche die Prothese einnehmen soll. Stattdessen verweist das Aktivierungsmuster auf Funktionen wie *Geste öffnen*, *Geste schließen*, *nächste Geste* oder gegebenenfalls auf eine *Abbruch-* oder *Zurück-*Funktion. Somit ist zumeist eine Geste selektiert, welche dann mit einer Aktivierungsgeste geöffnet oder mit einer anderen geschlossen wird. Mit einer weiteren Aktivierungsgeste kann nun beispielsweise zu einem anderen Griffmuster gewechselt werden. Hierfür muss der Benutzer jedoch zum einen über die Information verfügen, mit welcher Aktivierungsgeste welche Aktion ausgeführt werden soll und zum anderen, wie die verschiedenen Griffmuster zu aktivieren sind. Die Steuerung der Prothese basiert auf einem Zustandsautomaten, welcher beschreibt, wie der Nutzer zu dem von ihm gewünschten Griffmuster gelangt und dieses beispielsweise schließt oder öffnet sowie die Möglichkeit, in die Ruheposition zurückzukehren. Abbildung 2.3 zeigt den einfachsten Fall, wenn nur eine Aktivierungsgeste zur Verfügung steht. Die Prothese besitzt zwei Zustände: *Griff öffnet* und *Griff schließt*. Das Erreichen der Endposition eines Griffmusters sowie damit verbundene weitere Besonderheiten wurden für den Automaten der Einfachheit halber nicht berücksichtigt. Der Startzustand z_0 schließt die Prothese. Ist der Griff dabei bereits vollständig geschlossen, bleiben die Motoren weiter auf Schließen gestellt. Wird die Aktivierungsgeste ausgeführt und das daraus resultierende Aktivierungssignal gegeben ($A = 1$), so öffnet der Griff. Dies geschieht ebenfalls solange wie das Signal anliegt. Sobald dieses nicht mehr anliegt, beginnt die Prothese den Griff wieder zu schließen. Dabei spielt es keine Rolle, ob

2.2 Ansteuerung von Griffmustern aktiver Handprothesen

das Signal bewusst nicht mehr anliegt oder es unterbrochen wurde. Der Automat wechselt in den Zustand z_0 Griff schließt.

Soll die Endposition des Griffes für den Nutzer dynamisch einstellbar sein, so werden zwei unterschiedliche Aktivierungssignale für das Öffnen und Schließen sowie ein dritter Zustand *Stop* benötigt. Wird das jeweilige Aktivierungssignal nicht mehr gegeben, so stoppt die Prothese in der Ausführung des Griffes und die einzelnen Glieder verharren in der momentanen Position. Daraus folgert ein veränderter Zustandsautomat, da das *nicht Anliegen* der Signale zu einem Zustandsübergang nach *Stop* führt.

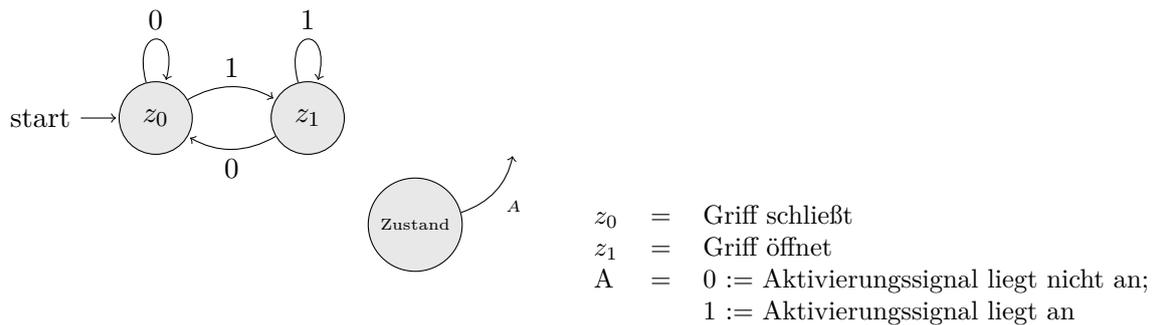


Abbildung 2.3: Zustandsautomat einer Armprothese mit nur einem Griff und einer Aktivierungsgeste

Soll eine Prothese zwei unterschiedliche Griffmuster unterstützen, so kann dies ebenfalls mit zwei unterschiedlichen Aktivierungssignalen für das Öffnen und Schließen erreicht werden. Jedes Griffmuster benötigt jeweils einen Zustand, in dem die zwei Tätigkeiten des Schließens und Öffnens repräsentiert sind. Somit werden zweimal so viele Zustände benötigt wie es Griffmuster gibt. Zudem ist eine Möglichkeit zum Wechseln des Griffmusters erforderlich. Hierfür kann ebenfalls ein Aktivierungssignal verwendet werden. Ein möglicher Zustandsübergangsautomat ist in Abbildung 2.4 dargestellt. Das erste Griffmuster ist mit den beiden Zuständen G_{0c} und G_{0o} dargestellt. Die Indizes c und o stehen dabei für *close* und *open*, also das Schließen und Öffnen des Griffmusters. Mit dem Aktivierungssignal $A1$ werden die Griffmuster G_0 und G_1 geöffnet und mit $A0$ geschlossen. Mit dem Signal $A2$ kann das Griffmuster gewechselt werden.

Der Vergleich der beiden Abbildungen 2.3 und 2.4 zeigt, wie die Komplexität mit steigender Anzahl an Gesten zunimmt.

Abbildung 2.5 zeigt den Zustandsübergangsautomaten der Prothese *VINCENT evolution3*, der Vincent Systems GmbH [102]. Der Automat dient in erster Linie Marketingzwecken und weniger einer detaillierten technischen Beschreibung.

Die Darstellung des Automaten erhebt daher nicht den Anspruch auf Vollständigkeit. Dennoch ist eine gestiegene Komplexität, insbesondere gegenüber den zuvor vorgestellten Automaten zu erkennen. Die Bedienung der *evolution3* erfolgt mit nur zwei Aktivierungsgesten und einer Feedback-Funktion. Letztere ist über den Feedback-Button, der sich auf dem Handrücken befindet oder über RFID-Karten zu bedienen. Die zwei möglichen Aktivierungsgesten liegen auf den Funktionen *close* und *open*, die jedoch überladen sind. In den meisten Fällen werden diese dazu verwendet, das Griffmuster zu öffnen oder zu schließen. In manchen Fällen ist das *close*- und *open*-Signal auch in Kombination mit oder anstatt der Feedback-Funktion zu nutzen, um ein

2 Steuerung von Handprothesen

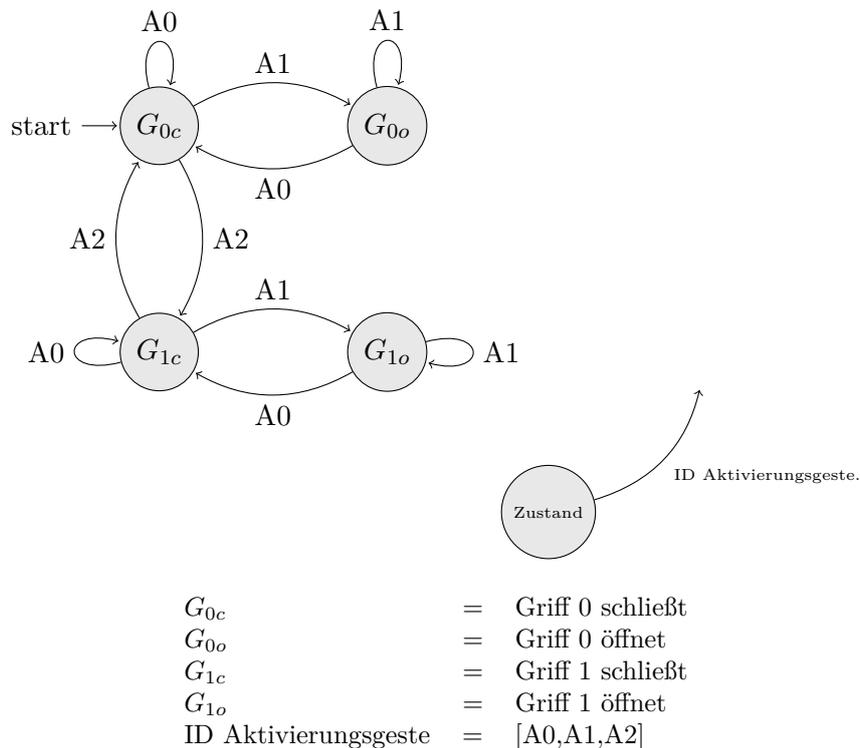


Abbildung 2.4: Zustandsautomat einer Armprothese mit zwei Griffen und drei Aktivierungsgesten

bestimmtes Griffmuster zu selektieren, siehe Abbildung 2.5. Dazu wird zusätzlich unterschieden, ob das *close*- und *open*-Signal durchgehend anliegt, auch wenn die Endposition bereits erreicht ist. Dadurch wird es zum *hold-open*- beziehungsweise *hold-close*-Signal. Dieses führt zu einem Griffmusterwechsel, dass in dem Automaten als eine Art untergeordneter Zustand innerhalb eines Ovals dargestellt ist. Die Prothese verfügt zudem noch über ein nicht näher definiertes *trigger*- sowie ein *timeout*-Signal.

Um die verschiedenen Griffmuster anzusprechen und die Prothese bestmöglich zu bedienen, muss der Nutzer den internen Zustandsübergangsautomaten auswendig lernen und jederzeit wissen, in welchem Zustand sich die Prothesensteuerung gerade befindet bzw. mit welcher Reihenfolge von Aktivierungsmustern er zu dem von ihm gewünschten Griffmuster gelangt.

Vier bekannte und weit entwickelte Prothesen mit Steuerungen dieses Types sind die *bebionic* von Ottobock mit 14 angegebenen Griffmustern, die *Michelangelo*-Hand von Ottobock mit sieben angegebenen Griffmustern und zwei Freiheitsgraden für das Handgelenk, wodurch eine Drehung des Daumens zur Körpermitte (Pronation) und Drehung nach außen (Supination) möglich sind, die *i-Limb*[®] Quantum von touch bionics mit 36 angegebenen Griffmustern sowie die *evolution3* von Vincent Systems GmbH mit 14 angegebenen Griffmustern [65–67, 69, 99, 100, 103]. Tabelle 2.1 zeigt vergleichend die Anzahl der unterstützten Griffmuster der derzeit auf dem Markt befindlichen Mehrfinger-Prothesen, die Anzahl der verwendeten EMG-Sensoren, die Anzahl an unterstützten Aktivierungsmustern und ob das Handgelenk aktiv oder passiv gesteuert werden kann.

2.2 Ansteuerung von Griffmustern aktiver Handprothesen

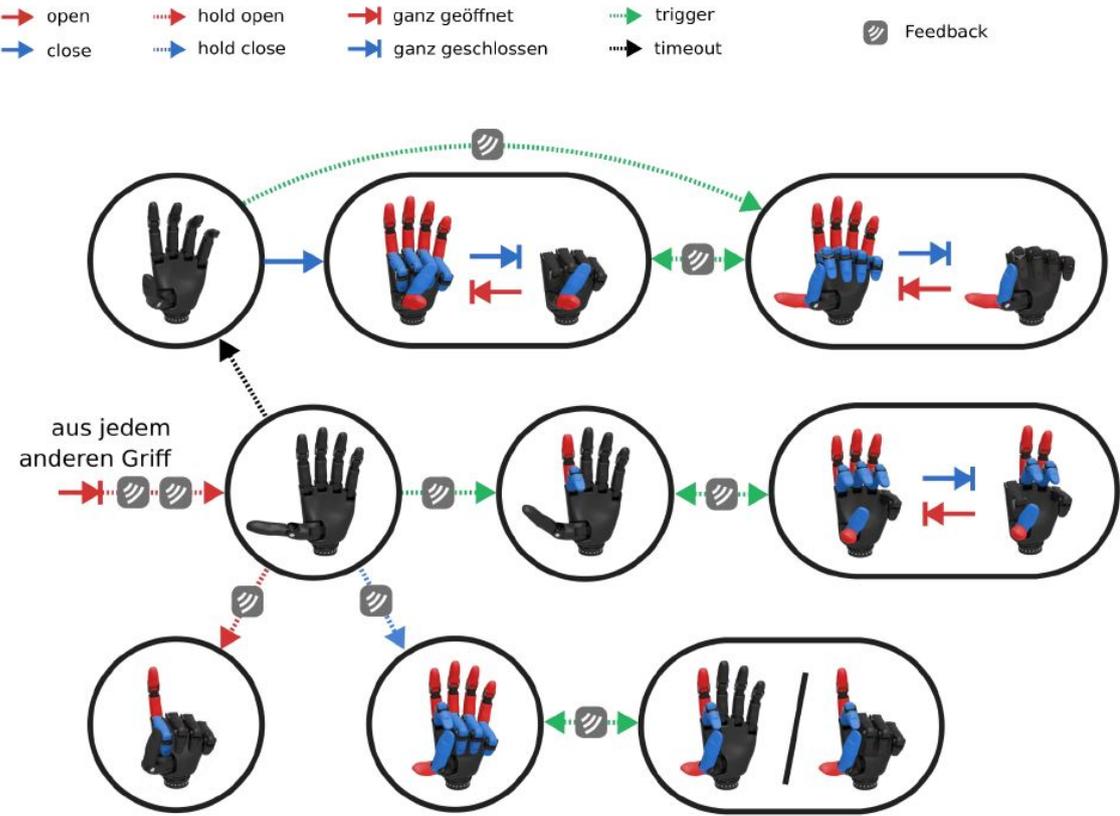


Abbildung 2.5: Der Zustandsübergangsautomat der VINCENT evolution3 [102]

2 Steuerung von Handprothesen

Im Hinblick auf die teils große Anzahl an unterstützten Griffmustern ist interessant, dass die Anzahl an Aktivierungsmustern zwischen eins und vier liegt. Dies bedeutet, dass die 36 unterstützten Griffmuster der *i-Limb*® Quantum durch lediglich vier und die übrigen Prothesen mit noch weniger Aktivierungsmuster angesteuert werden.

Folglich kann davon ausgegangen werden, dass immer mehr Griffmuster bei nicht ansteigender Anzahl an Aktivierungsmustern zu immer komplexeren Zustandsübergangsautomaten führen. Was wiederum dazu führt, dass sehr komplexe Automaten von den Nutzern auswendig zu lernen und zu steuern sind. Im schlimmsten Fall muss zum Weiterschalten des Griffmusters das dazugehörige Signal so oft wiederholt werden, wie es unterschiedliche Griffmuster gibt. Daher findet oftmals eine Vorauswahl an Griffmustern statt, sodass die Prothese für den Benutzer tatsächlich nur eine geringere Anzahl an Griffmustern zur Verfügung stellt.

Derzeit gibt es Bestrebungen in der Industrie, dieses Problem mit zusätzlichen Sensoren, welche in Form eines Armreifs angeordnet sind (Myo-Armbändern), zu beheben. Diese sind als modulare Schnittstelle zwischen Prothese und Benutzer konzipiert [70]. Die drei in dieser Arbeit vorgestellten Myo-Armbänder besitzen jeweils acht EMG-Sensoren (siehe Tabelle 2.2). Die Multi-Sensor-Armbänder können auch mit weiteren Sensoren wie einem Gyroskop oder mit Beschleunigungssensoren ausgestattet werden. Durch die Erhöhung der Anzahl an Sensoren besteht die Möglichkeit, die Auflösung der aufgenommenen EMG-Signale zu verbessern. Bereits durch die Steigerung von zwei auf vier Sensoren sinkt der Klassifikationsfehler deutlich ab [27]. Myo-Armbänder erlauben es somit, die erkannten Aktivierungsmuster und die möglichen unterstützten Griffmuster dynamisch zu verwalten. So können beispielsweise bei der Michelangelo-Hand sieben Griffmuster unterstützt werden und bei der bebionic 14 [66, 67]. Die Aktivierungsmuster hängen wiederum vom verwendeten Verfahren zur Klassifikation und den Umständen des Benutzers ab, wie beispielsweise die Art der Amputation oder die Muskelausprägung. Daher werden die Aktivierungsmuster zusammen mit einem Orthopädietechniker ausgewählt und eingestellt [69]. Das *Myo-Plus*-Armband von Ottobock fällt in die gleiche Kategorie von Myo-Armbändern, wie beispielsweise das Myo™-Armband von THALMICLABS™ [91]. Letzteres wird jedoch seit Oktober 2018 nicht mehr produziert. Eine noch in Produktion befindliche Alternative ist das *gForce100*-Armband von OYMotion [72]. Alle Myo-Armbänder weisen acht Sensoren auf und können so mehr Informationen der Muskelbewegung registrieren. Die Hersteller versprechen dadurch die Anzahl der Aktivierungsmuster erhöhen zu können. Das *Myo-Plus*-Armband gibt die Anzahl als dynamisch an und ist somit von den oben genannten Umständen des Probanden abhängig, welche die Rahmenbedingungen für die Nutzung bilden. Für das *gForce100* gibt es hierzu keine Aussage. Da das *gForce-Octopus* [71] von OYMotion auf der gleichen Technik basiert wie das *gForce100* und lediglich über eine Backout-Box mit Anschlüssen für acht Sensoren verfügt, ist davon auszugehen, dass für beide Produkte ähnliche Bedingungen für die Aktivierungsmuster gelten. Das *gForce-Octopus* wird ebenfalls zur Steuerung von Prothesen eingesetzt. Es bleibt zu erwähnen, dass sich bis zum Zeitpunkt dieser Arbeit Myo-Armbänder nicht gegen die konventionelle Steuerung von Handprothesen durchgesetzt haben.

In Tabelle 2.3 sind die standardmäßig vorhandenen Griffmuster der kommerziell erhältlichen Prothesen dargestellt, wobei die vom Benutzer selbst erstellten Griffmuster nicht berücksichtigt sind. Unterschiedliche Variationen eines Griffmusters wurden zu einem Griff zusammengefasst. Daher zählen die Variationen des Griffmusters Drei-Finger-Griff mit geschlossenem Ring- und kleinem Finger sowie mit fixiertem Daumen oder beweglichem Daumen als ein Griff. Auch mit dieser Vereinfachung zeigt sich, dass moderne Prothesen in der Lage sind, viele und komplexe Griffmuster auszuführen. Allein der Haltegriff wird von allen vier Prothesen unterstützt. Dage-

2.2 Ansteuerung von Griffmustern aktiver Handprothesen

Tabelle 2.1: Vergleich der technischen Daten von Prothesen [4, 65–67, 69, 99–103]

Eigenschaft	Typ-Bezeichnung			
	bebionic	Michelangelo	Quantum	evolution3
Griffmuster	14	7	36	14
EMG-Sensoren	2	2	2	n. a.
Aktivierungsmuster	2	n. a.	4	1
Handgelenk	Passiv	Aktiv	Passiv	Passiv

Tabelle 2.2: Vergleich der technischen Daten von alternativen Systemen zur Abnahme von EMG-Signalen und der Klassifikation zur Steuerung von Prothesen [68–70, 72]

Eigenschaft	Typ-Bezeichnung		
	Myo-Plus	gForce-Octopus	gForce100
Griffmuster	Dynamisch	Dynamisch	Dynamisch
EMG-Sensoren	8	8	8
Aktivierungsmuster	Dynamisch	8	n. a.

gen verwenden nur drei der vier Prothesen Griffmuster wie: Aktiver-Finger, Drei-Finger-Griff, Präzisionsgriff und Schlüsselgriff (Lateralgriff). Einige Prothesen unterstützen darüber hinaus das Hinzufügen fehlender Griffmuster. Dies wird in dieser Arbeit nicht weiter berücksichtigt.

Um den Benutzer mit der immer weiter ansteigenden Anzahl an möglichen Griffmustern nicht zu überfordern und die Steuerung weitgehend intuitiv zu halten, werden die unterstützten Griffmuster häufig auf wenige reduziert. Diese wählt der Orthopädietechniker beim sogenannten *fitting* gemeinsam mit dem Nutzer aus.

Auch hier zeigt sich, dass, wenn mehr als vier Griffmuster gewünscht sind, wie es die vier Prothesen versprechen, die Komplexität ansteigt. Dies gilt insbesondere, da eine direkte Aktivierung über Muskeln gewünscht ist. Um einer Überforderung des Nutzers entgegen zu wirken, ist eine Alternative zur Reduktion der unterstützten Griffmuster die Erhöhung der Aktivierungsmuster. Dafür müssen jedoch auch mehr als die bisher üblichen drei bis vier Aktivierungsmuster mit Hilfe von EMG-Signalen unterscheidbar und klassifizierbar sein. Auch diese Muster sind wie bisher für jeden Nutzer individuell zu ermitteln.

2 Steuerung von Handprothesen

Tabelle 2.3: Vergleich der unterstützten Prothesengriffe [66, 67, 99, 102, 103]

Griffart	bebionic	Michelangelo	Quantum	evolution3
Haltegriff	x	x	x	x
Aktiver Finger	x		x	x
Hakengriff	x	x		x
Klemmgriff	x	x		
Drei-Finger-Griff	x	x	x	
Präzisionsgriff	x		x	x
Vier-Finger-Griff				x
Bremsgriff				x
Tellerhand	x	x	x	
Mausgriff	x		x	
Schaltergriff	x			
Zeigefinger	x		x	
Schlüsselgriff	x	x	x	x
Handschlag			x	
Pronation		x		
Supination		x		
Handgelenk Flexion		x		
Handgelenk Extension		x		
Neutralposition	x	x		x

2.3 Steuersignale für Handprothesen

Für aktive Prothesen ist es wichtig zu definieren, wodurch das Steuersignal ausgelöst wird. Ein Körperteil oder auch nur die Wechselwirkung von elektrischen, chemischen oder mechanischen Zusammenhängen können Signalgeber für die Prothese sein. Die aktive Prothese benötigt einen Sensor, der die Signale des Signalgebers erkennt, um daraus letztlich ein Steuersignal für die Aktoren zu erzeugen, die dann ein Griffmuster ausführen oder in einfachen Fällen einen Greifer öffnen oder schließen. Weiterentwickelte Prothesen ermöglichen es, einzelne Finger und Gelenke in unterschiedliche Positionen zu bewegen, um so eine Vielzahl von komplexen Griffmustern auszuführen.

Wie eingangs erwähnt, kann das Steuersignal für eine Prothese auf viele verschiedene Arten detektiert werden. Eine der einfachsten Möglichkeiten ist es, die Kontraktion eines noch funktionsfähigen Muskels mechanisch abzunehmen und direkt in ein Griffmuster umzuwandeln. Auf diesem Ansatz basieren Prothesen wie beispielsweise die Sauerbruch-Hand.

Im Gegensatz dazu verwenden moderne Handprothesen Elektromotoren, um die einzelnen Glieder zu bewegen. Da die Motoren bereits elektrisch angesprochen werden, bietet es sich an, auch das Steuersignal elektrisch zu übertragen. Hierfür registrieren Sensoren Anregungen wie z. B. elektrische Spannungsänderungen und stoßen den Prozess der Ansteuerung an. Dieser prinzipielle Verarbeitungsablauf eines elektrischen Signals zur Ansteuerung einer Prothese ist in Abbildung 2.6 dargestellt. Den Beginn bildet das Ausführen einer Aktivierungsgeste. Diese wird durch einen Sensor aufgenommen und anschließend vorverarbeitet. Aus dem daraus entstehenden Signal können zunächst störende Anteile entfernt werden, um es anschließend weiterzuverarbeiten.

Das vorverarbeitete Signal eignet sich zur Berechnung unterschiedlicher Merkmale. Je nach verwendeter Methode zur Signalaufnahme sind hierfür Merkmale wie Root Mean Square (RMS) oder Zero Crossing (ZC) geeignet. Die Ansätze der Merkmalsberechnung unterscheiden sich dabei je nach Methode und können sehr unterschiedlich sein. So haben Phinyomark et al. 50 unterschiedliche Merkmale [75] untersucht, welche alle im Bereich der Klassifikation von EMG-Signalen zur Anwendung kommen. Nach der Berechnung der Merkmale können diese mit Hilfe von Pattern Recognition (PR) oder alternativen Klassifikationsverfahren einer Aktivierungsgeste zugewiesen werden. Daraufhin führen die Elektromotoren nach der Ansteuerung der Prothese das zur jeweiligen Aktivierungsgeste zugehörige Griffmuster aus.

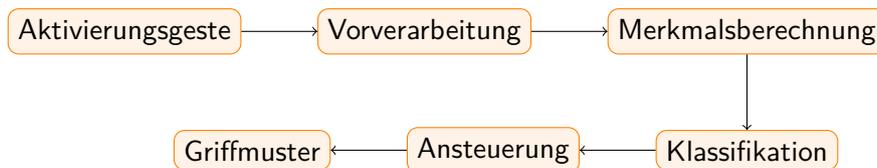


Abbildung 2.6: Schematischer Verarbeitungsablauf von Signalen zur Ansteuerung von Prothesen, von der Aktivierungsgeste bis zur ausgeführten Geste

Zwei etablierte Verfahren zur Erfassung von Muskelaktivitäten sind die Near Infrared Spectroscopy (NIRS) sowie die Elektromyographie (EMG).

Neben diesen Verfahren zur elektrischen Ableitung der Aktivierungsgesten gibt es noch weitere, die z. B. noch vor der eigentlichen Innervierung des Muskels den Beginn der geplanten Bewegung feststellen. So ist es mit Hilfe von Brain-Computer-Interfaces (BCIs) möglich, die Gehirnaktivität invasiv oder nicht-invasiv zu messen und daraus auf die Absicht des Benutzers [34] zu schließen. Hierdurch können Prothesen oder andere Geräte gesteuert werden. Zwei etablierte Verfahren hierfür sind die Electroencephalography (EEG) und die Electrocorticography (ECoG).

2.3.1 Electroencephalography (EEG)

Mit Hilfe von Elektroden auf der Kopfhaut lassen sich Spannungspotentiale messen, welche durch die Aktivität des Gehirns hervorgerufen werden. Die Elektroden werden zur Ableitung nach einem standardisierten Muster angeordnet. Die am häufigsten verwendete Anordnung ist das *10-20-System*, welches in Abbildung 2.7 dargestellt ist [34]. Diese Anordnungsform hat sich bewährt und stellt sicher, dass die Messpositionen bei verschiedenen Kopfformen und -größen an der gleichen Stelle sind und damit die aufgenommenen Werte der Messungen an unterschiedlichen Probanden vergleichbar sind.

Die mit Hilfe der EEG aufgenommenen Signale werden in Delta-, Theta-, Alpha-, Beta- und Gamma-Rhythmus unterteilt. Für die Rhythmen findet alternativ auch der Begriff *Wellen* Verwendung. Der *Delta-Rhythmus* liegt zwischen 0,5 und 4 Hz und tritt bei Erwachsenen zumeist während der Tiefschlafphase auf. Der *Theta-Rhythmus* liegt zwischen 4 und 7 Hz. Er lässt sich bei Erwachsenen vor dem Einschlafen oder in tiefen Entspannungsphasen messen. Der *Alpha-Rhythmus* zwischen 8 und 13 Hz zeigt sich im wachen Zustand während einer Entspannung, z. B. mit geschlossenen Augen. Der *Beta-Rhythmus* zwischen 13 und 30 Hz lässt sich vor allem in Konzentrationsphasen nachweisen. *Beta-Wellen* sind bei der aktiven Unterdrückung einer Bewegung oder bei der Lösung eines mathematischen Problems zu beobachten. Die höchsten Frequenzen

2 Steuerung von Handprothesen

ab 35 Hz hat der *Gamma-Rhythmus*. Er spiegelt unterschiedliche Abläufe des Bewusstseins wider [40].

Die EEG eignet sich zur Steuerung von Prothesen der oberen Extremitäten, da Ellbogen- und Hand-Gesten wie die Flexion oder die Extension durch EEG bestimmt und ausgeführt werden können [15, 47]. Problematisch bleibt das Steuern von mehrgliedrigen Prothesen der oberen Extremitäten mit einer Vielzahl an Griffmustern entsprechend der exakten Bewegungsabsicht des Nutzers [6]. Eine Möglichkeit, dieses Problem anzugehen besteht darin, die EEG-Daten mit anderen Sensordaten zu vereinen und somit einen größeren Raum an möglichen Bewegungen zu eröffnen, wie dies von Bandera et al. bereits zur Unterscheidung von vier Gesten vorgestellt wurde [6].

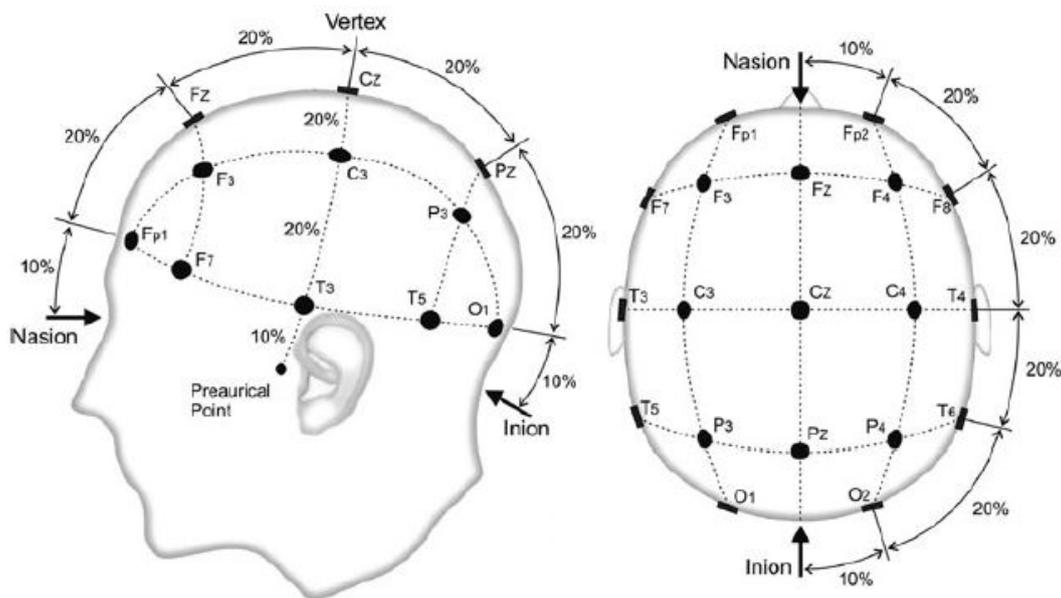


Abbildung 2.7: Internationales 10-20-System zur Aufzeichnung von EEG-Signalen [34]

2.3.2 Electrocorticography (ECoG)

Für die ECoG werden Elektroden direkt auf der exponierten Oberfläche des Gehirns angebracht, um die elektrische Aktivität der Großhirnrinde abzuleiten und aufzuzeichnen [40, 82]. Hierfür wird eine Kraniotomie, also das künstliche Öffnen des Schädelknochens, durchgeführt [34]. Durch die Anbringung der Sensoren direkt auf der Oberfläche des Gehirns werden weniger störende Signale gemessen, was zu einer höheren Qualität des Signals führt.

Bis auf die Anbringung der Elektroden ist die Funktionsweise ähnlich der EEG, sodass durch das Messen der Spannungspotentiale zwischen den einzelnen Sensoren ein Rückschluss auf die Aktivität einzelner Bereiche des Gehirns gezogen werden kann. Es können somit, wie mit der EEG, die im Abschnitt 2.3.1 genannten Rhythmen beobachtet und gemessen werden.

Yanagisawa et al. konnten zeigen, dass es möglich ist, eine Prothese mit Hilfe von ECoG-Signalen anzusteuern und je nach Proband diese drei bis fünf unterschiedliche Bewegungen ausführen zu lassen [110]. Die Autoren demonstrieren, dass die Klassifikation ohne zusätzliche Daten von anderen Methoden wie beispielsweise der EMG möglich ist. Yanagisawa et al. erreichten je nach

Proband für drei Hand-Gesten eine Korrekturklassifikationsrate (KKR) zwischen 61 % und 81 %, und für Ellbogen-Gesten einen Wert zwischen 64 % und 78 %.

Ein Vorteil von ECoG-Signalen gegenüber EEG-Signalen ist die höhere Qualität der aufgenommenen Daten und dass die Klassifikationsergebnisse über einen langen Zeitraum wie beispielsweise zwei Wochen stabil sind. Nachteilig ist jedoch der hohe invasive Anteil zur Platzierung der Sensoren. Zudem ist wie durch die EEG auch mit der ECoG nur eine geringe Anzahl an unterschiedlichen Gesten unterscheidbar.

2.3.3 Near Infrared Spectroscopy (NIRS)

Kleine Veränderungen des Hämoglobinwertes und damit des Sauerstoffanteils im Blut lassen sich durch Near Infrared Spectroscopy (NIRS) bestimmen. Dabei werden eine Photodiode und ein Leucht-Emitter kutan über dem zu beobachtenden Areal platziert. Je mehr Hämoglobin oder Myoglobin sich im Pfad des ausbreitenden Lichts befindet, desto mehr Licht wird von den beiden Stoffen absorbiert.

Dadurch ist es einerseits möglich, Rückschlüsse auf die Aktivierung von Hirnarealen zu erhalten, sodass NIRS als Alternative zu ECoG oder EEG Verwendung finden kann [34]. Andererseits wird bei einer Muskelaktivität Blut aus dem Gewebe gedrückt und somit die Absorption verringert. Dies wiederum kann durch die Photodiode gemessen werden und erlaubt so einen Rückschluss auf die Aktivität der Muskelgruppe direkt unterhalb des Sensors [4, 41].

Die Sensordaten von NIRS lassen jedoch keinen Rückschluss auf die Intensität der Muskelaktivierung zu. Allerdings sind der Beginn und das Ende einer Bewegung deutlicher erkennbar [41]. Dies ist der Hauptgrund dafür, warum NIRS häufig mit weiteren Sensordaten fusioniert wird. Daher konnte auch gezeigt werden, dass NIRS in Kombination mit anderen Sensordaten zur Steuerung von Prothesen geeignet ist [36, 41].

2.3.4 Elektromyographie (EMG)

Die Elektromyographie (EMG) ist eine Methode zur Messung der elektrischen Aktivität von Muskeln. Es gibt zwei weit verbreitete Arten von EMG: das Oberflächen-EMG und das intramuskuläre EMG.

Das intramuskuläre EMG wird durch Einführen einer Nadelelektrode oder einer Nadel mit zwei feinen Drahtelektroden in das Muskelgewebe durchgeführt [12]. Diese Methode ermöglicht eine hohe Ortsauflösung und kann Aussagen über einzelne Muskelfasern liefern. Alternativ kann eine geringere Ortsauflösung gewählt werden, um Aussagen über ganze Muskelgruppen zu erhalten, indem die einzelnen Aktionspotentiale zu einem Muskelsummenaktionspotential (MSAP) kumuliert werden.

Das Oberflächen-EMG hingegen erfasst elektrische Aktivität über einen größeren Bereich und weit weniger punktuell [11, 37]. Die Elektroden sind aufgrund ihrer mechanischen Dimensionen nicht in der Lage, die Aktivität einzelner motorischer Einheiten abzubilden. Oberflächenelektroden werden zum Beispiel in der Sport-Physiologie eingesetzt, um den Zeitpunkt des Beginns einer Muskelkontraktion zu bestimmen. In der Neurologie werden sie vor allem zur Tremoranalyse eingesetzt.

Die zu messenden Signale entstehen im Muskel, welche aus mehreren Muskelbündeln bestehen. Diese wiederum bauen sich aus mehreren Muskelfasern auf, welche von mehreren Myofibrillen

2 Steuerung von Handprothesen

gebildet werden (siehe Abbildung 2.8). Die Myofibrillen stellen etwa 50 % der Zellmasse und sind im Wesentlichen verantwortlich für die Kontraktion [54]. Mehrere Muskelfasern werden von einer motorischen Vorderhornzelle aus dem Rückenmark angesprochen. Diese innerviert die Muskelfasern über eine motorische Endplatte, welche den Nervenimpuls auf die Muskelfasern überträgt. Die verbundenen Muskelbündel, die Vorderhornzelle und die motorischen Endplatten bilden zusammen die motorische Einheit [28, 54]. Ein Muskel verfügt dabei über mehrere motorische Einheiten, wobei die Anzahl der verbundenen Muskelfasern bestimmt, wie fein die Bewegungen ausgeführt werden können. So hat die Fingermuskulatur etwa fünf bis zehn Muskelfasern pro motorischer Einheit, während es in der Rückenstrecker-muskulatur bis zu 2000 sind [54]. Diese Arbeit hat ihren Schwerpunkt auf den oberen Extremitäten. Dabei stehen die beiden Muskeln Flexor carpi radialis und Extensor digitorum im Fokus (siehe Abbildung 4.1). Diese verfügen über 235 und 890 motorische Einheiten [28]. Die Muskelfasern einer motorischen Einheit liegen nicht immer direkt nebeneinander und sind oft über einen Querschnitt von fünf Millimetern verteilt [54]. Zudem arbeiten verschiedene motorische Einheiten nicht gleichzeitig sondern phasenverschoben [54, 59]. Als messbare Potentiale entstehen das Endplattenpotential und das Muskelaktionspotential, auch Aktionspotential genannt. Das Endplattenpotential entsteht durch die elektrisch geladenen Natrium- und Kaliumionen, die durch die Zellmembrane wandern und so das Spannungspotential ändern [54]. Dieser Vorgang wird auch Depolarisation genannt. Wenn das Endplattenpotential einen bestimmten Schwellwert unterschreitet, wird das Muskelaktionspotential ausgelöst [54]. Eine motorische Einheit erregt alle mit ihr verbundenen Muskelfasern nahezu zeitgleich. Da jedoch nicht alle motorischen Einheiten gleichzeitig erregt werden, ist es möglich, über die Anzahl der erregten motorischen Einheiten die Muskelkraft zu variieren [54]. Nachdem ein Aktionspotential ausgelöst wurde, erfolgt eine kurze Muskelkontraktion, die sich als Muskelzucken bemerkbar macht. Wird kurz darauf ein weiteres Aktionspotential ausgelöst, so wird der Muskel aufgrund seiner Vorspannung noch weiter kontrahiert. So kann über die Frequenz der Aktionspotentiale die Muskelkontraktion und daraus die Muskelkraft reguliert werden. Ist die Aktivierungsfrequenz so hoch, dass es zu keiner Muskeler-schlaffung mehr kommt, so liegt der Zeitbereich des Tetanus oder die tetanische Kontraktion vor [54], siehe Abbildung 2.9.

Durch die Aktivierung einer motorischen Einheit wird ein Aktionspotential erzeugt, welches in Abbildung 2.10 dargestellt ist. Dieses Signal wird auch *motor unit action potential* (MUAP) genannt [59]. Bei der Spannungspotentialmessung werden die Aktionspotentiale aller einzelnen motorischen Einheiten aufsummiert und ergeben das für die EMG-Messung typische Muster [11, 54, 59]. Abbildung 2.11 zeigt ein solches EMG-Signal mit einer beginnenden Muskelaktivität. Der Muskel ist bis zur Zeitmarke von etwa 2,02 Sekunden in Ruhe, daraufhin beginnt nach etwa 200 ms die Kontraktion.

Moderne Handprothesen verwenden fast ausschließlich EMG-Signale zur Steuerung [66, 67, 99, 102, 103]. Prinzipiell ist die Methode der Aufzeichnung von Steuersignalen für Prothesen austauschbar, in dieser Arbeit werden exemplarisch EMG-Signale verwendet.

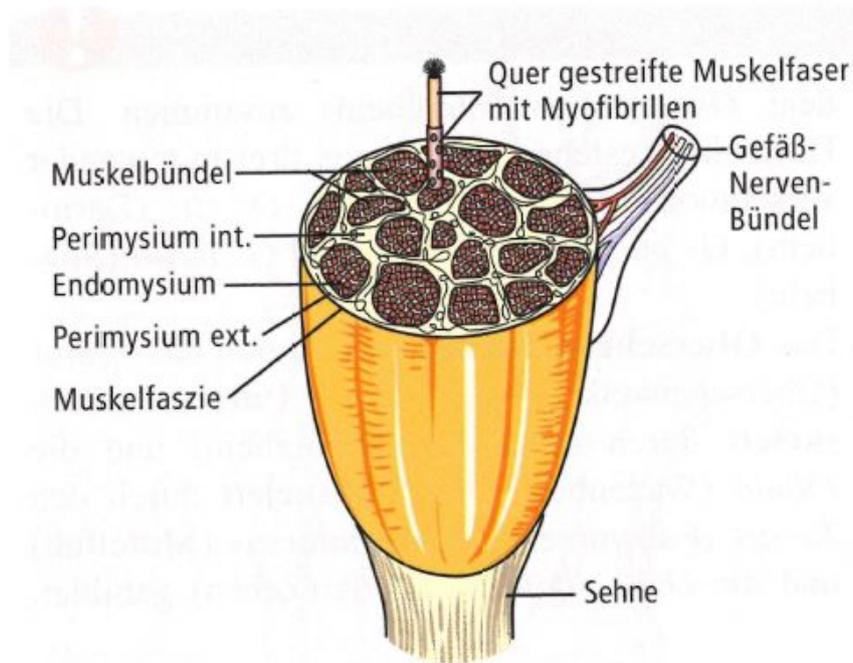


Abbildung 2.8: Schematischer Aufbau eines Skelettmuskels [58]

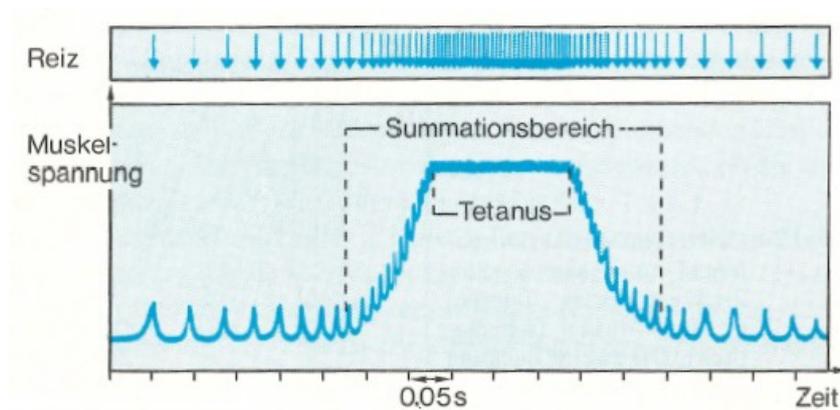


Abbildung 2.9: Tetanische Kontraktion bei hoher Aktivierungsfrequenz [58]

2 Steuerung von Handprothesen

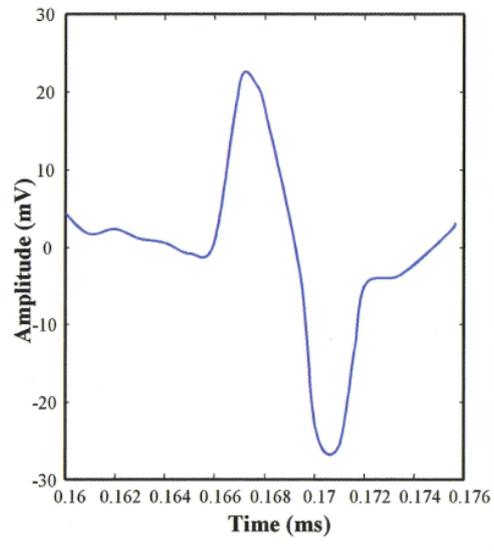


Abbildung 2.10: Ein *motor unit action potential* (MUAP) [59]

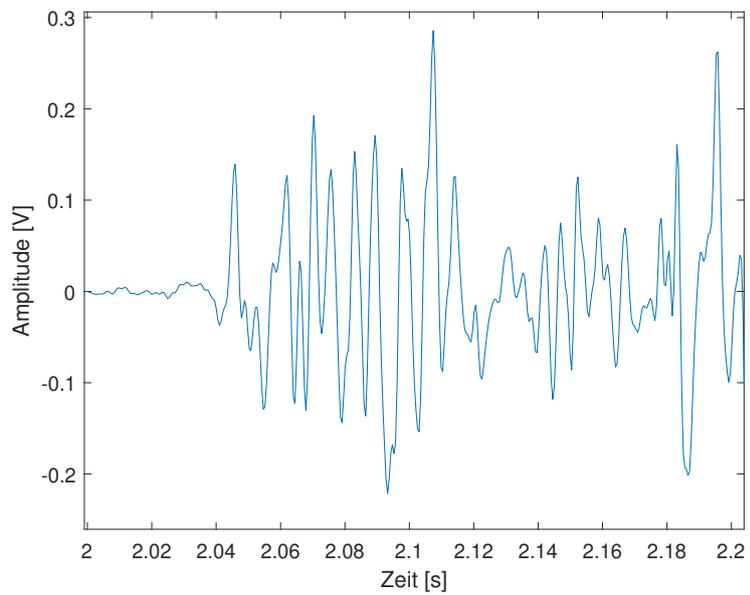


Abbildung 2.11: Ausschnitt eines EMG-Signals bei beginnender Muskelaktivität.

2.4 Vorverarbeitung der Signale zur Steuerung von Handprothesen

Ziel der Vorverarbeitung von elektrischen Signalen ist es, diese nach der Aufnahme zur Steuerung von Prothesen so weit zu verbessern, dass eine nachfolgende Klassifikation möglichst optimale Ergebnisse erzielt. Dabei gehört zur Vorverarbeitung das Herausfiltern von störenden oder nicht relevanten Frequenzen, das Schneiden bzw. das Erkennen von Anfang und Ende sowie die Berechnung von Merkmalen.

2.4.1 Filterung von EMG-Signalen

EMG-Signale setzen sich aus vielen einzelnen, phasenverschobenen, sich überlappenden MUAPs zusammen, welche zusätzlich von verschiedenen Störsignalen additiv überlagert sind. Da in dieser Arbeit die EMG-Signale von der Hautoberfläche aufgezeichnet werden, sind diese mit Störsignalen der Umgebung überlagert, beispielsweise durch elektromagnetische Wellen von Leuchtstoffröhren oder Handys.

Außerdem werden Spannungsunterschiede aufgenommen, die nicht durch die Kontraktion des zu messenden Muskels entstehen. So beeinflussen auch benachbarte oder sogar weiter entfernte innervierte Muskeln die Messung. Da das eigentliche EMG-Signal üblicherweise im Frequenzbereich bis 400 Hz liegt, ist dieses mit einem Tiefpassfilter dahin gehend isolierbar, indem höhere Frequenzen stark unterdrückt werden.

Der Hochpassfilter mit einer Grenzfrequenz von 5 Hz bis 20 Hz [53] reduziert niederfrequentes Rauschen, welches hauptsächlich aus zwei Quellen stammt: dem thermischen Rauschen des Verstärkers und dem elektrochemischen Rauschen der Haut-Elektroden-Schnittstelle.

2.4.2 Merkmalsberechnung für Handprothesen

Das aufgenommene Rohsignal, wie es in Abbildung 2.11 ausschnittsweise dargestellt ist, ist sehr schwer zu interpretieren und unterschiedliche Gesten sind durch das bloße Betrachten nicht zu unterscheiden. Daher werden Merkmale (engl. features) berechnet, welche die unterschiedlichen Charakteristika des Signals, wie z. B. die durchschnittliche Muskelaktivierung oder die Aktivierungsfrequenz zeigen.

Ein Merkmal kann sowohl für das gesamte Signal oder auch nur für einen Teil berechnet werden, siehe Abschnitt 2.6.

Root Mean Square (RMS): Der Root Mean Square entspricht der Stärke der durchschnittlichen Muskelaktivierung. Er ist in Formel (2.1) dargestellt. Neben dem Einsatz in der EMG wird das Merkmal auch in anderen Bereichen wie der Sprach- oder Musikererkennung zur Mustererkennung verwendet [73].

$$RMS = \sqrt{\frac{1}{N} * \sum_{k=1}^N x_k^2} \quad (2.1)$$

Abbildung 2.12 zeigt den berechneten RMS sowie das dazugehörige ungeschnittene EMG-Signal für die Geste Faust. Das Merkmal ist dabei wiederholt für jeweils 100 ms des Signals berechnet. Ein solcher 100 ms langer Abschnitt enthält 204 Messwerte.

2 Steuerung von Handprothesen

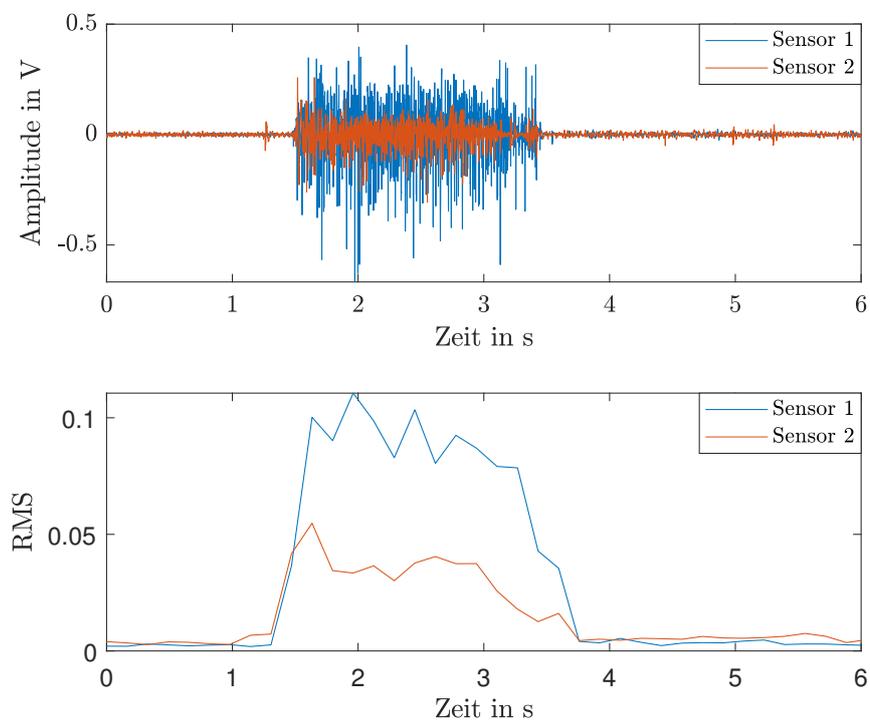


Abbildung 2.12: Ungeschnittenes EMG-Signal der Geste Faust mit zwei Sensoren (oben), RMS für beide Sensoren (unten)

Zero Crossing (ZC): Das Merkmal Zero Crossing zeigt die Aktivierungsfrequenz des Muskels, in form der Nulldurchgänge innerhalb eines Zeitintervalls. Hudgins und Tkach et al. empfehlen für EMG-Signale das ZC zusammen mit einem Schwellwert zu verwenden. Dieser wirkt wie ein Tiefpassfilter und verhindert, dass das Merkmal kleine Änderungen um den Nullpunkt erfasst. Der Schwellwert ist mit $\varepsilon \approx 0.01V$ angegeben [44, 98]. Abbildung 2.13 zeigt das ZC-Feature eines EMG-Signals mit Schwellwert. Dabei ist zu erkennen, dass das Ruhesignal am Anfang und Ende der Aufnahme fast vollständig bei Null liegt. Das verwendete Merkmal ist definiert durch:

$$ZC = \sum_{k=1}^{N-1} f_{zc}(x_k), \quad (2.2)$$

mit:

$$f_{zc}(x_k) = \begin{cases} 1 & \text{für } ((x_k > 0 \wedge x_{k+1} < 0) \vee (x_k < 0 \wedge x_{k+1} > 0)) \wedge |x_k - x_{k+1}| \geq \varepsilon \\ 0 & \text{sonst.} \end{cases} \quad (2.3)$$

x	=	Messwert
N	=	Anzahl berücksichtigter Messwerte
ε	=	Schwellwert
k	=	Zeitpunkt des Messwerts

Formel (2.3) ist an [44, 98] angelehnt, wobei die Variablen Deklaration an die bisherige Nomenklatur angepasst wird, sodass diese in allen bisher verwendeten Formeln gleich benannt sind.

Autoregressive Coefficients (ARs): Die Autoregressiven Koeffizienten (engl. Autoregressive Coefficients) einer Zeitreihenanalyse werden zur Identifizierung von zyklischen Zusammenhängen oder zur Vorhersage zukünftiger Ereignisse auf Grundlage der Zeitreihe verwendet [51].

In dieser Arbeit werden die AR zur Identifikation bzw. Charakterisierung des zu klassifizierenden Aktivierungssignals eingesetzt. Die autoregressiven Koeffizienten heißen auch Autokorrelationen, da sie Korrelationen einer Variablen mit sich selbst über verschiedene Zeitpunkte k der Zeitreihe sind [51]. Die maximale Anzahl an korrelierenden Zeitpunkten wird dabei auch als Ordnung K bezeichnet [50]. Zardoshti-Kermani et al. empfehlen für EMG-Signale die Ordnung vier zu verwenden, da gezeigt werden konnte, dass sich bei einer weiteren Erhöhung der Ordnung k das Rauschen empirisch nur noch unbedeutend verringern lässt [112].

Für die Ordnung eins gilt Formel (2.4)¹:

$$AR_1(t) = \Phi_1 AR_{t-1} + e_t \quad (2.4)$$

mit:

Φ	=	Regressionsgewicht
AR_{t-1}	=	Messwert des vorherigen Zeitschritts
e_t	=	Zufallskomponente (Weißes Rauschen)

¹In Anlehnung an [50, 51], Variablenbezeichnungen angepasst.

2 Steuerung von Handprothesen

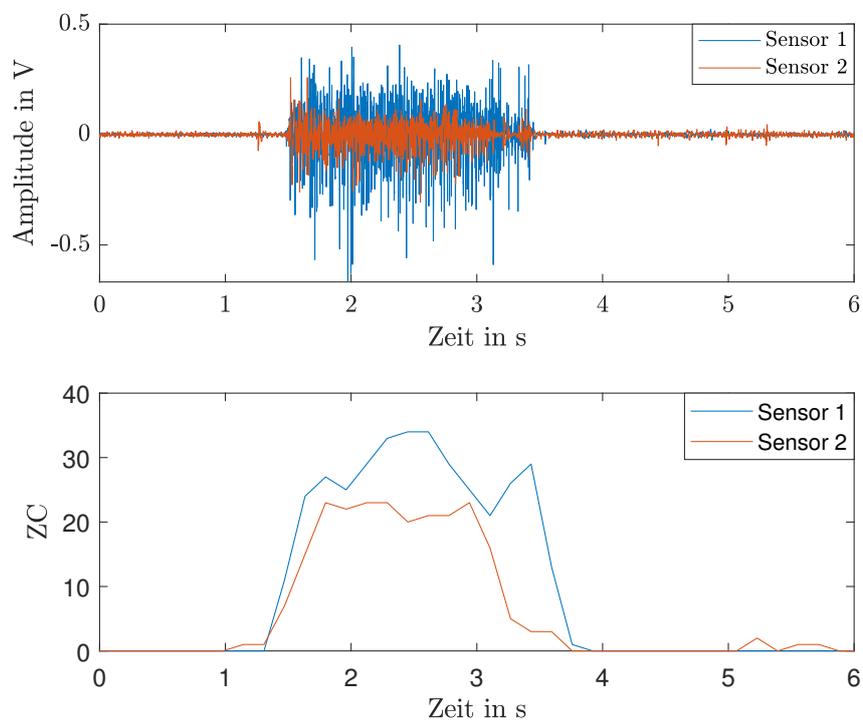


Abbildung 2.13: Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörendes ZC-Signal mit Schwellwert (unten)

2.4 Vorverarbeitung der Signale zur Steuerung von Handprothesen

Für eine beliebige Ordnung k gilt Formel (2.5)²:

$$AR_K(t) = \sum_{k=1}^K (\Phi_k AR_{t-k}) + e_t \quad (2.5)$$

mit:

$$\begin{aligned} K &= \text{Ordnung} \\ k &= \text{Korrelation} \end{aligned}$$

In Abbildung 2.14 sind die autoregressiven Koeffizienten der Ordnung 1 - 4 für das darüber abgebildete EMG-Signal von zwei Sensoren dargestellt.

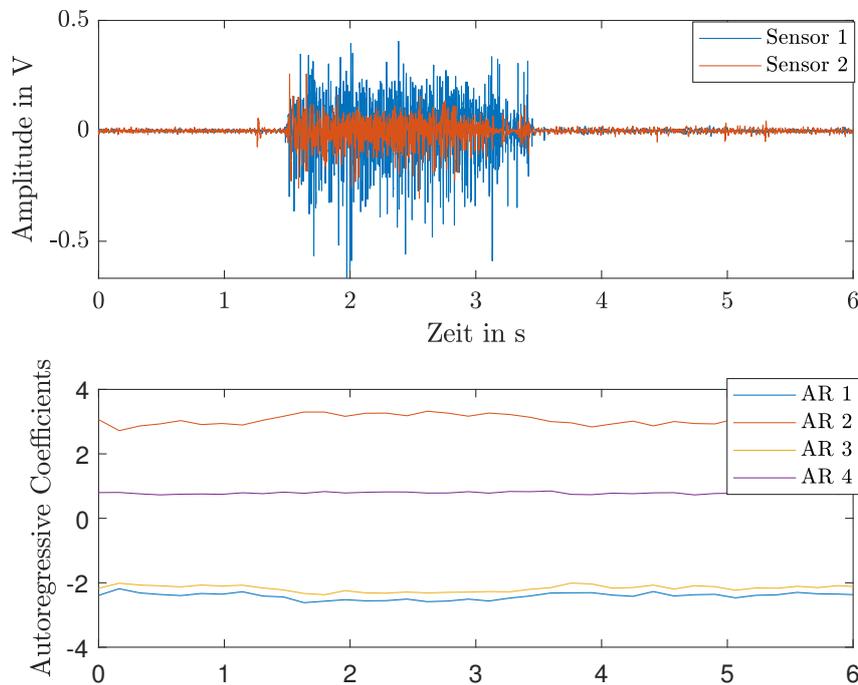


Abbildung 2.14: Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörige Autokorrelationskoeffizienten der Ordnung 1 bis 4 (unten)

Approximate Entropy (ApEn): Die Approximate Entropy beschreibt die Regelmäßigkeit eines Signals und quantifiziert so die Unvorhersehbarkeit von Schwankungen. Je regelmäßiger ein Signal ist, desto kleiner ist die ApEn, je unregelmäßiger es ist, desto größer ist die ApEn [21, 42, 76]. Sie nimmt dabei Werte im Bereich von $[0, 1]$ an. Obwohl Pincus empfiehlt, das Signal vorzuverarbeiten und jeglichen Trend zu entfernen [76], wurde von Delgado et al. gezeigt, dass die ApEn auch auf Rohsignale sehr wirkungsvoll ist [21]. *ApEn* resultiert aus der Gleichung (2.6)³, mit $\Phi(r)$ aus Gleichung (2.7)⁴ und $C(r)$ aus (2.8)⁵.

²In Anlehnung an [10, 51] Variablenbezeichnungen angepasst.

³In Anlehnung an [76] Variablenbezeichnungen angepasst.

⁴In Anlehnung an [76], Variablenbezeichnungen angepasst.

⁵In Anlehnung an [21], Variablenbezeichnungen angepasst.

2 Steuerung von Handprothesen

Es gilt: m ist die zu betrachtende Zeitabhängigkeit und r entspricht einem Schwellwert, der häufig in Abhängigkeit der Standardabweichung gesetzt wird. Als empfohlene Einstellungen gelten $m = 2$ und $r = 0,2 * \sigma$ [21, 75]. Abbildung 2.15 zeigt in der unteren Teilabbildung die $ApEn$ für das dazugehörige, darüber befindliche EMG-Signal von zwei Sensoren. Die dargestellte Gleichung verwendet die Form mit einem negativen ApEn-Wert. Dieser wird häufig für statistische Verfahren gewählt, da keine Verschiebung notwendig ist und er zudem als intuitiver gilt, insbesondere beim Vergleichen von Signalen.

$$-ApEn = \Phi^{m+1}(r) - \Phi^m(r) \quad (2.6)$$

mit:

$$\Phi(r) = (N - m + 1)^{-1} * \sum_{i=1}^{N-m+1} \ln(C_{i=1}^{N-m+1}(r)) \quad (2.7)$$

$$C(r) = \lim_{N \rightarrow \infty} \frac{1}{N^2} \sum_{i,j=1, i \neq j}^N \theta(r - |\bar{X}_i - \bar{X}_j|) \quad (2.8)$$

- N = Anzahl der Beobachtungen
- m = Blockgröße
- r = Schwellwert
- \bar{X} = Messwerte
- $\theta(x)$ = Heaviside Funktion (Schwellwertfunktion)

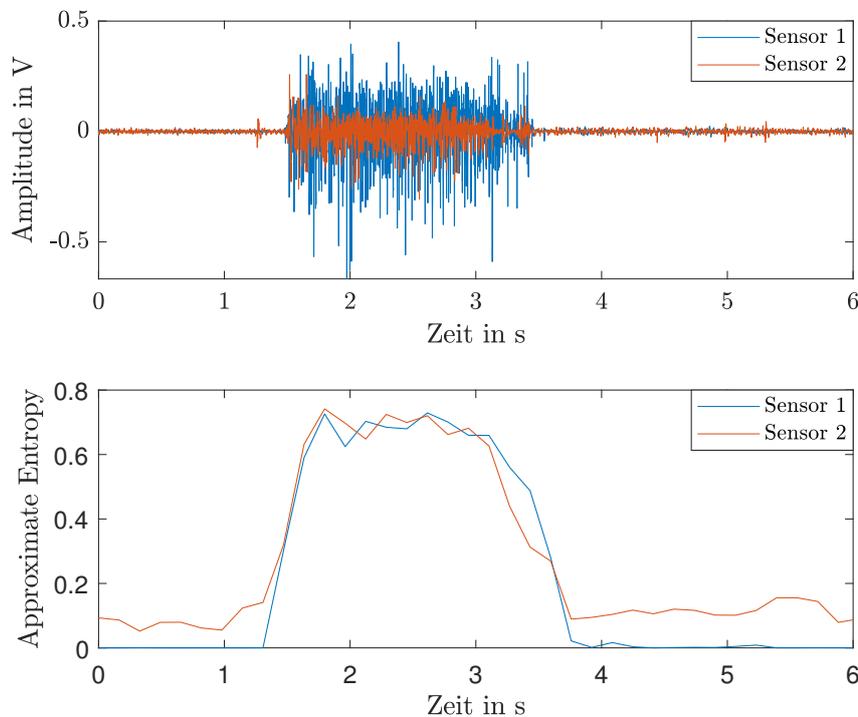


Abbildung 2.15: Ungeschnittenes EMG-Signal der Geste Faust (oben), dazugehörige ApEn (unten)

2.4.3 Fensterfunktionen

Werden Merkmale für die N Messwerte eines Signals berechnet, ergibt sich je nach verwendetem Merkmal ein skalarer Wert oder im Falle der AR ein Vektor der Ordnung K . Daraus resultiert ein stark komprimiertes Signal. Da häufig diese Merkmale in Kombination mit einem Schwellwert zur Ansteuerung verwendet werden [44], können zwei Nachteile auftreten: Zum einen kann aufgrund der im Abschnitt 2.1 und 2.2 beschriebenen Problematik bei der Verwendung von Merkmalen mit Schwellwert nur noch eine geringe Anzahl an Aktivierungsgesten berücksichtigt werden und zum anderen entsteht eine zeitliche Verzögerung von der Aktivierung des Muskels bis zur Überschreitung des Schwellwerts.

Dieser muss so hoch gesetzt sein, dass es nicht zu einer unbeabsichtigten Ansteuerung der Prothese kommt. Hudgins et al. schlagen daher vor, für ein Signal mehrere Merkmale zu berechnen und es zusätzlich in einzelne Abschnitte, sogenannte Fenster, aufzuteilen [44]. Dadurch ergeben sich Merkmalsfenster, deren Länge durch die Fenstergröße (engl. window size) ws bestimmt ist, die wiederum einen direkten Einfluss auf den Klassifikationsfehler hat. So führen sehr kurze Fenster zu sehr volatilen Merkmalswerten, sodass der Glättungseffekt zu gering ausfällt, um eine hohe Klassifikationsgüte zu erreichen. Wird das Fenster dagegen zu lang gewählt, wird das ursprüngliche Signal so stark gemittelt, dass ebenfalls keine zuverlässige Klassifikation möglich ist. Empirisch kann für EMG-Signale gezeigt werden, dass insbesondere Fenstergrößen im Bereich von 150 ms bis 250 ms geeignet sind und zu guten Klassifikationsergebnissen führen [87]. Wird ein Signal in mehrere Fenster unterteilt, entstehen durch die gestiegene Anzahl an Fenstern und die Vielzahl an unterschiedlichen Merkmalen zahlreiche neue Datenpunkte. Diese eignen sich zur Verwendung von Pattern Recognition, was wiederum die Anzahl an Aktivierungsmustern erhöht [108].

Der Abstand zwischen den einzelnen Fenstern wird Schrittweite sw genannt. Diese kann so gewählt werden, dass die Fenster kein gemeinsames Element besitzen. Im Grenzfall gilt $sw = ws$. Allerdings stellt die Schrittweite eine harte Grenze für die berechneten Merkmalswerte dar, sodass jedes Mal beim Übergang von einem Fenster zum nächsten eine Diskontinuität auftritt, bei der die Datenpunkte des vorhergehenden Fensters keinen Einfluss mehr auf die Berechnung des Merkmalswerts für das folgende Fenster haben. Deshalb wird häufig als Alternative die Schrittweite $sw = \frac{ws}{2}$ verwendet. Da die meisten Messwerte bei diesem Vorgehen zwei Fenster beeinflussen, kann dies zu einer stärkeren Glättung der resultierenden Merkmalswerte führen als bei der bloßen Aneinanderreihung von Fenstern. Aufgrund dieses positiven Effekts der Merkmalsglättung werden im Rahmen dieser Arbeit die überlappenden Fenster mit der Schrittweite $sw = \frac{ws}{2}$ eingesetzt. Allerdings bleibt das Problem einer möglichen Verzerrung der resultierenden Merkmalswerte auch bei diesem Verfahren bestehen, da Messwerte am Anfang und am Ende des Signals nur in einem Fenster enthalten sind. Auch innerhalb des Signals treten an den Fenstergrenzen immer wieder Diskontinuitäten auf, wenn Datenpunkte der vorhergehenden Fenster aus der Berechnung der Merkmalswerte herausfallen.

Um diesen Effekt weiter zu verringern und eine möglichst kontinuierliche Ausgangsfunktion der Merkmale zu gewährleisten, können die Werte innerhalb eines Fensters mit Gewichten versehen werden, um ihre Bedeutung für die Merkmalsberechnung zu modifizieren. Durch den Einsatz von Gewichten können beispielsweise Werte am Anfang und am Ende des Fensters abgeschwächt berücksichtigt werden, während Werte in der Mitte des Fensters stärker gewichtet werden. Dies trägt zu möglichst kontinuierlichen Merkmalswerten bei und minimiert den Einfluss von diskontinuierlichen Sprüngen auf die resultierende Merkmalsfunktion. Zwei häufig eingesetzte Fenster-

2 Steuerung von Handprothesen

funktionen sind das Hamming- und das Hanning-Fenster. Diese sind über die Gleichung (2.9) definiert [62, 89] :

$$w(k) = \alpha - (1 - \alpha) \cos\left(2\pi \frac{k}{n-1}\right), k = 1, \dots, n \quad (2.9)$$

Für α gilt, dass dies im Intervall von $0 \leq \alpha \leq 1$ liegt. Für den Fall, dass α gleich 0,54 ist, stellt die Funktion ein Hamming-Fenster dar. Bei einem Wert von 0,5 entspricht die Funktion einem Hanning-Fenster, wobei n die Anzahl der Daten des Fensters und damit auch die Fenstergröße wiedergibt.

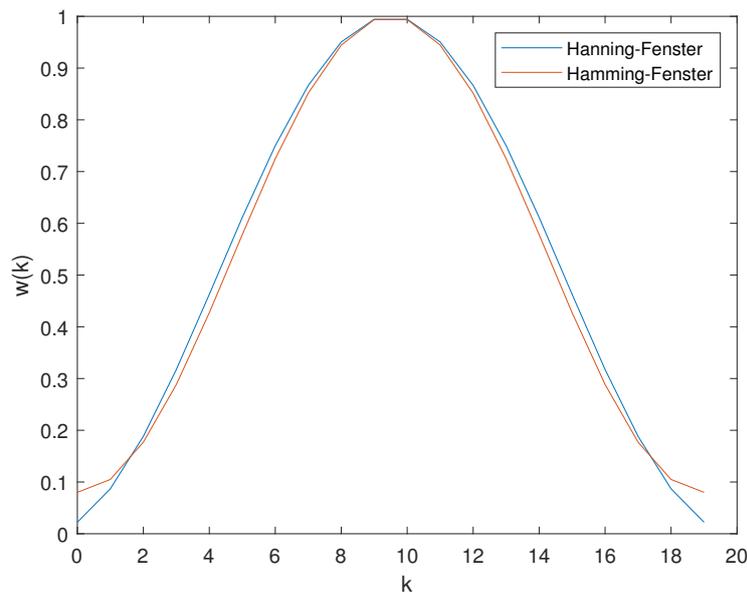


Abbildung 2.16: Darstellung der Hanning- und Hammingfunktion für die jeweiligen Fensterfunktionen

2.4.4 Schnitt von EMG-Signalen

Aufnahmen eines EMG-Signals beinhalten nicht nur das Signal der Geste, sondern auch Signale der Muskelvoraktivierung und der Ruhephase. Um einzelne Gesten zu einer Klasse zusammenzufassen, ist es daher wichtig, alle nicht benötigten Informationen zu entfernen. Hierzu gehört neben den im Abschnitt 2.4.1 beschriebenen Filtern auch das Schneiden der EMG-Signale. Abbildung 2.17 zeigt ein gefiltertes, ungeschnittenes EMG-Signal von zwei Sensoren. Dabei ist in der Abbildung die Ruhephase zu Beginn und am Ende der Aufnahme deutlich zu erkennen. Das Bewegungssignal beginnt nach einer kleineren Muskelaktivität bei etwa 1,5 s. Da der Beginn und etwaige vorgelagerte Muskelaktivitäten bei jeder Wiederholung einer Geste unterschiedlich sind, muss der Beginn der Geste individuell mit einer automatischen Start- und Stopp-Erkennung bestimmt werden.

Für die Start-Stop-Erkennung wird der RMS für ein, auf Fenstern unterteiltes, gefilterte EMG-Signal bestimmt. Aufgrund der Tatsache, dass die größte Muskelaktivität je nach Bewegung von unterschiedlichen Sensoren erfasst werden kann, müsste für das Schneiden der Bewegung

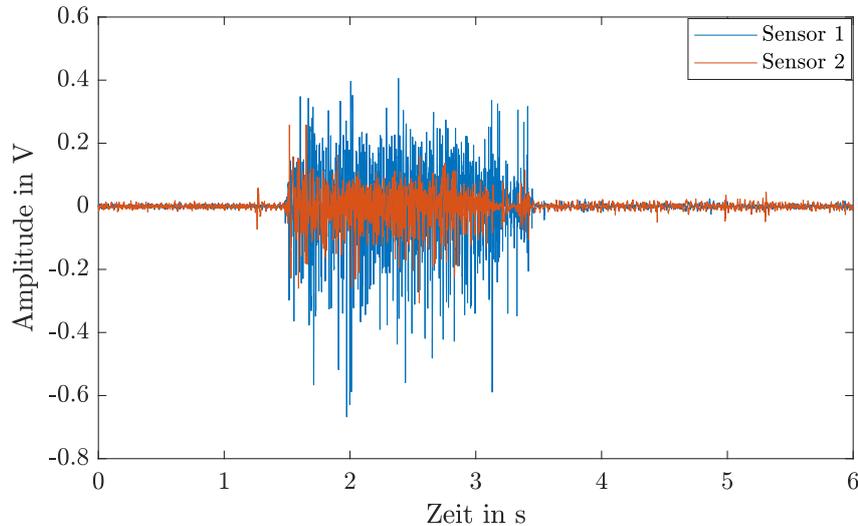


Abbildung 2.17: Ein ungeschnittenes EMG-Signal von zwei Sensoren

dieser Sensor vorher bestimmt werden. Um dies zu vermeiden und den Schneidevorgang davon unabhängig zu gestalten, können die RMS-Signale kumuliert werden, siehe Abbildung 2.18(a). Das erzeugt ein Signal, auf dem für jede Geste auch bei einer großen Anzahl an Sensoren die Start-Stopp-Erkennung durchgeführt werden kann. Um dabei gegenüber Ausreißern robust zu sein, kann für das Schneiden eine andere Fenstergröße gewählt werden als für die spätere Klassifikation der Signale. Oskoei empfiehlt als maximale Fenstergröße 300 ms für EMG-Signale [63]. Dadurch wird das Signal stärker geglättet und Ausreißer werden reduziert.

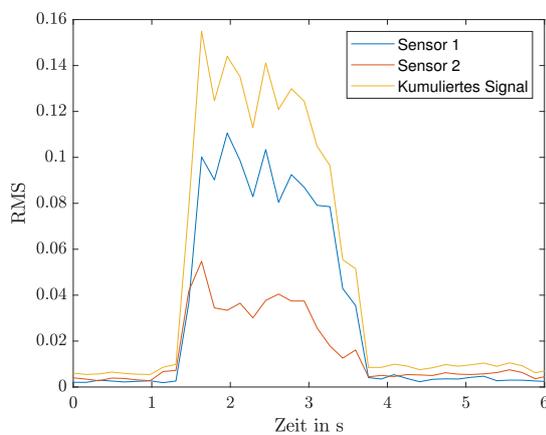
Ein naiver Ansatz für die Start-Stopp-Erkennung ist die Bestimmung eines Schwellwerts. Dies weist den Nachteil auf, dass der Schwellwert so hoch gewählt sein muss, dass er nicht ungewollt eine Bewegung erkennt. Gleichzeitig muss er so niedrig sein, dass er nicht vorzeitig das Signal als beendet definiert. Da diese beiden Anforderungen einen Gegensatz bilden, ist das Schneiden mit nur einem Schwellwert sehr ungenau. Daher ist für die Bestimmung des Start-Zeitpunkts und des Stopp-Zeitpunkts jeweils ein eigener Schwellwert zu ermitteln.

Zur Feststellung des Beginns einer Bewegung wird die Standardabweichung (σ) auf den Median addiert. Daraus resultiert ein Schwellwert, der den im Mittel erreichten RMS-Wert des Signals deutlich übersteigt. Wenn ein derart hoher Wert erreicht wird, ist davon auszugehen, dass zu dem Zeitpunkt ein Signal vorliegt. Experimentell hat es sich als sinnvoll erwiesen, lediglich 75 % der Standardabweichung zum Median zu addieren, um möglichst viele Datenpunkte vom Beginn der Bewegung zu behalten und gleichzeitig dennoch möglichst robust gegenüber möglichen Voraktivierungen des Muskels zu sein, siehe Abbildung 2.18(b).

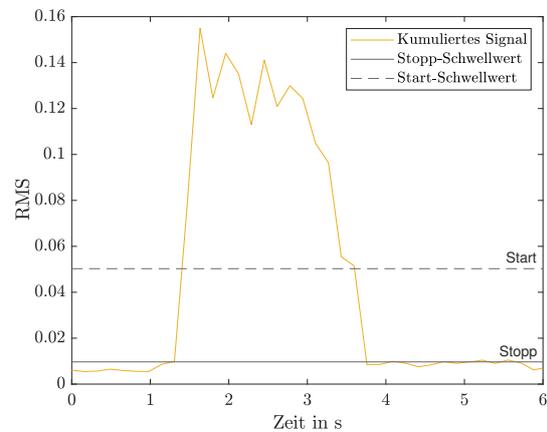
Für das Ende des Signals muss der Schwellwert auf einem der niedrigeren Werte liegen. Er muss jedoch so hoch sein, dass er unterschritten wird, wenn die eigentliche Bewegung endet. Zur Festlegung dieses Wertes wird die folgende Überlegung angestellt: Das aufgenommene EMG-Signal besteht aus drei Teilen. Der erste Teil sind ca. zwei Sekunden Ruhephase, gefolgt von ca. zwei Sekunden Aktivität in Form der Durchführung bzw. des Haltens der Geste und dem dritten Teil von zwei weiteren Sekunden Ruhephase. Somit besteht das aufgenommene EMG-Signal aus $\frac{2}{3}$ Ruhephase und $\frac{1}{3}$ Aktivität. Wird hierfür der Median bestimmt, so entspricht dieser einem der höheren Werte aus den beiden Ruhephasen. Im Gegensatz dazu nimmt das arithmetische

2 Steuerung von Handprothesen

Mittel auf Grund der hohen Werte der Aktivität in der Mitte des Signals einen deutlich höheren Wert an. Dadurch käme es bei dessen Verwendung dazu, dass das EMG-Signal etwas früher den Schwellwert unterschreitet und somit die Bewegung der Geste ebenfalls früher als beendet definiert. Für den Median spricht ebenfalls, dass, wenn eine stark ausgeführte Muskelaktivität endet, der durchschnittliche RMS-Wert deutlich absinkt und häufig unterhalb des Niveaus liegt, welches vor der Aktivität anlag. Somit stellt der Median sicher, dass möglichst viel des eigentlichen Bewegungssignals aufgenommen und erst nach dessen Ende die Ruhephase abgeschnitten wird. Die so ermittelten Schwellwerte ermöglichen die automatische Bestimmung des Beginns und des Endes der einzelnen Gesten und dadurch das Schneiden der Signale einer Aufnahme.



(a) RMS des ersten und zweiten Sensors sowie das daraus kumulierte RMS-Signal



(b) Median plus 75% der Standardabweichung als Startschwellewert und der Median als Endschwellewert

Abbildung 2.18: Verfahren zum automatischen Schneiden von EMG-Signalen und der Berechnung der Schwellwerte zur Erkennung von Anfang und Ende

2.4.5 Distanzmaße

Um Datenpunkte einer Gruppe zuzuordnen zu können, muss die Distanz zwischen den einzelnen Punkten oder den Punkten und dem Zentrum der Gruppe bestimmt werden. Hierfür stehen verschiedene Distanzmaße zur Verfügung. Anschließend kann mithilfe dieser Distanzmaße unter Einsatz eines Klassifikationsverfahrens die Wahrscheinlichkeit ermittelt werden, mit der der betrachtete Datenpunkt einer bestimmten Gruppe, das heißt Klasse, angehört. Nachfolgend werden drei Distanzmaße vorgestellt, die in dieser Arbeit Verwendung finden.

Euklidische Distanz: Die euklidische Distanz ist eines der am häufigsten verwendeten Distanzmaße und ist die Länge des Vektors, der zwei Elemente verbindet.

Sie ist wie in Gleichung 2.10 dargestellt definiert und gibt den Abstand eines Elements i zum Zentrum einer Gruppe g an, bzw. die Distanz zwischen zwei Elementen [5]. Die

2.4 Vorverarbeitung der Signale zur Steuerung von Handprothesen

euklidische Distanz eignet sich besonders für orthogonale und normierte Diskriminanzfunktionen.

$$D_{ig}^2 = \sum_{k=1}^K (Y_{ki} - \bar{Y}_{kg})^2 \quad (2.10)$$

Minkowski-Metrik: Eine Verallgemeinerung der euklidischen Distanz stellt die Minkowski-Metrik dar, die sich auf die Punkte oder Vektoren x und y bezieht. Sie ist in 2.11 definiert und wird mit einer Ordnung $p \in]0, \infty]$ angegeben [48].

$$D_p(x, y) = \left(\sum_{i=1}^m |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (2.11)$$

Bei $p = 1$ entspricht die Minkowski-Metrik der Manhattan-Metrik und für $p = 2$ der euklidischen Distanz. Für $p = \infty$ gilt:

$$D_\infty(x, y) = \max_{i=1}^m |x_i - y_i|. \quad (2.12)$$

Mahalanobis-Distanz: Die Mahalanobis-Distanz ist ein verallgemeinertes Distanzmaß basierend auf Kovarianzinformationen, welches auch im mehrdimensionalen Vektorraum verwendet werden kann. Die Mahalanobis-Distanz nimmt zu, wenn die Kovarianz der verglichenen Elemente abnimmt [5]. Somit enthält die Mahalanobis-Distanz die lineare Abhängigkeit zwischen den einzelnen Variablen. Bei zwei Variablen errechnet sich die quadrierte Distanz als

$$D_{ig}^2 = \frac{(X_{1i} - \bar{X}_{1g})^2 s_2^2 + (X_{2i} - \bar{X}_{2g})^2 s_1^2 - (X_{1i} - \bar{X}_{1g})(X_{2i} - \bar{X}_{2g}) s_{12}}{s_1^2 s_2^2 - s_{12}^2}. \quad (2.13)$$

Hier sind s_1^2 und s_2^2 die empirischen Varianzen, s_{12} die empirische Kovarianz und i das betrachtete Element. Die betrachtete Gruppe ist durch g dargestellt [5]. Im Gegensatz zur euklidischen Distanz bezieht sich die Mahalanobis-Distanz immer auf den Abstand eines Elements zum Zentrum der Gruppe. Der Vorteil der Mahalanobis-Distanz ist, dass diese nicht nur den Abstand zum Zentrum, sondern auch die Verteilung der Häufung entlang der Achsen betrachtet. Somit kann im Gegensatz zur euklidischen Distanz eine Verteilung mit elliptischer Form betrachtet und unterschieden werden.

2.5 Klassifikation von Steuersignalen

Bei der Nutzung einer Prothese wird das Aktivierungssignal vorverarbeitet und mittels Klassifikation einer Geste zugeordnet. Die Zuordnung basiert auf einem algorithmisch konstruierten Modell. Dies wird als maschinelles Lernen bezeichnet [18].

Es unterteilt sich in die Bereiche des überwachten, des unüberwachten und des bestärkenden Lernens. Als Zwischenstufe gibt es noch das teilüberwachte Lernen.

2.5.1 Datenmengen

Für das maschinelle überwachte Lernen werden üblicherweise drei Datenmengen definiert: die Trainings-, Validierungs- und Testmenge [18]. Test- und Validierungsmenge sind disjunkt und werden aus einem großen Teil der verfügbaren Daten gebildet, während der Rest die Trainingsmenge darstellt. Bei kleineren Datensätzen kann die Trainingsmenge etwa 70 – 80 % der Daten ausmachen, während bei größeren Datensätzen bis zu 95 % der Daten zur Erstellung der Trainingsmenge verwendet werden. Das übrige Datenvolumen wird dann auf die Validierungs- und Testmengen aufgeteilt. Dies wird auch als *Hold-Out* bezeichnet.

Die Trainingsmenge wird zur Erstellung des Modells genutzt, während die Validierungsmenge es ermöglicht, verschiedene Klassifikatoren miteinander zu vergleichen oder den Zustand eines Klassifikators zu bestimmen. Hierbei besteht jedoch die Möglichkeit einer Wechselwirkung zwischen Testmenge, Klassifikator und Validierungsmenge, da sich der Klassifikator sowohl an die Test- als auch an die Validierungsmenge anpassen kann. Dabei kann es zu einer Überanpassung kommen, bei der sich der Klassifikator zu stark an die Validierungsmenge anpasst. Im Extremfall speichert das Modell für jede Eingabe eine passende Ausgabe, was zu einer hervorragenden Leistung auf den Trainingsdaten führt, aber zu einer schlechten Leistung auf unbekanntem Daten. Zu einer Überanpassung kann es aus verschiedenen Gründen kommen, beispielsweise dem Vorhandensein einer stark begrenzten Trainingsmenge für komplexe Probleme oder dem zu häufigen Trainieren neuronaler Netze auf der Trainingsmenge [18].

Die davon unabhängige Testmenge wird schließlich zur abschließenden Bewertung des Klassifikators verwendet, da sie keinen Einfluss auf die Trainingsphase hatte.

2.5.2 Überwachtes Lernen

Beim überwachten Lernen ist bereits bei Trainingsbeginn bekannt, zu welcher Klasse der jeweilige Datenpunkt gehört. Hierzu wird für jeden Datenpunkt einer Datenmenge die dazugehörige Kennzeichnung (engl. label) y , welche das Element einer Klasse zuordnet, mit angegeben. Zudem verfügt jedes Element über einen Merkmalsvektor x der mindestens ein Element enthält. Daraus ergibt sich eine Menge bestehend aus $\{(x_i, y_i)\}_{i=1}^N$ [18]. Ziel des überwachten Lernens ist es, ein Modell zu entwickeln, das basierend auf den Informationen aus dem Merkmalsvektor x berechnet, zu welcher Klasse der Datenpunkt gehört.

2.5.3 Unüberwachtes Lernen

Im Gegensatz zum überwachten Lernen ist beim unüberwachten Lernen nicht bekannt, zu welcher Klasse der einzelne Datenpunkt gehört. Die Datenmenge $\{x_i\}_{i=1}^N$ besteht daher nur aus Merkmalsvektoren x [18]. Ziel des Algorithmus ist es, ein Modell zu erzeugen, welches einen Merkmalsvektor als Eingabe nimmt und diesen einer Klasse zuordnet oder eine Vorhersage trifft. Bei einem Klassifizierungsproblem ist dabei das Besondere, dass keine Informationen über die eigentlichen Klassen zur Verfügung stehen. Unüberwachtetes Lernen wird häufig dazu verwendet, Clusterbildung oder Ausreißer zu erkennen sowie die Anzahl der Dimensionen eines Merkmalsraums zu reduzieren.

2.5.4 Bestärkendes Lernen

Der Algorithmus des bestärkenden Lernens (engl. reinforcement learning) ist Teil eines Gesamtsystems und gibt den Zustand dieses Systems als Merkmalsvektor wieder [18]. In jedem Zustand können zusätzlich Aktionen durchgeführt werden, die das System in einen anderen Zustand überführen. Dabei führt jeder interne Zustand des Modells nach dem Erhalt der Information, ob die getroffene Ausgabe falsch oder richtig ist, zu einer Bestrafung oder Belohnung. Ziel des Algorithmus ist das Erlernen einer Vorschrift (engl. policy), welche die durchschnittliche Belohnung maximiert bzw. die durchschnittliche Bestrafung minimiert [18, 25].

Bestärkendes Lernen findet vor allem dann Anwendung, wenn die Entscheidungsfindung sequentiell erfolgt, wie z. B. im Falle von Spielen, Robotik oder Logistikproblemen [18]. Besondere Bekanntheit erlangte dieses Verfahren durch seine Erfolge bei einem der komplexesten Brettstrategiespiele der Welt, dem japanischen Spiel Go. Google setzte bestärkendes Lernen in Kombination mit überwachtem Lernen zum Trainieren seiner künstlichen Intelligenz AlphaGo ein und erschuf dadurch einen Algorithmus, dem es im Jahr 2015 gelang, den Europameister Fan Hui zu schlagen [86].

2.5.5 Bewertung von Klassifikationsergebnissen

Zur Bestimmung der Güte eines Klassifikators existieren verschiedene Methoden und Metriken. Die zwei bekanntesten sind die Konfusionsmatrix und die Receiver Operating Characteristic (ROC)-Kurve.

Beide Methoden sind für binäre Klassifikatoren definiert. Die Klassifikationsergebnisse können dabei die folgenden Zustände annehmen: Richtig-Positiv (RP) (engl. true positive (tp)), Richtig-Negativ (RN) (engl. true negative (tn)), Falsch-Positiv (FP) (engl. false positive (fp)) und Falsch-Negativ (FN) (engl. false negative (fn)). Tabelle 2.4 zeigt in den Zeilen die Beobachtungen und in den Spalten die Vorhersagen. Wird ein Ereignis x beobachtet und dies auch als x vorhergesagt, so wurde das Ergebnis richtig vorhergesagt und ist somit RP. Wird jedoch das nicht richtige Ergebnis \bar{x} vorhergesagt, so ist das Ergebnis FN. Wird ein \bar{x} beobachtet und fälschlicherweise ein x vorhergesagt, so ist das Ergebnis FP. Wird jedoch auch ein \bar{x} vorhergesagt, so ist dies RN. [16, 18]

2 Steuerung von Handprothesen

		Vorhersage	
		x	\bar{x}
Beobachtung	x	RP	FN
	\bar{x}	FP	RN

Tabelle 2.4: Ergebnisse einer binären Konfusionsmatrix

Mit Hilfe der Einteilung der Ergebnisse einer Klassifikation in diese vier Klassifikationsergebnisklassen können verschiedene Metriken berechnet werden. Diese umfassen zunächst die korrekten Klassifikationen T , die falschen Klassifikationen F , die Relevanz R , die Irrelevanz I , die Positivität P und die Negativität N .

Korrekte Klassifikationen: $T = RP + RN$

Falsche Klassifikationen: $F = FP + FN$

Relevanz: $R = RP + FN$

Irrelevanz: $I = FP + RN$

Positivität: $P = RP + FP$

Negativität: $RN + FN$

Häufig verwendete Quotienten sind die **Korrektklassifikationsrate (KKR)**, die **Spezifität**, die **Sensitivität**, die **Falsch-Positiv-Rate (FPR)** (engl. False Positive Rate), sowie die **Präzision**. Zudem wird der F_1 -Score oder auch F-measure vorgestellt. Die Anzahl aller Beobachtungen ist mit n angegeben.

Korrektklassifikationsrate (KKR): Die KKR ist eine der am häufigsten verwendeten Metriken. Sie wird auch aus dem Englischen **Accuracy (ACC)** oder **Genauigkeit** genannt. Die KKR gibt dabei an, wie viele Vorhersagen von allen durchgeführten Klassifikationen richtig klassifiziert wurden und ist damit eine leicht nachvollziehbare Metrik.

$$KKR = \frac{T}{n} = \frac{RP + RN}{RP + RN + FP + FN} \quad (2.14)$$

Sensitivität: Die Sensitivität hat viele alternative Bezeichnungen wie **Trefferquote**, **Relevanz**, **Richtig-Positiv-Rate (RPR)**, **Recall** oder **True Positiv Rate (TPR)**. Sie zeigt an, wie viele richtig-positive unter allen relevanten Vorhersagen sind. Damit weist eine hohe Sensitivität auch auf eine geringe Anzahl an FN hin und gibt somit an, wie zuverlässig ein Modell in der Lage ist korrekte Entscheidungen zu treffen.

$$Sen = \frac{RP}{R} = \frac{RP}{RP + FN} \quad (2.15)$$

Spezifität: Die Spezifität wird auch **Richtig-Negativ-Rate (RNR)** oder **True Negative Rate (TNR)** genannt. Sie gibt an, wie viele richtig-negative Ergebnisse das Modell unter allen negativen Fällen vorhersagt. Damit zeigt sie, wie gut negative Fälle richtig beurteilt werden und ist somit das Pendant zur Sensitivität.

$$Spez = \frac{RN}{N} = \frac{RN}{RN + FP} \quad (2.16)$$

Falsch-Positiv-Rate (FPR): Die FPR gibt an, wie oft das Modell ein positives Ergebnis vorhersagt, obwohl eine negative Beobachtung stattgefunden hat. Eine geringe FPR weist somit auf eine minimale falsche Aktivierung der Prothese hin.

$$FPR = \frac{FP}{I} = \frac{FP}{FP + RN} \quad (2.17)$$

Präzision: Die Präzision wird auch positiver **Vorhersagewert** oder **Genauigkeit** genannt. In dieser Arbeit wird jedoch der Begriff *Genauigkeit* ausschließlich synonym für die KKR genutzt. Die Präzision misst, ob die positiven beobachteten Ereignisse richtig vorhergesagt wurden. Damit stellt die Metrik das Gegenstück zur FPR dar und wird ebenfalls für den F_1 -Score verwendet.

$$\text{Präzision} = \frac{RP}{P} = \frac{RP}{RP + FP} \quad (2.18)$$

F_1 -Score: Der F_1 -Score ist das harmonische Mittel aus der Präzision und der Sensitivität. Einzelne Metriken können fehlinterpretiert werden oder ein falsches Bild des Klassifikators abgeben. Daher ist es wichtig, nicht nur mehrere Metriken zu betrachten, sondern diese auch miteinander zu verbinden. Dies erleichtert die Interpretation der Klassifikationsgüte.

$$\begin{aligned} F_1 &= 2 * \frac{\text{Präzision} * \text{Sensitivität}}{\text{Präzision} + \text{Sensitivität}} \\ &= \frac{2 * RP}{2 * RP + FP + FN} \end{aligned} \quad (2.19)$$

Die Ergebnisse der auf einem Quotienten beruhenden Metriken, befinden sich in dem Intervall $[0, 1]$ und werden daher häufig auch in Prozent angegeben.

Wie zu Beginn des Abschnitts erwähnt, sind die Metriken und die Konfusionsmatrix für binäre Klassifikatoren definiert. Sollen mehr als zwei Klassen klassifiziert und die Metriken dazu berechnet werden, so ist dies der Definition nach möglich. Da x die entsprechende Klasse und \bar{x} eine beliebige andere ist, ergibt sich somit eine größere Konfusionsmatrix. Für k Anzahl Klassen ist die Konfusionsmatrix eine $k * k$ Matrix. Dies hat zur Folge, dass die FN und die FP jeweils ein Vektor der Länge $k - 1$ sind. Für RN ergibt sich eine Matrix der Größe $(k - 1) * (k - 1)$ und für RP ein Skalar.

FN, FP, RP und RN können über alle Klassen aufsummiert werden. Die Vektoren der FP und der FN sowie das Skalar der RP verschieben sich entsprechend des Klassenindexes. Die elementweise Summe über alle Beobachtungen minus der Summe von FP, FN und RP ergibt die Anzahl an RN. Exemplarisch ist dies in Tabelle 2.5 dargestellt.

2 Steuerung von Handprothesen

	a	b	c	d	e	Summe
a	40	20	20	20	0	100
b	0	60	0	40	0	100
c	0	20	60	20	0	100
d	0	0	0	80	20	100
e	0	0	0	20	80	100

Tabelle 2.5: Beispiel für eine Multi-Klassen-Konfusionsmatrix mit 100 Beobachtungen pro Klasse (RP in Grün; FN in Grau; FP in Blau; RN in Orange)

Für das Beispiel in Tabelle 2.5 beträgt die KKR für die Klasse a 88%, bei einer TPR von 100%, einer TNR von 100%, einer Präzision von 40% und einem F_1 -Score von 57%. Dies zeigt, dass eine Betrachtung der KKR, welche mit 88% eine gute Klassifikationsgüte suggeriert, zu irreführenden Schlussfolgerungen führen kann, da die Präzision und der F_1 -Score deutlich niedrigere Werte aufweisen können. Dennoch wird häufig sowohl in der Wissenschaft [1] als auch in der Praxis die KKR herangezogen. Die Präzision und der F_1 -Score weisen jedoch in diesem Fall auf eine häufige falsche Klassifikation hin; siehe im Beispiel auf die Klassen $b - e$. Das ist ein weiterer Aspekt, der durch die KKR verzerrt dargestellt wird, da die Anzahl an RN mit steigender Klassenanzahl meist ebenfalls deutlich ansteigt. Somit suggeriert die KKR ein sehr viel besseres Klassifikationsergebnis als der Klassifikator tatsächlich liefert. Dies führt dazu, dass für eine Mehrklassen-Klassifizierung die KKR ihre Intuitivität verliert [79].

Im Gegensatz dazu eignet sich der F_1 -Score hier besser, da er das harmonische Mittel aus der Präzision und der Sensitivität ist. Für das eingangs erwähnte Beispiel beträgt für die Klasse a der F_1 -Score 57%. Das arithmetische Mittel über alle Klassen ist für die KKR 87% und für den F_1 -Score 64%. Daher wird im Folgenden vor allem der F_1 -Score für die Beurteilung herangezogen, während die Angabe der KKR hauptsächlich dem Vergleich mit anderen Arbeiten dient.

Ein weiteres Modell zum Vergleich von unterschiedlichen Klassifikatoren neben der Konfusionsmatrix ist die ROC-Kurve. Für diese werden die RPR und die FPR für diskrete Schwellwerte des Klassifikators in dem Intervall $[0, 1]$ berechnet [18]. Nun kann z. B. derjenige Schwellwert gewählt werden, mit dem eine möglichst hohe RPR bei einer möglichst geringen FPR erreicht wird.

Je größer die Fläche unter der Funktion (Area Under Curve (AUC)) ist, desto besser ist der Klassifikator [18]. Abbildung 2.19 zeigt vier ROC-Kurven mit den dazugehörigen AUC-Werten. Für eine Bewertung eines Klassifikators bei einem Multi-Klassifikationsproblem müssen für jede Klasse eine ROC-Kurve und die AUC berechnet und anschließend gemittelt werden.

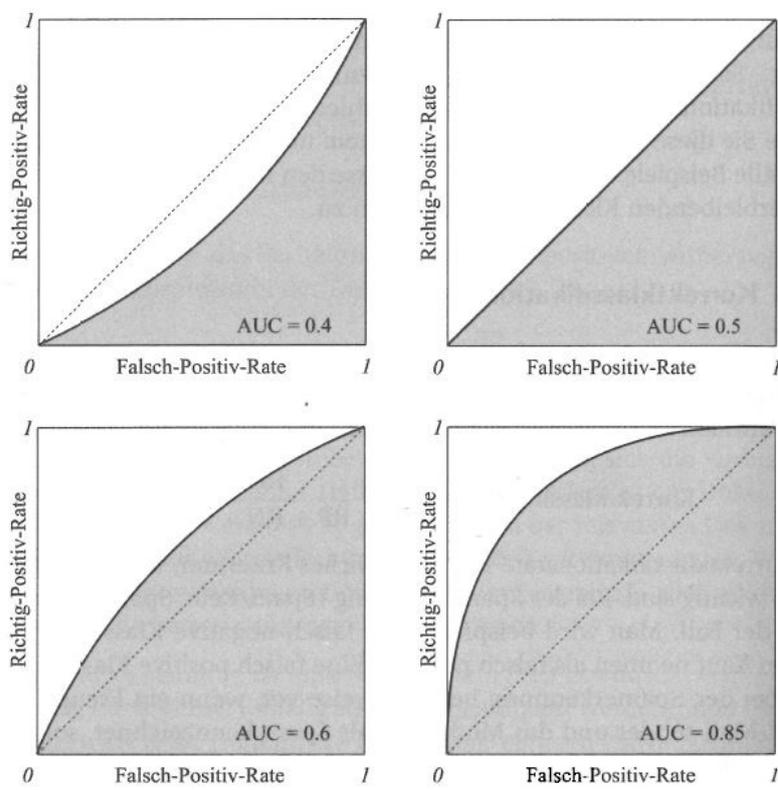


Abbildung 2.19: Vier unterschiedliche ROC-Kurven mit dazugehörigem Area Under Curve (AUC)-Wert [18]

2.5.6 Verwendete Klassifikatoren

Nachfolgend werden die zur Klassifikation von Myoelektrischen-Signalen am häufigsten genutzten Klassifikationsverfahren vorgestellt und die allgemeine Funktionsweise sowie die jeweiligen Einstellungen für jeden im Abschnitt 4.4 verwendeten Klassifikator beschrieben.

Lineare Diskriminanzanalyse (LDA): Die Lineare Diskriminanzanalyse ist eines der am häufigsten benutzten Verfahren des überwachten Lernens und eignet sich besonders gut zur Trennung von zwei Klassen [5]. Die Methode beruht darauf, dass eine Diskriminanzfunktion gesucht wird, welche die zu klassifizierenden Gruppen voneinander trennt [25]. Das Maximum der Diskriminanzfunktion $J(w)$ folgt aus dem Mittelwert μ und der Varianz s^2 :

$$J(w) = \frac{(\mu_1 - \mu_2)^2}{s_1 + s_2} \quad (2.20)$$

Die LDA ist gut interpretierbar, einfach anzuwenden und schätzt ihre Parameter mit Hilfe der Methode der kleinsten Quadrate (MKQ). Da dies mit geringer Rechenleistung möglich ist, können große Datenmengen damit gut verarbeitet werden.

Lim et al. haben die LDA mit 32 weiteren Klassifikatoren für 32 Datensets verglichen und sind zu dem etwas überraschenden Ergebnis gekommen, dass die LDA trotz der Einfachheit des Verfahrens gute Ergebnisse erzielt. Da das Verfahren im Test eine Platzierung unter den fünf besten Klassifikatoren erreichte, empfehlen Lim et al. die LDA auch gegenüber neueren Klassifikatoren als Vergleichsklassifikator zu verwenden [52].

Support Vector Machine (SVM): Die SVM ist ebenfalls ein häufig eingesetzter Klassifikator aus dem Bereich des überwachten Lernens. Der Algorithmus sucht im einfachsten Fall eine Gerade und im allgemeinen Fall eine Hyperebene, welche die Datenpunkte so trennt, dass der Abstand zwischen den einzelnen Klassen bzw. Objektvektoren jeweils maximal ist. Anstelle einer Geraden können alternativ auch eine oder mehrere beliebige, andere Entscheidungsfunktionen zur Trennung der Klassen verwendet werden [85]. Gefunden wird die zur Trennung verwendete Funktion durch das Einpassen des Merkmalsraums in eine Hyperebene durch Erzeugen eines mehrdimensionalen Raumes, dessen Dimensionalität beliebig groß sein kann [24].

In Abbildung 2.20⁶ ist eine Hyperebene dargestellt, welche beide Klassen optimal trennt. Ebenfalls eingezeichnet sind die Support-Vektoren R_1 und R_2 . Das Ziel der Berechnung ist es, die Vektoren so zu optimieren, dass ein größtmöglicher Abstand (margin) zur Hyperebene entsteht [25]. Damit sind die beiden Klassen sehr gut trennbar.

⁶In Anlehnung an [25], Grafik nach dem Scannen optisch überarbeitet.

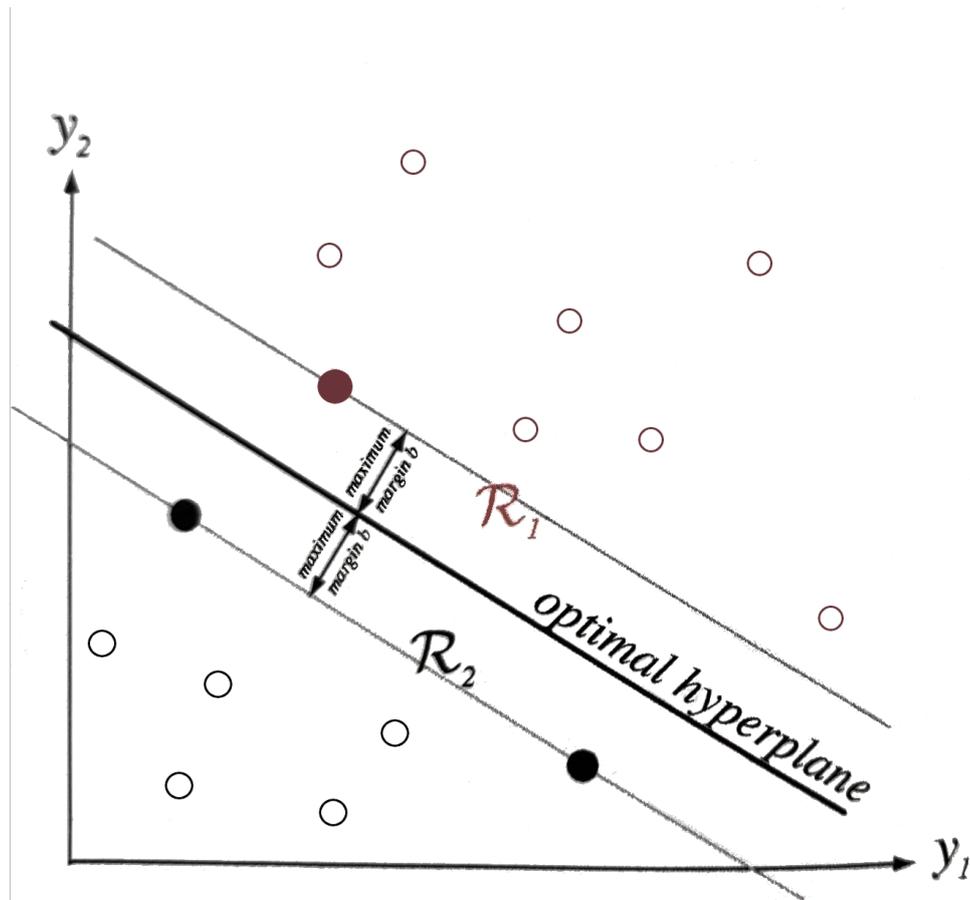


Abbildung 2.20: Hyperebene einer SVM im zweidimensionalen Raum mit maximierten Support-Vektoren

Entscheidungsbäume: Entscheidungsbäume gehören ebenfalls zu den erfolgreichen Klassifikatoren des überwachten Lernens. Ähnlich der LDA ist auch dieses Verfahren einfach zu implementieren. Ein Entscheidungsbaum ist ein gerichteter Graph, bei dem die Knoten den Merkmalen, die Kanten den zu treffenden Entscheidungen und die Blätter den möglichen Klassen entsprechen. Abbildung 2.21 stellt exemplarisch einen Entscheidungsbaum dar. In dem Beispiel wird ein Auto anhand der Merkmale Sitze, PS und Preis, welche an den Kanten stehen, in die Klassen Super Sportwagen, Luxuswagen, Mittelklassewagen und Kleinwagen eingeteilt. Die Klassen stehen in den Blättern am Ende eines Entscheidungspfades.

Entscheidungsbäume sind anhand von Eigenschaften wie Größe, Anzahl an Abzweigungen (engl. Splits), auch Tiefe genannt sowie den verwendeten Lernverfahren unterteilt [9], siehe Abschnitt 4.4. Der Entscheidungsbaum aus dem Beispiel in Abbildung 2.21 entspricht der Tiefe drei mit fünf Blättern bei fünf Klassen. Ein Entscheidungsbaum muss nicht über die gleiche Anzahl an Blättern wie Klassen verfügen.

2 Steuerung von Handprothesen

Eine Weiterentwicklung der Entscheidungsbäume sind Random Forests. Hierbei werden die Trainingssets in zufällige, kleinere Mengen aufgeteilt und für diese jeweils mindestens ein Entscheidungsbaum erzeugt. Kommen die Algorithmen der Entscheidungsbäume zu unterschiedlichen Ergebnissen, so kann die Gewichtung einzelner Bäume und die Verwendung eines Mehrheitsentscheids zu einer eindeutigen Entscheidung führen [14, 18].

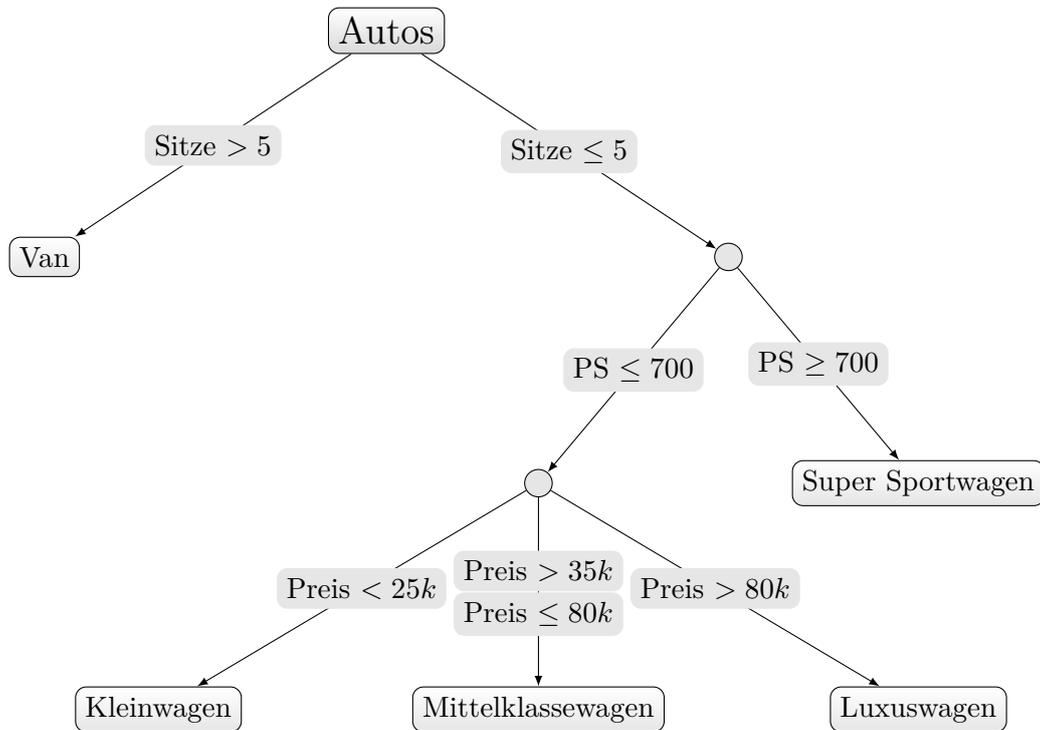


Abbildung 2.21: Beispiel für einen Entscheidungsbaum

k -Nächste Nachbarn (k -NN): Der k -NN-Algorithmus kontextualisiert Datenpunkte in dem benachbarte Daten betrachtet werden [78]. So teilt der Algorithmus einen Datensatz in k -Partitionen ein, sodass die Summe der quadrierten Abweichungen der Cluster-Schwerpunkte minimal ist [25]. Am häufigsten kommt der dreischrittige Algorithmus nach Lloyd zur Anwendung:

I. Initialisierung:

1. Lege den Wert von k fest.
2. Teile den Datensatz in einen Trainingsdatensatz und einen Testdatensatz auf.
3. Wähle eine Distanzmetrik aus, wie z. B. den euklidischen Abstand, den manhattanischen Abstand oder den minkowskischen Abstand.

II. Klassifizierung oder Regression:

1. Wähle einen Datenpunkt aus dem Testdatensatz aus.
2. Berechne die Distanz zwischen dem Datenpunkt und allen Datenpunkten aus dem Trainingsdatensatz, die mit entsprechenden Klassen oder Werten beschriftet sind.
3. Sortiere die Distanzen in aufsteigender Reihenfolge und wähle die k nächstgelegenen Nachbarn aus.
4. Bestimme die Klasse oder den Wert des Datenpunkts basierend auf den Klassen oder Werten der k nächstgelegenen Nachbarn. Dies kann durch Abstimmung, Mittelwertbildung oder andere Methoden erfolgen.
5. Wiederhole diesen Schritt für alle Datenpunkte aus dem Testdatensatz.

III. Bewertung:

1. Berechne die Genauigkeit oder den Fehler des k -NN-Algorithmus anhand der tatsächlichen Klassen oder Werte der Datenpunkte aus dem Testdatensatz und den vom Algorithmus bestimmten Klassen oder Werten.
2. Optimierte den Wert von k oder die Distanzmetrik, um die Genauigkeit oder den Fehler zu verbessern.

Nachteile des k -NN-Algorithmus sind die teils hohen Rechenkosten wenn die Anzahl der potenziellen Nachbarn groß ist, sowie die Empfindlichkeit gegenüber möglichen lokalen Strukturen der Trainingsdaten [81]. Zudem hängt die Lösung und die Güte der Klassifikation im Allgemeinen sehr stark vom gewählten k ab. Da das optimale k vorher nicht bekannt ist, aber zu Beginn festgelegt sein muss, ist es schwierig, eine Aussage darüber zu treffen, wie gut die gefundene Lösung ist. Eine Möglichkeit, eine Aussage über das k zu treffen, besteht darin, den Algorithmus mit zufällig gewählten k mehrfach zu starten und die am besten abschneidende Wahl zu nutzen.

Künstliche-Neuronale-Netze (KNN): KNNs oder auch Artificial Neural Networks (ANNs) sind ein nur vermeintlich neuer Klassifikator. Dies rührt daher, dass KNNs auf Grund ihrer Leistungsfähigkeit, der gestiegenen Rechenleistung, der Entwicklung von Rekurrenten Long Short-Term Memory (LSTM)-Netzen, Convolutional Neural Networks (CNNs) und Transformern sowie des Deep Learnings in den letzten Jahren an Beliebtheit stark zugenommen haben. William James veröffentlichte aber bereits 1890 einen grundlegenden Artikel, der die Idee neuronaler Netze beschreibt. In dieser Veröffentlichung beschreibt er miteinander verbundene Knoten, welche über Ausgaben Gedanken oder auch Entscheidungen herbeiführen [2].

2 Steuerung von Handprothesen

Ein neuronales Netz besteht aus mehreren Schichten stark vereinfachter Modelle von natürlichen Neuronen. Diese künstlichen Neuronen sind üblicherweise mindestens in einer Eingabe-, einer Ausgabe- und einer oder mehrere verborgenen Schichten angeordnet. Die Eingänge können mit dem Vektor $x = (x_1, \dots, x_n)^T$ dargestellt werden. Jeder Eingang eines Neurons verfügt über eine Gewichtung w und so ergibt sich die folgende, einfache Ausgabefunktion:

$$z = \sum_j^n (w_j x_j) \quad (2.21)$$

Jedes Neuron kann zusätzlich mit einem Gewicht, dem Bias (b) beaufschlagt werden. Mit b ergibt sich:

$$z = \sum_j^n (w_j x_j) + b \quad (2.22)$$

Die Ausgabe z wird an eine Aktivierungsfunktion meist eine Schwellwert- oder andere mathematische Funktion, weitergegeben. Wird ein definierter Schwellwert s überschritten, so wird dem Ausgang y der Wert 1 zugewiesen [13]:

$$y(z) = \begin{cases} 1, & z > s \\ 0, & \text{sonst} \end{cases} \quad (2.23)$$

Neben der Schwellwertfunktion finden die Lineare-, Sigmoid-, Tangenshyperbolicus- (\tanh) oder die Rectified-Linear-Unit-Funktion (ReLU) als Aktivierungsfunktionen Verwendung [18, 74].

$$\text{sig}(z) = \frac{1}{1 + e^{-z}} \quad (2.24)$$

$$\text{tanh}(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.25)$$

$$\text{relu}(z) = \begin{cases} 0, & z > 0 \\ z, & \text{sonst} \end{cases} \quad (2.26)$$

Es können auch andere Funktionen zur Festlegung der Ausgabe gewählt werden, was die Flexibilität von KNNs erhöht.

Eine weitere Konfigurationsmöglichkeit besteht in der Architektur der künstlichen Netze. Je nach Anwendungsfall ist die am besten geeignete Form zu wählen, wobei die feed-forward-Architektur mit mehrfach hinter einander gereihten Schichten die einfachste darstellt [13].

Abbildung 2.22 zeigt beispielhaft ein einfaches, voll vernetztes, vorwärts gerichtetes KNN mit fünf Neuronen, einer Eingangs-, einer verborgenen und einer Ausgangsschicht. Die Informationen laufen dabei immer in eine Richtung, vom Eingang zum Ausgang [60].

Convolutional Neural Network (CNN): CNNs oder auch Faltungsnetze gehören zu den sehr erfolgreichen KNNs. Sie werden häufig zur Mustererkennung in Bildern eingesetzt.

Eine der ersten kommerziell erfolgreichen Anwendungen war ein System zur automatischen Erkennung von handgeschriebenen Schecks von AT&T in den 1990er Jahren [33]. Bei dieser Entwicklung wurde erkannt, dass die Zahl der zu optimierenden Parameter bei

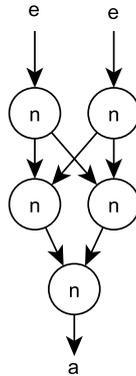


Abbildung 2.22: Darstellung eines einfachen, vorwärts betriebenen Netzes mit einer Eingangs-, einer verborgenen und einer Ausgabeschicht.

vorwärts gerichteten KNNs in einem hochdimensionalen Raum, wie ihn Bilder darstellen, sehr rasch anwächst.

Mit jeder Schicht l steigt die Anzahl an Parametern ap . Diese bestimmen sich nach der Formel $ap = (size_{l-1} + 1) * size_l$ [18]. Das entspricht der Anzahl an Eingängen e der Schicht $l-1$ zusammen mit dem Biasvektor b mal den Gewichtsparametern w der Schicht l . Folglich gilt: $(e_{l-1} + 1) * w_l$. Daraus folgen für eine Schicht mit vier Neuronen und zwei Eingängen $(2 + 1) * 4 = 12$ Parameter. Durch das Hinzufügen einer Schicht mit 1000 Elementen auf eine ebenso große Schicht folgen mehr als 1.000.000 Parameter [18].

CNNs benötigen deutlich weniger Parameter, da sie die Dimensionalität reduzieren. CNNs erhalten als Eingabe keinen Vektor, sondern eine oder mehrere zweidimensionale Matrizen. Über diese wird ein verschiebbares Fenster, ein sogenannter Filter, geschoben. Im Englischen wird hierbei auch häufig von einem Feature, also einem Merkmal, gesprochen. Der Filter F ist ebenfalls eine zweidimensionale Matrix, welche in den Abmessungen kleiner oder gleich der Eingangsmatrix P ist. Die Faltung, welche die Ähnlichkeit von F und P angibt, ist die Summe der elementweisen Multiplikation von Eingangsmatrix und Filter. Die Summe ergibt ein Maß über die Ähnlichkeit von F und P . Besitzt die Matrix F kleinere Abmessungen als die Matrix P , so ergibt sich nach der Faltung eine kleinere Ausgabematrix. Diese beschreibt die Ähnlichkeit von F an dem Ausschnitt von P . Es ist somit möglich, nach Merkmalen in der größeren Matrix P zu suchen. Abbildung 2.23 zeigt ein Beispiel der Faltung einer 4×4 Matrix mit einem 2×2 Filter. Zusätzlich ist noch ein Bias von 1 verwendet, der auf jeden Wert addiert wird. Bei dem Beispiel wird der Filter mit einer Schrittweite von eins über die Matrix geschoben. Somit entsteht durch die Faltung eine 3×3 Matrix, da $Anzahl\ Spalten(Matrix) - Anzahl\ Spalten(Filter) + 1 = Anzahl\ Spalten(gefaltete\ Matrix) = 4 - 2 + 1 = 3$. Das gleiche gilt für die Zeilen. Durch die Nutzung des des Filters wird somit die Zahl der Parameter deutlich reduziert.

2 Steuerung von Handprothesen

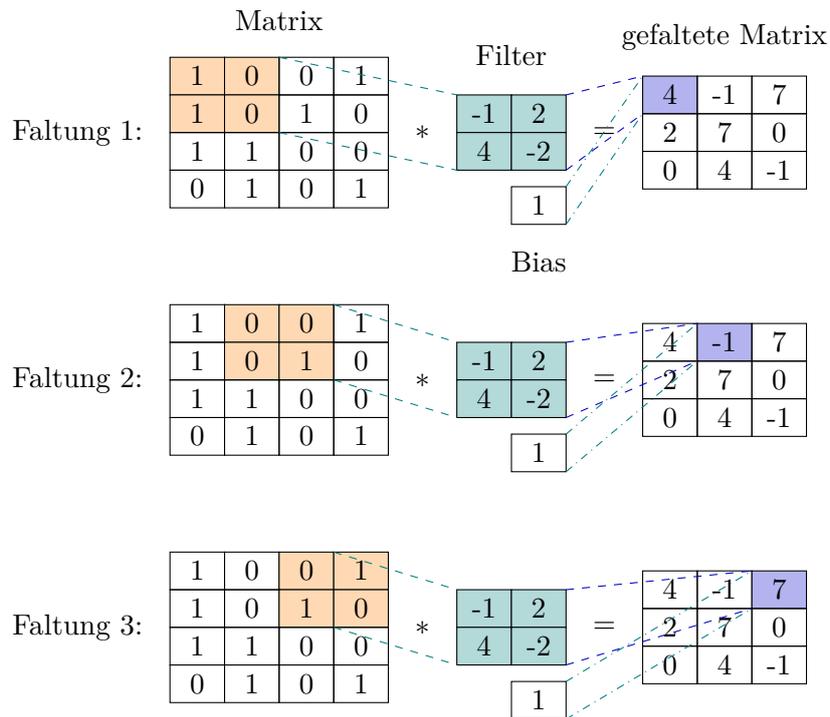


Abbildung 2.23: Faltung einer Matrix für CNNs [18]

Um die hohe Dimensionalität bei großen Datenmengen zu reduzieren, kann eine Matrix in Blöcke unterteilt und eine Funktion angewendet werden, die jeden Block auf einen Skalar abbildet. Ein möglicher Ansatz ist, den Maximalwert eines Blocks als Repräsentant für den gesamten Block zu wählen. Dieser Vorgang nennt sich Max-Pooling. Weitere Pooling-Funktionen sind das Min- und das Average-Pooling.

Abbildung 2.24 zeigt das Vorgehen bei einer 4×4 Matrix mit 2×2 Pooling mit der Maximum-Funktion und einer Schrittweite von zwei. Die resultierende Matrix ist eine 2×2 Matrix, wodurch die Daten um 75% reduziert wurden. Es ist jedoch zu beachten, dass Pooling einen Informationsverlust verursacht. Daher ist es wichtig, die Vorteile der Dimensionsreduktion, wie einen verbesserten Berechnungsaufwand, gegen den Informationsverlust abzuwägen.

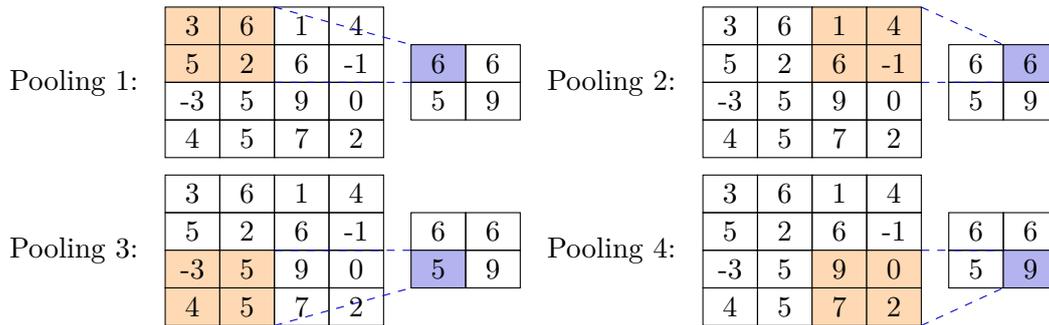


Abbildung 2.24: Max-Pooling für CNNs [18]

Long Short-Term Memory (LSTM): LSTMs gehören zu den rückgekoppelten Netzen oder auch Recurrent Neural Networks (RNNs). Die Ausgabe des Netzes ist somit auch von vorherigen Eingaben abhängig, wodurch sie auch einen inhärenten Speicher aufweisen. Dafür werden die Ausgänge von Neuronen zu Eingängen der gleichen oder anderer Neuronen von vorherigen Schichten zurückgeleitet. Rückgekoppelte Netze werden zur Erkennung und Erzeugung von Sequenzen genutzt und häufig bei Text- oder Spracherkennung eingesetzt. [18]

Ein Problem bei RNNs ist das des *verschwindenden* oder *explodierenden* Gradienten. Dies bedeutet, dass die partiellen Ableitungen der Fehlerfunktion über mehrere Zeitschritte hinweg sehr klein oder sehr groß werden, wodurch die Gewichts Anpassung oder der Lernschritt in den vorderen Schichten stagniert oder instabil wird. Insbesondere bei Verwendung der Sigmoid-Aktivierungsfunktion in RNNs tritt das Problem des verschwindenden Gradienten auf, da diese Funktion Werte zwischen 0 und 1 produziert und somit der Gradient nahe bei 0 oder 1 sehr klein wird. Eine Lösung für dieses Problem ist die Verwendung von Aktivierungsfunktionen, die eine größere Bandbreite an Werten produzieren und einen konstanten oder variablen Gradienten haben, wie z. B. die rectified linear unit (ReLU)-Aktivierungsfunktion.

Das Problem des explodierenden Gradienten entsteht dadurch, dass der Gradient bei jeder Rückkopplung multipliziert wird, und dies zu sehr großen oder sehr kleinen Werten führen kann. Das Verschwinden oder Explodieren des Gradienten tritt insbesondere bei RNNs auf, die einen größeren Kontext betrachten müssen, wie z. B. die Ausgabe von Eingaben, die weiter zurückliegen, wie es bei EMG-Signalen der Fall sein kann, wenn diese über den gesamten Zeitraum betrachtet werden. In solchen Fällen müssen die Gewichte für jeden zurückliegenden Zeitpunkt angepasst werden, was das Problem des verschwindenden oder explodierenden Gradienten verstärkt [18, 33].

LSTMs verhindern *verschwindende* oder *explodierende* Gradienten, indem sie einen internen Zellspeicher c_t verwenden, der Werte über beliebige Zeiträume speichern kann, und indem sie Gate-Units einführt [57]. Diese können intern Informationen speichern und für einen späteren Zeitpunkt nutzen [18]. LSTMs verwenden hierfür drei unterschiedliche Gate-Typen, die jeweils eine Sigmoid-Aktivierungsfunktion, eine Gewichtsmatrix W und einen Bias b haben: das Input-Gate i_t , das Forget-Gate f_t und das Output-Gate o_t . Das Input-Gate beschreibt den Einfluss des jetzigen Eingangs auf den internen Zellspeicher, das Forget-Gate wie viel Einfluss der vorherige Zellspeicher auf den aktuellen Zellspeicher

2 Steuerung von Handprothesen

hat und das Output-Gate den Einfluss des aktuellen Zellspeichers auf die Ausgabe des aktuellen Eingangs. Der Ausgang des LSTM wird mit h angegeben. Nach Mou kann mit zwei Gewichtsmatrizen gearbeitet werden, eine für die Eingänge x und eine für die Eingänge aus vorherigen Zeitschritten h_{t-1} [57]. In der einfacheren Form wird nur eine Gewichtsmatrix für die Eingänge x verwendet. Zudem gibt es wie bei den bereits vorgestellten neuronalen Netzen den Bias b . Im Nachfolgenden werden die Formeln nach Mou mit doppelten Gewichtsmatrizen, der Sigmoid-Funktion (σ) und dem internen Kandidaten-Merkmalvektor g_t , der eine tanh-Aktivierungsfunktion nutzt, vorgestellt [57].

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2.27)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (2.28)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (2.29)$$

$$g_t = \tanh(W_g x_t + U_g h_{t-1} + b_g) \quad (2.30)$$

W = Matrizen der Gewichte (Weight)
 U = Matrizen der Einheit (Unit)
 b = Bias-Terme

Der interne Speicher c_t errechnet sich aus dem vorherigen Zustand c_{t-1} sowie dem Input-Gate und dem Kandidaten-Merkmalvektor wie folgt:

$$c_t = i_t \circ g_t + f_t \circ c_{t-1}. \quad (2.31)$$

Das Zeichen „ \circ “ stellt die elementweise Multiplikation dar. Die Ausgabe h_t ergibt sich aus dem Output-Gate o_t und dem internen Speicher c_t wie folgt:

$$h_t = o_t \circ \tanh(c_t). \quad (2.32)$$

2.6 Bisherige Lösungen

Zur Steuerung von Handprothesen gibt es verschiedene Lösungen, wobei sich die etablierten Methoden in sensorische, myoelektrische, hybride und sogenannte Gedankensteuerung einteilen lassen.

Die Wahl der für einen Probanden geeigneten Steuerungsmethode hängt von verschiedenen Faktoren wie den individuellen Bedürfnissen sowie der Art und Schwere der Amputation ab. Einen Überblick über die Entwicklung und die Fortschritte der Prothesentechnik bis 1978 gibt Wirta [108]. Seine Arbeiten beschreiben die wesentlichen Entwicklungsschritte myoelektrischer Prothesen, ausgehend von der ersten EMG-gesteuerten Prothese von Reiter [77] aus dem Jahr 1948. Diese und weitere myoelektrische Prothesen arbeiten bis in die 1960er Jahre mit einer Eins-zu-eins-Zuordnung von Muskel und Aktivator, also dem anzusteuernenden Motor. Die Prothese wird dabei aktiv bewegt, sobald der Schwellwert mindestens eines Sensors überschritten wird. Alle frühen Fremdkraft-Steuerungen beruhen auf diesem Amplituden-Schwellwert-Prinzip. Dies stellt zugleich die einfachste Art der Steuerung einer Fremdkraft-Prothese dar und wird häufig als Direct Control (DC), also direkt gesteuert, bezeichnet [61].

Bei der Verwendung eines einzelnen Sensors führt eine Schwellwertüberschreitung zu einer Öffnung der Prothese, während eine Unterschreitung des Schwellwerts dazu führt, dass sie sich wieder schließt. Dieses auch als *Cookie-Crusher* bekannte Konzept ist sehr einfach in der Implementierung und eignet sich deshalb auch zur Steuerung durch Kinder [56]. Weitere Vorteile sind geringe Kosten und eine hohe Robustheit, die unter anderem daraus resultieren, dass lediglich ein EMG-Sensor verbaut ist [59]. Im Allgemeinen gilt DC, auch mit mehr als einem Sensor, als eine intuitive Möglichkeit zur Steuerung von Prothesen [61].

Eine komplexere Steuerung mittels Schwellwert, die das bedingt aktive Öffnen und Schließen unterstützt, benötigt mindestens zwei EMG-Sensoren, da drei Zustände (Öffnen, Schließen und Ruhe-Modus) zu unterscheiden sind. Wird lediglich der Schwellwert des einen Sensors überschritten, führt dies zu einer Öffnung der Prothese, während eine Überschreitung des Schwellwerts des zweiten Sensors das Schließen zur Folge hat. Zudem ermöglicht die gleichzeitige Überschreitung beider Schwellwerte die Identifikation einer dritten Aktivität.

Somit unterscheidet sich die Klassifikation im Rahmen der beiden Steuerarten dadurch, wie viele Dimensionen der entstehende Klassifikationsraum aufweist. Für eine einfache Prothese, wie den *Cookie-Crusher*, entsteht durch die Verwendung eines einzelnen Sensors ein eindimensionaler Raum, der durch den Schwellwert in zwei Bereiche getrennt wird, da jeder einzelne gemessene Punkt entweder über oder unter diesem Schwellwert liegt. Dies ermöglicht die Klassifikation der Aktivierungsgeste für das Öffnen der Prothese.

Bei einer komplexeren Steuerung mit Hilfe eines weiteren Sensors entsteht ein zweidimensionaler Merkmalsraum, in dem die zu einer Aktivierungsgeste gehörenden beiden Sensormesswerte einen Punkt bilden. Durch die Festlegung von Schwellwerten oder Gewichten lässt sich der zweidimensionale Raum in vier mögliche Teilflächen unterteilen. Für die Klassifikation wird anschließend diejenige Fläche ermittelt, zu der der gemessene Datenpunkt gehört, wobei die Höhe der Schwellwerte die Größe der Flächen bestimmt. Auf diese Weise können mit zwei Sensoren zwei Gesten sehr gut klassifiziert werden. Zusätzlich bietet sich die Möglichkeit, auch eine dritte Geste in die Untersuchung aufzunehmen, wenn beide Schwellwerte gleichzeitig überschritten werden. Da in diesem Szenario jedoch keine Eins-zu-eins-Beziehung mehr zwischen den Muskeln und den Aktoren besteht, handelt es sich streng genommen nicht mehr um DC.

2 Steuerung von Handprothesen

Deshalb schlagen Wirta et al. in den 1960er Jahren ein Verfahren der Mustererkennung (engl. Pattern Recognition) mittels linearen Trennfunktionen vor [108]. In ihren Experimenten berücksichtigen die Autoren vier Gesten (Handpronation, -supination sowie Ellbogenflexion und -extension) unter Verwendung von sechs EMG-Sensoren, wobei sie die einzelnen EMG-Signale gewichteten. Damit erreichten sie zwar bereits gute KKR-Werte, weisen jedoch auch explizit auf die Verwechslung einiger Gesten hin.

Bis Anfang der 1990er Jahre erfolgte somit die Steuerung von Prothesen häufig über DC oder sehr ähnliche Mechanismen, sodass es kaum möglich war, mehr Aktivierungsgesten zu erkennen, als Sensoren vorhanden waren.

Eine deutliche Weiterentwicklung der Zuordnung von EMG-Signalen stellten im Jahr 1993 Hudgins et al. vor [44]. Durch die Berechnung von Merkmalen für jedes EMG-Signal lässt sich ein mehrdimensionaler Vektorraum aufspannen. Somit wurde es möglich, mit weniger Sensoren mehr Gesten zu unterscheiden.

Wenn Merkmale so gewählt werden können, dass die einzelnen Gesten maximal voneinander getrennt sind, bilden sich Punktwolken oder Anhäufungen (engl. cluster) im Raum. Dieser bis dahin neue Ansatz in der Vorverarbeitung von EMG-Signalen erlaubte es Hudgins et al. für vier Aktivierungsgesten mit lediglich zwei Sensoren, bei zehn Wiederholungen mit fünf Probanden und 40 berechneten Merkmalen eine KKR von 70 % bis 98 % zu erzielen. Diese auf PR beruhende Steuerung grenzt sich sehr deutlich von der bis dahin vorherrschenden DC-Steuerung ab.

Neben der Berechnung von Merkmalen weisen Hudgins et al. auch darauf hin, dass EMG-Signale bei der Durchführung einer Geste eine Struktur besitzen und so eine fortlaufende Klassifikation mit Zeitfenstern ermöglichen [44]. Dazu wird das EMG-Signal in kleinere Abschnitte unterteilt, beispielsweise in Blöcke von 100 ms. Für jeden Block können anschließend Merkmale berechnet und eine PR durchgeführt werden. Somit ist eine Klassifikation bereits möglich, wenn nur ein kleiner Teil der Daten des Gesamt-Signals zur Verfügung steht.

Abbildung 2.25 zeigt eine aus diesem Verfahren resultierende Punktwolke für drei Gesten. Das EMG-Signal wurde mit zwei Sensoren aufgenommen und für jeden Sensor jeweils ein Merkmal berechnet.

Dabei ist bereits für drei Gesten erkenntlich, dass aufgrund der Überlappungen der Punktwolken durch PR die einzelnen Klassen nicht eindeutig zu trennen sind. Dies gilt insbesondere für Datenpunkte, bei denen beide Merkmale Werte kleiner 0,1 aufweisen.

Dieses Problem verschärft sich durch die Hinzunahme von weiteren Gesten, wie Abbildung 2.26 deutlich zeigt. In dieser sind neun Gesten dargestellt, welche kaum unterscheidbar sind. Um die Gesten besser voneinander zu trennen, wird häufig eine Erhöhung der Anzahl an Merkmalen vorgenommen. Eine beliebige Erhöhung ist dabei zum einen durch die verwendeten Klassifikatoren limitiert und zum anderen dadurch, dass empirische Erfahrung zeigt, dass selbst bei einer Verwendung von 40 Merkmalen nur vier Klassen eindeutig trennbar sind [44].

Eine andere Möglichkeit, den Klassifikationsfehler zu senken, ist die Vergrößerung der Anzahl an Sensoren. So zeigt sich, dass bei der Verwendung von vier statt zwei Sensoren die Klassifikationsgüte zunimmt [27, 87]. Dieser Effekt scheint jedoch ebenfalls limitiert zu sein. Abbildung 2.27 zeigt eine abnehmende Korrelation zwischen der KKR und der Anzahl der zu unterscheidenden Klassen [1, 20, 27, 32, 37, 39, 45, 83, 84, 104, 109, 111, 113]. Die Größe der Punkte spiegelt dabei die Anzahl an verwendeten Sensoren wider. Gut zu erkennen ist, wie die KKR auch mit bis zu 16 Sensoren immer weiter abnimmt, wenn mehr Gesten unterschieden werden sollen.

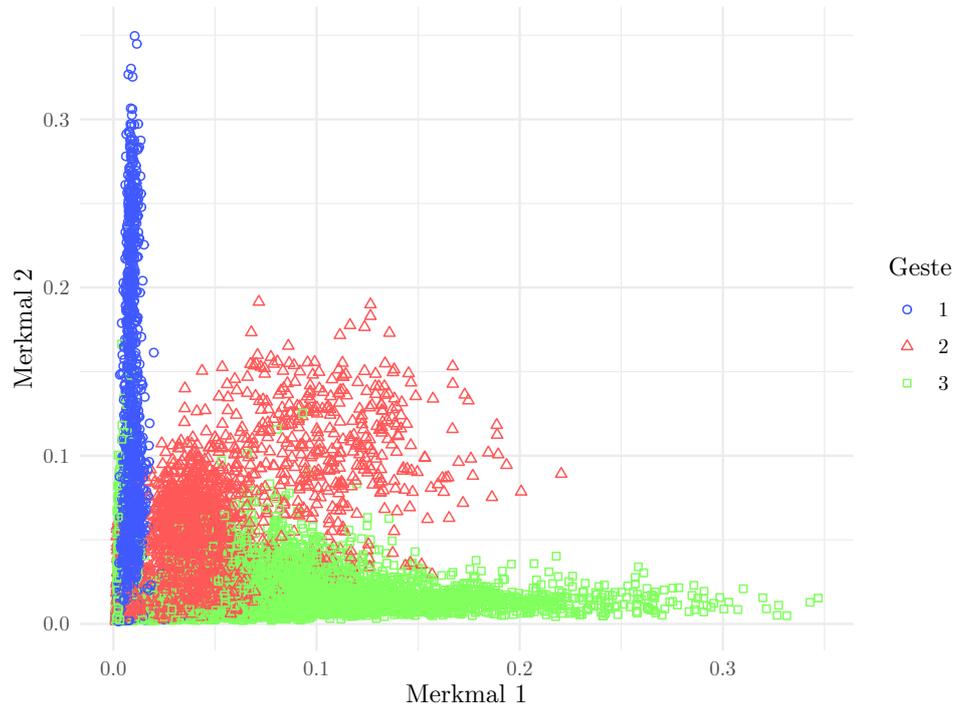


Abbildung 2.25: Streudiagramm von zwei Merkmalen über drei unterschiedliche Geste

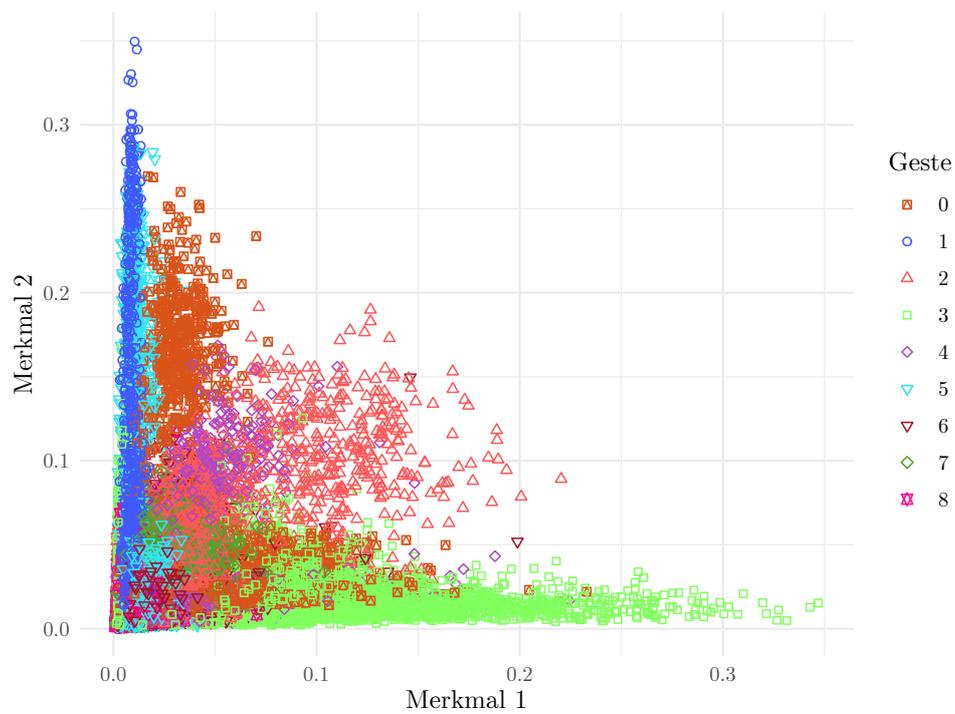


Abbildung 2.26: Streudiagramm von zwei Merkmalen über neun unterschiedliche Geste

2 Steuerung von Handprothesen

Aus praktischen Gründen werden meist nur zwei, in wenigen Fällen mehr Sensoren bezogen auf eine Referenzelektrode verwendet. So kommen bei der Steuerung aktueller Prothesen meist zwei Sensoren zum Einsatz [59, 61]. Insbesondere bei Transradialamputierten, welche den Großteil der Amputationen darstellen, lassen sich lediglich zwei Sensoren am Stumpf anbringen [61]. Als Elektroden werden entweder Gleichtaktverstärker oder Differentialverstärker verwendet [59]. Sollte kein Unterarmstumpf vorhanden sein, oder aus anderen Gründen die Anbringung von Sensoren in diesem Bereich nicht möglich sein, so können mit dem chirurgischen Verfahren der Targeted Muscle Reinnervation (TMR) Nervenverbindungen umgeleitet werden. Damit ist es möglich, statt des Unterarms die Brustmuskulatur anzusprechen und auf dieser wiederum einen Sensor anzubringen. Hargrove et. al konnten zeigen, dass PR in Zusammenhang mit TMR zu einer Verbesserung der Prothesensteuerung sowie der Akzeptanz von PR gegenüber der DC durch die Betroffenen führen kann [38].

Aufgrund dieser Limitierungen verwenden auch moderne Handprothesen seit 1993 erfolgreich

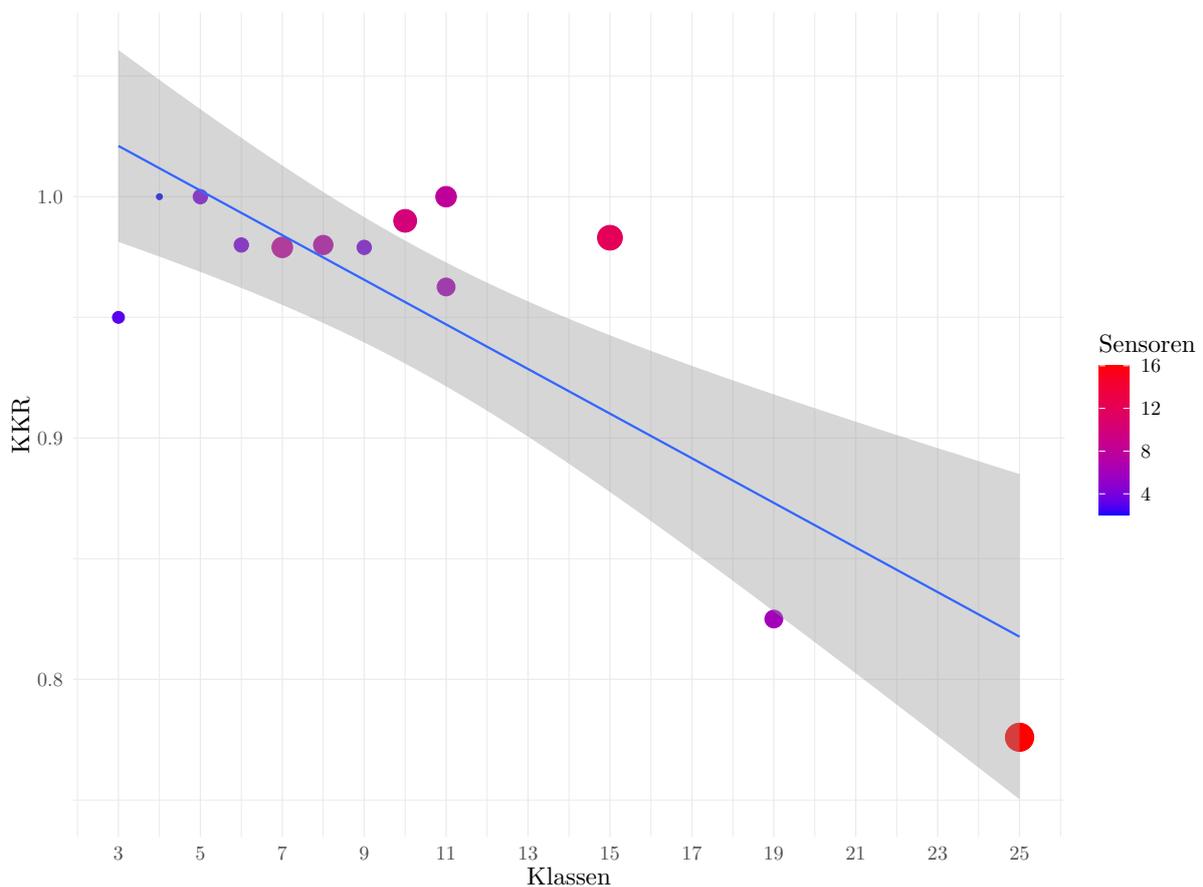


Abbildung 2.27: Korrelation zwischen der Anzahl an Klassen und der KKR unter Berücksichtigung der Anzahl der verwendeten Sensoren

die durch Hudgins vorgestellte Methode und lediglich zwei Sensoren. Eine Idee, dennoch die Anzahl an zu unterscheidenden Gesten zu erhöhen, leitet sich aus der Beobachtung von Hudgins ab, dass das EMG-Signal eine zeitliche Struktur aufweist. Um diese festzustellen wird, wie bereits beschrieben, das Signal in einzelne Fenster unterteilt. Diese können so über das Signal gleiten,

dass sie sich stark überlappen [44]. Ein resultierendes Signal ist in Abbildung 2.28 dargestellt. Es ist deutlich zu erkennen, wie der Sensor 2, in Orange eingefärbt, bis zum Erreichen des Maximums zunächst schnell und sehr deutlich zunimmt. Über den Verlauf von zwei Sekunden, fällt die Amplitude dann stetig ab, bis sie nach etwa vier Sekunden das Niveau vor der Ausführung der Geste erreicht. Kurz darauf ist ein letzter kurzer Ausschlag des Signals von Sensor 1 zu erkennen. Dieser allgemeine Verlauf ist typisch für die hier abgebildete Geste und entspricht der angesprochenen Struktur. Sie geht jedoch durch die PR der einzelnen Fenster verloren, da durch sie bei der Erzeugung der Merkmale der zeitliche Zusammenhang und die Relation der einzelnen berechneten Werte verloren geht.

Daher haben sowohl die Punkte mit der maximalen Aktivität des zweiten Sensors als auch die mit der geringeren Amplitude sowie alle Daten des ersten Sensors, in gleicher Art und Weise sowie unabhängig voneinander, Einfluss darauf, welcher Geste die einzelnen Punkte zugeordnet werden. Gegebenenfalls zählen einzelne Punkte, wie die des zweiten Sensors mit der hohen Amplitude oder der *Nachzügler* des ersten Sensors um die vier Sekunden als Ausreißer. Das führt zur Entfernung dieser Punkte aus den Datensätzen, obwohl sie charakteristisch für die jeweilige Geste sind.

Attenberger zeigte, dass durch die Betrachtung des EMG-Signals von seinem Beginn bis zu

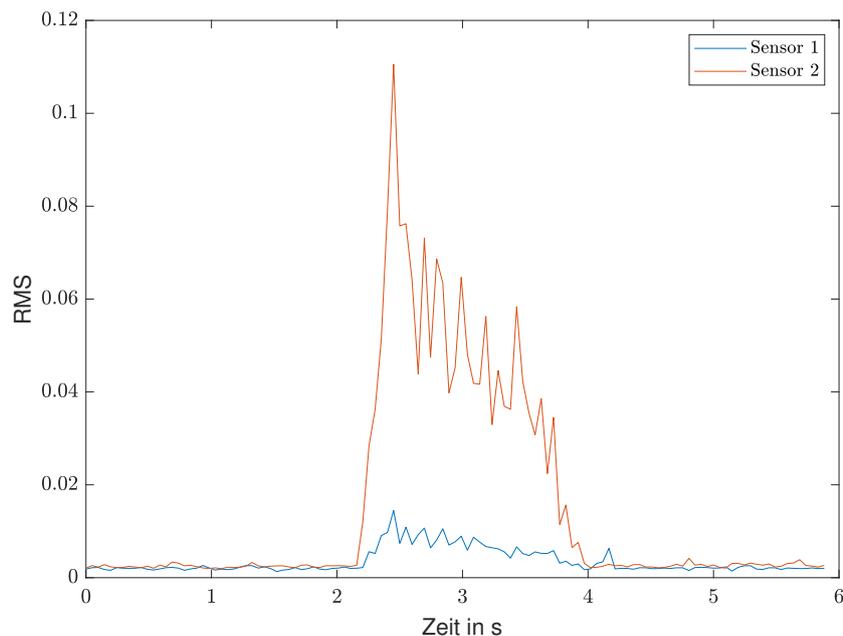


Abbildung 2.28: Verlauf des RMS-Merkmals einer Bewegung der Geste Extension

seinem Ende sich sogenannte Pfade bilden lassen. Mit deren Hilfe ist es möglich, bis zu sechs Gesten mit zwei Sensoren voneinander zu trennen [4].

Dafür berechnet er das Time Stamp (TS)-Merkmal, welches mit $TS = ID/n - 1$ definiert ist. Die ID ist eine fortlaufende Nummer für jedes berechnete Merkmal einer Bewegung und stellt somit einen Zeitpunkt innerhalb der Bewegung dar. Die Anzahl aller Zeitpunkte beträgt n . Somit werden die Merkmale von $[0; 1]$ mit $TS \in \mathbb{R} | 0 \leq TS \leq 1$ berechnet und dem Klassifikator als Information zur Verfügung gestellt. Da hierfür n bekannt sein muss, kann diese Methode

2 Steuerung von Handprothesen

jedoch erst nach dem Abschluss der Bewegung mit dem Klassifizieren beginnen.

Somit ergeben sich für EMG-Signale zwei Einschränkungen, die von der weiteren Forschung angegangen werden können. Zum einen ist es mit bisherigen Lösungen, wie der PR, nur möglich wenige Gesten von einander zu trennen und somit den Nutzern diese als Aktivierungsgeste zur Verfügung zu stellen.

Zum anderen ist es für den Nutzer hilfreich, wenn ein EMG-Signal möglichst frühzeitig klassifiziert werden kann, damit auch die Prothese innerhalb eines zufriedenstellenden Zeitfensters mit der Ausführung der Bewegung beginnt.

Diese sich ergänzenden Anforderungen stehen bisher im Widerspruch zueinander. Eine Schwellwertsteuerung kann sehr schnell sehr genau klassifizieren, jedoch nur sehr wenige Gesten voneinander trennen. Die Klassifikationsmethode von Attenberger erlaubt es mehr Gesten zu trennen, jedoch erst nach Beendigung der Geste.

In dieser Dissertation wird eine Methode vorgestellt, mit der es möglich ist, mehr als sechs Aktivierungsgesten eindeutig und weit vor Beendigung der Bewegung (≤ 200 ms) zu unterscheiden, sodass eine Prothese für die obere Extremität mit zwei Sensoren gesteuert werden kann.

3 Verbesserte Klassifikation von elektromyographischen Signalen

In den einleitenden Kapiteln wurde dargestellt, dass die Unterscheidung von einer bis zu vier Gesten mit etablierten Verfahren gut funktioniert und dies durch eine Erhöhung der Klassifikationsgüte noch verbessert werden kann. In diesem Kapitel wird gezeigt, dass der zeitliche Verlauf der Veränderung von Merkmalen für unterschiedliche Wiederholungen der gleichen Geste eine starke Ähnlichkeit besitzt und somit bis zu neun Aktivierungsgesten voneinander trennbar sind. Möglich wird dies durch eine zeitliche Normierung der EMG-Signale. Die entsprechend berechneten Merkmale werden verwendet, um sogenannte *Bewegungskörper* für die einzelnen Gesten zu bilden, mit deren Hilfe sich die normierten EMG-Signale besser klassifizieren lassen.

3.1 Zeitabhängigkeit der Signale

Bei der Ausführung einer Bewegung werden spezifische Muskelgruppen aktiviert. Die resultierenden Aktivierungsmuster sind für jede Bewegung einzigartig und wiederholen sich bei jeder erneuten Durchführung der gleichen Bewegung. Häufig verwendete Methoden zur Analyse von EMG-Signalen berücksichtigen jedoch nicht die zeitliche Veränderung dieser Aktivierungsmuster. In dieser Arbeit wird daher untersucht, ob eine Analyse der Zeitabhängigkeit von EMG-Signalen es ermöglicht, individuelle Aktivierungsmuster von Bewegungen zu identifizieren und zu unterscheiden. Jede Geste besitzt eine individuelle Aktivierung, und es ist anzunehmen, dass sich die Aktivierung für einzelne Wiederholungen nur geringfügig unterscheidet. Dieser Zusammenhang wird mit der Standardmethode bislang nur rudimentär berücksichtigt. Unter der Annahme, dass EMG-Signale zeitabhängig sind, entsteht eine Art Muster durch die individuelle Innervierung der Muskelgruppen. Dieses Muster unterscheidet sich zum einen durch die diskreten Zeitpunkte innerhalb der Aktivierung und zum anderen durch die Intensität der Muskelerregung. Wie bereits von Attenberger und Hudgins gezeigt [4, 44], weisen EMG-Signale eine gewisse Zeitabhängigkeit auf, die sich zur Klassifikation nutzen lässt. Abbildung 3.1 zeigt den Verlauf von 15 Bewegungswiederholungen für die Gesten Flexion und Extension über die Zeit. Jede Wiederholung bildet einen diskreten Signalpfad. Deutlich zu erkennen ist, dass sich die Signalpfade einer Geste ähneln und sie gebündelt dicht beieinander liegen. Insbesondere zu Beginn der Bewegung fällt auf, wie die Pfadbündel deutlich getrennt in unterschiedliche Richtungen auseinanderlaufen. Im Gegensatz zu einer Darstellung im Zweidimensionalen (Abbildung 2.25) lassen sich die Gesten im Dreidimensionalen bereits nach 0,02 s eindeutig unterscheiden. Wenn die Muskelaktivität gegen Ende der Bewegung abnimmt, überlagern sich die Bündel wieder. Sobald jedoch ein Datenpunkt einmal einem Signalpfad zugeordnet ist, lassen sich die Datenpunkte auch zu einem späteren Zeitpunkt unterscheiden, da die einzelnen Punkte als Signalpfade miteinander verbunden sind. So ist der Datenpunkt x immer noch mithilfe des Punkts x_{t-i} mit $0 < i < l$ (Länge des Signals) und t (betrachteter Zeitpunkt) unterscheidbar.

3 Verbesserte Klassifikation von elektromyographischen Signalen

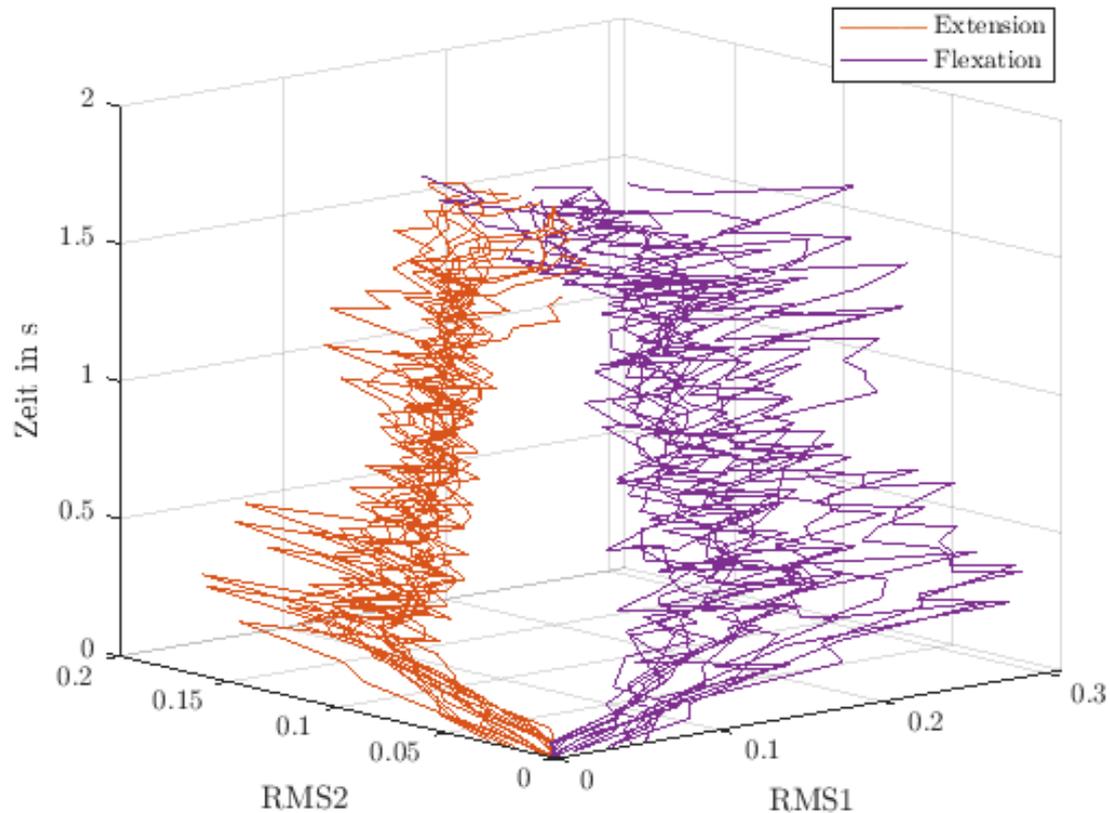


Abbildung 3.1: Zeitverlauf zweier Merkmale für die Bewegungen Flexion und Extension, dargestellt mit Signalpfaden

Da zu Beginn einer Bewegung die Muskeln stark und akzentuiert angesteuert werden ergibt sich im Merkmalsraum ein sehr expressiver zeitlicher Verlauf, welcher sich jedoch gut einordnen lässt und nicht als Ausreißer betrachtet wird. Somit ist in dem gewählten Beispiel alleine durch das Berücksichtigen der Zeit bereits eine bessere Klassifikation mit Hilfe der Signalpfade zu erwarten.

Werden die einzelnen Bewegungswiederholungen in Abbildung 3.1 genauer betrachtet, so zeigt sich, dass die berechneten Merkmalswerte schnell das Maximum erreichen und einen für die Geste charakteristischen Verlauf folgend, mit abnehmender Bewegungsenergie auf den Nullwert zurückgehen. Auffällig ist auch, dass die im Bündel enthaltenen Bewegungen unterschiedlich lang sind. Da, wie in Abschnitt 2.3.4 erklärt, die Entstehung der EMG-Signale variieren kann, ist jede Bewegungswiederholung im Zeitverlauf und der zeitlichen Ausdehnung leicht unterschiedlich, bei ähnlichem Kraftaufwand und bei gleichlang anhaltenden Gesten sind sich die einzelnen Signalpfade aber ähnlich.

3.2 Zeitnormierung von EMG-Signalen

Die im vorangegangenen Abschnitt vorgestellten Signalfade weisen unterschiedliche Längen und deutliche Unregelmäßigkeiten auf. So zeigen die Bündel jeweils deutliche Ausschläge der Merkmalswerte. Dies liegt zum einen an der schon angesprochenen unterschiedlichen Länge der einzelnen Bewegungsaufnahmen und zum anderen an der unterschiedlichen Geschwindigkeit, mit der die Bewegungen durchgeführt wurden. Diese Geschwindigkeitsunterschiede kommen selbst dann zum Tragen, wenn die eigentliche Dauer der Bewegung gleich lang war. Zusätzlich ist dieser Effekt auch abhängig von der Fenstergröße.

Jedes Fenster liefert einen Datenpunkt für das berechnete Merkmal. Liegt der Wert über einem Schwellwert, so wird dieser für die Klassifikation berücksichtigt. Zu Beginn und am Ende der Bewegung besitzt der Schwellwert eine besondere Bedeutung, da dieser über den Beginn und das Ende des aufgenommenen Bewegungssignals entscheidet. Die Fenstergröße wiederum hat Einfluss darauf, wie stark das Gewicht einzelner Messwerte für das jeweilige zu berechnende Merkmal ist. Je kleiner die Fenstergröße, desto weniger Daten liegen in dem Fenster und desto größer ist deren Gewichtung. Ist das Fenster größer und beinhaltet es mehr Messdaten, so nimmt der Einfluss eines einzelnen Messwertes auf das Merkmal ab.

Um diese Unterschiede zu verringern und die Signale somit zu vereinheitlichen, werden diese auf eine gemeinsame Länge normiert. Abbildung 3.2 zeigt nebeneinander dargestellt die Signale EMG1 und EMG2 für zwei Ausführungen derselben Geste. Anhand dieser beiden Signale ist die Normierung beispielhaft beschrieben. Die beiden oberen Teilabbildungen zeigen die Merkmale beider Bewegungen mit einer angenommenen, einheitlichen Fenstergröße von 0,5 s. Diese am häufigsten angewendete Art der Berechnung von Merkmalen für EMG-Signale wird im Folgenden als Standardmethode bezeichnet und beruht auf Ideen von Hudgins [44]. In der darunter angeordneten Abbildung ist das Signal auf die gleiche Zahl von Fenstern normiert und so in einzelne, vergleichbare Segmente unterteilt. Bei diesem Schritt ist die Anzahl der Fenster so zu wählen, dass die Fenstergröße zwischen 11 bis 16 Segmente beträgt. Diese werden im Folgenden Zeitscheiben genannt. Die Größe wurde experimentell in der Art bestimmt, dass die Mittelung des Merkmals durch die Fenstergröße eine gute Klassifikation ergibt.

In dem konkreten Beispiel in Abbildung 3.2 wurden beispielhaft vier Segmente verwendet. Formal verhält sich dies bei einer gegebenen Signallänge von l , einer Normierungsgröße von N und einer Fenstergröße von w wie folgt:

$$w = \lfloor l/N \rfloor \quad (3.1)$$

$$\begin{aligned} w &= \text{Fenstergröße,} \\ l &= \text{Signallänge,} \\ N &= \text{Normierungsgröße.} \end{aligned}$$

Der zuvor erwähnte Verlust von Daten ist in der ersten Zeile von Abbildung 3.2 exemplarisch dargestellt. Das Ende eines Signals wird durch einen Schwellwert bestimmt (siehe Abschnitt 2.4.4). Je nach gewähltem Wert ist es möglich, dass Teile des Signals verloren gehen, obwohl sie sich deutlich vom Ruhesignal unterscheiden und damit zu der beobachteten Bewegung gehören. So wird das rechte der beiden Signale frühzeitig beendet, da die Werte des letzten Fensters nicht mehr ausreichen, um mit dem berechneten Merkmal den Schwellwert zu übersteigen. Das Problem des trennenden Schwellwerts bleibt auch bei der Zeitnormierung erhalten. Es wird jedoch

3 Verbesserte Klassifikation von elektromyographischen Signalen

dadurch abgeschwächt, da für das Schneiden der EMG-Signale und das Berechnen der Merkmale unterschiedliche Schwellwerte gewählt werden können, anders als dies mit der bisherigen Verarbeitung mit einer festen Fenstergröße möglich ist.

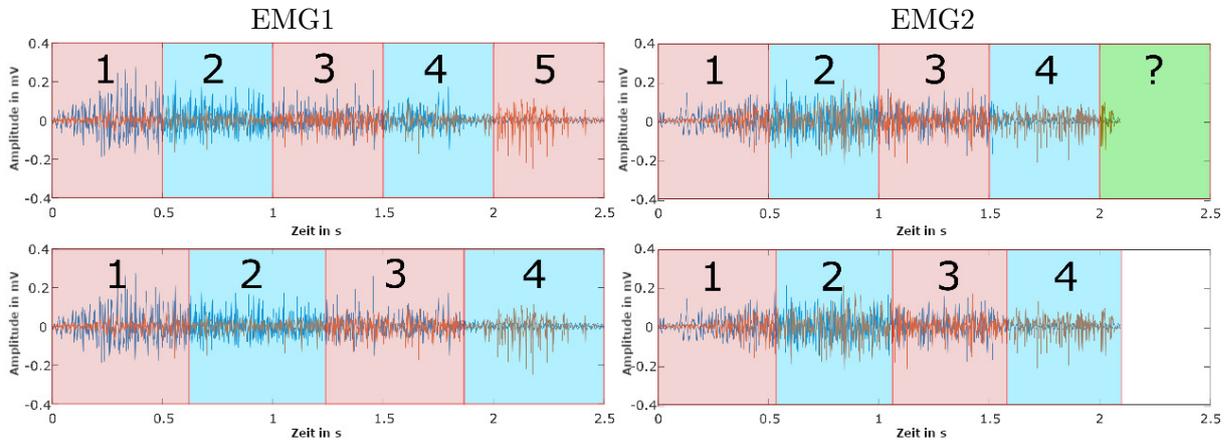


Abbildung 3.2: Normierung von zwei EMG-Signalen mit vier Zeitscheiben

Nach der Zeitnormierung sind alle Signale der unterschiedlichen Gesten und der einzelnen Wiederholungen gleich lang. Werden die normierten Signale in einem mehrdimensionalen Merkmalsraum dargestellt, so ergeben sich normierte Signalpfade. Jede Geste stellt einen Pfad dar. Diese sind für die Gesten Extension und Flexion in Abbildung 3.3 zu sehen. Im Vergleich zu den Pfaden in Abbildung 3.1 sind diese durch die Zeitnormierung *geglättet*. Hierdurch ist noch deutlicher zu erkennen, dass Bewegungswiederholungen sich ähneln und in einer Art *Schlauch* liegen. Durch die Normierung wird auch die unterschiedliche Lage der zwei Gesten deutlich. Die Signalpfade der Extension und der Flexion unterscheiden sich in ihrer räumlichen Lage nun noch deutlicher voneinander. Die Ausprägung weg vom Nullpunkt und später wieder zurück zum Nullpunkt ist jetzt für die einzelnen Wiederholungen der Geste sehr viel einheitlicher.

Ein weiterer interessanter Aspekt der Signalpfade von zeitnormierten EMG-Signalen ist, dass sich bei der Betrachtung einer Geste von einem Aufnahmetag Ausreißer besser erkennen lassen. Abbildung 3.4 stellt Signalpfade der Geste Extension dar. Das linke Teilbild zeigt die Signalpfade des Aufnahmetags zwei, das rechte die gleiche Geste am Tag sechs. Wie bei den Clustern aus Abbildung 3.5 bilden die Pfade in dem Teilbild einen *Schlauch* in dem alle Signalpfade ähnlich und räumlich nah beieinander verlaufen. Das rechte Teilbild lässt erkennen, dass sich zwei der 15 Wiederholungen sehr stark von dem Rest unterscheiden. Dies deutet auf eine fehlerhafte Aufnahme hin. Die dreidimensionale Darstellung der Signalpfade kann somit auch dazu verwendet werden, von der Hautoberfläche abgelöste Sensoren oder fehlerhaft abgeleitete EMG-Signale zu erkennen.

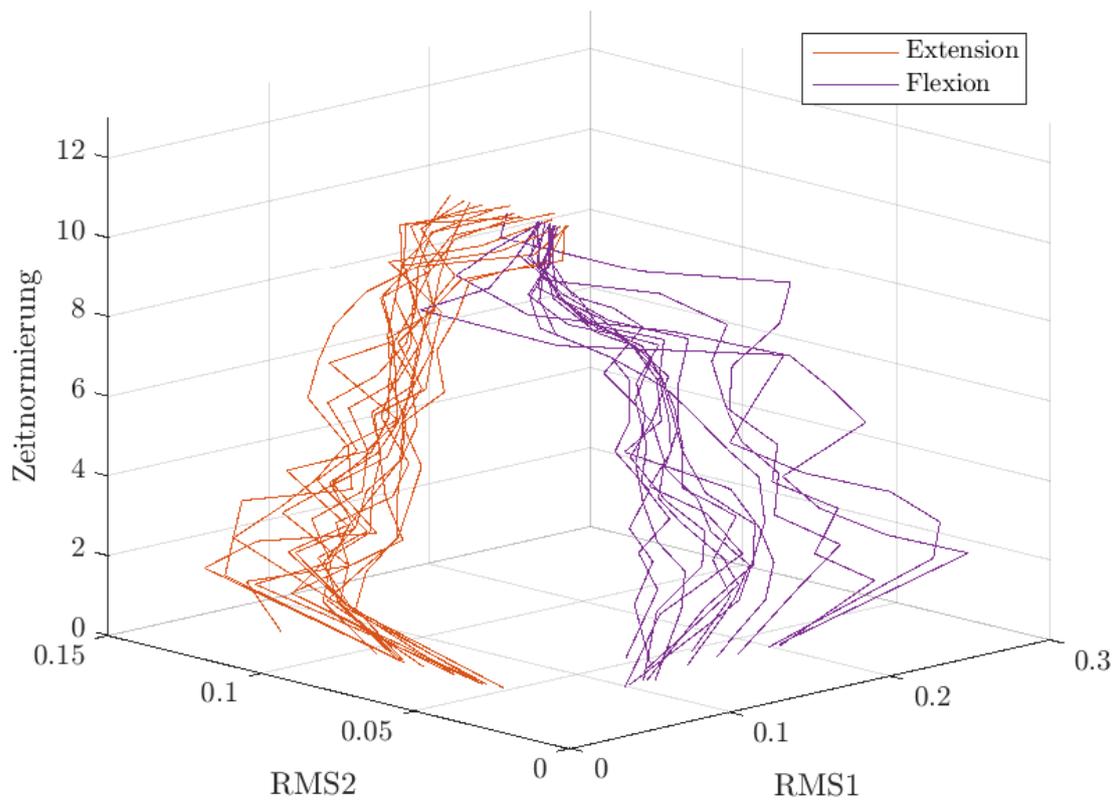


Abbildung 3.3: Normierte dreidimensionale EMG-Signale von den zwei Gesten Extension und Flexion

3 Verbesserte Klassifikation von elektromyographischen Signalen

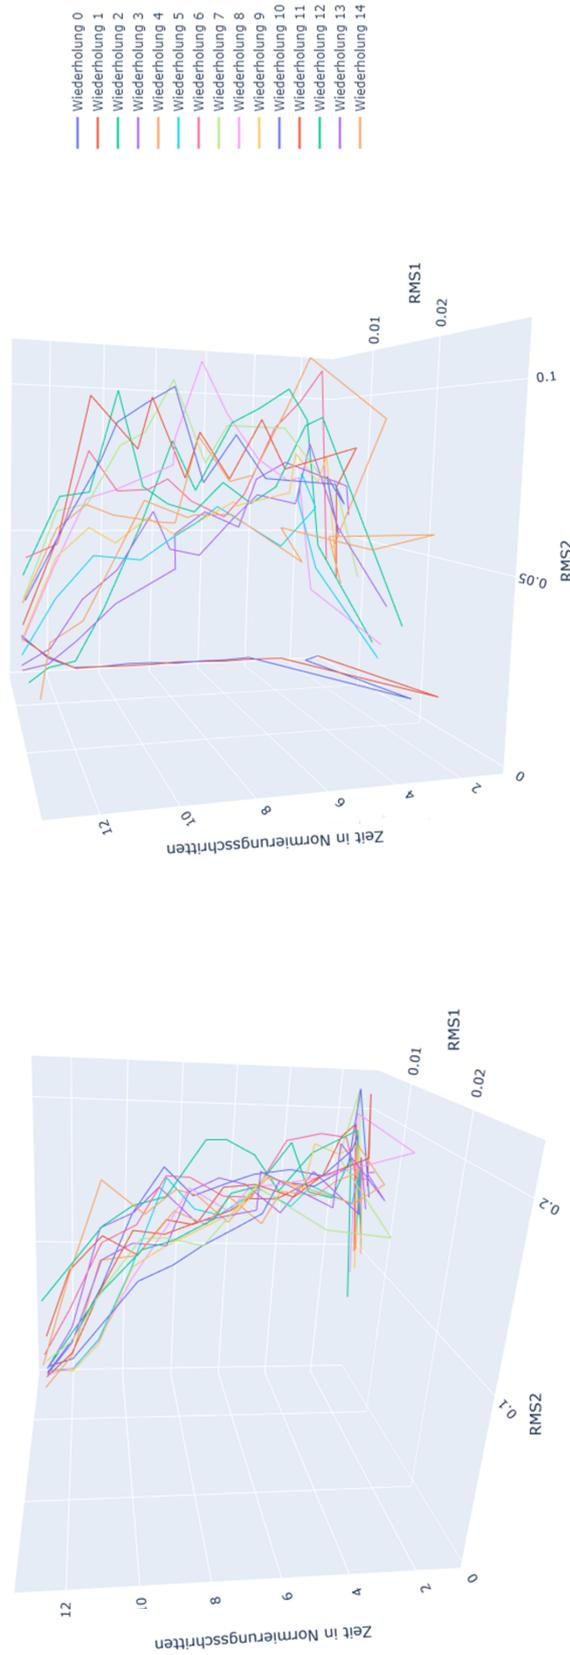


Abbildung 3.4: Linkes Teilbild: Alle Wiederholungen des Probanden 2 vom Aufnahmetag 2 ohne Aufnahmefehler, Rechtes Teilbild: Alle Wiederholungen des Probanden 2 vom Aufnahmetag 6 mit zwei fehlerhaften Aufnahmen

Eine andere Betrachtungsweise von zeitnormierten EMG-Signalen ist in Abbildung 3.5 dargestellt. Diese Grafik zeigt die normierten Signale als Streudiagramm. In dieser Art der Darstellung geht die Information, zu welcher Wiederholung einer Geste die einzelnen Punkte gehören, verloren, alle Punkte der Geste zusammen betrachtet, erscheinen dann jedoch als in einem Körper liegend. In der Grafik ist die Geste Extension des Probanden 1 dargestellt. Es sind alle Wiederholungen der Geste von zwei unterschiedlichen Aufnahmetagen (blau: 1. Aufnahmetag und rot: 3. Aufnahmetag) gezeigt. Auffällig ist, dass alle Wiederholungen eines Tages ein Cluster bilden. Dies lässt sich für alle fünf Probanden an allen sechs Aufnahmetagen und für jede der neun Gesten, also an 270 Beobachtungen, zeigen. Somit ist zu erkennen, dass die EMG-Signale, welche an einem Tag aufgenommen wurden, eine hohe Ähnlichkeit zueinander haben. Aufnahmen einer Geste von unterschiedlichen Tagen können jedoch zu räumlich verschobenen Clustern führen. Die einzelnen Signalpfade behalten allerdings für die jeweiligen Tage weiterhin ihre Ähnlichkeit zueinander.

Im nächsten Abschnitt wird die Überlegung angestellt, wie auf Grundlage der einzelnen Datenpunkte der normierten Signalpfade Regeln zur weiteren Vereinheitlichung der gewonnenen Daten abgeleitet werden können.

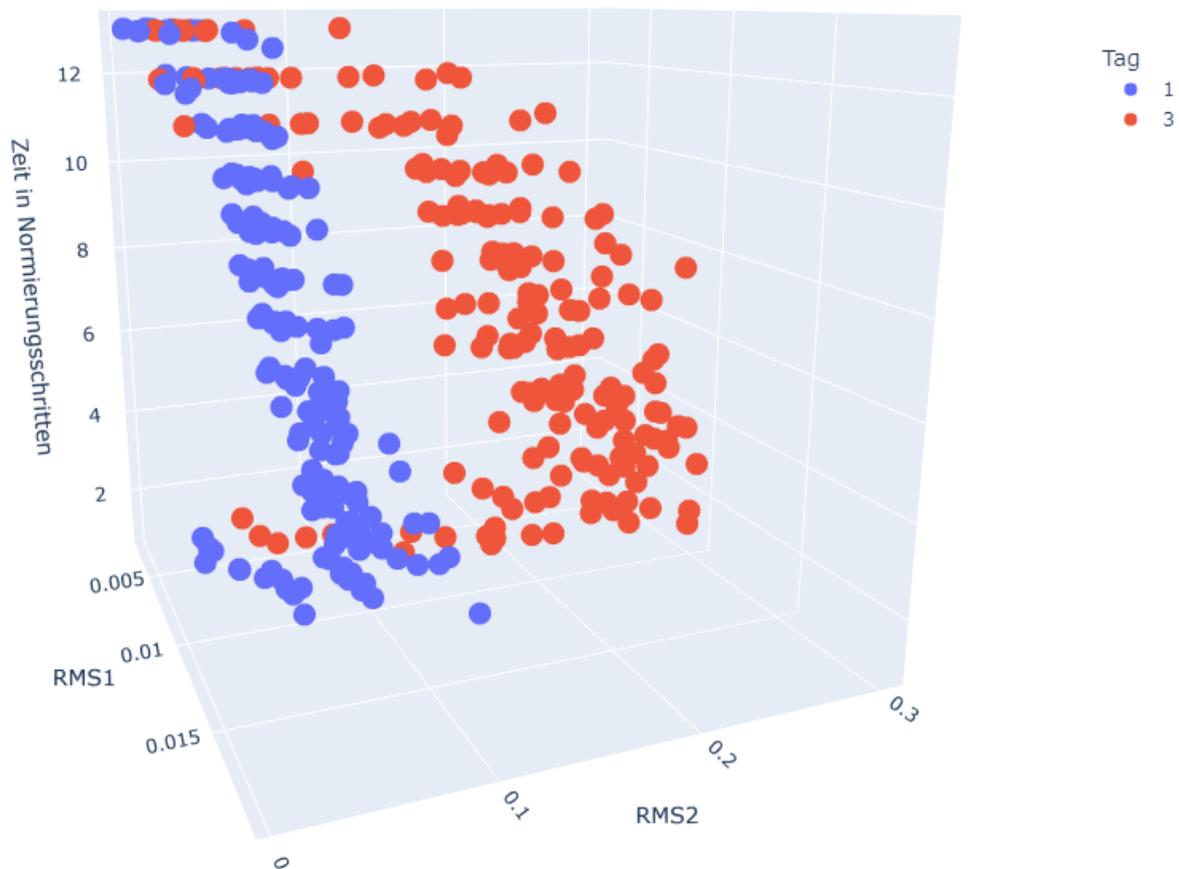


Abbildung 3.5: Die Punkteverteilung der Geste Extension für Proband 1. Alle Wiederholungen: blau Tag 1 und rot Tag 3

3.2.1 Betrachtung mehrerer Signalpfade in Zeitscheiben

Im vorangegangenen Kapitel wurden die Signalpfade normiert und somit auf eine einheitliche Länge gebracht. Dadurch konnte gezeigt werden, dass die Signalpfade einzelner Gesten sich ähneln. Das erzeugte Streudiagramm lässt Gesten-Cluster deutlich erkennen.

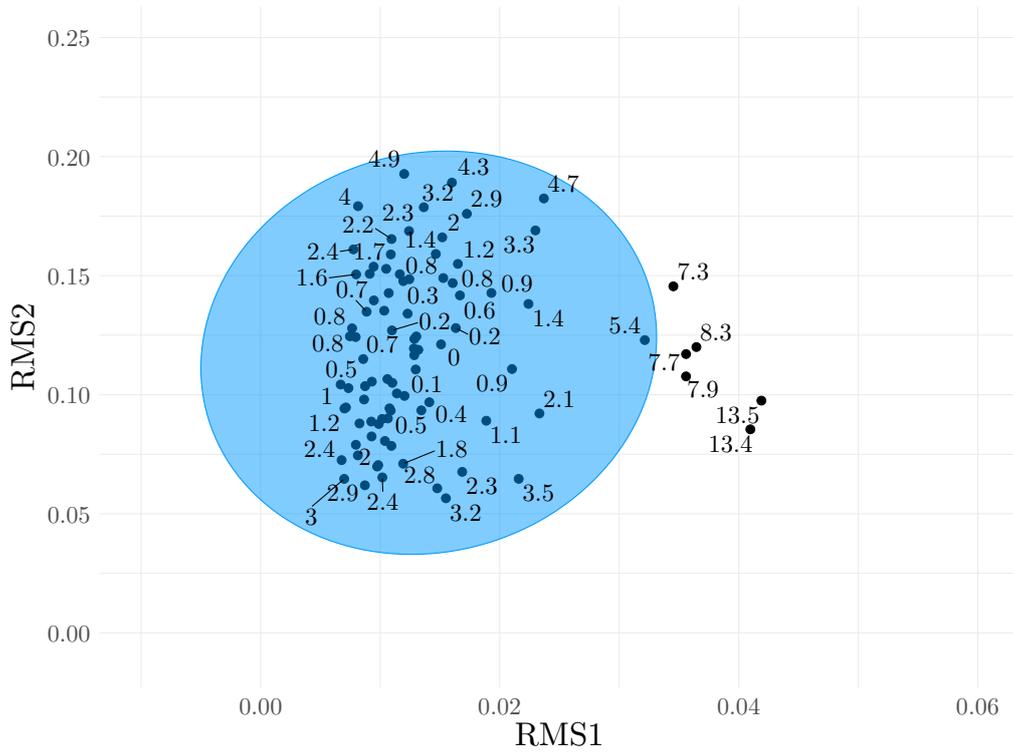
In diesem Abschnitt geht es darum, die entstehenden Cluster weiter zu vereinheitlichen, um daraus Informationen abzuleiten, welche die Klassifikation verschiedener Gesten ermöglichen und verbessern.

Die einzelnen Datenpunkte der normierten Signalpfade, welche in Abbildung 3.5 dargestellt sind, bilden zu einem diskreten Zeitpunkt der Normierung einen Querschnitt durch das Gesten-Cluster. Für jeden Cluster kann ein Zentrum und eine Dichte bestimmt werden. Mit diesen Informationen lässt sich der Abstand, den die einzelnen Datenpunkte zu dem Zentrum besitzen, berechnen. Damit kann wiederum darauf geschlossen werden, zu welchem Cluster die Punkte neu hinzugefügter Signalpfade gehören.

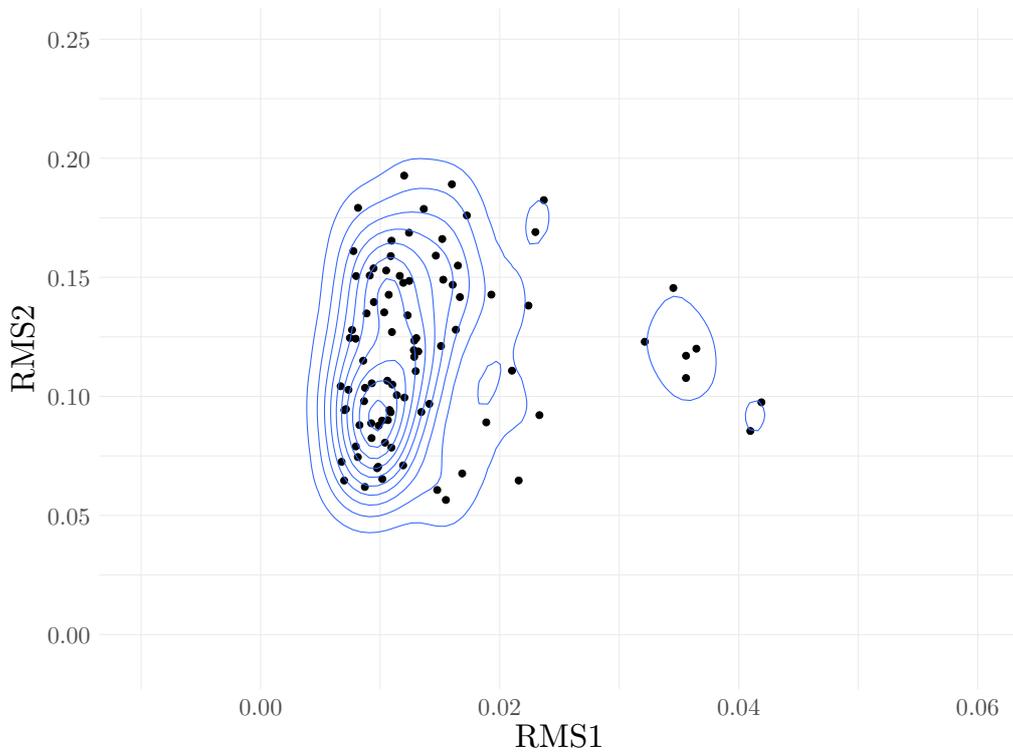
Als alternative Methoden, um die Cluster-Zentren sowie die Abstände der Punkte zu berechnen, bieten sich die Wahrscheinlichkeitsdichtefunktion (WDF) und die Mahalanobis-Distanz (siehe Abschnitt 2.4.5) an. Ausreißer lassen sich mit beiden Methoden als distante Einzelpunkte bestimmen und gegebenenfalls entfernen.

Abbildung 3.6 zeigt die fünfte Zeitscheibe der Geste Extension mit 90 Punkten. Jeder Punkt entspricht einem diskreten Zeitpunkt eines Signalpfads für Proband 2. In Abbildung 3.6(b) wurden Dichte und Cluster-Zentren der Scheibe mit der WDF für das RMS-Merkmal und zwei Sensoren berechnet. Durch diese Methode entstehen vier Zentren, ein großes und drei kleine. Die kleineren Cluster sind hier als Ausreißer zu betrachten, da sie anderenfalls die Klassifikation erschweren. Alternativ dazu kann die Mahalanobis-Distanz verwendet werden, die nur ein Cluster-Zentrum bildet. Für die gleiche Zeitscheibe ist in Abbildung 3.6(a) die Mahalanobis-Distanz dargestellt. Zur besseren Visualisierung der Ausreißer ist in der Abbildung zusätzlich zum Distanzmaß an den einzelnen Punkten das 95. Perzentil als Ellipse eingezeichnet, welches sich empirisch als gutes Maß erwiesen hat. So zeigt sich, dass im Gegensatz zur WDF bei der Mahalanobis-Distanz das Zweierpäarchen bei etwa $0,25 \text{ RMS}_1$ und $0,155 \text{ RMS}_2$ dem 95 %-Perzentil zugeordnet wird, während die kleinere Häufung um die $0,04 \text{ RMS}_1$ einen Ausreißer darstellt.

Aus diesen Informationen lassen sich in einem nächsten Schritt Körper bilden. Im Abschnitt 3.2 wurde bereits festgestellt, dass die Signalpfade einer Geste sich scheinbar innerhalb eines *Schlauch-ähnlichen* Körpers bewegen. Um aus den Informationen der Zeitscheiben dreidimensionale Körper zu bilden, ist aus den umhüllenden Ellipsen der Zeitscheiben für jeden Cluster ein Hüllkörper zu erstellen. Dabei eignen grundsätzlich sich sowohl die WDF als auch die Mahalanobis-Distanz zur Berechnung der Umhüllenden. Da durch die Mahalanobis-Distanz nur ein Cluster entsteht, wird diese Methode im Weiteren zur Beschreibung von Zeitscheiben verwendet, um möglichst gute Klassifikationsergebnisse zu erhalten. Durch das anschließende Verbinden der Umhüllenden für aufeinanderfolgende Zeitscheiben ergeben sich Hüllkörper.



(a) Angetragene Mahalanobis-Distanz an den Punkten mit einer zusätzlichen Ellipse des 95. Perzentils für die Verteilung der Zeitscheibe



(b) Die berechnete WDF für die Verteilung der Zeitscheibe

Abbildung 3.6: Bildung von Umhüllenden auf Datenpunkte von 90 Bewegungswiederholungen der fünften Zeitscheibe aus der Geste Extension von Proband 2

3.2.2 Bewegungskörper für EMG-Signale

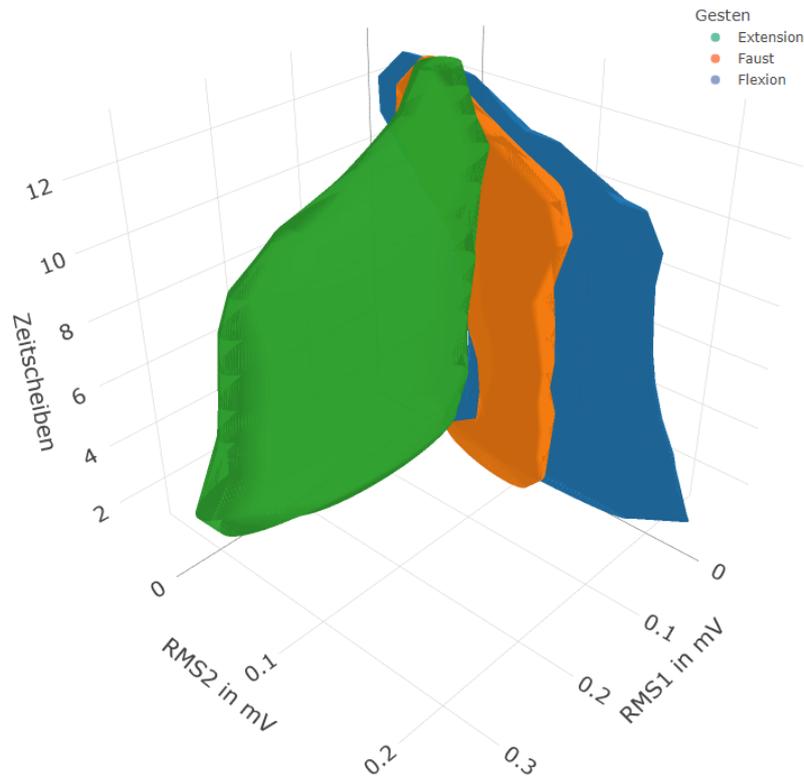
Die im vorherigen Abschnitt beschriebenen Hüllkörper lassen sich für jede Geste erzeugen, so dass diese im Folgenden als Bewegungskörper bezeichnet werden. Abbildung 3.7 zeigt drei solche Bewegungskörper. Jeder dieser Körper enthält Daten von 90 Wiederholungen über sechs Aufnahmetage, wobei alle Datenpunkte entfernt wurden, die nicht im 95. Perzentil der jeweiligen Zeitscheibe liegen. Durch das Verbinden der konvexen Hüllen von aufeinanderfolgenden Zeitscheiben einer Geste entsteht der zugehörige Bewegungskörper. Abbildung 3.7(a) zeigt deutliche Unterschiede der drei Körper hinsichtlich ihrer Ausprägung, ihrer Form und auch ihrer Lage. Da alle Bewegungen aus der Ruhelage starten, überlagern sich die Körper in der Nähe des Nullpunktes. Die weiteren Überlagerungen hängen stark von der Ausprägung der Umhüllenden ab, die wiederum durch die gewählte Mahalanobis-Distanz bestimmt wird. Die resultierenden Ellipsoide sind sich zu Beginn der Bewegung noch sehr ähnlich, verändern ihre Form jedoch bereits nach kurzer Zeit und sind ab diesem Zeitpunkt gut trennbar.

Besonders auffällig ist, dass der Körper der Flexion sehr flach ist. Bereits kurz nach Beginn der Messung ist der Extensions-Körper etwa 50% breiter als der Flexions-Körper. Beispielsweise ergibt sich für die Wände des Flexions-Körpers in der vierten Zeitscheibe ein Abstand von 0,053 mV, während für die Extension die Ausdehnung 0,116 mV beträgt. Im Unterschied zu diesen dennoch sehr ähnlichen Körpern weist der Körper der Geste Faust eine auffällig konkave Form auf, sodass die Bewegungskörper alleine durch ihre verschiedenen Lagen und Formen bereits gut zu unterscheiden sind.

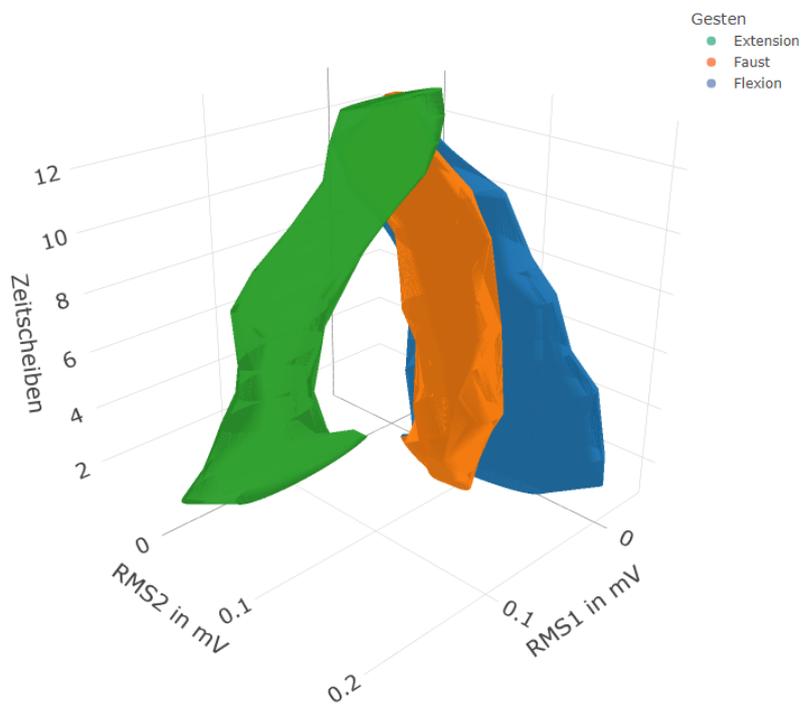
Allerdings stellt nur der Bewegungskörper der Faust den eigentlich zu erwartenden Verlauf dar, da alle Gesten aus der Ruhelage den gleichen Startpunkt haben, von dort ihre charakteristische Merkmalsentwicklung nehmen und abschließend wieder zur Ruhelage zurückkehren. Dies deutet daraufhin, dass insbesondere die Körper der Gesten Extension und Flexion durch die hohe Streuung der Daten über mehrere Aufnahmetage hinweg verzerrt sind, während die Merkmalsausprägungen der Geste Faust eine höhere Stabilität aufzuweisen scheinen. Dieser Eindruck bestätigt sich in der Abbildung 3.7(b), welche die gleichen Bewegungskörper darstellt, die aber lediglich die Daten von einem Aufnahmetag beschreiben. Sie sind verglichen mit den Körpern aus sechs Tagen deutlich kleiner und Ausprägung, Form sowie auch Lage sind klar ersichtlich besser trennbar. Dadurch ist bei jedem Körper die zuvor erwähnte konkave Biegung zu erkennen. Dies deutet darauf hin, dass eine sehr gute Klassifikation durch die Verwendung von Signalpfaden und die daraus resultierenden Bewegungskörper möglich erscheint.

Die unterschiedliche Ausprägung der Körper bei Verwendung von einem oder von sechs Aufnahmetagen deutet eine Zeitabhängigkeit an, welche nachfolgend genauer untersucht wird.

3.2 Zeitnormierung von EMG-Signalen



(a) Dreidimensionale Körper auf Basis von normalisierten RMS-Daten von sechs Aufnahmetagen, basierend auf dem 95 %-Perzentil der Mahalanobis-Distanz



(b) Dreidimensionale Körper auf Basis von normalisierten RMS-Daten von einem Aufnahmetag, basierend auf dem 95 %-Perzentil der Mahalanobis-Distanz

Abbildung 3.7: Hüllkörper von Bewegungsaufnahmen dreier Gesten von einem und sechs Tagen

3.2.3 Zeitabhängige Änderung der Bewegungskörper

In dem vorangegangenen Abschnitt wurde festgestellt, dass die Bewegungskörper bei der Betrachtung über mehrere Aufnahmetage an Kontur verlieren. Bereits Kaufmann et al. [46] und Zia ur Rehman et al. [113] stellen in ihren Untersuchungen fest, dass der Klassifikationsfehler mit zunehmender Länge des Betrachtungszeitraums ansteigt. Dies liegt vor allem daran, dass die entstehenden Cluster für jede Geste von Tag zu Tag unterschiedlich sind [105]. Dadurch unterscheidet sich auch die Qualität der Klassifikationsergebnisse. Dies könnte darauf zurückzuführen sein, dass die Signale der Probanden von der Tagesform abhängig sind und über den Untersuchungszeitraum variieren. Auch eine leicht unterschiedliche Sensorplatzierung sowie minimale Variationen in der Gestenausführung können Einfluss auf das Pattern Recognition (PR) und die entstehenden Signalfade haben.

Daher sind Bewegungskörper, die aus Daten bestehen, die über mehrere Tage oder einen noch längeren Zeitraum aufgenommen wurden, generell breiter und haben eine weniger ausgeprägte Form.

Abbildung 3.8 zeigt im Gegensatz dazu die Bewegungskörper der Geste Extension von sechs einzelnen Tagen. Hier ist zu erkennen, dass die Körper der einzelnen Tage einander sehr ähnlich sind. Allerdings befindet sich jeder Tagesbewegungskörper an einer anderen Position im Raum. Somit können die Feststellungen der Forschungsgruppen um Kaufmann und Zia ur Rehman mit den Bewegungskörpern visuell dokumentiert werden.

Die Unterschiede der Tagesbewegungskörper variieren dabei. Dies wird deutlich beim Vergleich zwischen Tag 6 und Tag 2. Der Körper für Tag 6 liegt zwischen 0,005 und 0,015 RMS1 und zwischen 0,05 und 0,1 RMS2. Die Wiederholungen von Tag 2 hingegen erzielen deutlich höhere Werte über 0,15 und maximal etwas über 0,2 RMS2. Der RMS1-Wert ist dagegen ähnlich wie der von Tag 6 und liegt zwischen 0,01 und maximal über 0,2 RMS1.

Ähnliches gilt auch für andere Bewegungsarten, wie die Flexion, wie in Abbildung 3.9 dargestellt, sowie für weitere nicht dargestellte Gesten. Die zeitlichen Verläufe ähneln sich dabei, wie die verschiedenen Ansichten zeigen, weshalb die einzelnen Tageskörper verschiedener Gesten gut zu unterscheiden sind.

Die Veränderung der Tageskörper lässt darauf schließen, dass sich die von Kaufmann [46] erwähnten möglichen Ursachen der Veränderung in den Bewegungskörpern widerspiegeln und daher z. B. eine minimale Lageänderung der Körper von einer Positionsänderung der Sensoren herrührt. Für Änderungen, wie sie bei der Extension zwischen Tag 2 und Tag 5 sowie bei der Flexion zwischen Tag 2 und Tag 3 auftreten, scheint dies jedoch unwahrscheinlich. Die Signalfade unterscheiden sich deutlich, was durch eine minimal veränderte Sensor-Position kaum zu erklären ist. Mögliche Ursachen hierfür sind Einflüsse einer veränderten Durchführung der Geste sowie physiologische Gegebenheiten des Muskels und des Hautwiderstandes.

Zusammenfassend kann festgehalten werden, dass erst durch das Zusammenführen der Daten mehrerer Tage die breiten Bewegungskörper in Abschnitt 3.2.2 entstehen. Es ist somit zu erwarten, dass sich die Klassifikationsergebnisse entsprechend steigern lassen, wenn, gegenüber der Verwendung von sechs Tagen, nur die Daten eines Tages berücksichtigt werden.

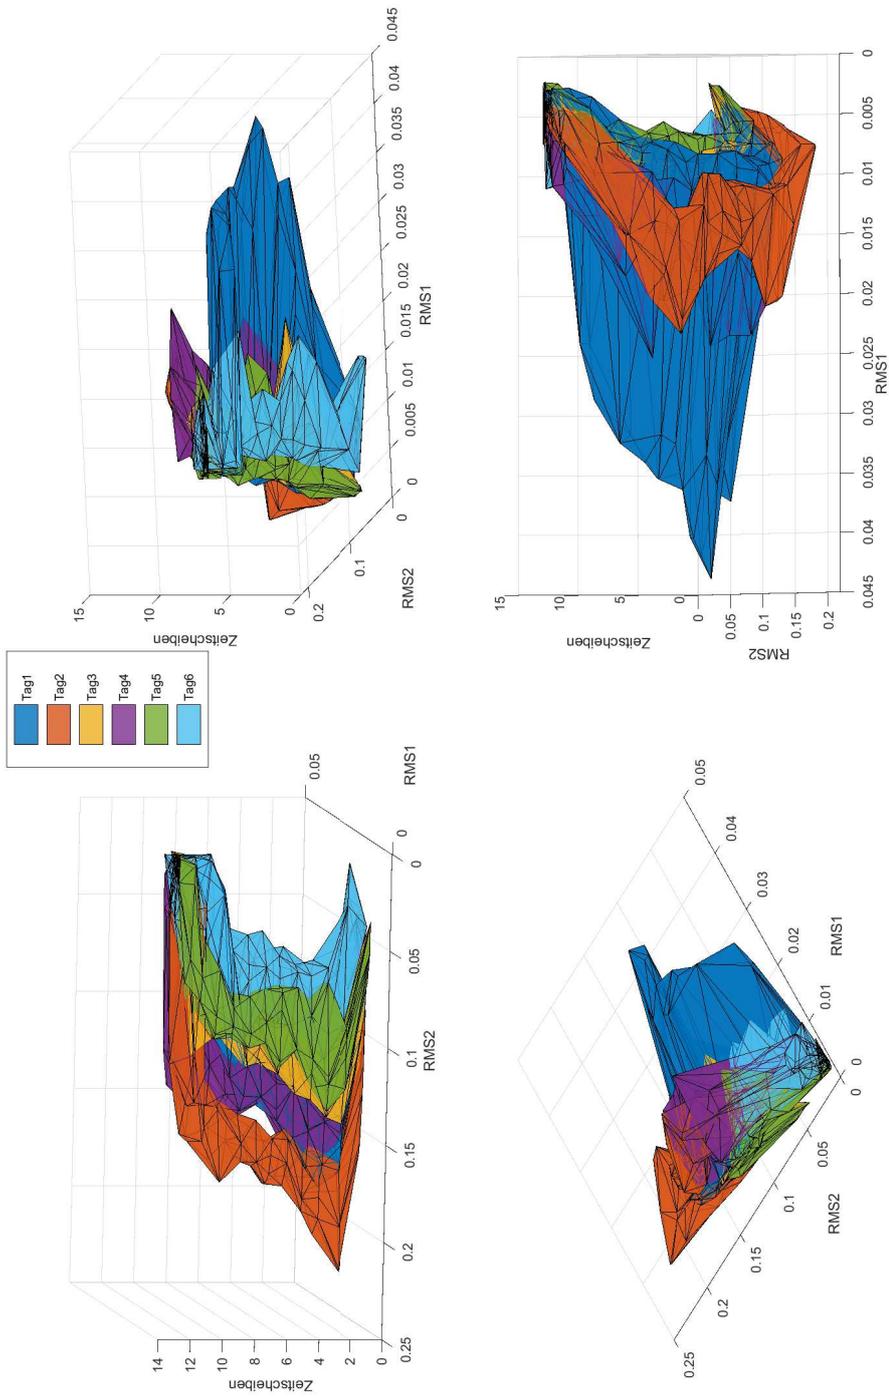


Abbildung 3.8: Unterschiedliche Ansichten der Bewegungskörper Extension für sechs Tage

3 Verbesserte Klassifikation von elektromyographischen Signalen

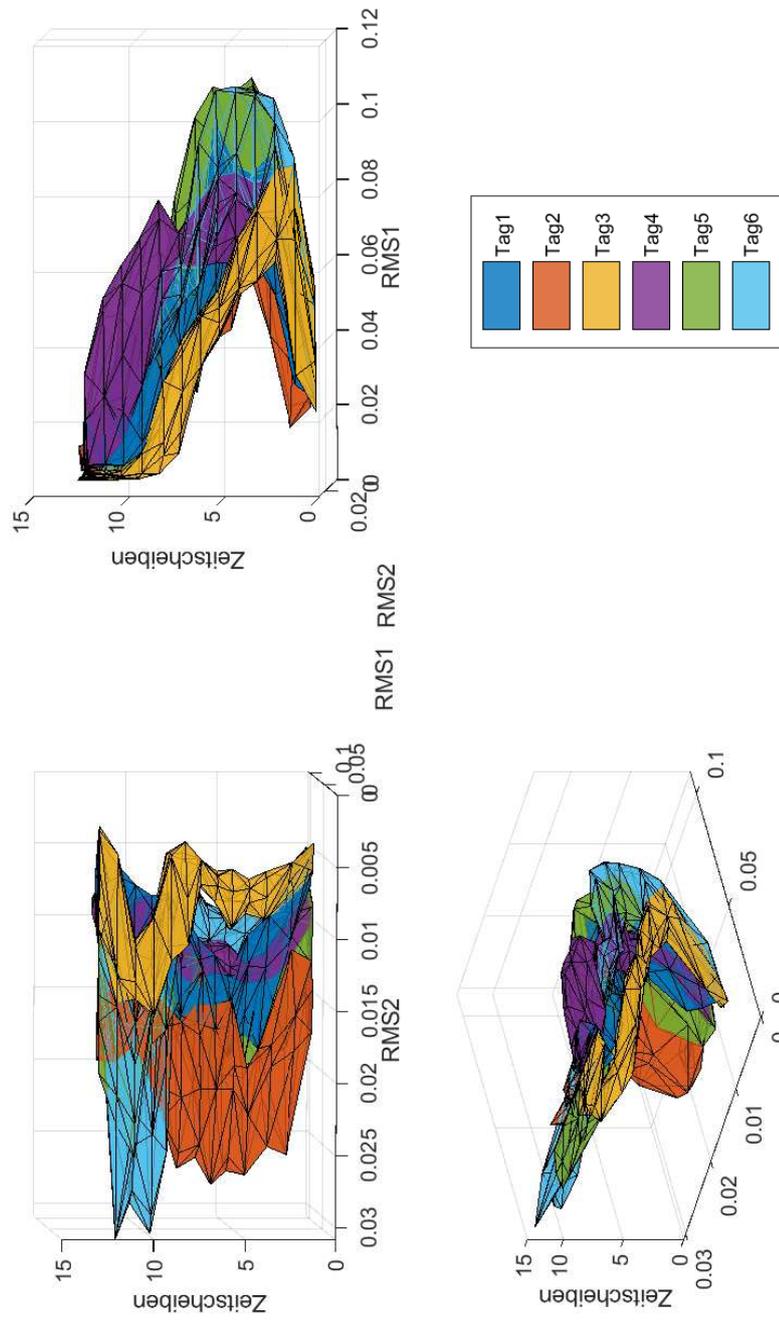


Abbildung 3.9: Unterschiedliche Ansichten der Bewegungskörper Flexion für sechs Tage

3.2.4 Klassifikation von EMG-Signalen mit Signalpfaden und Bewegungskörpern

Die vorangegangenen Abschnitte zeigen, wie EMG-Signale auf eine vorgegebene Länge normiert werden und wie daraus unter Berücksichtigung des zeitlichen Verlaufs Bewegungskörper entstehen. Die Abbildungen der Bewegungskörper in Abschnitt 3.2.2 legen nahe, dass die Normierung eine genauere Unterscheidung der verschiedenen Gesten ermöglicht als die Standardmethode.

Dieses Kapitel skizziert einen Ansatz zur Unterscheidung von EMG-Signalen anhand von Signalpfaden und Bewegungskörpern. Um die EMG-Signale zu klassifizieren, werden sie zunächst normiert und dann in Trainings- und Testsets aufgeteilt. Aus den Daten des Trainingssets werden anschließend die Bewegungskörper gebildet.

Die normierten Daten des Testsets entsprechen einzelnen Signalpfaden der jeweiligen Geste. Eine Möglichkeit, einen Signalpfad einer Klasse zuzuordnen besteht darin, zu überprüfen, in welchem Bewegungskörper er liegt. Hierfür werden die Bewegungskörper aus einer Zweierkombination der verwendeten Merkmale und der Zeit berechnet. Die Anzahl der Merkmalskombinationen k ergibt sich dabei aus der Anzahl der Sensoren s und der Anzahl der verwendeten Merkmale m . Für zwei Sensoren und zwei Merkmale beträgt $k = s * m = 4$, sodass der Rechenaufwand mit der Anzahl der Sensoren und der Anzahl der berechneten Merkmale steigt. Die Anzahl der zu erstellenden Bewegungskörper ergibt sich somit aus $\binom{k}{2}$ oder $\binom{s*m}{2}$. Diese Funktion wächst schnell an. Bei zwei Sensoren und zwei Merkmalen ergeben sich sechs Bewegungskörper, und bei $s = 2$ und $m = 4$ ergeben sich 28 Bewegungskörper. Wenn jedoch, wie bei einigen Gestenarmbändern [72, 91] der Fall, acht Sensoren mit vier Merkmalen verwendet werden, ergibt sich eine Anzahl von 496 Bewegungskörpern.

Um die Berechnung und Auswertung vieler Körper zu vermeiden, wird auf die Erstellung vollständiger Bewegungskörper verzichtet. Stattdessen ist nur noch diejenige Zeitscheibe zu betrachten, in der sich der zu klassifizierende Datenpunkt des Testsets befindet. Sei beispielsweise der Datenpunkt an Position i des Signalpfades, so wird dieser Punkt mit allen Zeitscheiben i der Bewegungskörper verglichen.

Die Zuordnung des Punktes kann dabei über sehr verschiedene Algorithmen erfolgen. Eine Möglichkeit ist es z. B. die Mahalanobis-Distanz für jeden der $9 * 90$ (9 Gesten * 6 Tage * 15 Wiederholungen pro Geste) Datenpunkten des Trainingssets und der dazugehörigen Zeitscheibe zu berechnen. Anschließend wird der Datenpunkt demjenigen Gesten-Cluster aus dem Trainingsset zugeordnet, dessen Abstand minimal ist.

Diese Vorgehensweise ähnelt dem k-NN-Verfahren. Auf die gleiche Weise lassen sich auch normierte EMG-Signale mit traditionell verwendeten Klassifikatoren wie z. B. SVMs, Entscheidungsbäumen oder ANNs zuordnen. Anstelle der Bewegungskörper können die normierten Signale als Trainingsset für die Klassifikatoren verwendet werden. Die Klassifikatoren bestimmen dann, zu welcher Klasse die normierten EMG-Signale des Testsets gehören.

Die bisher erzeugten Bewegungskörper zeigen eine räumliche Trennung, was darauf hindeutet, dass das vorgestellte Normierungsverfahren eine bessere Klassifikation als die Standardmethode ermöglicht. Dies wird im empirischen Teil dieser Arbeit im Abschnitt 5.2.2 überprüft.

3.3 Fortlaufende Zeitnormierung von EMG-Signalen

Ziel dieses Abschnitts ist die Präsentation einer Methode zur Beschleunigung der Klassifikation von EMG-Signalfaden, was zu einer besseren Reaktionsgeschwindigkeit und deutlichen Erleichterungen in der Nutzung einer Handprothese führt. Die hier vorgestellte Methode basiert auf der in den vorherigen Abschnitten vorgestellten Zeitnormierung, die es erlaubt, aus den EMG-Signalen Signalfade und Bewegungskörper zu extrahieren, die eine höhere Klassifikationsgüte ermöglichen. Allerdings hat die Normierung auch einen Nachteil: Sie kann erst nach dem Ende der Bewegung angewendet werden, was zu einer späten Klassifikation und einer verzögerten Prothesenreaktion führt (siehe Abschnitt 2.6). Um dieses Problem zu lösen, muss die Methode so verbessert werden, dass die Normierung schon während der Bewegung durchgeführt werden kann und somit eine frühere Klassifikation und Prothesensteuerung möglich ist.

Die bisherige Arbeit hat mit Hilfe der Normierung des EMG-Signals gezeigt, dass EMG-Signale von mehreren Bewegungen einer Geste immer gleich oder ähnlich aufgebaut sind und, dass diese Bewegungen einer Regelmäßigkeit unterliegen (siehe Kapitel 3.2). Es kann daher davon ausgegangen werden, dass, wenn sich das Signal über die Zeit hinweg bildet und es dabei in regelmäßigen Abständen normiert wird, die resultierenden Bewegungskörper ebenfalls einer Regelmäßigkeit unterliegen. Ein Klassifikator kann diese Regelmäßigkeit erlernen und nutzen, um Signalfade analog zur normierten Methode zuzuordnen.

Die einzelnen Visualisierungen in Abbildung 3.10 zeigen exemplarisch, wie der finale Bewegungskörper für die Geste Flexion schrittweise entsteht. Der initiale Bewegungskörper der Serie (links oben) resultiert aus dem normierten EMG-Signal der ersten 100 ms. Jeder folgende Körper berechnet sich aus den Signalen der Vorgänger plus dem EMG-Signal für weitere 100 ms. Dauert die durchgeführte Bewegung zwei Sekunden an, so entstehen 20 fortlaufende Körper.

In Abbildung 3.10 ist gut zu erkennen, wie der Bewegungskörper mit jedem Schritt seine Form verändert. Die Veränderung bildet dabei den Körper mit jedem Schritt so, dass sich dieser der Form des Körpers aus dem Abschnitt 3.2.2 immer weiter annähert. Die einzelnen Körper bilden somit für die Klassifikation eine Basis auf der Grundlage bisher berechneter Signalfade und werden daher im Folgenden Zeitbasis genannt.

3.3 Fortlaufende Zeitnormierung von EMG-Signalen

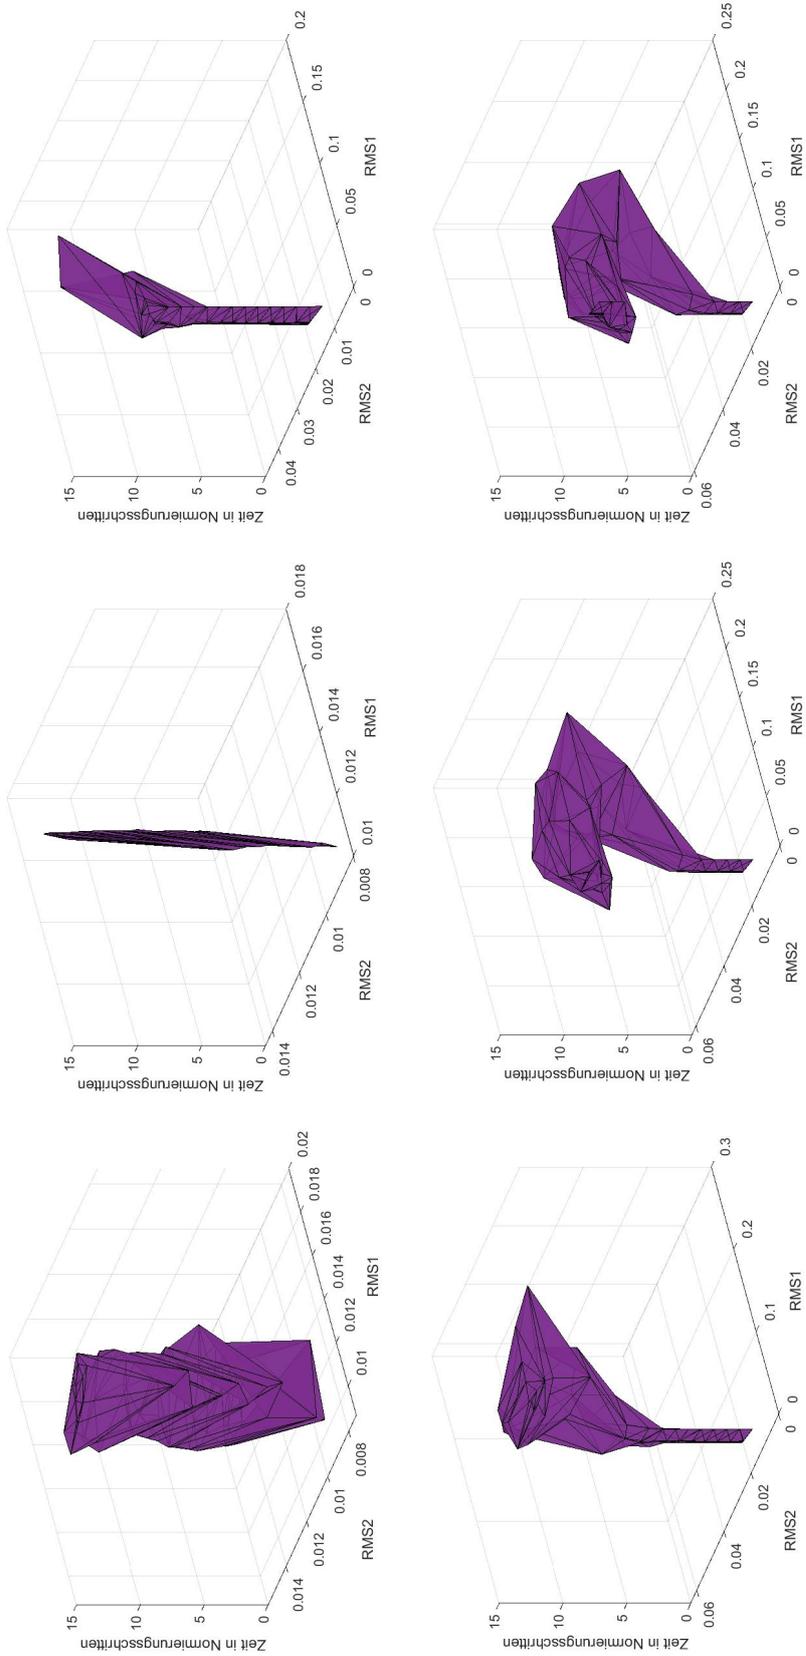


Abbildung 3.10: Schrittweiser Aufbau des Bewegungskörpers für die Geste Flexion durch Normierung zu markanten Zeitpunkten

3 Verbesserte Klassifikation von elektromyographischen Signalen

Durch die fortlaufende Normierung entsteht eine Matrix, ähnlich der Matrix der Normierungsmethode aus Abschnitt 3.2. Die Matrix für die fortlaufende Normierung besteht aus den berechneten Merkmalen, einer fortlaufenden Identifikationsnummer (ID) der Normierung (siehe Abschnitt 3.2.1) und einer ID für die Zeitbasis. Alle Zeilen der Zeitbasis z enthalten somit die normierten Daten der Bewegung bis zu diesem Zeitpunkt. Eine beispielhafte Matrix mit zwei Merkmalen, den IDs der Zeitscheibe und den IDs der Zeitbasis ist in Tabelle 3.1 dargestellt.

Für das Beispielsignal mit der Normierungsgröße von drei entstehen drei Zeitscheiben und vier Zeitbasen. Jede Zeitbasis ist dabei eine für jeden Intervallschritt neu berechnete Matrix und stellt den normierten Bewegungsablauf der Geste bis zu diesem Zeitpunkt dar. Die Matrix enthält somit Informationen über den zeitlichen Verlauf einer Geste. Diese Informationen können von einem Klassifikator verwendet werden, um diese bereits vor dem Beenden der Geste zuzuordnen.

Die Anzahl an Zeitbasen ist für jede Geste und jede Bewegung unterschiedlich, da jede Geste eine unterschiedlich lange Ausführungszeit hat und jede Bewegung sich in ihrer Haltedauer unterscheidet. Die Unterschiede sind zwar meist geringer als eine Sekunde, doch kann dies bereits dazu führen, dass zehn weitere Normierungen durchzuführen sind.

Die Größe des Trainingsets hängt somit von der Anzahl an Merkmalen und der Normierungsgröße ab. Für das Training der Klassifikation benötigt das Trainingsset zusätzlich das Label für die Zuordnung der Geste.

Eine Klassifikation ist mit verschiedenen Klassifikatoren möglich. So kann, wie zuvor beschrieben, ein Signalpfad ermittelt werden. Wenn dieser innerhalb eines zuvor erstellten und somit erlernten Körpers liegt, so gehört der Signalpfad der Klasse des Körpers an. Im Gegensatz zu der zuvor vorgestellten Methode wird dieses Vorgehen jedoch dadurch erschwert, dass eine Geste durch die fortlaufende Zeitnormierung aus mehreren Körpern besteht.

Alternativ können analog zu dem in Abschnitt 3.2.4 beschriebenen Verfahren, die einzelnen Datenpunkte eines Signalpfades mit den Zeitscheiben des Bewegungskörpers der aktuellen Zeitbasis verglichen werden. Dabei ist zu beachten, dass jede Geste nach jedem Intervallschritt verschiedene Erscheinungsbilder annimmt, also unterschiedliche Körper für jede Zeitbasis formt. Der zu klassifizierende, fortlaufende Signalpfad ist mit der für ihn korrelierenden Zeitbasis zu vergleichen. Somit ist es auch möglich, alle Informationen aus den bisherigen Normierungsschritten zu nutzen, indem jeder Datenpunkt eines fortlaufenden Signalpfades bis zu dem Zeitpunkt mit dem entsprechenden fortlaufenden Gestenkörper verglichen wird. Dadurch können alle bisherigen Normierungsschritte einbezogen werden, um eine umfassende Klassifikation durchzuführen. Da hierdurch die Dimensionalität stark ansteigt, ist davon auszugehen, dass nicht jeder Klassifikator hierfür geeignet ist.

Durch die fortlaufende Zeitnormierung wird mit jeder Iteration eine neue Normierung für die entsprechende Zeitbasis erzeugt. Hierdurch nähert sich der entstehende Körper immer weiter dem Körper der Normierung an, wie er ganz am Ende der Bewegung entsteht. Es stellt sich die Frage, ob eine ausreichende Klassifikation stattfinden kann, bevor die Bewegung der Geste abgeschlossen ist und damit die übrigen Berechnungen überflüssig werden. Dabei ist anzunehmen, dass die Wahrscheinlichkeit einer richtigen Klassifikation mit der Zeit besser wird, während die Körper für die ersten Normierungen, welche bereits kurz nach Beginn der Bewegungen stattfinden, sich noch stark ähneln und daher eine Klassifikation eher schwierig ist. Im Abschnitt 5.2.4 wird untersucht, ob und ab wann eine frühzeitige Klassifikation mit der fortlaufenden Normierungsmethode möglich ist.

3.3 Fortlaufende Zeitnormierung von EMG-Signalen

Tabelle 3.1: Beispielmatrix für eine fortlaufende Normierung mit einer Normierungsgröße von drei und vier resultierenden Zeitbasen

Sensor 1		Zeitscheibe	Zeitbasis
Merkmal 1	Merkmal 2		
Skalar	Skalar	1	1
Skalar	Skalar	2	1
Skalar	Skalar	3	1
Skalar	Skalar	1	2
Skalar	Skalar	2	2
Skalar	Skalar	3	2
Skalar	Skalar	1	3
Skalar	Skalar	2	3
Skalar	Skalar	3	3
Skalar	Skalar	1	4
Skalar	Skalar	2	4
Skalar	Skalar	3	4

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

In den vorangegangenen Kapiteln wurden zwei Methoden zur Vorverarbeitung von EMG-Signalen vorgestellt, die eine gesteigerte Klassifikationsgüte erwarten lassen. Nun wird der Versuchsaufbau beschrieben, mit dem geprüft wird, ob die beiden Normierungsmethoden die Klassifikationsgüte im Vergleich zur Standardmethode erhöhen können. Dazu werden die verwendeten Aktivierungsgesten und das System zur Aufnahme der EMG-Signale vorgestellt. Eine Erläuterung der Parameter für die Normierungen sowie der verwendeten Klassifikatoren ist ebenfalls Teil dieses Kapitels. Im Anschluss an die Experimente werden die Ergebnisse der beiden neuen Normierungsmethoden und der fortlaufenden Normierung im Vergleich zur Standardmethode für verschiedene Gesten und Klassifikatoren diskutiert.

4.1 Verwendete Aktivierungsmuster

Diese Arbeit verwendet neun Aktivierungsmuster für Training, Klassifikation und Bewertung unterschiedlicher Methoden, wie in Tabelle 4.1 dargestellt. Die gewählten Muster umfassen häufig verwendete Griffmuster sowie solche, die sich hinsichtlich der Muskelaktivität sehr ähnlich sind.

Die Aktivierungsmuster basieren auf drei Bewegungsarten: Faust, Flexion und Extension. Dazu kommen drei Griffmuster mit unterschiedlicher Fingerstellung: OK, Index und Daumen-Hoch. Außerdem wurde die Geste Kokontraktion hinzugefügt, die der Faust sehr ähnlich ist. Handgelenkdrehungen wie Pronation und Supination werden ebenfalls für die Untersuchungen betrachtet.

Mit dieser Auswahl können sowohl Bewegungsarten, welche ursächlich vom Handgelenk ausgehen, als auch reine Fingeraktionen untersucht und bewertet werden.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

Tabelle 4.1: Beschreibung der Aktivierungsmuster mit der dazugehörigen Identifikationsnummer

ID	Bezeichnung	Beschreibung	Abbildung
0	Kokontraktion (engl. co-contraction)	Alle fünf Finger werden ausgestreckt aneinander gelegt.	
1	Extension	Das Handgelenk wird nach außen abgewinkelt.	
2	Faust (engl. fist)	Die Hand wird zur Faust geballt.	
3	Flexion	Das Handgelenk wird nach innen abgewinkelt.	
4	Index	Der Zeigefinger wird ausgestreckt.	
5	OK	Die Spitzen des Daumens und des Zeigefingers werden zusammengeführt. Mittel-, Ring- und kleiner Finger werden ausgestreckt.	
6	Daumen-Hoch (engl. Thumb-Up)	Zeige-, Mittel-, Ring- und kleiner Finger werden angewinkelt. Der Daumen wird ausgestreckt.	
7	Pronation	Drehung des Handgelenks zum Körper	
8	Supination	Drehung des Handgelenks vom Körper weg	

4.2 Aufnahme von EMG-Signalen

Zur Erfassung der Bewegungsmuster werden die EMG-Signale mithilfe von zwei auf der Haut aufgelegten Sensoren aufgenommen. Diese Sensoren gehören zum Bagnolie™-4-EMG-System von Delsys®, nachfolgend als Bagnolie™ bezeichnet. Das System dient zur Messung und Verstärkung der elektrischen Aktivität der Muskeln und wird üblicherweise nicht direkt zur Steuerung von Prothesen verwendet, sondern ist für den Einsatz in Forschung und Lehre konzipiert [22].

Das Bagnolie™ besteht aus drei Hauptkomponenten: Dem Verstärker, dem Input-Modul und den angeschlossenen Sensoren sowie einer Referenzelektrode. Der Verstärker des Bagnolie™-Systems bietet drei dekadisch gestufte Verstärkerstufen mit einer Spannungsverstärkung von 1000. Die aufgenommenen Signale können im Bereich von $\pm 100 \mu\text{V}$ bis $\pm 5 \text{ mV}$ liegen. Bei Verwendung der Verstärkerstufe $1k$ ergibt sich somit ein Ausgangsspannungssignal von $\pm 100 \text{ mV}$ bis $\pm 5 \text{ V}$. Der Verstärker enthält zudem einen Hochpassfilter mit einer Grenzfrequenz von 20 Hz und einen Tiefpassfilter mit einer Grenzfrequenz von 450 Hz.

Das Input-Modul des Bagnolie™ unterstützt bis zu vier Sensoren und eine gemeinsame Referenzelektrode und fungiert als Verbindungsglied zwischen dem Verstärker und den Sensoren [22].

Für die meisten Messungen wurden zwei Differenzialsensoren mit zwei Elektroden verwendet. Die Ausgabe eines Sensors beträgt $V_{out} = V_1 - V_2$ bezogen auf die Referenz-Elektrode. Elektroden dieser Art eignen sich für die Messung von Signalen verschieden großer Muskeln.

Die vom Bagnolie™-System aufgenommenen Signale werden über Bayonet Neill Concelman (BNC)-Kabel an einen Analog-Digital-Wandler (AD-Wandler) von National Instruments, den NI USB-6229 mit 16 Bit, geleitet. Dieser stellt das Signal dann zur Weiterverarbeitung digital zur Verfügung.

Wie bereits erläutert werden für die Messungen nur zwei Sensoren verwendet, da dies der späteren Umsetzung in einem Prothesenaufbau am besten entspricht.

Für die Untersuchungen wurden die beiden Sensoren über dem Extensor digitorum und dem Flexor carpi radialis platziert. Diese beiden Muskeln sind relativ stark ausgeprägt und befinden sich im Unterarm, wo sie einen großen Teil der Arbeit bei dem Bewegen des Handgelenks und der Finger verrichten. Abbildung 4.1(a) zeigt den Extensor digitorum (grün), welcher den Zeige-, Mittel- und Ringfinger streckt und beim Ausführen der Extension des Handgelenks aktiv ist. Der Muskel Flexor carpi radialis ist in Abbildung 4.1(b) ebenfalls grün dargestellt. Er bedingt die Flexion des Handgelenks und ist bei der Bildung der Faust sowie der Kokontraktion maßgeblich beteiligt.

Zur Aufzeichnung der gewonnenen Daten mit einer Abtastrate von 2048 Hz und deren Vorverarbeitung wurde Matlab® von MathWorks® verwendet. Die Aufzeichnung des Signals für eine Geste dauert sechs Sekunden. Somit besteht eine Aufnahme aus 24.576 Messungen, welche nach der Vorverarbeitung direkt klassifiziert werden. Der Vorverarbeitungsschritt ist notwendig, um unnötige Informationen zu entfernen und dem Klassifikator nur relevante Daten zur Verfügung zu stellen. Zu den Vorverarbeitungsschritten gehört das Entfernen störender Frequenzen sowie die Berechnung von Merkmalen aus den Rohdaten. Zur weiteren Optimierung des Signals wird es zunächst auf die zu klassifizierende Bewegung geschnitten und anschließend eine Fensterfunktion darüber gelegt. In Abschnitt 2.4.3 wurde ausführlich dargelegt, wie das Hamming-Fenster, das vor allem für seinen Einsatz vor der Fourier-Transformation bekannt ist, auch bei der vorliegenden Problematik dazu beitragen kann, die Daten an den Fensterübergängen zu glätten.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale



- (a) Der Muskel Extensor digitorum, welcher zum Strecken des Zeige-, Mittel- und Ringfingers sowie des Handgelenks verwendet wird.
- (b) Der Muskel Flexor carpi radialis, welcher zum Beugen des Handgelenks genutzt wird. Zudem ist er beim Formen der Faust angespannt.

Abbildung 4.1: Die Muskeln Extensor digitorum und Flexor carpi radialis ¹

4.2.1 Filterung von EMG-Signalen

Zur Steuerung einer Prothese für die obere Extremität ist der Frequenzbereich von 20 Hz bis 50 Hz des EMG-Signals ausschlaggebend. Wie oben beschrieben, unterdrückt das verwendete Bagnolie™-System bereits Signalteile außerhalb des interessierenden Bereichs, jedoch wie Versuche zeigten, nicht ausreichend.

Das mit einem NI USB-6229 Analog-Digital-Wandler von National Instruments digitalisierte EMG-Signal (Abbildung 4.2(c)) weist neben einem Gleichspannungsanteil (offset) von 0,18 V auch noch nennenswerte Signalanteile unter 20 Hz und über 450 Hz auf, Abbildung 4.2(a). Um eine korrekte Merkmalsberechnung durchführen zu können, beispielsweise die korrekte Bestimmung der Nulldurchgänge ZC, und um höherfrequente Störsignalkomponenten zu eliminieren, ist daher eine weitere Bandbegrenzung erforderlich.

Die zusätzliche Filterungsstufe kann als zweigliedriges Finit Impulse Response (FIR)-Filter realisiert werden, da das initiale analog realisierte Antialiasing Filter im Bagnoli™ gerade ausreichend ist. Auch hier besteht die Filterkette aus einem 20 Hz Hochpass- mit nachgeschaltetem 450 Hz Tiefpassfilter. Die Parameter für die zusätzliche Filterstufe sind in Tabelle 4.2 zusammengefasst. Die dazugehörigen Amplitudengänge der Filter sind in Abbildung 4.3(b) (Tiefpassfilter) und in Abbildung 4.3(a) (Hochpassfilter) dargestellt. Dadurch lassen sich diese Frequenzen mit der schnellen Fourier-Transformation wie in Abbildung 4.2(b) dargestellt, nicht mehr erkennen. Zusätzlich ergibt sich durch die Entfernung der Gleichkomponente und der hohen Ordnung der Filter das in 4.2(d) dargestellte Spektrum für das Rohsignal.

¹Quelle der Abb.: Human 3.0 von BIODIGITAL HUMAN

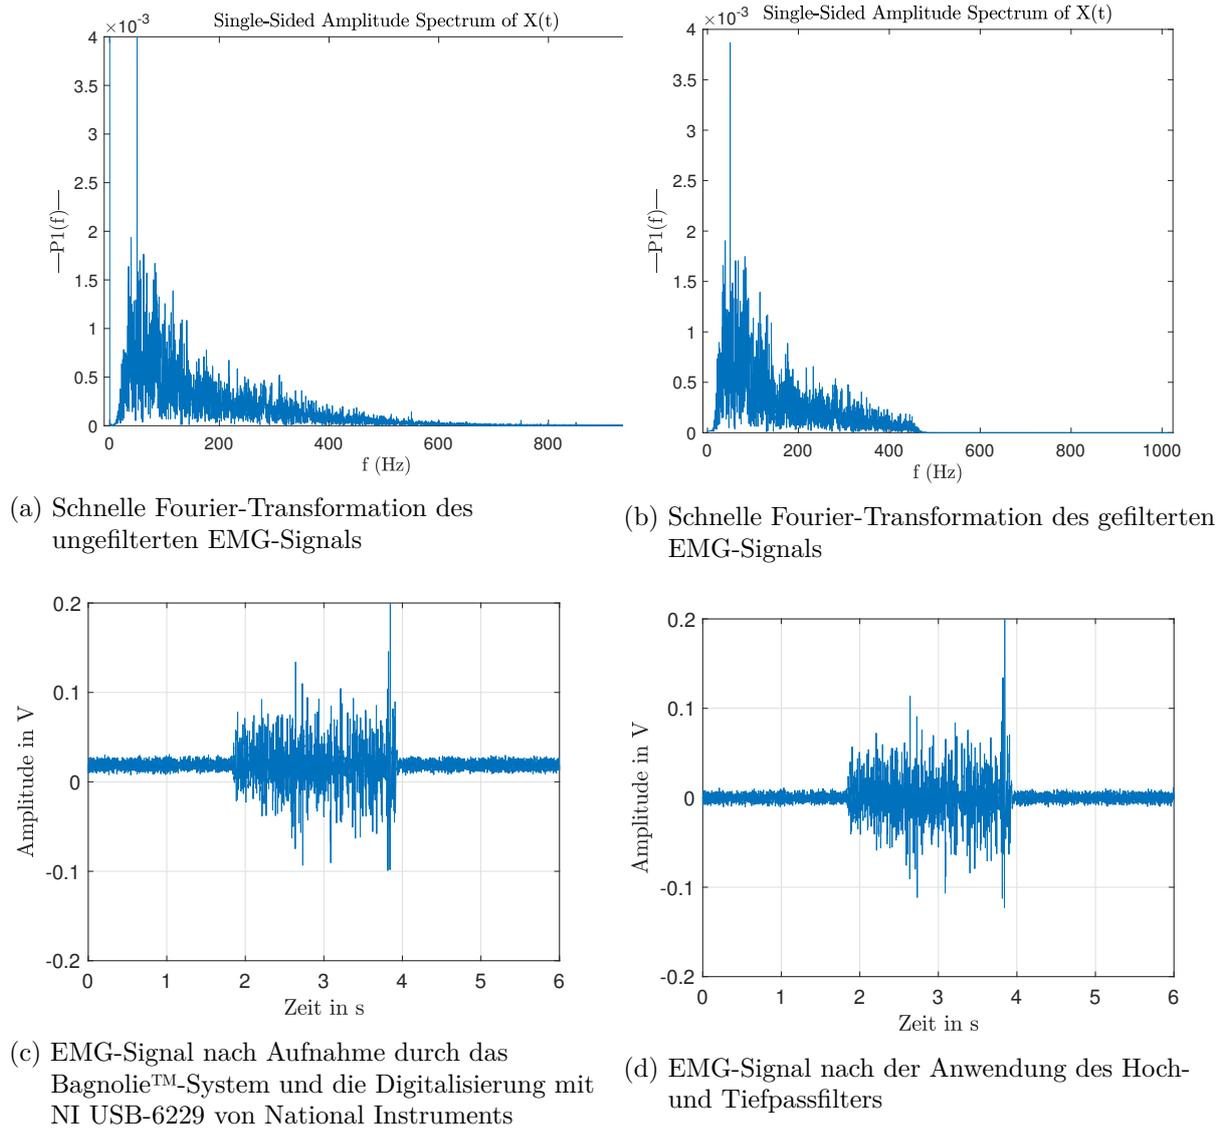
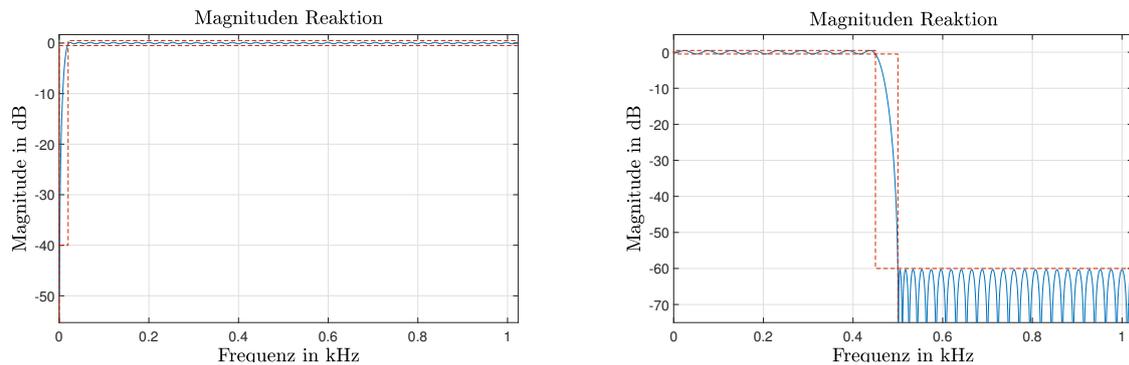


Abbildung 4.2: Beispielhafte Darstellung eines EMG-Signals mit und ohne Filterung

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale



(a) Magnituden des 20 Hz Hochpassfilters.

(b) Magnituden des 500 Hz Tiefpassfilters.

Abbildung 4.3: Amplitudengänge der entworfenen Hoch- und Tiefpassfilter

Tabelle 4.2: Parameter der Hoch- und Tiefpassfilter

Funktion	Hochpass	Tiefpass
Stopband-Frequenz	0,01 Hz	500 Hz
Durchlassband-Frequenz	20 Hz	450 Hz
Stopband-Dämpfung	40 dB	60 dB
Welligkeit im Durchlassbereich	1 dB	1 dB
Ordnung	154	82
Abtastrate	2048 Hz	2048 Hz

4.2.2 Schnitt der Signale

Um das Bewegungssignal aus der Gesamtaufnahme herauszuschneiden, müssen der Anfang und das Ende der Bewegung bestimmt werden. Dazu wird das EMG-Signal in Fenster aufgeteilt, für die die in Abschnitt 2.4.2 vorgestellten Merkmale berechnet werden können. Ein Fenster enthält eine Reihe von Messwerten des EMG-Signals und hat eine Länge zwischen 32 ms und 350 ms [64]. Für Gesten, die typischerweise länger als 350 ms sind, ergeben sich mehrere Fenster, für die ein oder mehrere Merkmale berechnet werden. Ein solches Merkmal kann ein Skalar, ein Vektor oder eine Matrix sein.

Die einfachste Methode zur Erkennung des Beginns und des Endes einer Bewegung ist die Verwendung von Schwellwerten (engl. threshold). Wenn das Signal den Schwellwert überschreitet, gilt dies als Beginn der Bewegung; wenn es den Schwellwert unterschreitet, endet die Bewegung. Da die Amplitude, wie in Abbildung 2.11 zu sehen ist, relativ schnell abfällt und dann wieder ansteigt, ist diese Methode auf dem Rohsignal nicht geeignet, da es fortlaufend zu Über- und Unterschreitungen des Schwellwerts kommen würde. Um dies zu verhindern, kann das Signal in den positiven Bereich *gedreht* werden, was strenggenommen nichts anderes als die Berechnung eines Merkmals ist. Für die Erkennung des Beginns und des Endes einer Bewegung eignet sich z. B. ein Merkmal, das ein Rechtecksignal mit ansteigender Flanke am Anfang und abfallender Flanke am Ende der Bewegung erzeugt, wie das RMS-Merkmal (2.4.2). Wird das Merkmal RMS in Abbildung 2.12 betrachtet, ist zu erkennen, dass sich das RMS-Signal einem Rechteck annä-

hert. Für die Anfangserkennung sollte der Anfangsschwellwert so hoch gewählt werden, dass der Beginn der Bewegung sicher erkannt wird und Schwankungen im Terrassenbereich nicht fälschlicherweise als Bewegungsende interpretiert werden. Eine Möglichkeit, das Signal zu glätten und die Schwankungen zu reduzieren, besteht darin, die Fenstergröße zu erhöhen. Dadurch wird das Merkmal über einen größeren Bereich berechnet, was eine verbesserte Anfangs- und Enderkennung durch Mittelwertbildung ermöglicht.

Der Schwellwert muss zusätzlich so niedrig gesetzt sein, dass das Ende der Bewegung sicher erkannt wird, aber nicht vorzeitig eine beginnende Bewegung festgestellt wird.

Da das EMG-Signal in der Mitte der Bewegung hohe, jedoch schwankende Werte aufweist, widersprechen sich die Zielsetzungen. Eine beispielhafte Betrachtung des Merkmals RMS in Abbildung 2.12 zeigt das an ein Rechteck angenäherte RMS-Signal. Für die Anfangserkennung kann somit der Anfangsschwellwert so hoch gesetzt werden, dass der Beginn der Bewegung sicher erkannt wird und Schwankungen im Terrassenbereich nicht fälschlicherweise als Bewegungsende gedeutet werden. Der Schwellwert muss außerdem so niedrig gelegt werden, dass das Ende der Bewegung sicher erkannt wird, aber nicht vorzeitig eine beginnende Bewegung festgestellt wird. Da das EMG-Signal in der Mitte der Bewegung hohe, jedoch schwankende Werte aufweist, widersprechen sich die Zielsetzungen.

Daher werden häufig unterschiedliche Schwellwerte zur Erkennung von Bewegungsanfang und Bewegungsende verwendet. Wurden zur Aufnahme zwei oder mehr Sensoren verwendet, so ist ein Primär-Sensor zu bestimmen. Dessen Sensorsignal gibt die Start- und Endzeitpunkte für das Schneiden vor. Der Primär-Sensor liegt über dem Muskel oder der Muskelgruppe, welche für die ausgeführte Bewegung hauptsächlich aktiviert werden und verfügt somit über die stärkste Aktivität. Messen zwei Sensoren eine ähnlich starke Aktivität, so ist nicht mehr eindeutig zu bestimmen, welcher Sensor der Primär-Sensor ist und auf welchem Sensor der Schwellwert anzulegen ist. Dieses Problem lässt sich durch die Addition von berechneten Merkmalswerten lösen. Auf dieses kumulierte Signal findet, wie beschrieben, der doppelte Schwellwert Anwendung. Dies wird in Abbildung 2.18(a) dargestellt, wo das RMS-Signal, berechnet auf zwei Sensoren, sowie das kumulierte Signal abgebildet sind.

Die Kumulation der Merkmale über alle Sensoren hat den Vorteil, dass unabhängig vom Einzelmuskel die Gesamtaktivität aufgezeichnet wird. Zudem kann diese Methode auch für mehr als zwei Sensoren Verwendung finden, wie es beispielsweise bei Gestenarmbändern der Fall ist (siehe Tabelle 2.2).

4.3 Normierung der Signale zur Merkmalsberechnung

Dieser Abschnitt beschreibt, mit welchen Parametern die Berechnung der normierten Signale aus den vorverarbeiteten EMG-Signalen erfolgen sollte, um möglichst gute Ergebnisse zu erzielen. Eine kleinere Normierungsgröße umfasst längere Segmente und mehr Messpunkte, was zu einer stärkeren Glättung des Signals führt. Allerdings führt dies auch zu einem höheren Informationsverlust, siehe Abschnitt 3.2. Die Wahl kürzerer Segmente bzw. die Erhöhung der Anzahl der Segmente liefert somit mehr Informationen, die für die Klassifikation nützlich sein können. Allerdings fallen in kürzeren Segmenten, die nur wenige Messpunkte umfassen, Ausreißer stärker ins Gewicht. Dies kann die Merkmalswerte des Segments verfälschen und sich somit nachteilig auf die Klassifikationsgüte auswirken. Daher beeinflusst die Normierungsgröße die resultierende Signalqualität des berechneten Merkmals und sollte sorgfältig ausgewählt werden.

In dieser Arbeit wurde $n = 13$ als Normierungsgröße gewählt, die sich als im Durchschnitt optimal für die Probanden erwiesen hat. Allerdings variiert die optimale Normierungsgröße je nach Proband und sollte daher für eine konkrete Prothesensteuerung individuell angepasst werden. Für die fortlaufende Zeitnormierung erfolgt die erste kontinuierliche Normierung 200 ms nach Beginn der Bewegung. Danach wird alle 100 ms eine weitere kontinuierliche Normierung durchgeführt, bis die Bewegung abgeschlossen ist. Auf diese Weise entstehen Datenpunkte, die mit verschiedenen Klassifikatoren einer bestimmten Bewegung zugeordnet werden können.

Nach der Bestimmung der Normierungsgröße und dem Unterteilen des EMG-Signale in Segmente sowie der kontinuierlichen Normierung sind die entsprechenden Merkmale zu berechnen. Diese wurden im Abschnitt 2.4.2 vorgestellt. Zur Feststellung der Intensität von ausgeführten Gesten dienen die Merkmale RMS sowie ZC. Dies sind zwei sehr häufig verwendete Merkmale. Zudem wird das Merkmal ApEn berechnet, um eine Aussage über die Regelmäßigkeit eines Segments zu erhalten. Zuletzt erfolgt die Berechnung der AR. Auch dieses Merkmal betrachtet eine Zeitreihe und versucht aufgrund der letzten Werte den kommenden vorauszusagen. Da die AR eine Aussage über den nächsten Wert trifft, sich der Körper jedoch im nächsten Intervall an sich verändert, erscheint es sinnvoll, die AR durch eine andere Metrik wie die Maximum Fractal Length (MFL) oder die Waveform Length (WL) für Verfahren mit Normierung, zu ersetzen, da davon auszugehen ist, dass hauptsächlich die Standardmethode von der AR profitiert. Insbesondere für die beiden Verfahren mit Normierung eröffnet dies neue Möglichkeiten. Durch die Verwendung von alternativen Metriken kann eine präzisere Analyse erfolgen, die den potenziellen Einfluss von Körperveränderungen in den nächsten Intervallen besser berücksichtigt. Das AR-Merkmal dient somit in dieser Arbeit dazu der Standardmethode eine Berücksichtigung des zeitlichen Verlaufes zu ermöglichen, während die Normierungen nicht weiter davon profitieren. Dennoch wird sich damit untersuchen lassen, ob die Normierung der Signale einen westlichen Vorteil gegenüber der lediglichen Verwendung eines Merkmals erreicht.

4.4 Verwendete Klassifikatoren

Zur Klassifikation der EMG-Signale stehen die in Abschnitt 2.5.6 vorgestellten Algorithmen für den Vergleich unterschiedlicher Klassifikationsverfahren hinsichtlich Ergebnisqualität und Performanz zur Verfügung. Hierzu werden einheitlich vorverarbeitete Signale in drei Testsets verwendet. Ein Set enthält nicht normierte, das zweite normierte und das dritte zeitnormierte Signale.

Durch Verwendung mehrerer Klassifikatoren wird vermieden, dass die untersuchten Methoden sich lediglich für einen speziellen Klassifikator eignen. Daher werden mehrere Instanzen von Klassifikationsalgorithmen verwendet.

Zu den typischen Algorithmen gehören LDA, SVMs, Entscheidungsbäume und Nächste-Nachbarn-Klassifikation (NNK), für die insgesamt 22 unterschiedliche Instanzen erzeugt werden. Zusätzlich kommen drei unterschiedliche neuronale Netze zum Einsatz. Hierzu gehört ein vorwärts gerichtetes neuronales Netz, ein rekursives sowie ein Faltungsnetz. Die Parameter für die jeweilige Instanz eines Klassifikators sind in Abschnitt 8.1 angegeben.

Im Folgenden werden die verwendeten Klassifikatoren beschrieben, wobei auch kurz auf die Besonderheiten der einzelnen Instanzen eingegangen wird.

Die LDA gilt verglichen mit SVMs und neuronalen Netzen als einfach [25]. Der Klassifikator maximiert die Varianz der Datenpunkte entlang einer oder mehrerer parametrierbarer Trennlinien.

Es kommen drei Instanzen der LDA zum Einsatz. Eine davon gehört dem Ensemble Learning Paradigma an, wobei viele kleine oder schwache Klassifikatoren erzeugt werden anstelle eines großen [18]. Die kleinen Klassifikatoren bilden ein Meta-Modell, welches über einen Mehrheitsentscheid die letztliche Zuordnung herbeiführt. Mögliche Beispiele für einen Mehrheitsentscheid sind das Votieren sowie das Bilden eines Durchschnitts über die Ergebnisse der einzelnen schwachen Klassifikatoren.

LinearDiscriminant: Die LDA nach Fisher [25] legt eine lineare Funktion zur Trennung zwischen die Klassen. Die Instanz dient hier vor allem dazu, Basiswerte zur vergleichenden Einschätzung zu ermitteln. Zudem kann mit Hilfe des relativ einfachen Verfahrens ein Rückschluss darauf gezogen werden, ob die beiden neuen Methoden zur Vorverarbeitung von EMG-Signalen eine höhere Klassifikationsgüte zulassen. Ist dies mit der LDA möglich, so ist anzunehmen, dass die Klassifikationsgüte mit Klassifikatoren, welche sich besser an die zu unterscheidenden Daten anpassen, noch weiter gesteigert werden kann.

QuadraticDiscriminant: Anstelle einer linearen Trennfunktion tritt eine quadratische. Die Funktion kann sich daher besser an die Struktur der Gesten-Cluster anpassen und diese somit genauer unterscheiden. Dabei ist zu erwarten, dass die Klassifikationsgüte gegenüber der LDA ansteigt. Es bleibt zu untersuchen, ob dies auch für die beiden neuen Normierungsmethoden gilt.

SubspaceDiscriminant: Diese Instanz erzeugt 30 zufällige Untermengen des übergebenen Datensets. Diese werden mit der LDA klassifiziert und anschließend wird ein Mehrheitsentscheid durchgeführt. Damit gehört diese Instanz zu den Ensemble-Klassifikatoren. Aufgrund der Dimensionalität der fortlaufend normierten Daten ist davon auszugehen, dass *SubspaceDiscriminant* eine bessere Klassifikationsgüte erzielt als *LinearDiscriminant*.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

Support Vector Machines werden häufig zur Unterscheidung von EMG-Signalen verwendet [1, 84, 111]. Der SVM-Algorithmus verwendet Unterstützungsvektoren, um den Abstand der Datenpunkte zur Trennfunktion zu maximieren. Die Trennfunktion wird mit Hilfe sogenannter Kernel berechnet. Oft ist es sinnvoll, die Daten in einem höherdimensionalen Raum zu transformieren und anstelle einer Geraden eine Ebene oder Hyperebene zu verwenden. Diese Klassifikatoren sind in Matlab[®] umgesetzt. Die gewählten Parameter der Funktion *templateSVM* [96], welche zur Erzeugung der SVMs verwendet werden, finden sich in Abschnitt 8.1.

In dieser Arbeit werden sechs unterschiedliche Instanzen von SVMs erzeugt.

SVMLinear: Zum Trennen der Cluster wird hier eine lineare Kernelfunktion verwendet. Diese Instanz bietet sich als Vergleichsklassifikator zur LDA sowie den folgenden Instanzen der SVM an.

SVMQuadratic: Diese SVM nutzt eine quadratische Kernelfunktion, wodurch sich die Klassifikation oft verbessern lässt.

SVMCubic: Diese SVM verwendet ein Polynom der Ordnung drei (kubische Kernelfunktion), welche bei Datenpunkten in mehrdimensionalen Räumen, wie sie durch die fortlaufende Normierung entstehen, tendenziell besser abschneidet. Dies kann insbesondere für die Klassifikation von fortlaufend normierten EMG-Signalen vorteilhaft sein.

SVMFineGaussian: Nutzt einen Kernel auf der Grundlage der Radial Basis Function (RBF). In Matlab[®] ist diese wie in Formel (4.1) definiert. Das Verwenden der RBF führt zu einer radialen Trennfunktion [95]. Dies ist vor allem dann hilfreich, wenn sich ein zu unterscheidender punktförmiger Cluster innerhalb eines weiteren Clusters befindet. Dies ist in Abbildung 4.4 [95] beispielhaft dargestellt.

$$G(x_1, x_2) = \exp(-\|x_1 - x_2\|^2). \quad (4.1)$$

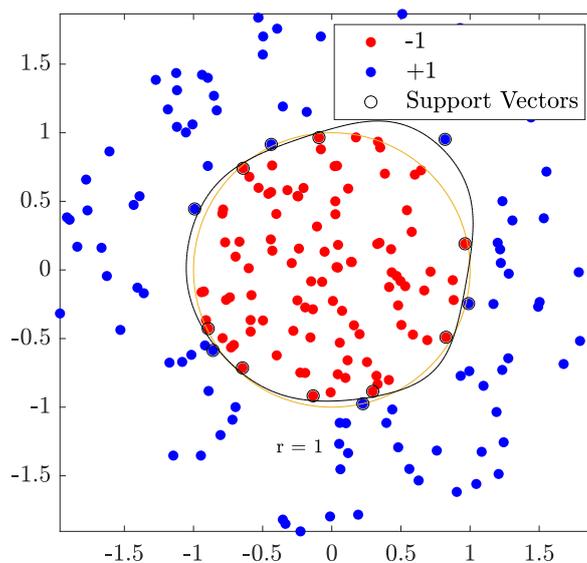


Abbildung 4.4: SVM mit einem RBF-Kernel

Der Klassifikator `SVMFineGaussian` verwendet in Matlab® den Parameter `KernelScale` (σ oder γ). Dieser bestimmt die Breite der Gauss-Glocke und gewichtet damit den Abstand der Datenpunkte zur Trennfunktion. Je höher die `KernelScale` gewählt wird, desto stärker wird die Trennfunktion um einzelne Punkte gebogen. Für den `SVMFineGaussian` in Abbildung 4.4 beträgt der Parameter `KernelScale` $\sigma = 0,5$.

SVMMediumGaussian: Dieser Klassifikator nutzt ebenfalls einen Kernel auf Grundlage der RBF. Die `KernelScale` ist dabei um den Faktor 4 höher als bei der `SVMFineGaussian`. Damit wird eine stärkere zylindrische Form der Klassifikation ermöglicht.

SVMCoarseGaus: Auch diese SVM nutzt eine RBF. Die Parameter werden ähnlich gewählt mit dem Unterschied, dass die `KernelScale` auf acht gesetzt und somit eine Trennfunktion gefunden wird, die stark um die einzelnen Gesten gebogen ist. Dabei besteht jedoch die Gefahr der Überanpassung.

Weitere fünf Klassifikationsinstanzen gehören den Entscheidungsbäumen an. Es gibt einfache Entscheidungsbaum-Klassifikatoren, bei denen jeweils ein Baum mit bestimmten Parametern erzeugt wird, sowie Ensemble-Klassifikatoren.

Nachfolgend sind die mit Matlab® und der Funktion `fitctree` [92] sowie der Funktion `fitensemb` [93] erzeugten Klassifikatoren beschrieben.

SimpleTree: Der `SimpleTree` ist ein einzelner Entscheidungsbaum mit geringer Komplexität, wie im Abschnitt 2.5.6 beschrieben. Er wird mit spezifischen Parametern erstellt, wobei die maximale Tiefe des Baums auf vier begrenzt ist, wie im Abschnitt 8.1 erläutert. Dadurch kann der Klassifikator von der Wurzel bis zu den Blattknoten maximal vier Entscheidungen treffen, bevor die Ausgabe für den Eingabedatensatz feststeht. Aufgrund der geringen Komplexität des `SimpleTree` wird erwartet, dass er ähnliche Ergebnisse wie die LDA erzielt. Daher kann er als Vergleich für einfache Klassifikationsverfahren und herkömmliche Entscheidungsbaum-Klassifikatoren dienen.

MediumTree: Der Klassifikator `MediumTree` ist ebenfalls ein einzelner Entscheidungsbaum, allerdings mit einer erhöhten Tiefe von 20. Durch die größere Tiefe verfügt der `MediumTree` über eine erhöhte Vielschichtigkeit, um komplexe Zusammenhänge im Eingabedatensatz zu erkennen. Mit der erhöhten Tiefe kann der Klassifikator detailliertere Muster und Merkmale in den Daten berücksichtigen, was zu einer potenziell höheren Vorhersagegenauigkeit führt, insbesondere, wenn die Daten eine hohe Komplexität aufweisen. Eine erhöhte Tiefe steigert aber auch die Gefahr der Überanpassung an die Trainingsdaten. Dies bedeutet, dass der Klassifikator möglicherweise spezifische Muster und Rauschen in den Trainingsdaten erlernt, die nicht auf neue, unbekannte Daten generalisierbar sind. Zudem kann ein tiefer Baum anfälliger für Ausreißer sein, da ein Ausreißer den Entscheidungsprozess beeinflussen und zu fehlerhaften Vorhersagen führen kann.

ComplexTree: Dieser Klassifikator erreicht die größte Komplexität mit einer Tiefe von 100. Es bleibt zu untersuchen, ob dies zu einer Überanpassung führt oder ob der Klassifikator aus dieser Tiefe einen Mehrwert generieren und die Klassifikationsgüte erhöhen kann. Es wird erwartet, dass der `ComplexTree` bei der fortlaufenden Normierung bessere Ergebnisse erzielt als die beiden zuvor vorgestellten Baumklassifikatoren. Die Daten der fortlaufenden Normierung weisen eine hohe Komplexität auf und es kann vorteilhaft sein, einen tieferen Entscheidungsbaum zu haben, um diese Komplexität besser abzubilden.

BaggedTree: Der BaggedTree gehört zum Lernparadigma des Ensemble Learnings. Dabei werden insgesamt 30 schwache Lerner in Form von Entscheidungsbäumen erzeugt. Jeder Baum wird auf der Grundlage einer Untermenge des Trainingsdatensatzes erstellt. Dies erfolgt durch Anwendung des Prinzips des Zurücklegens, auch bekannt als Bootstrap-Verfahren. Für jeden Entscheidungsbaum wird eine zufällige Stichprobe aus dem Trainingsdatensatz gezogen. Da die Stichprobe mit Zurücklegen erfolgt, kann derselbe Datenpunkt mehrmals in einem Baum enthalten sein, während andere Datenpunkte möglicherweise nicht ausgewählt werden. Dies ermöglicht die Erzeugung vieler verschiedener Entscheidungsbäume, die jeweils auf einer unterschiedlichen Datenmenge basieren.

BoostedTree: Der Klassifikator BoostedTree ist ebenfalls Teil des Ensemble Learnings. Als schwache Lerner werden Entscheidungsbäume verwendet, die jedoch den AdaBoost-Algorithmus als Lernmethode in der Matlab[®]-Implementierung nutzen. Der AdaBoost-Algorithmus zielt darauf ab, die schwachen Lerner zu verbessern, indem er einige wenige Lerner identifiziert, die die leicht zu unterscheidenden Klassen trennen können. Anschließend werden weitere Lerner eingesetzt, um die schwerer zu unterscheidenden Klassen zu behandeln. Dadurch stehen mehr Lerner für die schwerer zu trennenden Klassen zur Verfügung, was wiederum die Klassifikationsgüte erhöht [29].

In Matlab[®] ist der AdaBoost-Algorithmus nach der Formel (4.2)

$$\varepsilon_t = \frac{1}{2} \sum_{n=1}^N \sum_{k \neq y_n} d(t)_{n,k} (1 - h_t(x_n, y_n) + h_t(x_n, k)) \quad (4.2)$$

implementiert, mit $h_t(x_n, k)$ die Konfidenz des schwachen Lerners zum Zeitpunkt t für die Klasse k [93]. Der Wert kann zwischen 0 (keine Konfidenz) und 1 (starke Konfidenz) liegen. Die beobachteten Gewichte für die Klasse k zur Zeit t sind als $d(t)_{n,k}$ definiert. Das Label der wahren Klasse y_n wird aus K ausgewählt, wobei die zweite Summe über alle Klassen außer der wahren Klasse y_n läuft.

Der AdaBoost-Algorithmus ermöglicht es, die Stärken der einzelnen schwachen Lerner zu kombinieren und dadurch eine leistungsstarke Klassifikation zu erreichen. Durch das Gewichten der Lernerergebnisse und die iterative Anpassung der Gewichte werden schwerer zu trennende Klassen verstärkt berücksichtigt, was die Klassifikationsgenauigkeit erhöht. Die gewählten Parameter finden sich im Anhang in Abschnitt 8.1.

RUSBoostedTrees: Der Klassifikator RUSBoostedTrees ist ein weiteres Beispiel für das Ensemble Learning Paradigma mit Entscheidungsbäumen als schwache Lerner. Dabei wird das Random Undersampling Boosting (RUS-Boosting)-Verfahren als Lernmethode verwendet [93]. Der Algorithmus ähnelt dem AdaBoost-Algorithmus, konzentriert sich jedoch auf unterrepräsentierte Klassen.

Beim RUS-Boosting werden aus allen K Klassen nur jeweils so viele Beobachtungen gezogen, wie in der kleinsten Klasse k vorhanden sind. Dadurch wird der Fokus auf die unterrepräsentierte Klasse gelegt und ein Ausgleich zwischen den Klassen hergestellt. Dies ist besonders hilfreich, wenn es im Datensatz eine ungleiche Verteilung der Klassen gibt und einige Klassen deutlich weniger Beobachtungen aufweisen als andere. Da alle Gesten gleich durchgeführt wurden, kommt dies zwar nicht mit der normierten Methode vor, jedoch durchaus für die Standard- und für die fortlaufend normierte Methode.

Der k -Nächste Nachbarn (k-NN) Algorithmus ist ein weit verbreiteter Klassifikator, der in Abschnitt 2.5.6 vorgestellt wurde [25]. Er bestimmt die Zugehörigkeit eines Datenpunkts zu einer Klasse, indem er die Abstände zu den nächsten k Nachbarn in einem Trainingsdatensatz misst. Dafür können verschiedene Abstandsfunktionen wie die euklidische Distanz oder die Kosinusfunktion verwendet werden.

Es besteht die Möglichkeit, die Anzahl der zu berücksichtigenden Punkte, sowie das verwendete Distanzmaß anzupassen.

Die folgenden sieben Klassifikatoren wurden in Matlab[®] mithilfe der Funktion `fitcknn` erzeugt [93].

KNNFine: Der KNNFine-Klassifikator ist eine spezifische Instanz des k-NN-Algorithmus, bei dem zur Klassifikation eines neuen Datenpunktes nur der nächstgelegene Nachbar berücksichtigt wird. Hierbei wird die euklidische Distanz als Distanzmaß verwendet. Durch die Berücksichtigung nur eines einzigen Nachbarn reagiert der Klassifikator besonders empfindlich auf einzelne nahegelegene Datenpunkte. Dies kann bei der Zuordnung von Signalpfaden ein Vorteil sein. In solchen Szenarien ermöglicht der KNNFine-Klassifikator eine präzise und sensitive Klassifikation, indem er stark auf die unmittelbare Nachbarschaft des zu klassifizierenden Punktes reagiert.

KNNMedium: Dieser Klassifikator dient als Vergleich zu dem KNNFine-Klassifikator. Anstelle eines benachbarten Datenpunktes werden hier 10 berücksichtigt. Es ist zu erwarten, dass dies mit steigender Anzahl zu unterscheidender Gesten einen Vorteil gegenüber dem KNNFine bewirkt. Insbesondere für die Klassifikation von normierten EMG-Signalen lässt dies eine Verbesserung vermuten.

KNNCoarse: Wie mit dem KNNMedium-Klassifikator wird auch hier die Anzahl an zu berücksichtigenden Datenpunkten erhöht. Der KNNCoarse-Klassifikator betrachtet 100 Nachbarn. Es bleibt zu untersuchen, ob dies zu einer Überanpassung bei der Standardmethode sowie der Normierung führt.

Im Gegensatz zum KNNFine-Klassifikator, der nur den nächsten Nachbarn zur Klassifikation berücksichtigt, werden hier 100 benachbarte Datenpunkte einbezogen. Durch die erneute Erweiterung der Nachbarschaftsgröße wird erwartet, dass der KNNCoarse-Klassifikator bei einer größeren Anzahl zu unterscheidender Gesten einen Vorteil bietet. Insbesondere für die Klassifikation von normierten EMG-Signalen lässt dies eine Verbesserung der Klassifikationsgenauigkeit vermuten, da durch die Berücksichtigung einer größeren Anzahl von Nachbarn mehr Informationen aus den umgebenden Signalpfaden des zu klassifizierenden Punktes einfließen können, was zu einer genaueren und robusten Klassifikation führen kann.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

KNNCubic: Der KNNCubic-Klassifikator ist eine weitere Instanz des k-NN-Algorithmus, bei der anstelle der euklidischen Distanz die Minkowski-Distanz mit $p = 3$ verwendet wird, wie in Abschnitt 2.4.5 und 8.1 beschrieben. Durch die Verwendung der Minkowski-Distanz mit $p = 3$ ermöglicht diese Instanz feinere Abstufungen zwischen den zu unterscheidenden Clustern. Dies kann dazu beitragen, dass die Klassifikation genauer und differenzierter erfolgt.

KNNCosine: Der KNNCosine-Klassifikator ist ebenfalls eine Instanz des k-NN-Algorithmus, bei der als Distanz eine Kosinusfunktion verwendet wird [93, 94]. Diese basiert auf dem Kosinus des Winkels zwischen den Vektoren x und y , definiert als $D_{x,y} = 1 - \cos(\varphi_{x,y})$. Dabei wird der Winkel zu k -Nachbarn bestimmt und der Datenpunkt derjenigen Klasse zugeordnet, bei dem der Winkel minimal ist.

Die Verwendung der Kosinusfunktion ermöglicht eine Berücksichtigung der Richtungsinformationen in den Daten, was für die Klassifikation von Signalpfaden vorteilhaft sein kann. Daher erscheint der KNNCosine-Klassifikator besonders für die Klassifikation von normierten Daten vielversprechend zu sein. Bei der fortlaufenden Normierung, bei der sich die Signalpfade selbst verändern und in der Position verschoben sein können, ist jedoch anzunehmen, dass dieser Algorithmus nicht optimal abschneidet.

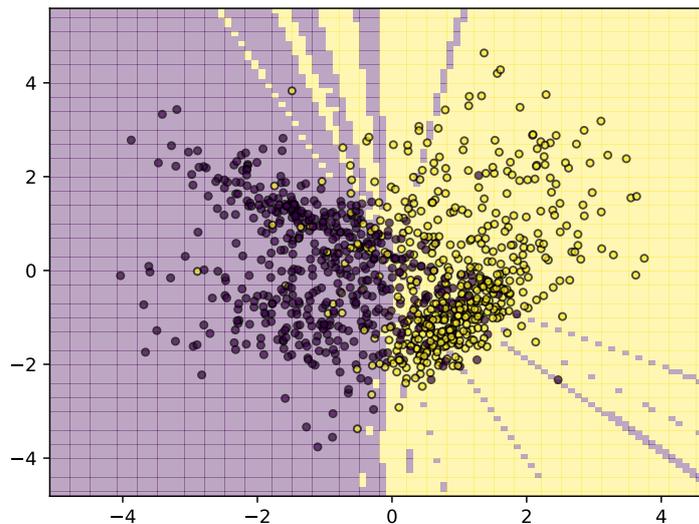


Abbildung 4.5: KNNCosine-Klassifikator, welcher als Distanz eine Kosinus-Funktion nutzt

KNNWeighted: Der KNNWeighted-Klassifikator ist eine spezielle Instanz des k-NN-Algorithmus, bei der die Zuordnung eines Datenpunktes zu einer Klasse basierend auf einer gewichteten Distanz erfolgt [93]. Das Gewicht für die Zuordnung wird gemäß der Formel

$$\text{Gewicht} = \frac{1}{\text{euklidische Distanz}^2}. \quad (4.3)$$

festgelegt.

Bei der Klassifikation werden die 10 nächsten gewichteten Nachbarn betrachtet. Der beobachtete Punkt wird derjenigen Klasse zugeordnet, welche das größte summierte Gewicht erreicht. Datenpunkte die dem beobachteten Punkt nahe sind, haben einen stärkeren Einfluss auf die Klassifikation, als es allein ihre berechnete Distanz vermuten lassen würde. Dieser Ansatz kann insbesondere bei der fortlaufenden Normierung vorteilhaft sein.

SubSpaceKNN: Der SubSpaceKNN-Klassifikator gehört zum *Ensemble Learning Paradigma* und verwendet als schwache Lerner Klassifikatoren des NNK-Algorithmus [93]. Dies ermöglicht es, dass einzelne schwache Lerner sich an Teilmengen anpassen können, um die Zuordnung durch einen Mehrheitsentscheid zu treffen, ähnlich wie bei Entscheidungsbaum, die dem *Ensemble Learning Paradigma* angehören. Durch die Kombination mehrerer schwacher Lerner kann die Klassifikationsgenauigkeit verbessert werden.

Künstliche-Neuronale-Netze sind eine weit verbreitete Methode zur Klassifikation von EMG-Daten [7, 20, 32, 109]. In Abschnitt 2.5.6 wurden verschiedene Typen von neuronalen Netzen vorgestellt. Es werden jeweils eine Instanz eines einfachen, tiefen, vorwärts gerichteten Netzes, eines rekursiven (LSTMs) und eines Faltungsnetzes (CNN) erstellt. Die Implementierung erfolgte in Python Version 3.6.8 unter Verwendung des Frameworks TensorFlow [55] Version 1.13.1 und Keras [19, 90] Version 2.2.4.

NN: Das NN ist eine Instanz eines einfachen vorwärts gerichteten neuronalen Netzes. Es besteht aus zwei versteckten Schichten mit jeweils 100 Neuronen sowie einer Input- und Output-Schicht. Die Konfiguration des Netzes ist im Abschnitt 8.1 dargestellt. Dieses sehr einfache neuronale Netz dient dazu, einen weiteren Vergleichswert der Klassifikationsgüte zu erhalten, an dem sich komplexere Klassifikatoren wie der SVMCubic oder auch einige KNNs als auch weniger komplexe Klassifikatoren messen lassen.

recur6: EMG-Signale weisen eine zeitliche Abhängigkeit auf, daher ist anzunehmen, dass rekurrente Netze besser als vorwärts gerichtete Netze geeignet sind, die Bewegungsarten zu klassifizieren, da sie die Datenpunkte der Vergangenheit mitberücksichtigen können. Diese Datenpunkte müssen jedoch dem Algorithmus bereitgestellt werden. Daher ist es nicht möglich, Daten der Standardmethode mit diesem Algorithmus zu klassifizieren.

Die Instanz des LSTM-Netzes ist nach dem Trichter-Prinzip aufgebaut: Nach der Input-Schicht folgt eine bidirektionale LSTM-Schicht mit 50 Neuronen. Darauf folgen drei versteckte Schichten mit 50, 100 und 150 Neuronen. Den Abschluss bildet eine LSTM-Schicht mit so vielen Neuronen, wie es zu unterscheidende Gesten gibt, sowie der darauf folgenden Aktivierungsschicht mit gleicher Anzahl an Neuronen. Der Aufbau ist in Abbildung 4.6 dargestellt.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

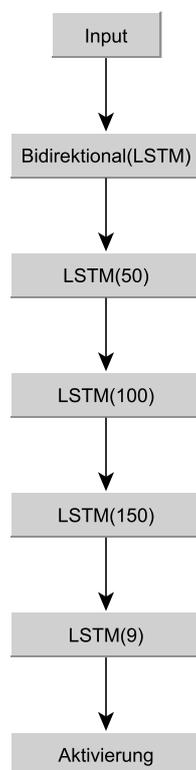


Abbildung 4.6: Schichten-Modell des recur6-Klassifikators

CNN: Diese kommen unter anderem bei der Objektklassifikation in Bildern zum Einsatz. Dort können CNNs Muster erkennen und klassifizieren. Die normalisierten Daten mit den berechneten Merkmalen stellen, genau wie Bilder, eine Matrix dar, welche wiederum in einem mehrdimensionalen Raum Muster darstellen (siehe Abschnitt 3.2.2). Daher eignen sich CNNs, um diese zu erkennen und zu klassifizieren. Der Klassifikator kann jedoch nicht genutzt werden, um Daten der Standardmethode zu unterscheiden, da diese als Skalar und nicht als Matrix vorliegen.

Der CNN-Klassifikator besteht aus zwei CNN-Schichten mit unterschiedlichen Kernelgrößen. Die erste Schicht verwendet einen Kernel der Größe fünf, während die zweite Schicht einen Kernel der Größe drei verwendet. Diese Kernelgrößen bestimmen das Erfassungsfeld des CNN und beeinflussen, welche Muster erkannt werden können (siehe Abschnitt 2.5.6). Nach den CNN-Schichten folgt jeweils eine MaxPooling-Schicht, die dazu dient, die räumliche Dimension der Merkmalsarten zu reduzieren. Dies hilft dabei, Merkmale für große Bereiche zu erfassen und gleichzeitig die Anzahl der Parameter im Modell zu reduzieren. Anschließend folgt eine vorwärts gerichtete dichte Schicht mit 100 Neuronen, bevor das Netzwerk auf die Ausgangsgröße entsprechend der Anzahl an zu unterscheidenden Gesten reduziert wird. Die letzte Schicht bildet eine Aktivierungsschicht. Das Schichten-Modell des CNN-Klassifikators ist in Abbildung 4.7 dargestellt.

4 Experimentelle Klassifikation zeitnormierter elektromyographischer Signale

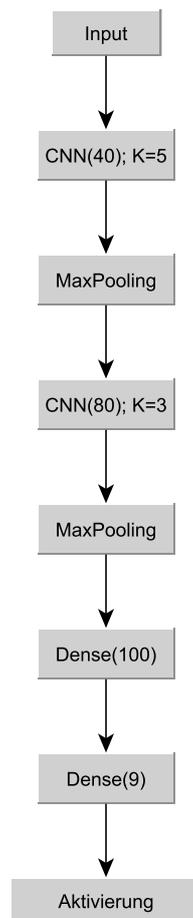


Abbildung 4.7: Schichten-Modell des CNN-Klassifikators

5 Verifikation und Validierung

In den vorangegangenen Kapiteln sind die drei Vorverarbeitungsmethoden, die Standard-, die Zeitnormierung (normierte) und die fortlaufend normierte Methode zur Klassifikation von EMG-Signalen vorgestellt worden. Wie in Abschnitt 3.2.2 gezeigt, lassen sich durch die beiden Normierungen im mehrdimensionalen Merkmalsraum charakteristische Körper der jeweiligen Gesten erstellen. Die Form und Verteilung der Körper im Raum legen den Schluss nahe, dass sich diese gut voneinander trennen lassen und somit erwartet werden kann, dass sich die Klassifikation von Gesten dadurch deutlich verbessern lässt.

In diesem Kapitel folgt die Evaluierung, ob die beiden Methoden der Zeitnormierung und der fortlaufenden Normierung zu einer Verbesserung der Klassifikationsergebnisse gegenüber der bisherigen Standardmethode führen.

Durch das Gegenüberstellen der Klassifikationsgüten der beiden neuen Verfahren gegenüber der Standardmethode wird untersucht, ob sich die Anzahl der zu unterscheidenden Bewegungsklassen ohne Berücksichtigung der Ruhelage erhöhen lässt.

Es folgt eine Analyse der Robustheit der beiden normierten Methoden über einen Zeitraum von sechs Aufnahmetagen gegenüber den Ergebnissen eines einzelnen Aufnahmetages.

Abschließend ist der Vergleich der erreichten Klassifikationsgüte für neun unterschiedlichen Gesten dargestellt.

5.1 Vorgehensweise und Versuchsaufbau

Für die Datenerhebung führten fünf Probanden die in Abschnitt 4.1 beschriebenen Aktivierungsmuster durch. Diese wurden als EMG-Signale mit dem in Abschnitt 4.2 vorgestellten System und den dazugehörigen Einstellungen aufgenommen. Da die Klassifikationsgüte über mehr als einen Tag zu betrachten ist, fand die Datenaufnahme über einen Zeitraum von ein bis zwei Monaten an sechs Aufnahmetagen statt. Aufgrund der Durchführung von neun verschiedenen Griffmustern musste die Anzahl an Wiederholungen der einzelnen Griffmuster reduziert werden, da es sonst aufgrund der Muskelermüdung zu vermehrten fehlerhaften Signalen gekommen wäre. Jedes Aktivierungsmuster wurde daher an einem Aufnahmetag nur 15 mal wiederholt. Dies führte zu einer durchschnittlichen Sitzungslänge von etwa 1,5 h pro Aufnahmetag. Für jeden Probanden entstanden somit 810 Aufnahmen daher stehen 4050 Aktivierungsmuster für die Auswertung zur Verfügung.

Tabelle 5.1 zeigt Geschlecht, BMI und das Alter zum Aufnahmezeitpunkt der fünf Probanden. Alle Probanden sind gesund und es bestehen keine Amputationen oder Einschränkungen der Muskulatur. Diese Auswahl wurde getroffen, um die Vergleichbarkeit mit anderen Publikationen zu gewährleisten.

Geschlecht	BMI	Alter
weiblich	21,2	32 Jahre
männlich	19,4	33 Jahre
männlich	24,2	35 Jahre
männlich	25,5	30 Jahre
männlich	23,1	31 Jahre

Tabelle 5.1: Grunddaten der fünf Probanden

Die Signale wurden mit zwei differentiellen EMG-Sensoren und Standardfiltern aufgenommen (siehe Abschnitt 4.2). Sensor 1 wurde hierzu auf der Unterseite des Unterarms über dem Muskel flexor carpi radialis aufgelegt, Sensor 2 auf der Oberseite des Unterarms über dem Muskel extensor digitorum.

Vor der Aufnahme der Signale erfolgte eine Vorbesprechung mit den Probanden sowie eine Erklärung des prinzipiellen Versuchsaufbaus und der durchzuführenden Bewegungen. Die Positionierung der Sensoren wurde so gewählt, dass möglichst rauschfreie Signale aufgenommen wurden. Zudem wurde den Probanden mitgeteilt, dass die Ausführung der Bewegung zur Aufnahme so stattfinden muss, dass die Lage und die Orientierung des Armes während der Messung unverändert bleibt. Jede Bewegung war dabei mit maximaler Muskelkraft auszuführen.

Während der Durchführung der Messung wurden die Probanden mit einem in Matlab[®] geschriebenen Script visuell angeleitet. Nachdem eine auszuführende Bewegung gezeigt wurde, bestätigte der Proband diese mit einem Tastenanschlag oder durch Drücken einer Maustaste. Dies initiierte die Aufnahme von sechs Sekunden mit einer Abtastrate von 2048 Datenpunkten pro Sekunde. Ein sich ständig aktualisierendes Fenster zeigte dem Probanden während der Aufnahme die bisherigen Amplituden der beiden Sensoren an. Dieses Feedback erleichterte es, den Arm zwei Sekunden in der Ruhelage zu belassen, anschließend die Bewegung auszuführen und die entsprechende Geste mit voller Muskelanspannung für etwa zwei Sekunden zu halten. Darauf folgten zwei weitere Sekunden Ruhelage. Die Aufnahmen wurden alle begleitet, um sicherzustellen, dass die Rahmenbedingungen bei allen Aufnahmen gleich waren und um möglicherweise falsch durchgeführte Bewegungen korrekt zu wiederholen.

Ein Hochpassfilter von 20 Hz und ein Tiefpassfilter von 450 Hz unterdrückten unerwünschte Frequenzen nach der erfolgreichen Aufnahme der Signale. Zur Isolierung des Bewegungssignals aus der sechs Sekunden langen Aufnahme wurden die Signale wie im Abschnitt 4.2.2 beschrieben, geschnitten und gefiltert. Nach diesem Teil der Vorverarbeitung der Daten resultierten gefilterte und geschnittene Rohsignale, die mit den drei Methoden Standard, Normiert und fortlaufend Normiert, weiter verarbeitet und anschließend klassifiziert wurden.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

In diesem Abschnitt werden die Ergebnisse der Klassifikationen von EMG-Signalen der Aktivierungsmuster analysiert, die mit der Standardmethode, der normierten Methode und der fortlaufend normierten Methode vorverarbeitet sind. Dabei werden 25 unterschiedliche Klassifikatoren verwendet.

Beim Vergleich der Klassifikationsergebnisse der drei Methoden werden zwei Faktoren berücksichtigt: Die Anzahl der Merkmale (zwei oder vier) und die Anzahl der Gesten (drei oder neun). Die Standardmethode dient als Referenzwert für den Vergleich mit den beiden normierten Methoden. Es wird untersucht, wie diese im Vergleich zur Standardmethode und zueinander abschneiden sowie ob die erwartete Verbesserung der Klassifikation eintritt. Die anschließende Untersuchung der Ergebnisse der einzelnen Probanden zeigt, ob durch die Normierung alle Probanden profitieren oder ob bestimmte Klassifikatoren für einzelne Probanden besser geeignet sind. Die Auswirkung der Hinzunahme von Aufnahme tagen auf den Klassifikationsfehler ist ein weiterer Bestandteil der Analyse der Klassifikationsergebnisse für alle drei Methoden. Die Betrachtung etwaiger Klassifikationsunterschiede einzelner Gesten, je nach verwendeter Methode, stellt den Abschluss der Untersuchungen dar. Der Schlussteil des Abschnitts umfasst eine Abgrenzung zum Zeitstempelmerkmal und die Diskussion der Ergebnisse.

5.2.1 Klassifikationsgüte der Standardmethode

Nach der Beschreibung der verwendeten Klassifikatoren und deren Einstellungen in Abschnitt 4.4 folgt die Untersuchung der Klassifikation von Zeitnormierten Signalen und nicht Zeitnormierten Signalen, also solchen, wie sie dem derzeitigen Stand der Vorverarbeitung und Klassifikation kommerzieller Prothesen entsprechen. Um zu zeigen, dass sich die auf eine gemeinsame Länge normierten Signale deutlicher voneinander abgrenzen und sich damit auch besser klassifizieren lassen, wurden in Abschnitt 3.2.2 dreidimensionale Körper aus den einzelnen normierten Signalpfaden gebildet. Wie bereits gezeigt, lassen sich die resultierenden Körper qualitativ besser voneinander trennen als die zuvor bestehenden Punktwolken. Dieser Beobachtung schließt sich hier eine quantitative Untersuchung an.

Eine Aussage über die Güte ermöglichen die Metriken aus Abschnitt 2.5.5. Da ein breites Spektrum an unterschiedlichen Klassifikatoren gewählt wurde, kann so eine allgemeine Aussage zu der Klassifikationsgüte für die jeweilige Methode abgeleitet werden. Insgesamt werden 4050 Aktivierungsmuster durch die vorgestellten Klassifikatoren, zu denen drei künstliche neuronale Netze sowie weitere 22 Klassifikatoren gehören, unterschieden.

Die Untersuchung der Standardmethode liefert einen Grundwert, an dem sich die verschiedenen Verfahren messen und vergleichen lassen. Des Weiteren können damit auch die unterschiedlichen Testsets und die erzielten Klassifikationsergebnisse auf Plausibilität überprüft werden. Dabei ist zu erwarten, dass sich mit steigender Anzahl an unterschiedlichen Gesten und Tagen die Ergebnisse verschlechtern, während eine Erhöhung der berechneten Merkmale eine Verbesserung der Klassifikationsergebnisse zur Folge hat.

Abbildung 5.1 zeigt den F_1 -Boxplot für die Gesten Faust, Flexion und Extension über alle Tagessets für alle Probanden. Die Grafik beruht auf zwei Merkmalen, was dem derzeitigen Stand der Technik entspricht. Bei der Betrachtung des F_1 -Scores ist festzustellen, dass dieser im Median 80 % erreicht. Dies stellt den im Folgenden verwendeten Vergleichsmaßstab dar.

5 Verifikation und Validierung

Das Minimum des F_1 -Scores findet sich bei 19 % und das Maximum erreicht 95 %. Dies deutet auf eine hohe Streuung der verschiedenen Ergebnisse hin. Da jedoch die Standardabweichung bei lediglich 8,7 % liegt und hierbei die Ergebnisse für alle Probanden, Tagessets und Gesten berücksichtigt sind, erscheint die Klassifikation robust. Dies bestätigt sich in späteren Untersuchungen, wie in Tabelle 8.1 dargestellt.

Die Sensitivität weist im Median einen Wert von 79 % auf. Das zeigt, dass die drei Gesten häufig richtig positiv klassifiziert wurden. Dieser Wert ist insbesondere für den Vergleich mit den normierten Methoden bei einer gleichen Anzahl an Merkmalen und Gesten relevant. Mit einer steigenden Anzahl an Gesten ist davon auszugehen, dass die Sensitivität deutlich sinkt, im Gegensatz zur Spezifität, bei der mit einem Anstieg zu rechnen ist. Eine Zusammenfassung der Werte findet sich in Tabelle 5.3.

Die Darstellung der unterschiedlichen Klassifikatoren in Abbildung 5.1 zeigt, dass diese ähnlich gute Ergebnisse im Bereich von 75 % bis 85 % liefern. Lediglich das Resultat des SVMCubic streut deutlich stärker. Ersichtlich ist dies durch das 25. Perzentil mit lediglich 61 %, welches gleichzeitig den geringsten erreichten Wert aller 25 %-Quantile darstellt sowie dem 75. Perzentil mit 84 %. Die Streuung der Klassifikationswerte zeigt sich auch in der Standardabweichung, welche 18,7 % beträgt. Damit liegt diese deutlich über dem Durchschnitt von 8,8 %. So streut der SVM-Cubic im Durchschnitt fast 10 Prozent Punkte (%P) stärker als die restlichen Klassifikatoren. Wird diese Instanz des SVM-Algorithmus mit dem sehr ähnlichen SVMQuadratic-Klassifikator verglichen, so zeigt sich, dass dieser einen höheren Median (ca. 82 %) erreicht, während die Standardabweichung mit 7,4 % deutlich geringer ausfällt als die des SVMCubic. Da der SVM-Quadratic eine Trennfunktion niedrigerer Ordnung verwendet, kann davon ausgegangen werden, dass die Trennfunktion des SVMCubic für diese Methode mit zwei Merkmalen ungeeignet ist.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

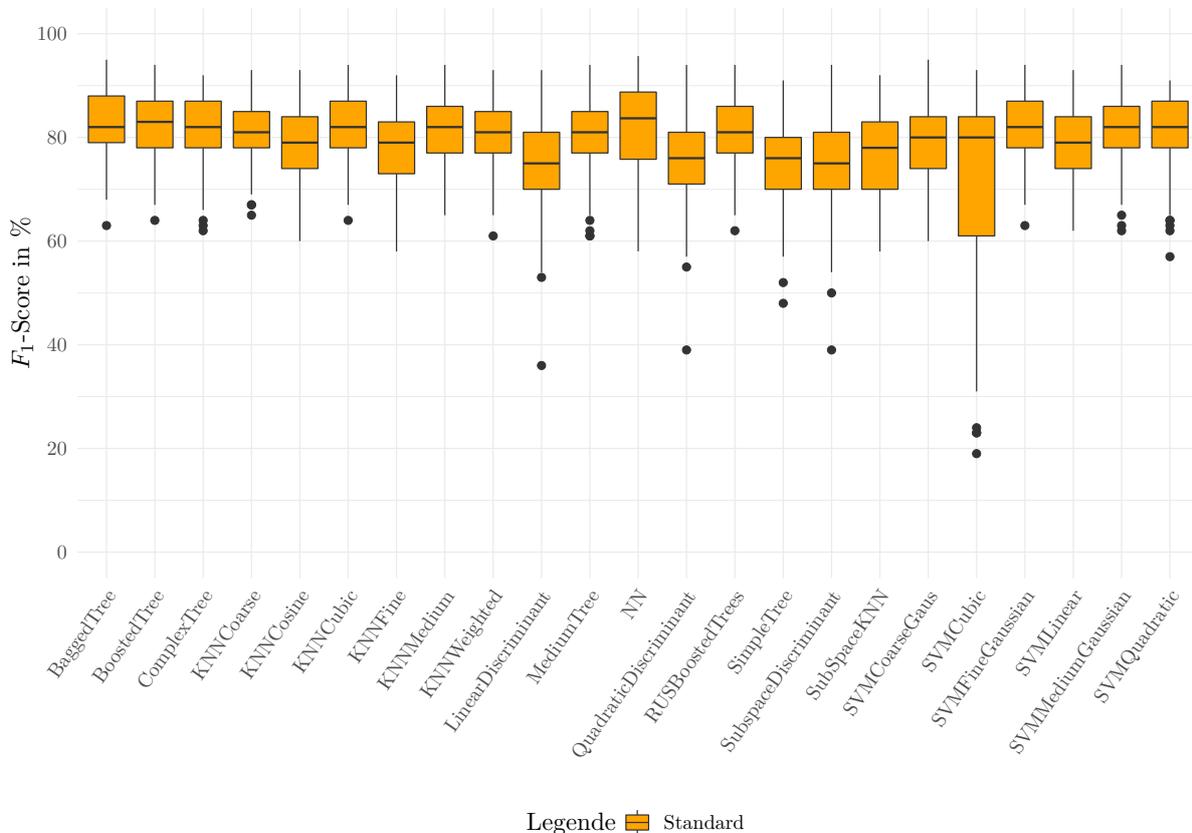


Abbildung 5.1: Boxplot des erreichten F_1 -Scores der Klassifikationsergebnisse mit drei Bewegungsklassen und zwei Merkmalen für die Gesten Flexion, Faust und Extension

Den Vergleich der F_1 -Scores mit zwei bzw. vier Merkmalen zeigt Abbildung 5.2 für die Standardmethode und die Gesten Flexion, Faust und Extension. Die Graphik spiegelt die aktuellen Anstrengungen in der Forschung wider, die Auflösung der Daten und die damit verbundene Verbesserung der Klassifikationsgüte durch die Hinzunahme von Merkmalen zu erhöhen. Wie zu erwarten, nimmt der durchschnittliche F_1 -Score über nahezu alle Klassifikatoren zu. Der Median mit vier Merkmalen ist mit 84% leicht höher als der für zwei Merkmale mit 80%. Auch eine Verbesserung für das 25. und das 75. Perzentil ist festzustellen. So steigen diese zwischen drei und sechs %P an. Dies bestätigt die Annahmen einer Verbesserung der Klassifikationsergebnisse durch die Hinzunahme weiterer Merkmale.

Es ist jedoch auch ein Anstieg der Standardabweichung von 8,8% auf 11% zu beobachten (siehe Tabelle 5.3), was maßgeblich durch den Klassifikator SVMFineGaussian beeinflusst ist. Dieser fällt in der Klassifikationsgüte durch Verwendung von vier Merkmalen deutlich von 82% auf 68%. Die Standardabweichung steigt für diesen Klassifikator von 6,7% auf 16,9%. Das erreichte Minimum liegt bei lediglich 10%. Dem Klassifikator gelingt es somit mit der RBF nicht, Gesten-Cluster deutlich voneinander zu trennen.

5 Verifikation und Validierung

Der F_1 -Score für den KNNCosine, welcher ebenfalls eine radiale Trennfunktion nutzt, steigt dagegen um 5 %P auf 84 %.

Die besten Ergebnisse erreicht der Klassifikator NN (ein einfaches neuronales Netz) bei welchem der Median von 84 % auf 94 % ansteigt. Das 25. Perzentil liegt mit 88,1 % etwa 11 %P über dem Median aller Klassifikatoren. Die Standardabweichung fällt mit vier Merkmalen leicht von 8,7 auf 8,1 %. Dies zeigt eine deutliche Verbesserung der Ergebnisse und macht ihn zum besten Klassifikator.

Ebenfalls deutlich steigern konnten sich die Ergebnisse des Klassifikators SVMCubic, welcher zuvor durch einen niedrigen F_1 -Score bei hoher Standardabweichung aufgefallen war. Durch die Hinzunahme weiterer Merkmale gelingt es besser, die höhere Ordnung der Trennfunktion zu nutzen.

Im Schnitt gilt über alle Klassifikatoren hinweg, dass sich die Sensitivität um 3 %P verbessert, mit einer gleichzeitigen leichten Erhöhung der Standardabweichung von 8,7 auf 10,9 %. Die Spezifität und die KKR steigen ebenfalls leicht um 3 %P an (siehe Tabelle 5.3).

Es zeigt sich, dass eine Verbesserung der Klassifikationsergebnisse durch die Erhöhung der Anzahl an Merkmalen zu erreichen ist und sich die Klassifikationsergebnisse für 19 der 23 Klassifikatoren verbessern.

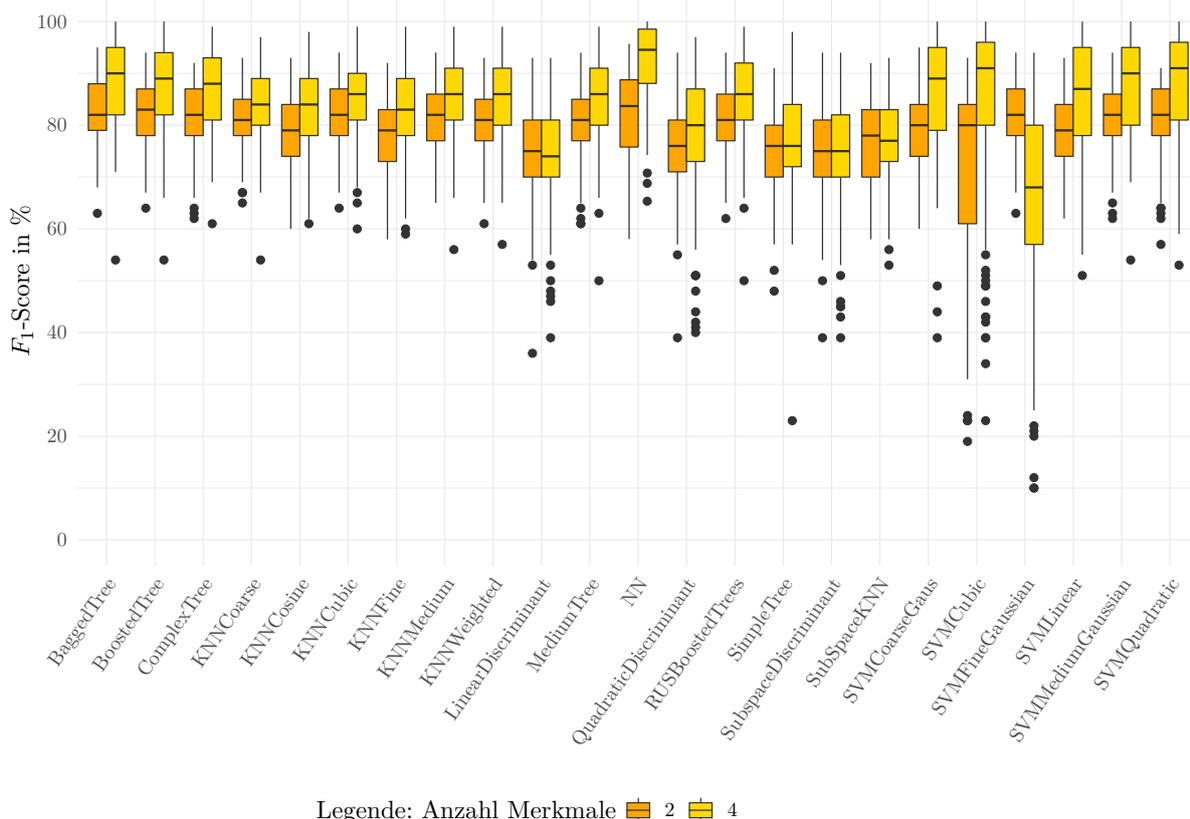


Abbildung 5.2: F_1 -Score mit drei Bewegungsklassen und zwei bzw. vier Merkmalen

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

Drei Gesten lassen sich bereits mit zwei Merkmalen, wie in Abbildung 5.1 gezeigt, gut trennen. Es ist jedoch erkennbar, dass bei einer tatsächlichen Anwendung auf einer Prothese mit falschen Klassifikationen der Gesten zu rechnen ist. Dies lässt sich durch die Hinzunahme weiterer Merkmale reduzieren, was in dieser Arbeit exemplarisch durch die Erhöhung auf vier Merkmale ersichtlich wurde. Abbildung 5.2 verdeutlicht dies, indem zu erkennen ist, dass sich ein Großteil der Klassifikatoren dadurch verbessert. Besonders deutlich fällt dies bei den Klassifikatoren BaggedTree, NN, SVMCubic, SVMMediumGaussian und SVMQuadratic auf, welche alle über 90 % erreichen.

Im Folgenden wird untersucht, wie sich die Klassifikationsergebnisse verändern, wenn die Anzahl der zu unterscheidenden Gesten erhöht wird. Dies ist von Bedeutung, um einen Referenzwert zu erhalten, anhand dessen die Leistungsfähigkeit der normierten Methoden bewertet werden kann. Zudem ermöglicht es eine Aussage darüber, ob die Anzahl der unterscheidbaren Gesten erhöht werden kann.

Abbildung 5.3 stellt den erreichten F_1 -Score für drei bzw. neun Gesten bei Nutzung von zwei Merkmalen dar. Durch die zusätzlichen Gesten sinkt der F_1 -Score im Median über alle Klassifikatoren um 28 %P. Das arithmetische Mittel verschlechtert sich um 27 %P auf 52 %, wobei das Minimum um 19 %P auf 0 % sinkt, siehe Tabelle 5.2. Zudem steigt die Standardabweichung des F_1 -Scores auf 20,2 %, was auf die zu erwartende, stärkere Streuung der Klassifikationsergebnisse hinweist.

Insgesamt erzielen sechs Klassifikatoren einen F_1 -Score unterhalb der Marke von 50 %. Diese Klassifikatoren zeigen die schlechtesten Ergebnisse und sind daher weniger geeignet. Zu diesen gehören MediumTree, LinearDiscriminant, SubspaceDiscriminant, SubSpaceKNN und SimpleTree, die im Median lediglich einen F_1 -Score von 38 % aufweisen.

Die fünf Klassifikatoren, welche den höchsten F_1 -Score mit neun unterschiedlichen Gesten erzielen, sind in aufsteigender Reihenfolge SVMMediumGaussian, SVMQuadratic, BaggedTree, KNNCoarse und SVMFineGaussian. Der Median des F_1 -Scores liegt bei 57 %.

Die KKR erhöht sich um 4 %P von 86 % auf 90 %, obwohl die Anzahl der zu unterscheidenden Gesten von drei auf neun gestiegen ist. Dies hängt vor allem mit dem Problem der zunehmenden RNs und der Definition der KKR-Berechnung zusammen, wie in Abschnitt 2.5.5 beschrieben und in Tabelle 5.3 dargestellt. Aus diesem Grund wird die KKR für spätere Vergleiche nicht mehr berücksichtigt.

Der Klassifikator SimpleTree weist die schlechteste Performance auf. Hier liegen die Quantilgrenzen des F_1 -Scores bei 0,12 % und 53 %. Im Vergleich mit der Klassifikation von drei Gesten reduziert sich das 50. Perzentil um 64 %P.

Dieser starke Abfall aller Klassifikatoren zeigt deutlich, dass eine zuverlässige Klassifikation und die damit verbundene Ansteuerung einer Prothese für neun unterschiedlichen Gesten mit der derzeitig verwendeten Methode sowie dem Einsatz von nur zwei Sensoren und der Berechnung von zwei Merkmalen aufgrund der niedrigen Klassifikationsgüte nicht praktikabel ist.

Eine erste Möglichkeit, die Klassifikationsgüte zu steigern, besteht darin, die Anzahl an Merkmalen zu erhöhen. Wie bereits dargelegt, geht damit eine Verbesserung der Klassifikationsgüte einher, siehe auch Tabelle 5.2.

Um ein ähnliches Akzeptanzniveau zu erreichen, müssten neun Gesten mit vier Merkmalen etwa so gut zu klassifizieren sein, wie derzeit drei Gesten mit zwei Merkmalen. Abbildung 5.4 vergleicht den erreichten F_1 -Score der beiden Kombinationen aus Gesten und Merkmalen. Es ist deutlich zu erkennen, dass die Klassifikatoren mit vier Merkmalen und neun Gesten nicht

5 Verifikation und Validierung

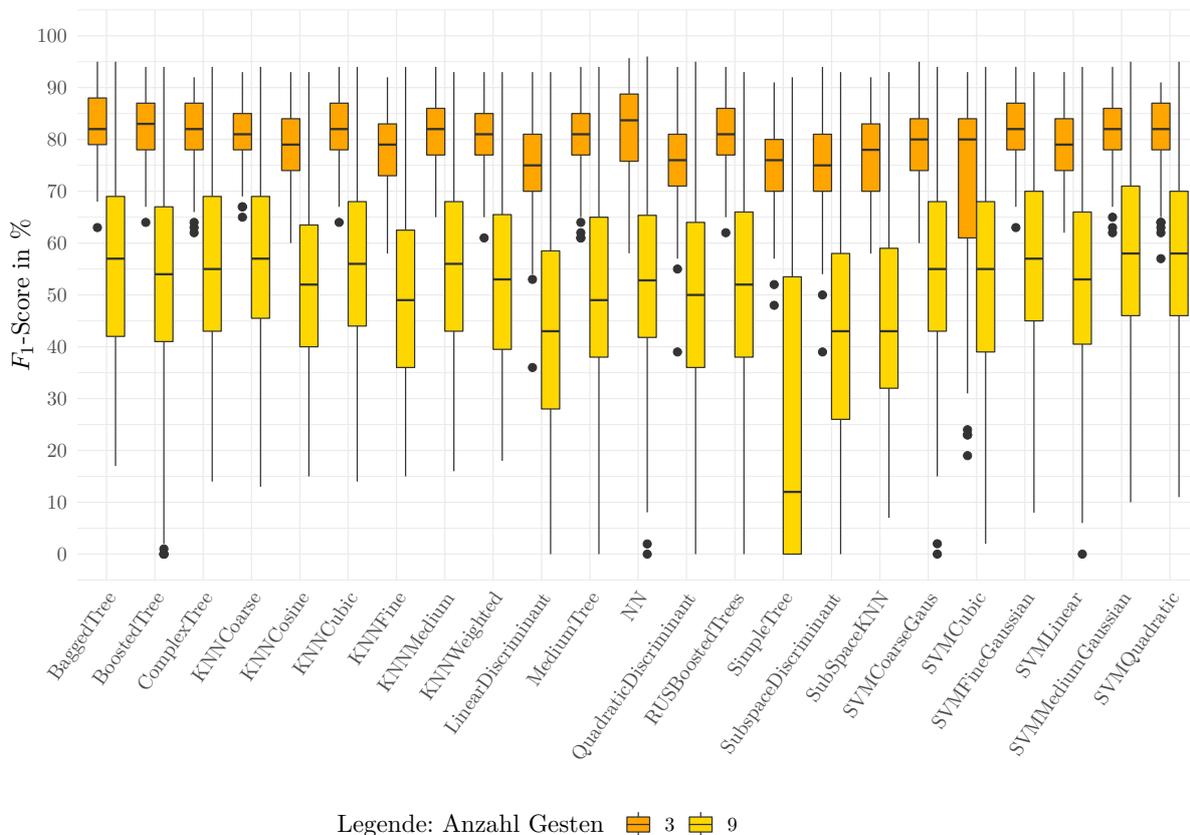


Abbildung 5.3: Der Boxplot vergleicht die erreichten F_1 -Scores der Klassifikatoren für zwei Merkmale sowie drei und neun Gesten.

auf das Niveau von drei Gesten mit zwei Merkmalen kommen. Der Median des F_1 -Scores über alle Klassifikatoren liegt für drei Gesten mit zwei Merkmalen bei 80 %, der für neun Gesten mit vier Merkmalen bei 58 %. Besonders auffällig ist dies für die Klassifikatoren LinearDiscriminant und SimpleTree. Ersterer fällt von 75 % auf 43 % und zweiterer von 76 % auf 12 %. Für den Entscheidungsbaum reicht offensichtlich die Tiefe von vier nicht aus, um mit den zur Verfügung stehenden vier Merkmalen auf zwei Sensoren neun unterschiedliche Gesten voneinander zu trennen. Der LinearDiscriminant, welcher eine lineare Trennfunktion nutzt, ist ebenfalls für diese Kombination ungeeignet.

Am SVMFineGaussian ist zu sehen, wie stark der Rückgang der Klassifikationsgüte ist, welche von 82 % auf 11 % fällt, während die Standardabweichung von 7 % auf 15 % ansteigt. Daher ist die gekrümmte Trennfunktion des Klassifikators für die Kombination aus neun Gesten mit zwei Merkmalen nicht geeignet.

In Abbildung 5.4 ist gut zu erkennen, wie die Standardabweichung für fast alle Klassifikatoren deutlich zunimmt. Das ist an den langen Boxplots und dem großen Abstand zwischen dem 25. und 75. Perzentil zu erkennen. Dies verdeutlicht ebenfalls die zunehmende Schwierigkeit der Klassifikation von neun Gesten gegenüber von drei.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

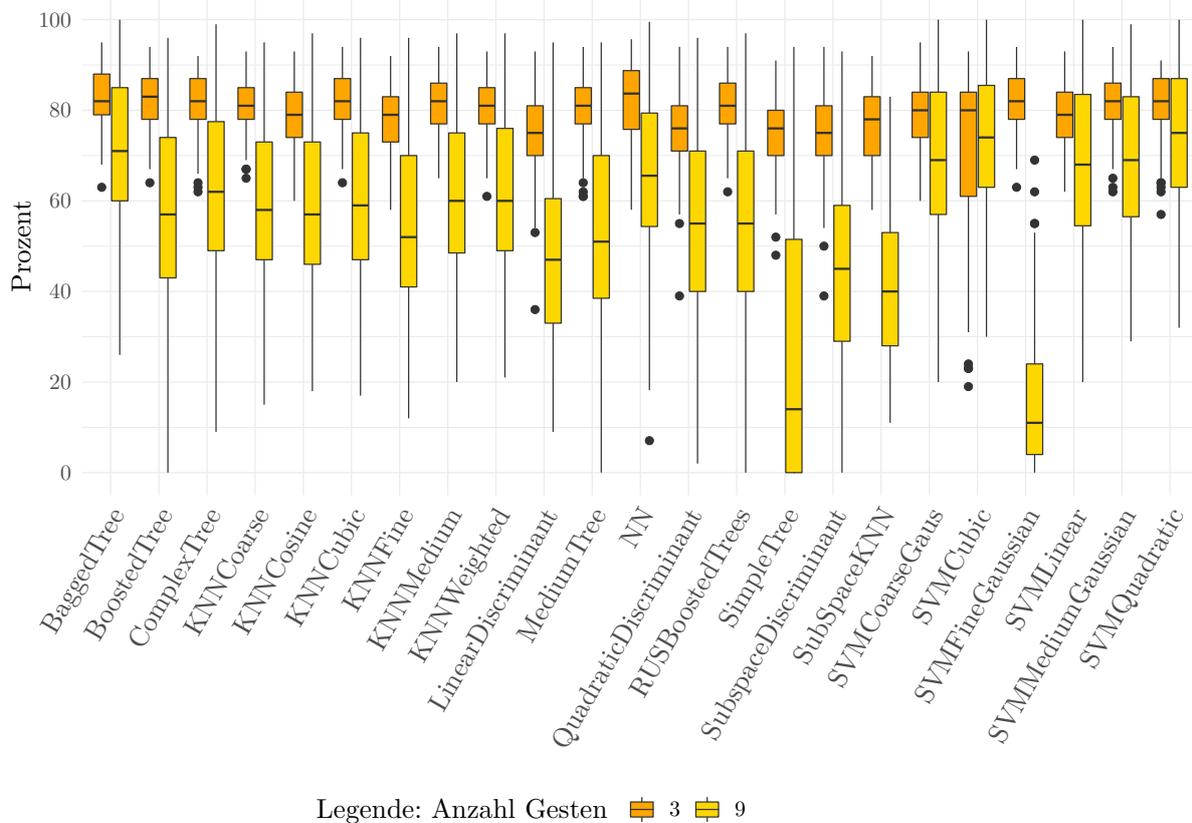


Abbildung 5.4: F_1 -Scores der Klassifikatoren von drei Gesten mit zwei Merkmalen und neun Gesten mit vier Merkmalen.

Die vorgestellten Ergebnisse zeigen, dass drei Gesten mit einem F_1 -Score von 80 % erfolgreich zu klassifizieren sind. Dabei ist die Wahl des Klassifikators für die Standardmethode zur Vorverarbeitung nicht entscheidend und hat nur einen geringen Einfluss auf die Klassifikationsgüte. Für neun Gesten ist diese Art der Vorverarbeitung jedoch nicht ausreichend, da die Falschklassifikation stark zunimmt, was zu einer Akzeptanzminderung der Prothese führt. Der nächste Abschnitt befasst sich daher mit den Klassifikationsergebnissen der verbesserten Vorverarbeitungsmethode durch Normierung.

5.2.2 Klassifikationsgüte der normierten Methoden

In diesem Abschnitt wird untersucht, ob Gesten durch Normierung der EMG-Signale besser trennbar sind. Die Normierung ist eine Methode zur Vorverarbeitung, bei der die EMG-Signale auf eine gleiche Anzahl an Zeitzeilen normiert werden (siehe Abschnitt 3.2). Dies ermöglicht es, den zeitlichen Verlauf der Signale für die Klassifikation von Gesten zu nutzen. Die folgenden Abschnitte vergleichen hierfür die Klassifikationsergebnisse der Standardmethode mit denen der normierten Methode. Unterschieden wird dabei jeweils die Anzahl an zu trennenden Gesten und die Anzahl an berechneten Merkmalen.

Abbildung 5.5 stellt den erreichten F_1 -Score der 25 Klassifikatoren über alle Probanden, alle Tagessets und die Gesten Flexion, Faust und Extension dar. In dieser Auswertung werden neben den 23 Klassifikatoren aus dem vorherigen Kapitel auch die Klassifikatoren CNN und Recur6 berücksichtigt. Diese beiden Klassifikatoren sind neuronale Netze, die eine Matrix von Merkmalen als Eingabe erwarten. Diese Matrix enthält Informationen über die zeitliche Abfolge des EMG-Signals sowie dessen Merkmale und deren Beziehung zueinander. Die einzelnen Datenpunkte können daher nicht für die Standardmethode genutzt werden, da diese die Punkte jeweils unabhängig voneinander betrachtet. Die beiden neuronalen Netze sind jedoch in der Lage, durch die beiden Normierungsmethoden vorverarbeitete EMG-Signale auszuwerten.

5.2.2.1 Normierungsergebnisse für drei Gesten mit zwei Merkmalen

Beim Vergleich der beiden Methoden in Abbildung 5.5 fällt auf, dass die normierte Methode bei allen Klassifikatoren zu höheren F_1 -Scores führt. So liegt der Median für die Normierung über alle Klassifikatoren bei 84 %. Die Standardmethode erreicht 80 % wie in Tabelle 5.2 dargestellt. Zudem verbessern sich die KKR, die Sensitivität und die Spezifität.

Allerdings erzielt der Klassifikator Recur6 mit 35 % den niedrigsten F_1 -Score aller getesteten Modelle. Dies ist unerwartet, da LSTM-Netze eine spezielle Form von rekurrenten neuronalen Netzen sind, die für die Analyse von sequentiellen Daten besonders geeignet sind [57]. LSTM-Netze verfügen über ein internes Gedächtnis, das es ihnen ermöglicht, langfristige Abhängigkeiten zu erfassen und das Problem des verschwindenden oder explodierenden Gradienten zu vermeiden [43]. Dennoch gelingt es dem Netz nicht, eine verallgemeinerte Trennfunktion zu erlernen und die KKR erreicht lediglich den Erwartungswert von 33 %. Unter Berücksichtigung der gleichverteilten Eintrittswahrscheinlichkeiten der einzelnen Ergebnisse trifft der Klassifikator somit ähnlich gute Entscheidungen wie zufälliges Raten ohne Domänenwissen, was letztendlich dem unqualifizierten Raten entspricht. Ein möglicher Grund hierfür könnte eine Überanpassung an die drei Gesten sein, da dieses Phänomen bei Untersuchungen mit neun Gesten nicht mehr beobachtet werden konnte.

Im Gegensatz dazu erreicht das CNN einen sehr guten F_1 -Score mit einem Median von 100 %. Auch das 25 %-Quantil (Q_{25}) sowie das 75 %-Quantil (Q_{75}) erreichen 100 %. Somit ist das CNN der am besten abschneidende Klassifikator unter den besten fünf Klassifikatoren (CNN, NN, BaggedTree, SVMFineGaussian und BoostedTree), die durch die Normierung im 50 %-Quantil (Q_{50}) einen F_1 -Score von 91 % erreichen. Im Vergleich dazu erreicht die Standardmethode einen Median von 83 %.

Für die normierte Methode mit nur zwei Merkmalen lässt sich feststellen, dass sich eine Steigerung des F_1 -Scores sowohl für den Median, das arithmetische Mittel als auch bezüglich des Minimums und Maximums ergibt. Auch die Metriken der KKR sowie die Sensitivität und die Spezifität wurden durch die Normierung verbessert und die Standardabweichung sinkt von 8,7 % auf 7,9 %. Diese Verbesserungen sind besonders beachtenswert, da sie nicht durch eine der bisher diskutierten Methoden, wie die Erhöhung der Auflösung der EMG-Daten durch eine höhere Abtastrate, mehr Sensoren oder die Verwendung von mehr Merkmalen zustande kommen.

Im nächsten Abschnitt wird untersucht, ob durch das Erhöhen auf vier Merkmale die Klassifikationsgüte der Normierung verbessert und sich die Methode damit analog zur Standardmethode verhält.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

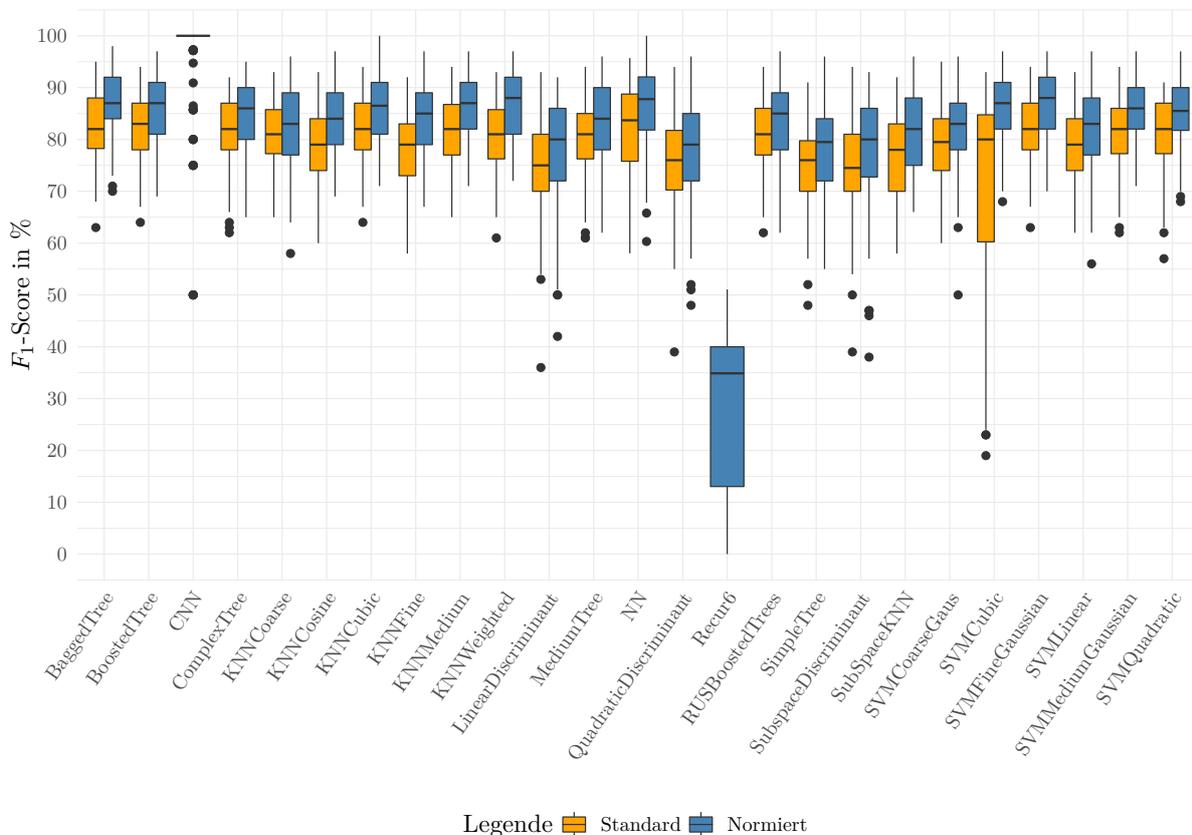


Abbildung 5.5: F_1 -Score der Standard- und der normierten Methode für zwei Merkmale über alle Probanden und Testsets der drei Gesten Faust, Flexion und Extension

5.2.2.2 Normierungsergebnisse für drei Gesten mit vier Merkmalen

Durch die Verwendung von vier Merkmalen verbessert sich der F_1 -Score sowohl bei der Standardmethode als auch bei der normierten Methode, wie aus Tabelle 5.2 hervorgeht. Dies gilt auch für die Metriken KKR, Sensitivität und Spezifität, wie in Tabelle 5.3 dargestellt. Im Vergleich zur Standardmethode zeigt sich, dass die Klassifikation durch die Normierung noch weiter verbessert werden kann. Der Median des F_1 -Scores steigt von 84 % auf 88 %. Auch die anderen drei Metriken zeigen eine Verbesserung der Klassifikationsgüte durch die neue Methode.

Wie in Abbildung 5.6 dargestellt, lassen sich durch die Normierung die Gesten mit allen Klassifikatoren besser trennen. Im Vergleich zwischen zwei und vier Merkmalen bleibt jedoch der Klassifikator Recur6 auf einem unerwartet niedrigen Niveau (Median 35 %) und das CNN erreicht weiterhin 100 % für alle drei Quantile.

Die besten fünf Klassifikatoren sind absteigend geordnet: CNN, NN, BaggedTree, SVMCubic und SVMQuadratic. Es zeigt sich, dass mit steigender Anzahl an Merkmalen die Ergebnisse sowohl bei der Standardmethode als auch bei der Normierungsmethode besser werden. Zudem nehmen F_1 -Score, KKR, Sensitivität und Spezifität zu, sodass sich die Klassifikationsgüte durch die Normierung der EMG-Signale deutlich verbessert.

5 Verifikation und Validierung

Besonders bemerkenswert ist beim Vergleich des erreichten F_1 -Scores der Standardmethode mit vier Merkmalen (84%), dass dieser mit der Normierung bereits für nur zwei Merkmale erreicht wird. Dies deutet darauf hin, dass die normierte Darstellung einen signifikanten Einfluss auf die Klassifikationsleistung hat. Es zeigt sich, dass eine Reduktion der Merkmalsdimension möglich ist, ohne die Klassifikationsgüte wesentlich zu beeinträchtigen.

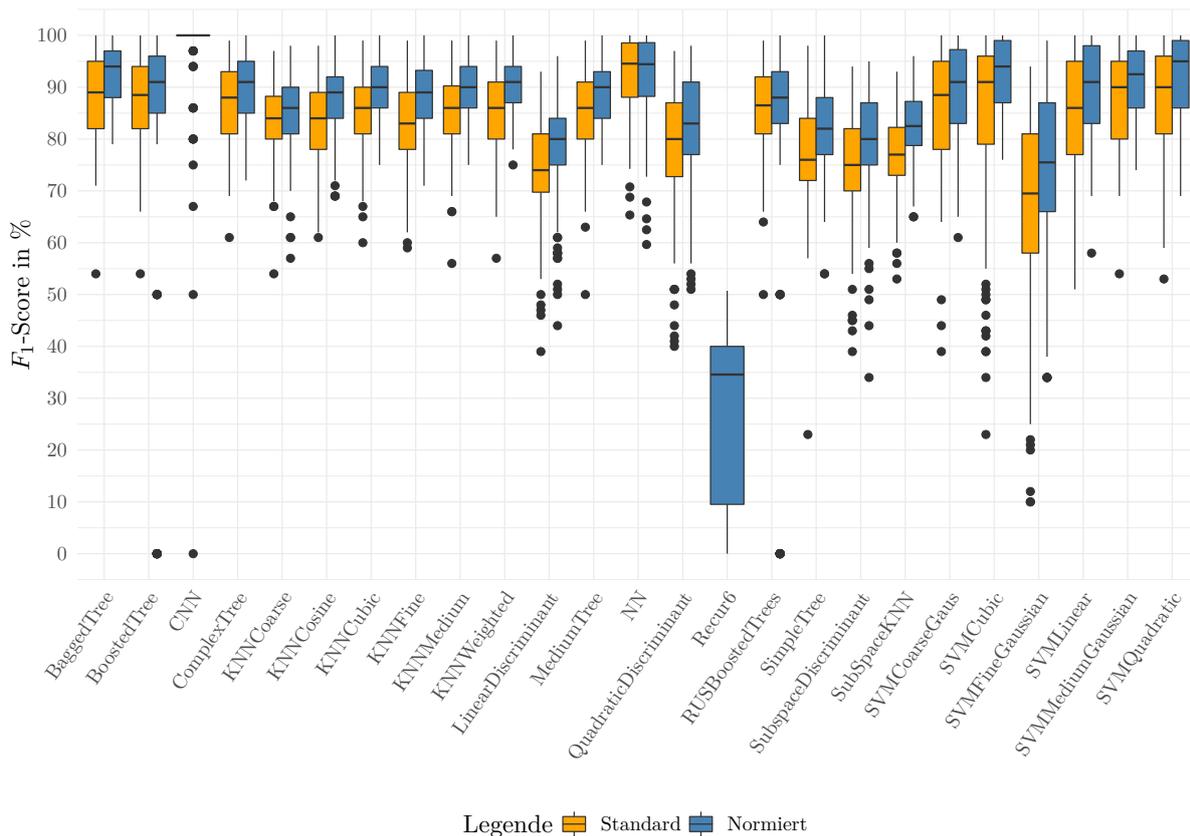


Abbildung 5.6: F_1 -Score der Standard- und der normierten Methode. Klassifiziert wurden drei Gesten mit Hilfe von vier Merkmalen und daraus der Boxplot über alle Probanden, alle Testsets und die drei Gesten Faust, Flexion und Extension erstellt.

5.2.2.3 Normierungsergebnisse für neun Gesten und zwei Merkmale

In diesem Abschnitt wird die Klassifikationsgüte unter Verwendung von nur zwei Merkmalen zur Trennung von neun Gesten untersucht.

Die Ergebnisse zeigen, dass die Klassifikationsgüte für beide Methoden bei neun im Vergleich zu drei Gesten sinkt (siehe Tabelle 5.2). Die Standardmethode verliert 28 %P und die Normierungsmethode 20 %P. Gleichzeitig nimmt die Standardabweichung um etwa 12 %P zu, was bedeutet, dass die Ergebnisse insgesamt stärker streuen. Die KKR stellt eine Ausnahme dar. Sie verbessert sich generell mit der Hinzunahme weiterer Gesten (siehe Abschnitt 2.5.5).

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

Im direkten Vergleich der beiden Methoden mit jeweils neun Gesten ist in Abbildung 5.7 deutlich zu erkennen, dass die Normierungsmethode merklich bessere Ergebnisse liefert als die Standardmethode. Der Median aller Klassifikatoren liegt bei 65 % mit der Normierungsmethode und bei 52 % mit der Standardmethode. Der Klassifikator SimpleTree schneidet am schlechtesten ab, während sich der F_1 -Score für den LinearDiscriminant durch die Normierung dennoch verbessert. Es ist somit möglich, auch mit einfachen Klassifikatoren die Unterscheidungsgenauigkeit für neun Gesten deutlich zu verbessern.

Der bisher am schlechtesten abschneidende Klassifikator Recur6 wird mit der Normierung zum zweitbesten Klassifikator und erreicht 74 %. Mit einem F_1 -Score von 86 % ist CNN der beste Klassifikator. Er übertrifft somit auch den Median der F_1 -Scores der Standardmethode mit drei Gesten und zwei Merkmalen. Die fünf besten Klassifikatoren in dieser Permutation sind CNN, Recur6, SVMMediumGaussian, SVMQuadratic und BaggedTree.

Für die Normierung mit neun Gesten und zwei Merkmalen ist somit festzustellen, dass sich die Klassifikationsgüte gegenüber der Standardmethode nachgewiesen durch F_1 -Score, KKR, Sensitivität sowie Spezifität, verbessert.

Dennoch erreicht nur das CNN ein F_1 -Score von 86 % und ist damit voraussichtlich für eine Prothesensteuerung verwendbar.

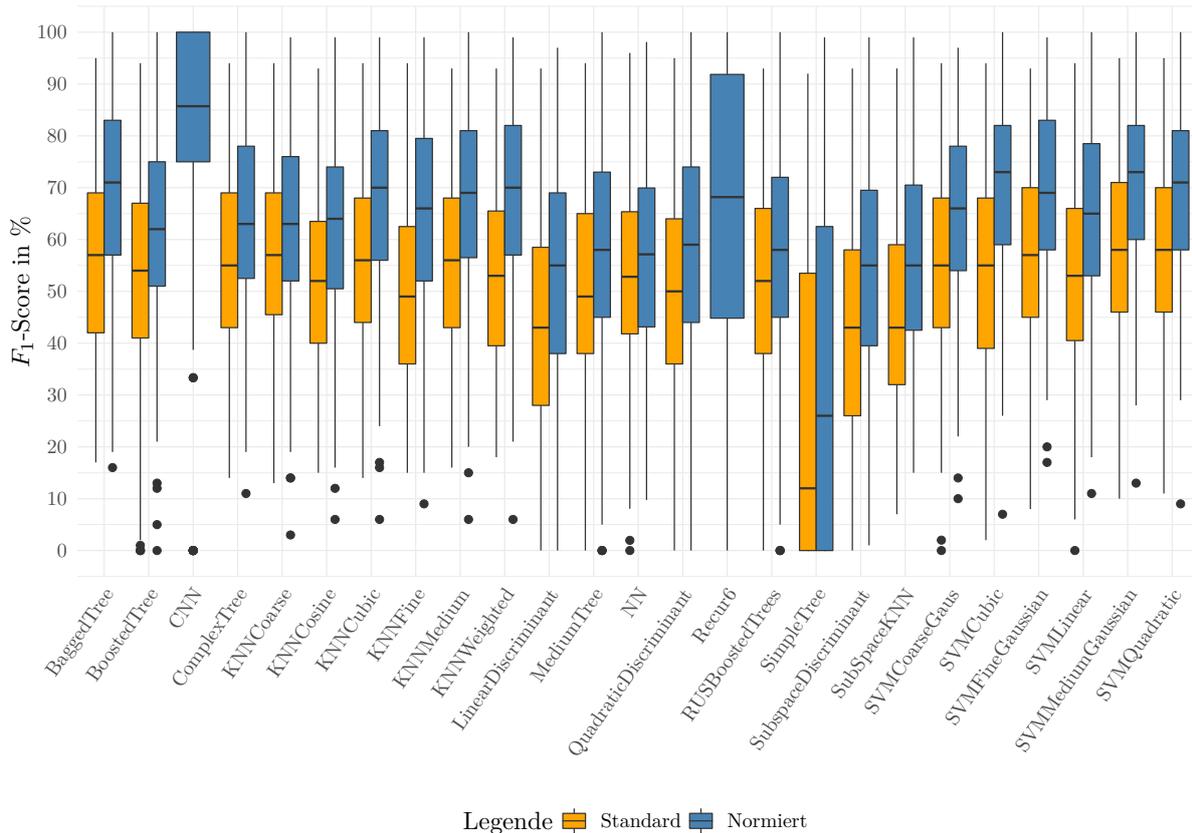


Abbildung 5.7: F_1 -Scores der Standard- und der normierten Methode für neun Gesten mit zwei Merkmalen für fünf Probanden und alle Testsets

5.2.2.4 Normierungsergebnisse für neun Gesten und vier Merkmale

Die nächste Untersuchung berücksichtigt vier Merkmale. Im Ergebnis steigt der Median bei beiden Methoden um 6 %P und die Normierung resultiert in einem Median von 70 % (siehe Tabelle 5.2 und Abbildung 5.8). Es zeigt sich, dass alle Klassifikatoren von der Normierung profitieren. Im Vergleich zu den Ergebnissen mit zwei Merkmalen fällt jedoch auf, dass SVMFineGaussian neun Gesten mit vier Merkmalen erheblich schlechter unterscheiden kann. Mit vier Merkmalen erreicht der Klassifikator einen F_1 -Score von 34 %, während er mit zwei Merkmalen einen F_1 -Score von 69 % erzielt. Obwohl sowohl SVMFineGaussian als auch SVMMediumGaussian und SVMCoarseGaussian eine RBF als Trennfunktion nutzen, erreichen nur die letzten beiden eine hohe Klassifikationsgüte. Dies lässt darauf schließen, dass der gewählte Parameter für die RBF des SVMFineGaussian für diese spezifische Kombination aus Gesten und Merkmalen ungünstig ist. Weitere Details zu den Parametern sind in Abschnitt 2.5.6 und im Anhang Abschnitt 8.1 erläutert. Dies zeigt die Bedeutung der Parameterabstimmung für die Leistung von Klassifikatoren und verdeutlicht, dass nicht alle Parameterkombinationen gleich gut funktionieren. Der Recur6-Klassifikator schafft es mit 76 % unter die besten zehn Klassifikatoren. Er schneidet jeweils für neun Gesten deutlich besser ab als für drei.

Die fünf besten Klassifikatoren für neun Gesten mit vier Merkmalen sind CNN, SVMQuadratic, Recur6, SVMCubic und BaggedTree. Bei der Betrachtung der Normierung ergibt sich eine leicht andere Reihenfolge. Das beste Ergebnis erreicht das CNN mit 97 % gefolgt von BaggedTree und SVMLinear mit 82 %. Damit liegen diese auf dem Niveau der Klassifikatoren für die Standardmethode mit zwei Merkmalen bei drei unterschiedlichen Gesten.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

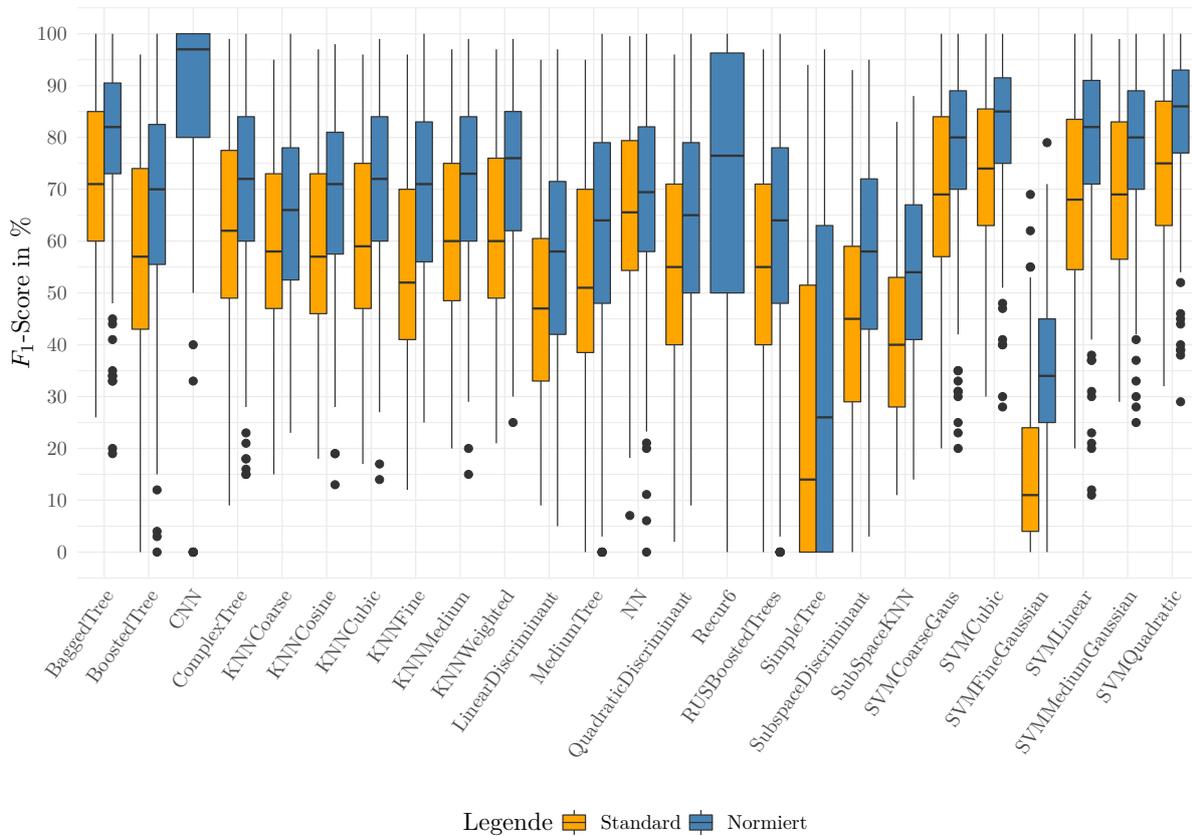


Abbildung 5.8: Vergleich des F_1 -Scores der Standard- und der normierten Methode für neun Gesten und vier Merkmale über fünf Probanden und alle Testsets

5.2.2.5 Zwischenfazit Normierung

Die Ergebnisse des Vergleichs der durchschnittlichen Klassifikationsgüte zwischen den beiden Verfahren Standard und Normierung sind in den Tabellen 5.2 und 5.3 zusammengefasst. Tabelle 5.2 zeigt die Metriken des F_1 -Scores für die Standardmethode und das normierte Verfahren. Es werden Median, arithmetisches Mittel, Minimum, Maximum und Standardabweichung jeweils für unterschiedliche Anzahlen an Merkmalen und Gesten einander gegenübergestellt. Die aufgeführten Werte beziehen sich auf alle Probanden, auf drei bzw. neun Gesten, alle Klassifikatoren sowie alle Testsets. Die Klassifikatoren CNN und Recur6 wurden nicht berücksichtigt, da sie in ihrer verwendeten Form die Daten der Standardmethode nicht klassifizieren können. Die Tabelle zeigt, dass die Normierung bei gleicher Anzahl an Gesten und Merkmalen in allen Fällen besser ist und die Standardabweichung durch die Erweiterung auf neun Gesten von 10 % auf ca. 20 % ansteigt. Dies wird auch durch den Vergleich von KKR, Sensitivität und Spezifität, wie in Tabelle 5.3 dargestellt, bestätigt.

5 Verifikation und Validierung

Tabelle 5.2: Vergleich des F_1 -Scores der Normierungsmethode mit drei Gesten sowie zwei und vier Merkmalen. Es sind nur Klassifikatoren berücksichtigt, welche sowohl Daten der Standardmethode als auch der normierten Methode klassifizieren können.

Verfahren	Anz. Merkmale	Anz. Gesten	Median	Arithmetisches Mittel	Minimum	Maximum	Standardabweichung
Standard	2	3	80 %	79 %	19 %	95 %	8,7 %
Normiert	2	3	84 %	83 %	38 %	100 %	7,9 %
Standard	4	3	84 %	83 %	10 %	100 %	10,9 %
Normiert	4	3	88 %	87 %	0 %	100 %	10,3 %
Standard	2	9	52 %	52 %	0 %	95 %	20,3 %
Normiert	2	9	64 %	62 %	0 %	100 %	20,5 %
Standard	4	9	58 %	56 %	0 %	100 %	20,5 %
Normiert	4	9	70 %	66 %	0 %	100 %	22,5 %

Es lässt sich zusammenfassend feststellen, dass der Klassifikator CNN mit der Normierung für neun Gesten einen beeindruckenden F_1 -Score von 97 % erreicht, der sogar höher ist als der F_1 -Score des NN mit der Standardmethode für drei Gesten und vier Merkmale (94 %). Dies zeigt deutlich, dass durch die Normierung eine verbesserte Unterscheidungsfähigkeit für neun Gesten erreicht werden kann, die über den aktuellen Stand der Technik für drei Gesten hinausgeht. Die Anwendung der Normierung ermöglicht somit eine präzisere und zuverlässigere Klassifikation von Bewegungsgesten.

Tabelle 5.3: Vergleich von KKR, Sensitivität und Spezifität der beiden Verfahren Standard und Normiert. Es wurden drei Gesten berücksichtigt und zwischen zwei und vier Merkmalen unterschieden.

Verfahren	Anz. Merkmale	Anz. Gesten	KKR	Sensitivität	Spezifität
Standard	2	3	86 %	79 %	89 %
Normiert	2	3	89 %	84 %	92 %
Standard	4	3	89 %	83 %	92 %
Normiert	4	3	92 %	87 %	94 %
Standard	2	9	89 %	52 %	94 %
Normiert	2	9	91 %	64 %	96 %
Standard	4	9	91 %	57 %	95 %
Normiert	4	9	93 %	67 %	96 %

5.2.3 Klassifikationsgüte der fortlaufenden Normierungsmethode

Dieser Abschnitt untersucht die Methode der fortlaufenden Normierung als Schritt der Vorverarbeitung eines EMG-Signals. Es wird angenommen, dass diese Methode aufgrund der wiederholten Durchführung während der Bewegung schlechtere Ergebnisse erzielt als die zuvor untersuchte Normierung, die erst am Ende des Signals erfolgt, wenn alle Bewegungsinformationen vorliegen. In diesem Zusammenhang werden die Ergebnisse der Klassifikatoren sowie die von ihnen erzielten Metriken wie F_1 -Score, KKR, Sensitivität, Spezifität und Standardabweichung betrachtet. Dabei umfasst die Untersuchung die drei Methoden Standard, Normiert und fortlaufend Normiert. Die Analyse umfasst den Durchschnitt über alle Probanden und Testsets. Dabei erfolgt für jede Permutation aus Anzahl an Merkmalen und Gesten eine separate Untersuchung.

5.2.3.1 Fortlaufende Normierung für drei Gesten und zwei Merkmale

Abbildung 5.9 stellt die Ergebnisse für die Kombination aus zwei Merkmalen und drei Gesten vergleichend für drei verschiedene Methoden dar: Standardmethode, Normierung und fortlaufende Normierung. Es ist deutlich zu erkennen, dass die meisten Klassifikatoren durch die fortlaufende Normierung einen höheren F_1 -Score erreichen als durch die anderen beiden Methoden. Tabelle 8.1 bestätigt diese Beobachtung, da die fortlaufende Normierung im Durchschnitt einen F_1 -Score von 94 % erreicht, was 8 %P über der Normierung und 12 %P über dem Durchschnitt der Standardmethode liegt.

Der CNN-Klassifikator erreicht mit 99 % den höchsten F_1 -Score, obwohl sich dieser gegenüber der Normierung verschlechtert. Der Median reduziert sich um 1 %P. Die besten fünf Klassifikatoren sind CNN, BaggedTree, BoostedTree, SVMCoarseGaus und SVMQuadratic, deren erreichte F_1 -Scores im Bereich von 98 % bis 99 % liegen. Die Standardabweichung von 7,5 % ist die bisher niedrigste, was darauf hindeutet, dass die Ergebnisse der Klassifikatoren sehr nah beieinander liegen. Eine Ausnahme stellt der Klassifikator Recur6 dar, der wie zuvor schon mit drei Gesten einen niedrigen F_1 -Score von nur 34 % erreicht.

5 Verifikation und Validierung

Die fortlaufende Normierung verbessert auch die Metriken KKR, Sensitivität und Spezifität deutlich, wie in Tabelle 8.2 im Anhang dargestellt ist. Insgesamt erreicht die fortlaufende Normierung für die Kombination aus zwei Merkmalen und drei Gesten, was dem derzeitigen industriellen Stand der Technik für Prothesen entspricht, eine deutlich bessere Klassifikationsgüte als die Methoden Standard und Normierung. Das gilt für alle Probanden und Tagessets.

Sowohl die Normierung als auch die fortlaufende Normierung verbessern die Klassifikationsgüte für nahezu jeden Klassifikator. Insbesondere die fortlaufende Normierung erzielt noch bessere Ergebnisse als die Normierung. Dies zeigt, dass die Anwendung von Normierungsmethoden einen positiven Einfluss auf die Leistungsfähigkeit der Klassifikatoren hat. Die fortlaufende Normierung ermöglicht eine präzisere Unterscheidung von Gesten und erzielt einen höheren F_1 -Score im Vergleich zur Standardmethode. Das positive Abschneiden der fortlaufenden Normierung ist dabei unerwartet. Mögliche Ursachen hierfür werden ansatzweise in Kapitel 5.2.4 untersucht.

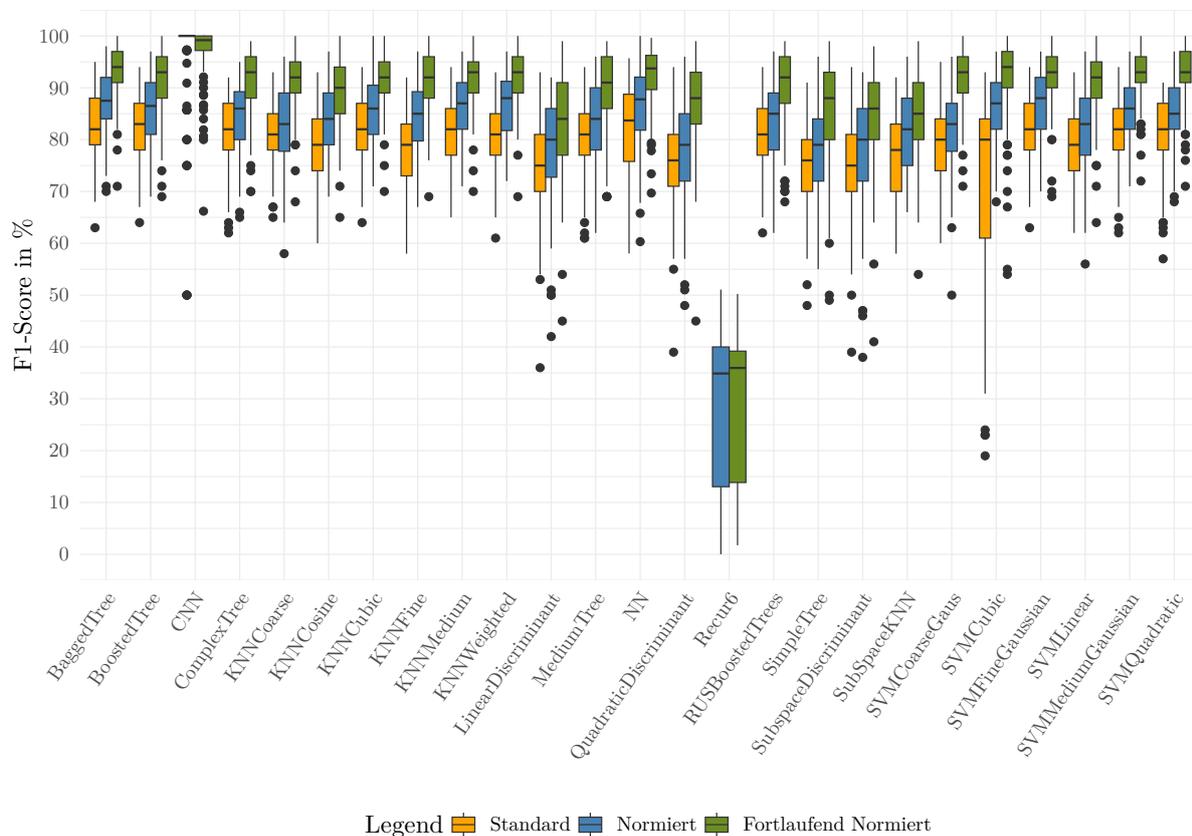


Abbildung 5.9: Vergleich des F_1 -Scores der drei vorgestellten Methoden für drei Gesten und zwei Merkmalen über fünf Probanden und alle Testsets

5.2.3.2 Fortlaufende Normierung für drei Gesten und vier Merkmale

Mit dieser Untersuchung wird überprüft, ob die fortlaufende Normierung mit mehr verfügbaren Merkmalen ebenfalls einen höheren F_1 -Score erreichen kann.

Der Boxplot in Abbildung 5.10 zeigt, dass die Klassifikatoren im Vergleich zur Standardmethode teils sogar deutlich an Klassifikationsgüte gewinnen. Von 25 Klassifikatoren erzielten 20 einen F_1 -Score von über 90 %, wobei CNN, BaggedTree, BoostedTree, SVMCoarseGaus und SVMQuadratic mit sehr guten Werten im Bereich von 98 % bis 99 % die besten fünf sind.

Während die meisten Klassifikatoren von der fortlaufenden Normierung profitieren, können CNN und SVMFineGaussian keinen weiteren Nutzen daraus ziehen. Der Klassifikator CNN erreicht bereits mit der Normierung den maximalen Wert von 100 % und fällt durch die fortlaufende Normierung lediglich um 1 %P. Dies ist darauf zurückzuführen, dass die EMG-Signale bereits zu einem sehr frühen Zeitpunkt normiert werden. So findet die erste Klassifikation bereits nach 100 ms statt, was dazu führt, dass der Klassifikator den nahezu perfekten Wert nicht erreicht, da die Daten zu diesem Zeitpunkt noch sehr ähnlich und schlecht zu trennen sind. Der Klassifikator SVMFineGaussian hat bereits in vorherigen Untersuchungen Schwierigkeiten mit der Klassifikation bei einer Erhöhung der Dimensionalität gezeigt, wodurch die Verringerung des F_1 -Scores bei der fortlaufenden Normierung nicht unerwartet ist.

Insgesamt schneidet die fortlaufende Normierung im Durchschnitt über alle Klassifikatoren um 9 %P besser ab als die Standardmethode und um 5 %P besser als die Normierung (siehe Tabelle 8.1 im Anhang). Die Metriken KKR, Sensitivität und Spezifität verbessern sich ebenfalls im Vergleich zu den beiden anderen Methoden (siehe Tabelle 8.2 im Anhang). Die Klassifikatoren können die Gesten besser trennen als mit der normierten Methode und sehr viel besser als mit der Standardmethode.

Es zeigt sich somit, dass auch für die fortlaufende Normierung mit der Erweiterung von Merkmalen eine Verbesserung der Klassifikationsgüte einhergeht, insbesondere im Vergleich mit den beiden anderen Methoden, jedoch noch einmal besonders deutlich gegenüber der Standardmethode. Des Weiteren geht mit der fortlaufenden Normierung eine Verbesserung der Klassifikationsgüte für fast alle Klassifikatoren einher. Sie verbessert sich insbesondere im Vergleich zu den beiden anderen Methoden, jedoch noch einmal sehr deutlich im Vergleich zur Standardmethode.

5.2.3.3 Fortlaufende Normierung für neun Gesten und zwei Merkmale

Die nachfolgende Analyse untersucht die Klassifikationsgüte von neun Gesten mit zwei Merkmalen. Dabei sind deutlich mehr Gesten zu unterscheiden, als dies derzeit bei den meisten Prothesen der Fall ist. Aus Abbildung 5.11 geht hervor, dass der erreichte F_1 -Score durch die fortlaufende Normierung für 21 von 25 Klassifikatoren höher ist als der durch die Standardmethode erzielte Wert. Das Q_{50} des F_1 -Scores liegt gemäß Tabelle 8.1 (siehe Anhang) im Durchschnitt bei 62 %, was 10 %P höher ist als der F_1 -Score der Standardmethode. Obwohl sich die Metrik im Vergleich zur Normierung verringert, fällt sie jedoch nur um 2 %P.

Der Klassifikator SubSpaceKNN erzielt durch die fortlaufende Normierung im Vergleich zur Standardmethode und der normierten Methode mit 42 % zu 46 % und 56 % einen niedrigeren F_1 -Score. Dieser Trend zeigt sich jedoch nicht bei den Klassifikatoren KNNCoarse, KNNCosine, KNNFine, KNNMedium und KNNWeighted. Daraus lässt sich schließen, dass der k-NN-

5 Verifikation und Validierung

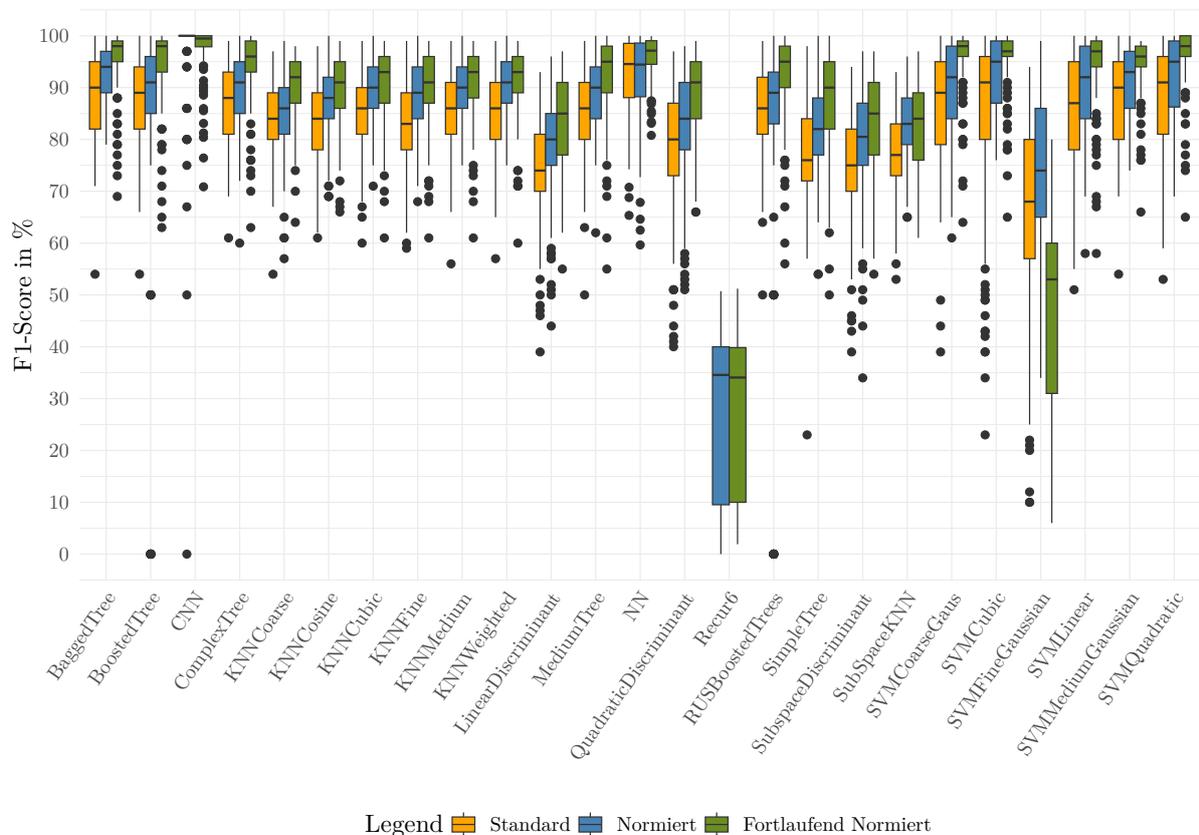


Abbildung 5.10: Vergleich des F_1 -Scores der drei vorgestellten Methoden über drei Gesten und vier Merkmale über fünf Probanden und alle Testsets

Algorithmus prinzipiell geeignet ist, um neun Gesten mit der fortlaufenden Normierung zu unterscheiden. Der wesentliche Unterschied zwischen dem SubSpaceKNN und den restlichen k-NN-Algorithmen besteht darin, dass er zufällige Untermengen bildet. Obwohl dieses Vorgehen dem der Klassifikatoren BaggedTree, BoostedTree und SubspaceDiscriminant ähnelt, führt die fortlaufende Normierung bei diesen Algorithmen zu einer Verbesserung. Das lässt darauf schließen, dass der SubSpaceKNN aufgrund der Kombination der gewählten Parameter (siehe Abschnitt 4.4) und der zufälligen Untermengen für die fortlaufende Normierung mit neun Gesten ungeeignet ist.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

Die fünf Klassifikatoren, nämlich CNN, Recur6, SVMMediumGaussian, NN und SVMQuadratic erzielen für die fortlaufende Normierung von neun Gesten mit zwei Merkmalen den höchsten F_1 -Score. Der Vergleich mit den vorherigen Ergebnissen zeigt, dass das CNN mit einem F_1 -Score von 85 % im Median erneut die besten Ergebnisse erzielt. Der beste Klassifikator für drei Gesten mit zwei Merkmalen hat lediglich 84 % erreicht. Die F_1 -Scores der nachfolgenden Klassifikatoren auf den Rängen 2 bis 4 liegen im Bereich von 78 % bis 70 %, was einem ähnlichen Niveau entspricht wie die mittleren bis schlechteren Klassifikatoren bei drei Gesten und zwei Merkmalen, siehe Abbildung 5.1. Infolgedessen lässt sich ableiten, dass neun Gesten mit der fortlaufenden Normierung unter Verwendung ausgewählter Klassifikatoren ähnlich gut oder sogar besser zu unterscheiden sind als durch den derzeitigen Stand der Technik. Zusätzlich ist anzunehmen, dass sich die Klassifikationsgüte durch die Hinzunahme weiterer Merkmale noch steigern lässt.

Die KKR, Sensitivität und Spezifität bilden den Abschluss des Überblicks der Klassifikation von neun Gesten mit zwei Merkmalen. Wie im Anhang in Tabelle 8.2 zu erkennen, verbessern sich alle drei Metriken der beiden normierten Methoden gegenüber der Standardmethode. Die fortlaufende Normierung unterscheidet sich hingegen nur geringfügig von der normierten Methode.

Es lässt sich festhalten, dass die Klassifikationsgüte bei der Klassifikation von neun unterschiedlichen Gesten mit zwei Merkmalen durch die fortlaufende Zeitnormierung im Vergleich zur Standardmethode verbessert wird. 22 von 25 Klassifikatoren weisen einen höheren F_1 -Score auf. Gegenüber der Normierung kann dieser Trend nicht bestätigt werden. Nur 5 von 25 Klassifikatoren übertreffen die Normierung. Allerdings ist zu beachten, dass sich die Klassifikatoren unterschiedlich gut eignen, um EMG-Signale durch die fortlaufende Normierung zu trennen. Insbesondere der Klassifikator CNN erreicht gute Werte. Eine Auswahl der Klassifikatoren erscheint sinnvoll, da die fortlaufende Normierung nicht bei allen Klassifikatoren zu einer Verbesserung des F_1 -Scores führt. Zudem erreichen die fünf am besten abschneidenden Klassifikatoren ein Niveau, welches dem des erreichten Durchschnitts für drei Gesten mit zwei Merkmalen entspricht.

5 Verifikation und Validierung

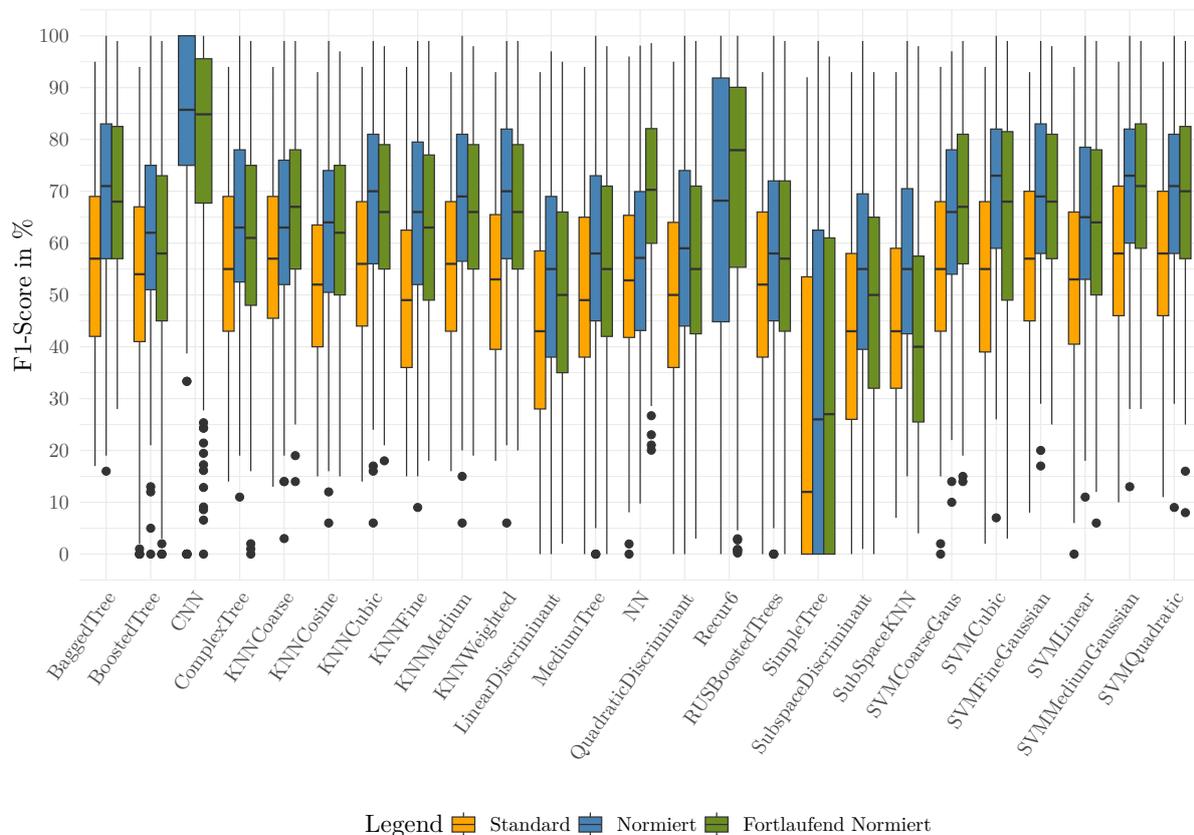


Abbildung 5.11: Vergleich des F_1 -Scores der drei vorgestellten Methoden über neun Gesten und zwei Merkmale über fünf Probanden und alle Testsets

5.2.3.4 Fortlaufende Normierung für neun Gesten mit vier Merkmalen

Die vorangehende Untersuchung zeigt, dass eine fortlaufende Normierung der Signale bei ausgewählten Klassifikatoren zu einem F_1 -Score für neun Gesten führt, der dem Stand der Technik für drei Gesten entspricht. Es soll nun untersucht werden, ob die Verwendung von vier Merkmalen die Klassifikationsgüte weiter erhöhen kann. Abbildung 5.12 stellt die erreichten F_1 -Scores als Boxplot dar.

Im Vergleich zur Standardmethode erzielt lediglich der SubSpaceKNN keinen höheren F_1 -Score. Dies wurde bereits bei der Kombination aus neun Gesten und zwei Merkmalen beobachtet. Die restlichen 22 Klassifikatoren zeigen ebenfalls Verbesserungen. Wie aus der Verschiebung des Q_{50} in Tabelle 8.1 im Anhang hervorgeht, steigt dabei das Quantil um 6 %P auf 64 % an.

Der Klassifikator CNN erreicht erneut den höchsten F_1 -Score mit 87 %. Die fünf am besten abschneidenden Klassifikatoren sind CNN, Recur6, SVMQuadratic, SVMCubic und SVMCoarseGaus. Das Recur6-Netz liegt bei ca. 85 %, wobei beide neuronalen Netze die Ergebnisse des NN-Klassifikators vom Stand der Technik (84 %) übertreffen. Die SVMQuadratic liegt mit 82 % nur 2 %P dahinter. Auch die Klassifikatoren SVMCubic und SVMCoarseGaus erreichen mit 80 % und 79 % gute Werte.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

Es ist jedoch auch festzustellen, dass die fortlaufende Normierung nicht das Niveau der Normierung (70%) erreicht. So liegt der Median der fortlaufenden Normalisierung 6%P zurück. Die Metriken KKR, Sensitivität und Spezifität bleiben im Vergleich zu neun Gesten und zwei Merkmalen ähnlich. Die KKR unterscheidet sich, bei den verschiedenen Methoden nur um 1%P bis 2%P. Die Sensitivität und Spezifität verbessern sich, durch die Hinzunahme weiterer Merkmale um bis zu 8%P. Im Vergleich zur Standardmethode ist vor allem bei der Sensitivität durch beide Normierungsmethoden ein Zugewinn bis 10%P zu beobachten.

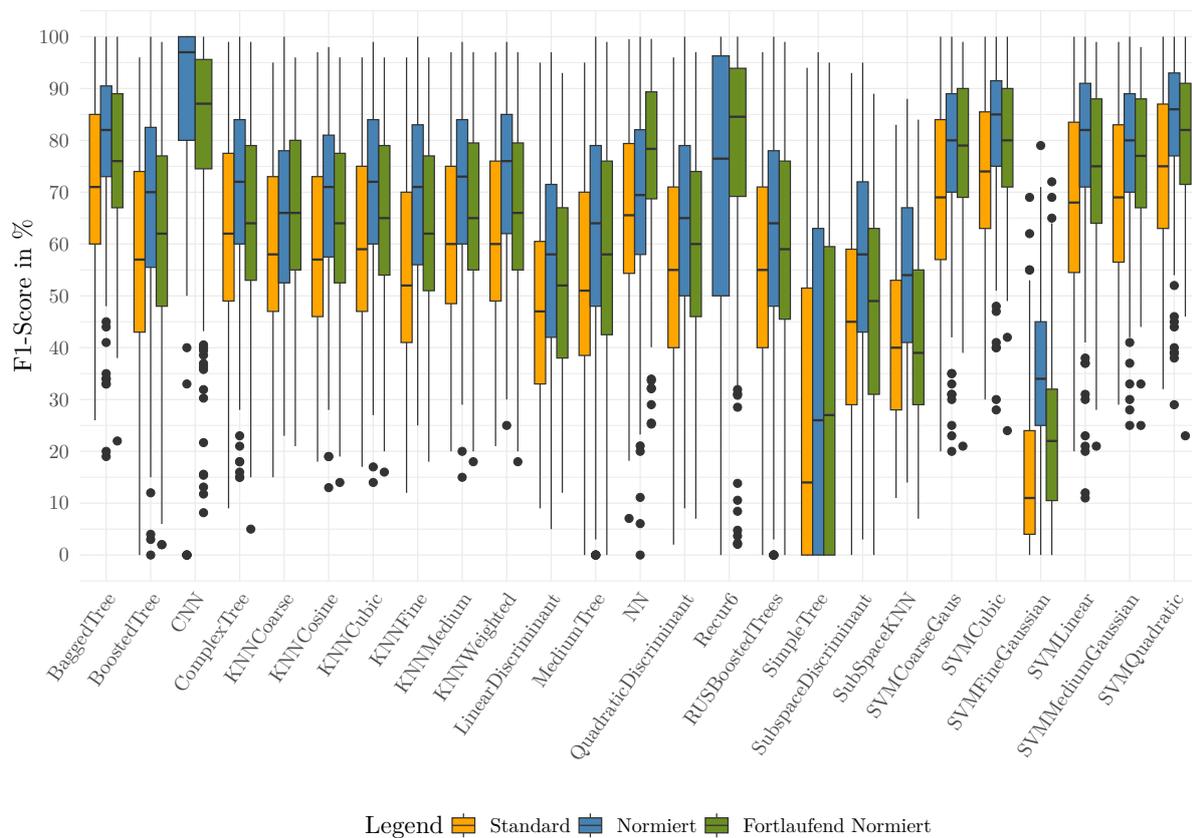


Abbildung 5.12: Vergleich des F_1 -Scores der drei vorgestellten Methoden über neun Gesten, vier Merkmale, fünf Probanden und alle Testsets

Tabelle 5.4: Der Median aus der Kombination von Methode, Anzahl Gesten und Anzahl Merkmale der fünf besten Klassifikatoren

Verfahren	Anz. Merkmale	Anz. Gesten	Median
Standard	2	3	82 %
	4	3	91 %
	2	9	57 %
	4	9	72 %
Normiert	2	3	89 %
	4	3	95 %
	2	9	74 %
	4	9	85 %
Fortlaufend Normiert	2	3	95 %
	4	3	98 %
	2	9	74 %
	4	9	82 %

5.2.3.5 Zwischenfazit fortlaufende Normierung

Obwohl teilweise deutliche Einbußen beim F_1 -Score hingenommen werden müssen, wenn die Anzahl der Gesten auf neun erhöht wird, zeigt sich für alle vier Permutationen aus Gesten und Merkmalsanzahl, dass die Klassifikationsgüte der meisten Klassifikatoren mit fortlaufender Normierung im Vergleich zur Standardmethode zunimmt.

Eine Auswahl an Klassifikatoren schneidet jedoch verglichen mit der Normierung als auch mit der Standardmethode mit der fortlaufenden Normierung besser ab. Besonders der Klassifikator CNN liefert für jede Permutation von Gesten und Merkmalen sehr gute Ergebnisse. Der Recur6-Klassifikator erreicht ebenfalls hohe F_1 -Scores, jedoch nur, wenn neun Gesten zu unterscheiden sind. Mögliche Ursachen dafür könnten Überanpassungen sein, die bei der Unterscheidung von nur drei Gesten auftreten sowie eine ungeeignete Architektur des neuronalen Netzes.

Insgesamt konnte gezeigt werden, dass eine Klassifikation von neun Gesten mit beiden Normierungsmethoden möglich ist und dass dabei der Vergleichsmaßstab des derzeitigen Standes der Technik übertroffen wird. Obwohl die fortlaufende Normierung eine hohe Leistung der Klassifikatoren für neun Gesten ermöglicht, liegt der Median mit der fortlaufenden Normierung 6 %P unter dem Niveau der Normierung. Bei Verwendung von zwei Merkmalen, wie es dem Fall entspricht, wenn wenig Rechenleistung zur Verfügung steht, bleiben die Metriken KKR, Sensitivität und Spezifität im Vergleich zu neun Gesten und vier Merkmalen stabil.

In Tabelle 5.4 sind die erreichten F_1 -Scores der besten fünf Klassifikatoren für verschiedene Kombinationen von Verfahren, Merkmalen und Gesten aufgeführt. Der Vergleichsmaßstab entspricht dem Standardverfahren mit zwei Merkmalen und drei Gesten, welcher bei 82 % liegt und in der Tabelle blau markiert ist. Werte über dem Vergleichsmaßstab sind grün, Werte darunter orange hinterlegt.

5.2 Untersuchung der vorgestellten Klassifikationsverfahren

Es zeigt sich, dass die Klassifikationsgüte durch die Verwendung von mehr Merkmalen gesteigert werden kann. Allerdings ist es mit der Standardmethode nicht möglich, für neun Gesten den Vergleichsmaßstab zu erreichen. Die Klassifikatoren übertreffen mit der Normierung den Vergleichsmaßstab in fast jedem Fall und ermöglichen eine bessere Unterscheidung von drei und neun Gesten. Allerdings benötigen neun Gesten vier Merkmale, um über die Schwelle von 82 % zu gelangen. Die fortlaufende Normierung führt zu einer weiteren Verbesserung, insbesondere für drei Gesten, deren Median auf 95 % steigt. Bei der Unterscheidung von neun Gesten kommt es zu einem leichten Rückgang, jedoch wird der Vergleichsmaßstab dennoch erreicht.

Insgesamt lässt sich zusammenfassen, dass die Normierung eine effektive Methode ist, um die Klassifikationsgüte zu steigern. Die fortlaufende Normierung kann zu einer weiteren Verbesserung führen, insbesondere bei der Unterscheidung von drei Gesten. Allerdings kommt es bei der Unterscheidung von neun Gesten zu leichten Einbußen. Eine Erhöhung der Merkmalsanzahl führt ebenfalls zu einer Steigerung der Klassifikationsgüte.

5.2.4 Frühzeitige Klassifikation bei fortlaufender Normierung

Wie in Abschnitt 3.3 gezeigt, nähern sich die fortlaufend normierten Daten während der Ausführung einer Geste immer mehr denen der Normierung an. Dieser Abschnitt untersucht, ob es möglich ist, die fortlaufende Normierung vor dem Ende einer Bewegung abzuschließen und zu bestimmen, ab welchem Zeitpunkt eine gute Klassifikation möglich ist.

Hierfür wird zunächst die Anzahl der Normierungsschritte pro Signal betrachtet, also wie viele Intervalle die fortlaufende Normierung durchgeführt hat. Dies entspricht der höchsten Zeitbasis des Signals (siehe Kapitel 3.3). Abbildung 5.13 zeigt, dass Signale mit bis zu 20 nutzbaren Zeitbasen häufig auftreten und zu klassifizierende Signale mit mehr als 50 Zeitbasen sehr selten vorkommen.

Abbildung 5.14 zeigt zusammenfassend die Kerndichtefunktion für vier Permutationen bezüglich der Anzahl an Gesten und Merkmalen über den Zeitbasen. In allen vier Fällen liegt die Wahrscheinlichkeit einer richtigen Klassifikation im Bereich, in dem 86 % der nutzbaren Signale liegen, am höchsten. Bei der Unterscheidung von drei Gesten steigt die Wahrscheinlichkeit einer richtigen Klassifikation schnell an, und bereits nach drei Intervallen übertrifft die Dichtefunktion der wahren Klassifikationen, die der falschen. Es ist daher bereits nach drei Intervallen eine sehr gute Klassifikation möglich.

Der Unterschied in der Dichtefunktion zwischen zwei und vier Merkmalen fällt deutlich geringer aus als der Unterschied in Bezug auf die Anzahl der Gesten. Demnach hat die Anzahl der Merkmale nur einen geringen Einfluss auf den Zeitpunkt, zu dem eine Geste frühzeitig klassifiziert werden kann.

Für neun Gesten ist deutlich erkennbar, dass die Wahrscheinlichkeit einer falschen Klassifikation zu Beginn einer Bewegung deutlich höher ist. Ab der fünften bis zur siebten Zeitbasis übersteigt die Kurve der als wahr evaluierten Ergebnisse größtenteils diejenige der falschen Klassifikationen. Ungefähr zur Zeitbasis 24 nehmen auch beide Dichtefunktionen deutlich ab. Das ist ungefähr der Zeitpunkt an dem die Anzahl der zu klassifizierenden Zeitbasen deutlich abfällt. Teilweise unterschreitet dabei sogar die Funktionskurve der richtigen die der falschen Zuordnungen.

Bei Verwendung von zwei Merkmalen für neun Gesten bleibt die Dichtefunktion der korrekten Klassifikationen weitgehend über derjenigen der falschen Zuordnungen.

Da zu diesem späten Zeitpunkt nur noch wenige Gesten berücksichtigt werden, sinkt allerdings die Aussagekraft des Vergleichs zu diesem Zeitpunkt.

5 Verifikation und Validierung

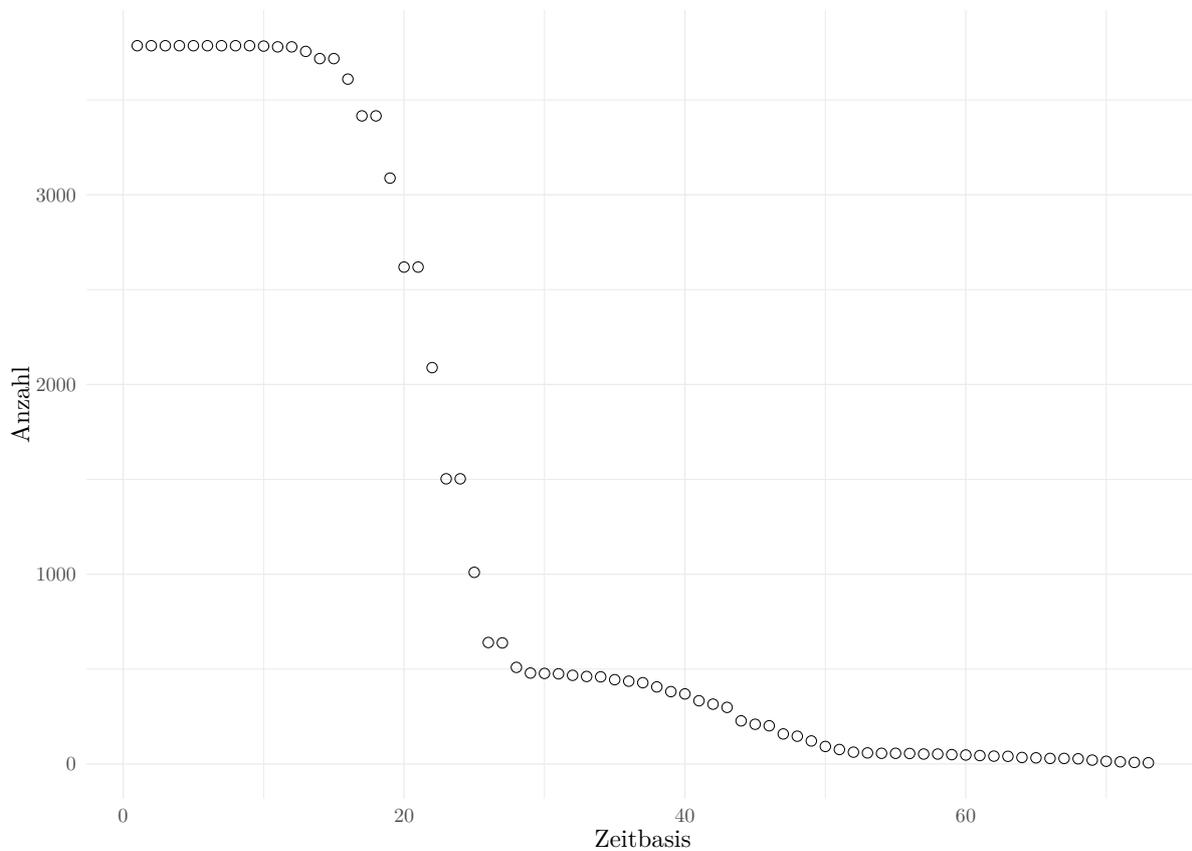


Abbildung 5.13: Anzahl der zu klassifizierenden Zeitbasen

Bei Betrachtung der Kerndichtefunktionen zeigt sich, dass bereits nach wenigen Intervallen eine Klassifikation möglich ist. Da jedoch zu Beginn der Bewegung noch fehlerhafte Klassifikationen auftreten, ist entsprechend der Anzahl der Gesten eine angemessene Zahl von Intervallen abzuwarten, bis die Wahr-Dichtefunktion stabil über der Falsch-Dichtefunktion liegt.

Wenn die fortlaufende Normierung in dieser Art und Weise frühzeitig beendet wird, ist zu erwarten, dass die Ergebnisse, ähnlich wie in den vorangegangenen Untersuchungen, weiterhin sehr gut sind. Darauf deuten auch die bisherigen Ergebnisse der fortlaufenden Normierung hin, welche deutlich besser abschneidet als ursprünglich prognostiziert.

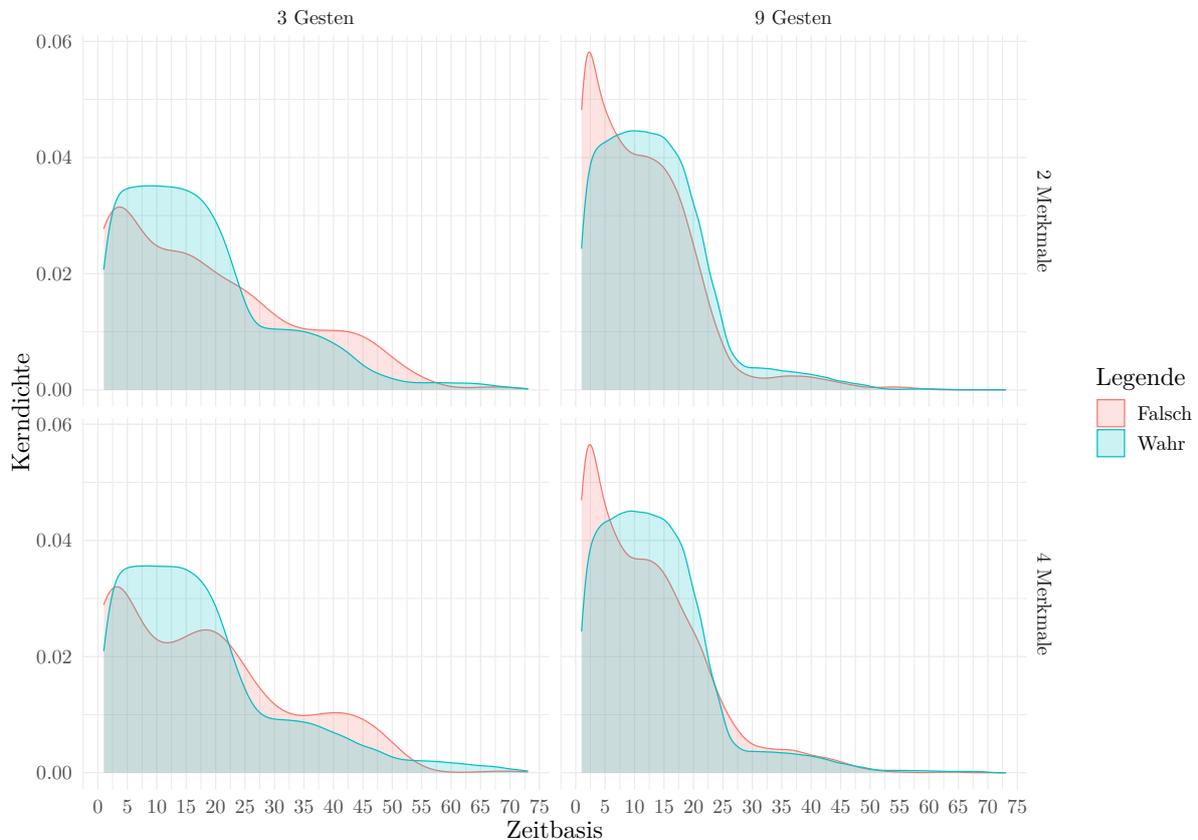


Abbildung 5.14: Kerndichtefunktion der richtig und falsch klassifizierten Gesten im Verlauf über die Zeitbasen

5.3 Probanden

Der vorangegangene Abschnitt zeigt, dass sich die Klassifikationsgüte durch Normierung und fortlaufende Normierung verbessern lässt. Dies wurde mittels des Durchschnitts über alle Probanden, Gesten und Testsets nachgewiesen. Im vorliegenden Abschnitt wird untersucht, ob sich eine Verbesserung der Klassifikationsgüte für jeden einzelnen Probanden belegen lässt. Zu diesem Zweck werden für jeden Probanden sieben Test- und Trainingssets gebildet. Diese umfassen jeweils ein Test- bzw. Trainingsset pro Einzeltag, das nur die EMG-Signale von diesem Aufnahmetag enthält, und ein Sechs-Tage-Set, das die Daten aller Aufnahmetage enthält. Nach Klassifikation der EMG-Signale und Bestimmung der zugehörigen Metriken wie des F_1 -Scores oder der KKR wird der Durchschnitt über die Ergebnisse aller Gesten und Testsets des Probanden berechnet.

Da im vorherigen Abschnitt gezeigt wurde, dass nicht alle Klassifikatoren für die Normierung und fortlaufende Normierung geeignet sind, werden in der folgenden Untersuchung nur die besten fünf Klassifikatoren für die jeweilige Kombination aus Gesten und Merkmalen verwendet.

5.3.1 Drei Gesten mit zwei Merkmalen pro Proband

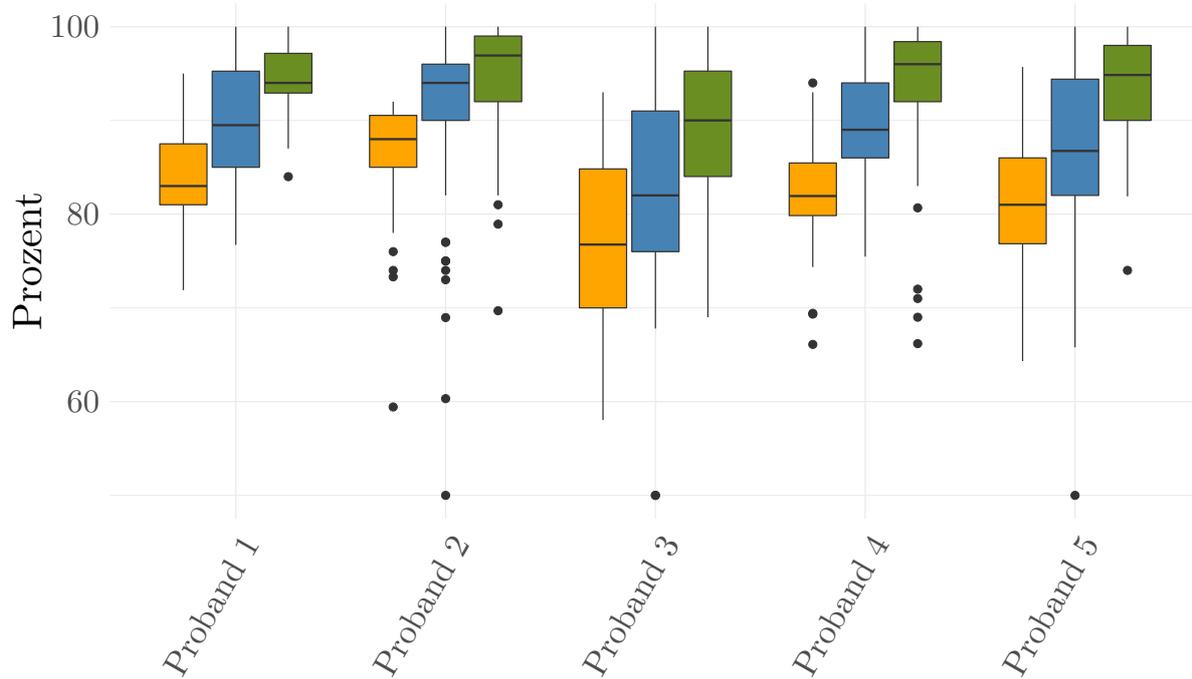
Für die Kombination aus drei Gesten und zwei Merkmalen haben sich bei der Auswertung der Klassifikatoren die Modelle CNN, NN, BaggedTree, SVMFineGaussian und BoostedTree im Durchschnitt als am besten erwiesen. Allerdings kann das CNN-Modell keine Gesten mit der Standardmethode klassifizieren. Aus den Ergebnissen in Abbildung 5.15 wird deutlich, dass die Anwendung der Normierung zu einer Verbesserung des F_1 -Scores für jeden Probanden führt. Durch die fortlaufende Normierung konnte der Median im Vergleich zur Normierung und zur Standardmethode weiter gesteigert werden. Bei allen Probanden konnte durch die Normierung eine höhere Klassifikationsgüte als mit der Standardmethode erzielt werden. Die fortlaufende Normierung kann diese Leistung nochmals steigern. Es zeigt sich, dass der Median der Klassifikationsmethoden pro Proband sogar meist über dem 75. Perzentil der vorherigen Methode liegt. Wie erwartet ist festzustellen, dass sich die einzelnen Methoden für jeden Probanden im Detail unterscheiden. Insgesamt lässt sich jedoch beobachten, dass bei allen fünf Probanden eine Stufenfunktion entsteht, bei der die Normierung einen höheren Wert als die Standardmethode erreicht. Dies gilt sowohl für den Median als auch für die einzelnen Quantile. Gleiches gilt für die fortlaufende Normierung im Vergleich zur Normierung.

Im Vergleich zur Standardmethode und zur Normierung ist der Median bei der fortlaufenden Normierung für alle Probanden auf einem ähnlichen Niveau bei etwa 95 % angesiedelt. Dabei schwankt die Ausprägung insgesamt weniger als bei den anderen Methoden, wie in Tabelle 8.3 im Anhang dargestellt ist. Die Tabelle zeigt auch den Zugewinn des F_1 -Scores der neuen Methoden im Vergleich zur Standardmethode.

Bei der Kombination aus drei Gesten und zwei Merkmalen konnte der größte Zugewinn mit der fortlaufenden Normierung erzielt werden. Dieser beträgt bis zu 14 %P.

Wie bereits zuvor zeigen sich auch bei Betrachtung der Metriken KKR, Sensitivität und Spezifität Verbesserungen durch die beiden neuen Normierungsmethoden. In Tabelle 8.4 im Anhang ist der Median der Metriken sowie das Delta zur Standardmethode für die einzelnen Probanden dargestellt. Beide Normierungsmethoden führen zu einer Verbesserung der Metriken, wobei die fortlaufende Normierung die stärkste Verbesserung zeigt. Insbesondere die Sensitivität (TPR) verbessert sich bei vier Probanden um 10 bis 14 %P, und bei Proband 2 immerhin noch um 8 %P. Durch die fortlaufende Normierung erreicht die TPR bei allen Probanden einen Wert zwischen 89 % und 96 %, wobei der zweitniedrigste Wert der TPR bei Probanden 1 und 5 bei 94 % liegt. Nur Proband 3 bildet mit 89 % eine Ausnahme.

Für alle fünf Probanden konnten sowohl durch die Normierung als auch durch die fortlaufende Normierung signifikante Verbesserungen der Klassifikationsgüte im Vergleich zur Standardmethode erzielt werden. Somit sind die beiden Methoden nicht nur für einzelne Probanden oder im Durchschnitt wirksam, sondern führen tatsächlich für jeden Probanden zu einer höheren Klassifikationsgüte. Inwieweit dies auch für die verschiedenen Permutationen von Anzahl Gesten und Merkmalen gilt, wird im Folgenden untersucht.



Legende ■ Standard ■ Normiert ■ Fortlaufend Normiert

Abbildung 5.15: Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über drei Gesten, zwei Merkmale und alle Tages-Testsets. Berücksichtigt sind die Ergebnisse der besten fünf Klassifikatoren CNN, NN, BaggedTree, SVMFineGaussian und BoostedTree

5.3.2 Drei Gesten mit vier Merkmalen pro Proband

Nachfolgend werden die Klassifikationsergebnisse für drei Gesten und vier Merkmale für jeden der fünf Probanden einzeln betrachtet. Dabei wurden die Metriken wie oben im Durchschnitt über die besten fünf Klassifikatoren gebildet. Zu diesen zählen in aufsteigender Reihenfolge: SVMCubic, BaggedTree, SVMQuadratic, NN und CNN.

Abbildung 5.16 zeigt die erreichten F_1 -Scores als Boxplot. Wie zuvor lässt sich auch hier beobachten, dass die Normierung besser als die Standardmethode abschneidet. Sie übertrifft diese sowohl im Median als auch für die beiden Quantile Q_{25} und Q_{75} (siehe Tabelle 8.3 im Anhang). Die fortlaufende Normierung übertrifft, wie bereits bei zwei Merkmalen, die beiden anderen Methoden im Median. Die Stufenfunktion lässt sich jedoch nicht mehr durchgehend beobachten, da die Normierung sich bereits stark an die 100% annähert und diese für einen Probanden mit dem

5 Verifikation und Validierung

Q_{75} erreicht. Daher können sowohl der Median als auch das Q_{25} diesen nicht mehr übertreffen. Der Median der fortlaufenden Normierung liegt dennoch für alle Probanden, mit Ausnahme des Probanden 3, oberhalb dem der Normierung. Für Proband 3 liegen die beiden normierten Methoden gleichauf und erreichen einen Median von 94 %.

Ähnliches zeigt sich auch in den Metriken TPR, TNR und ACC in Tabelle 8.4 im Anhang, die sich alle drei mit den neuen Methoden verbessern. Obwohl Proband 3 die niedrigsten Werte erzielt, liegen auch diese zwischen 89 % und 95 %. Die anderen vier Probanden überbieten diese Werte. So erreicht die TPR 96 % bis 98 %, lediglich Proband 3 erzielt nur 90 %. ACC und TNR schneiden dabei noch besser ab (siehe Tabelle 8.4 im Anhang).

Zusammenfassend ist festzustellen, dass für drei Gesten mit vier Merkmalen eine Verbesserung aller Metriken bei allen Probanden zu beobachten ist. Während sich die Metriken Spezifität und KKR in den meisten Fällen zwischen 1 %P und 4 %P nur leicht verbessern, ist für die Probanden 4 und 5 ein Anstieg von bis zu 10 %P zu beobachten. Besonders die fortlaufende Normierung zeigt eine höhere Wirksamkeit als die anderen Methoden.

Die Sensitivität sowie der F_1 -Score verbessern sich durch die neuen Normierungsmethoden für jeden Probanden sehr deutlich. Dabei erzielt die Methode der fortlaufenden Normierung die besten Ergebnisse, insbesondere durch das Anheben des 25. Perzentils auf einen Mindestwert von 88 % und bis zu einem Maximum von 97 %. Bei vier der fünf Probanden ist ein sehr ähnliches Verhalten der beiden Normierungsmethoden zu erkennen, lediglich bei Proband 3 schneidet die fortlaufende Normierung im Vergleich etwas schlechter ab. Sie übertrifft dennoch die beiden anderen Methoden. Die bereits sehr guten Werte der Standardmethode bestätigen den aktuellen Forschungsstand, dass drei unterschiedliche Gesten mit einer Erhöhung der Anzahl an Merkmalen sehr gut klassifiziert werden können. Weitere Verbesserungen lassen sich durch die Normierungsverfahren erzielen. Dieses Prinzip konnte experimentell für jeden Probanden gezeigt werden. Im nächsten Schritt wird untersucht, wie sich die Klassifikation für die einzelnen Probanden bei der Erhöhung der Anzahl an Gesten von drei auf neun verhält.

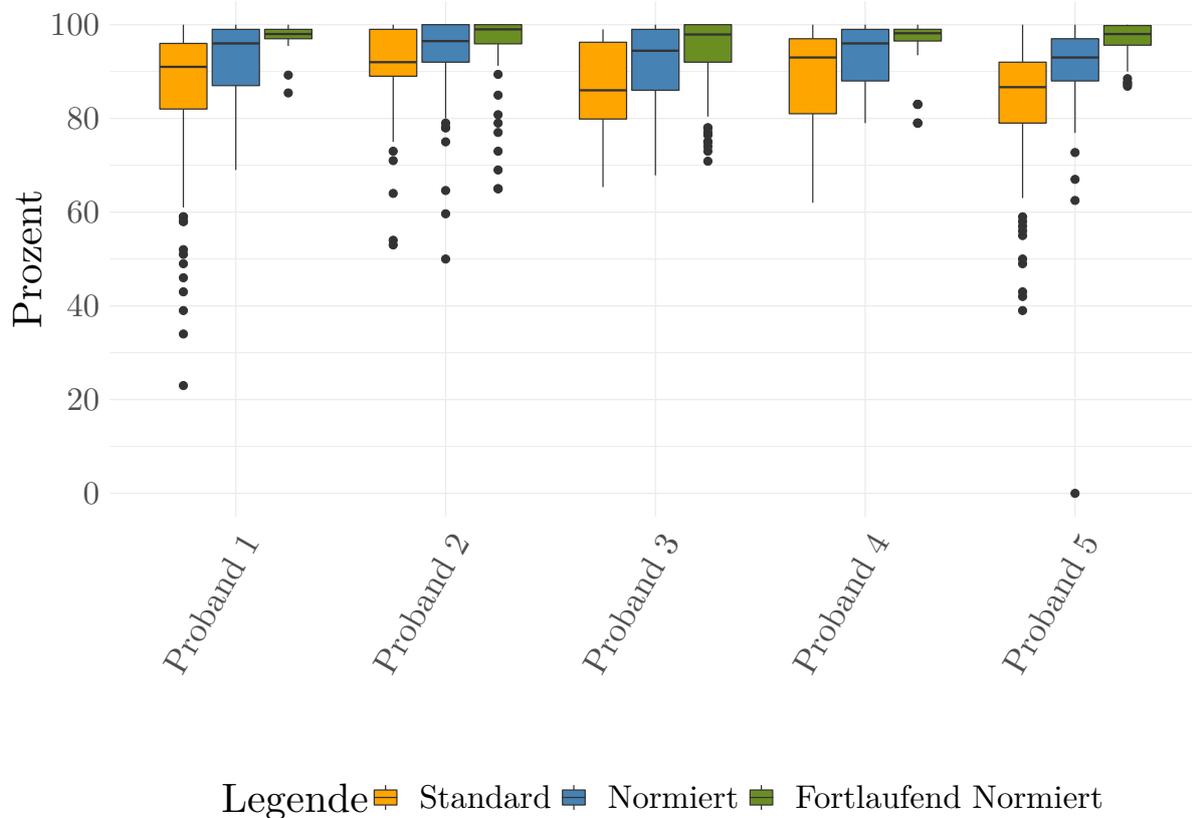


Abbildung 5.16: Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über drei Gesten, vier Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren BaggedTree, SVMCubic, SVMQuadratic, NN und CNN.

5.3.3 Neun Gesten mit zwei Merkmalen pro Proband

Bei Betrachtung der Klassifikationsergebnisse von neun Gesten und zwei Merkmalen ist bei jedem Probanden deutlich zu erkennen, dass die beiden Normierungsmethoden für jeden Probanden besser abschneiden als die Standardmethode. Abbildung 5.17 zeigt dies deutlich. Der Median mit der Normierung liegt bei etwa 71 %, wobei bei Proband 5 der Median der fortlaufenden Normierung gegenüber der Normierung leicht abgesenkt ist. Dennoch sind die Werte der beiden neuen Methoden deutlich höher als die der Standardmethode mit etwa 58 %. Die Klassifikationsergebnisse wurden durch folgende Klassifikatoren in absteigender Reihenfolge erzielt: CNN, Recur6, SVMMediumGaussian, SVMQuadratic und BaggedTree.

Im Vergleich zu den beiden Untersuchungen mit drei Gesten fällt jedoch auf, dass die fortlaufende Normierung die Normierung nicht mehr so stark überragt wie zuvor. Dies zeigt sich auch

5 Verifikation und Validierung

in den Quantilen, die in Tabelle 8.3 im Anhang dargestellt sind. Bei Betrachtung der Metriken ACC, TPR und TNR in Tabelle 8.4 im Anhang fällt der deutliche Anstieg der TPR auf. Durch die Normierung steigt diese bei jedem Probanden um mindestens 10 %P und maximal 20 %P an. Die ACC liegt bei allen Klassifikationsmethoden bei etwa 96 %. Die TNR ist ebenfalls stabil, mit einer leichten Verbesserung durch die Normierung um 2 %P bis 3 %P.

Zusammenfassend kann festgestellt werden, dass sich die Klassifikationsgüte durch beide Normierungsmethoden verbessert, insbesondere der F_1 -Score und die Sensitivität bei allen fünf Probanden. Dennoch liegen die erreichten Werte unter dem Vergleichsmaßstab von 82 % aus dem vorangegangenen Abschnitt. Daher wird im Folgenden die Anzahl der Merkmale auf vier erhöht.

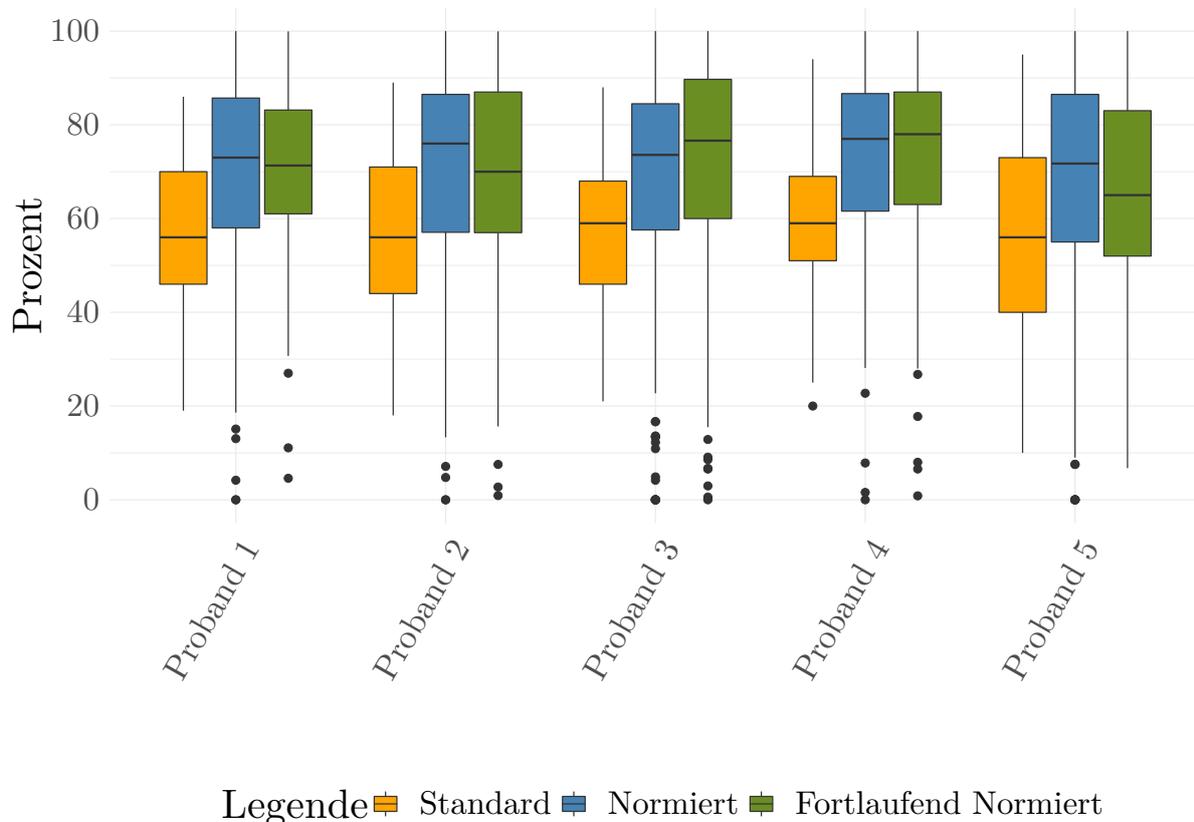


Abbildung 5.17: Erreichte F_1 -Scores der Probanden der drei unterschiedlichen Methoden über neun Gesten, zwei Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren CNN, BaggedTree, KNNWeighted, KNNCubic und KNNMedium.

5.3.4 Neun Gesten mit vier Merkmalen pro Proband

Nach der Erhöhung von zwei auf vier Merkmale erzielen die Klassifikatoren BaggedTree, SVM-Cubic, Recur6, SVMQuadratic und CNN in aufsteigender Reihenfolge bei der Trennung von neun Gesten mit vier Merkmalen die höchsten F_1 -Scores. Abbildung 5.18 zeigt die Ergebnisse dieser Klassifikatoren als Boxplot. Die Normierungen führen in beiden Fällen zu einer Verbesserung des F_1 -Scores für jeden Probanden. Dabei ist bei vier der fünf Probanden ein leicht geringerer Median der fortlaufenden Normierung gegenüber der Normierung zu beobachten, wobei der Unterschied maximal 5 %P beträgt. Bei den Probanden 2 und 4 ist der Median nahezu unverändert. Die Sensitivität verbessert sich ebenfalls bei beiden Normierungsmethoden gegenüber der Standardmethode für alle Probanden, wobei der Anstieg pro Proband zwischen 8 %P und 15 %P liegt (siehe Tabelle 8.4 im Anhang). Die Spezifität wird nur geringfügig verbessert, indem sie für beide Methoden lediglich um mindestens 1 %P und maximal um 2 %P erhöht wird. Allerdings liegen die Werte zwischen 96 % und 97 %, was kaum noch eine Steigerung zulässt. Die KKR ist durch die Normierung 7 %P bis 8 %P höher als die Standardmethode. Die fortlaufende Normierung hingegen ist kaum verändert und weicht zwischen -4 %P und 1 %P ab.

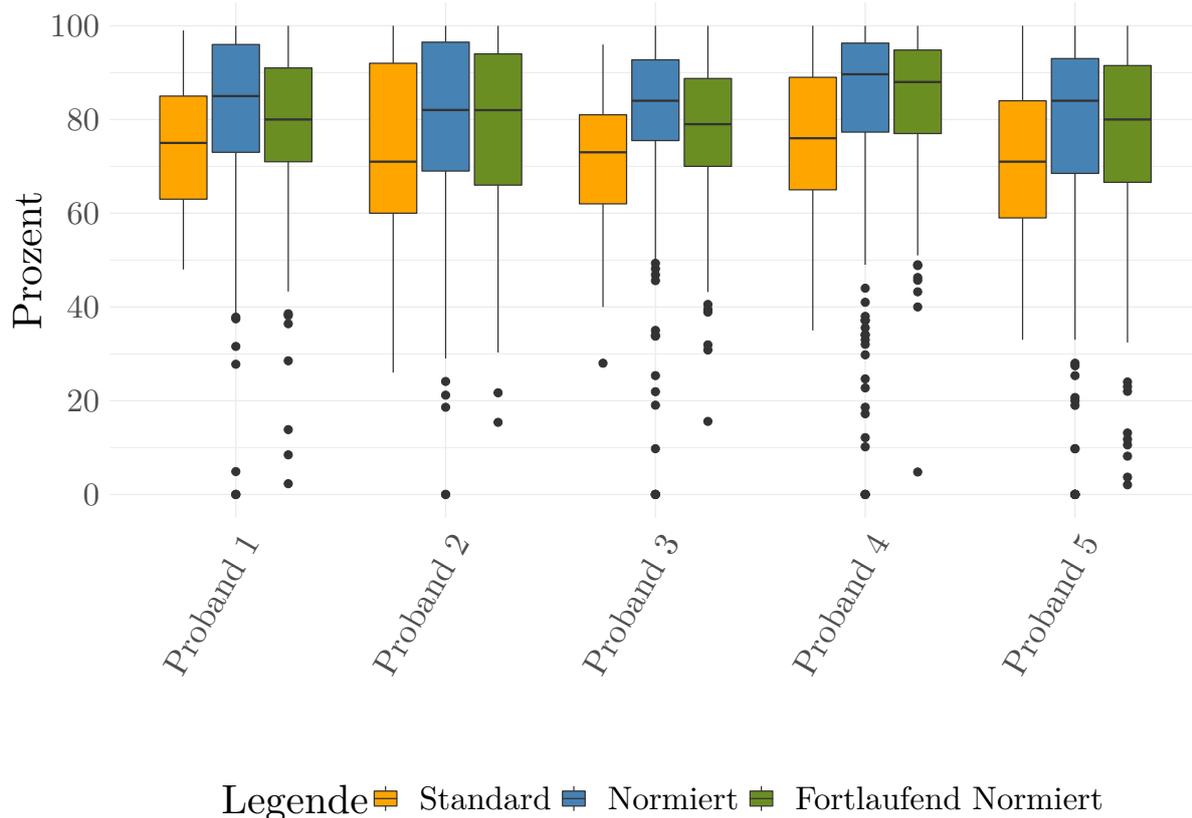


Abbildung 5.18: Erreichte F_1 -Scores der drei unterschiedlichen Methoden über neun Gesten, vier Merkmale und alle Tages-Testsets. Berücksichtigt sind in aufsteigender Reihenfolge die Ergebnisse der besten fünf Klassifikatoren BaggedTree, SVMCubic, Recur6, SVMQuadratic und CNN.

5.3.5 Zwischenfazit für Probanden

Tabelle 5.5 gibt den F_1 -Score des besten Klassifikators pro Methode über alle Testsets je Proband. Dabei stellt das neuronale Netz (NN) den F_1 -Score für die Standardmethode dar, die aktuell den Stand der Technik mit drei Gesten und zwei Merkmalen repräsentiert. Die F_1 -Scores der Methoden Normiert und fortlaufend Normiert werden vom Klassifikator CNN erzeugt.

Um die erreichten Werte der unterschiedlichen Methoden eines Probanden zu vergleichen, werden sie in der Tabelle dargestellt. Dabei werden die Vergleichswerte des Stands der Technik in blau hervorgehoben, während Werte, die unterschritten wurden, orange hinterlegt sind und Werte, die erreicht oder übertroffen wurden, grün markiert sind.

Bei Betrachtung der Ergebnisse der Normierung fällt auf, dass alle fünf Probanden mit dieser Methode neun Gesten genauso gut oder besser unterschieden können wie mit der Standardmethode drei Gesten. Proband 1 und 4 erreichen dabei sogar den maximal möglichen Wert von 100 %. Die anderen drei Probanden erzielen Werte zwischen 86 % und 91 %, was ebenfalls deutlich über dem Wert von 80 % aus Abschnitt 5.2.1 liegt.

Die Auswertung für die fortlaufende Normierung zeigt, dass vier der fünf Probanden die Werte der Klassifikation des Stands der Technik übertreffen. Proband 2 ist der einzige, dem dies mit 82 % nicht gelingt. Er schneidet 6 %P schlechter ab als für drei Gesten und zwei Merkmale. Die anderen vier Probanden erreichen Werte zwischen 84 % und 91 %. Wodurch sich die Klassifikation um 1 %P und bis zu 12 %P verbessert. Damit liegen alle fünf Probanden teils deutlich über dem 80 % Durchschnitt aus Abschnitt 5.2.1.

Diese Ergebnisse zeigen, dass Probandenvergleiche sehr schwierig sind und von vielen Randbedingungen wie den Testsets, den zu unterscheidenden Gesten oder den verwendeten Merkmalen abhängen. Dieser Abschnitt belegt jedoch, dass durch beide Normierungsmethoden die Klassifikationsgüte deutlich gesteigert werden kann und eine Klassifikation von neun unterschiedlichen Gesten auf hohem Niveau möglich ist.

Tabelle 5.5: Der Median des besten Klassifikators für die jeweilige Methode. Verglichen wird das Ergebnis des Stands der Technik mit dem F_1 -Score der Normierungsmethoden je Proband.

Verfahren	Anz. Merkmale	Anz. Gesten	Proband	Median
Standard	2	3	Proband 1	83 %
			Proband 2	88 %
			Proband 3	76 %
			Proband 4	82 %
			Proband 5	78 %
Normiert	4	9	Proband 1	100 %
			Proband 2	88 %
			Proband 3	91 %
			Proband 4	100 %
			Proband 5	86 %
Fortlaufend Normiert	4	9	Proband 1	84 %
			Proband 2	82 %
			Proband 3	84 %
			Proband 4	91 %
			Proband 5	90 %

5.4 Zeiträume

Zur Überprüfung der Robustheit der Klassifikation dreier Methoden über mehrere Tage werden zwei verschiedene Durchschnitte gebildet. Der erste umfasst alle Testsets der einzelnen Tage und ermöglicht es, im Durchschnitt die Klassifikationsgüte zu bewerten, wenn die Daten zeitlich nahe beieinander liegen und die störenden Effekte der Verschiebung von EMG-Signalen, die über einen längeren Zeitraum auftreten, keinen Einfluss haben (vgl. Kapitel 3.2.3). Dies stellt den Durchschnitt dar, wie er in vielen Veröffentlichungen verwendet wird.

Der zweite Durchschnitt wird über ein Testset gebildet, das Daten von allen sechs Tagen enthält. Durch den Vergleich der beiden Maßeinheiten ist festzustellen, ob es durch die Normierungen möglich ist, über sechs Tage einen ähnlichen guten Wert zu erreichen wie über die Einzeltage. Hierbei ist davon auszugehen, dass sich die Klassifikationsergebnisse von mehreren Tagen, gegenüber einzelnen Tagen verschlechtern. Somit erlaubt der zweite Durchschnitt es zusätzlich festzustellen, wie groß der Rückgang ist und wie sich die Klassifikation über einen größeren Zeitraum durch die Normierung verhält.

5.4.1 Zeitliche Stabilität von drei Gesten mit zwei Merkmalen

Abbildung 5.19 stellt den erreichten F_1 -Score der drei Methoden dar, für jeweils einen Tag und für alle sechs Tage zusammen. Die Verwendung der normierten Methoden führt bei gleichen Parametern zu einer Verbesserung des F_1 -Scores, sowohl für die Testsets über einzelne Tage als auch über alle sechs Tage. Im Vergleich zur Standardmethode können durch die Normierungen bis zu 20 %P dazugewonnen werden, wie in Tabelle 5.6 zu erkennen ist.

Für die drei Methoden ergibt sich eine Stufenfunktion für die einzelnen Tage, bei der die Standardmethode das schlechteste und die fortlaufende Normierung das beste Ergebnis erzielt. So liegt die Standardmethode im Median bei 82 %. Die Normierung (90 %) und die fortlaufende Normierung (89 %) liegen hingegen in etwa gleich auf.

Für das Testset über sechs Tage übertreffen beide Normierungsmethoden die Standardmethode, wobei für die fortlaufende Normierung insbesondere das Q_{25} besser abschneidet als bei der normierten Methode. Die Ergebnisse zeigen, dass die Klassifikationsergebnisse bei Verwendung der Standardmethode sowie bei beiden Normierungsmethoden robust gegenüber einer Erweiterung der Anzahl an Tagen sind.

Die Verbesserung durch beide Normierungsmethoden kann auch für die drei Metriken ACC, TPR und TNR bestätigt werden, wie in Tabelle 5.7 dargestellt. Das Delta der drei Metriken ist in der Tabelle spaltenweise farbig nach Häufigkeit markiert, wobei gilt, je größer der Unterschied, desto dunkler ist die Markierung. Dabei ist festzustellen, dass das Delta für jede Metrik positiv und für die fortlaufende Normierung sowohl für Einzeltage als auch für sechs Tage mit 6 – 11 %P am größten ist.

Zusammenfassend kann für drei Gesten und zwei Merkmale festgehalten werden, dass die Klassifikation bei Verwendung von Daten über mehrere Tage im Vergleich zu einem einzelnen Tag erwartungsgemäß erschwert wird. Dennoch kann die Normierung die Robustheit der Klassifikation steigern, wie durch die geringere Varianz der Klassifikationsergebnisse gezeigt wird. Die Standardabweichung beider Testsets ist ebenfalls gering, was zusätzlich auf eine gute Robustheit hindeutet.

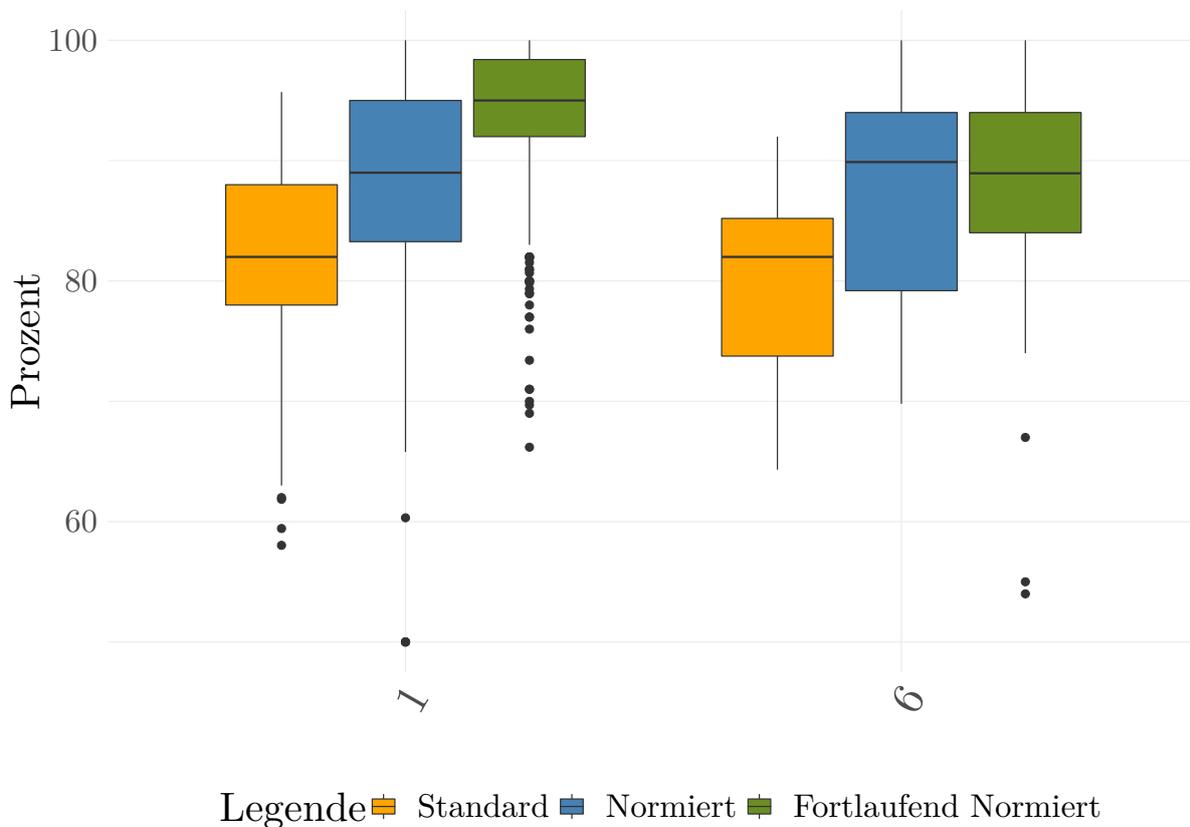


Abbildung 5.19: Erreichte F_1 -Scores mit drei unterschiedlichen Methoden für drei Gesten, zwei Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: SVMQuadratic, BaggedTree, SVMFineGaussian, NN und CNN

5.4.2 Zeitliche Stabilität von drei Gesten mit vier Merkmalen

Abbildung 5.20 zeigt den Boxplot der F_1 -Scores für die Tagestestsets. Es ist deutlich zu erkennen, dass Gesten mit beiden Normierungsmethoden sowohl für Einzeltage als auch für längere Zeiträume besser zu unterscheiden sind. Die Normierung erreicht einen F_1 -Score von 95 % und die fortlaufende Normierung erreicht sogar 98 %. Wenn der Zeitraum auf sechs Tage erhöht wird, bleibt die Normierung stabil und die fortlaufende Normierung reduziert sich leicht auf 96 %. Trotzdem liegt der erreichte F_1 -Score immer noch leicht über dem der Normierung und deutlich über dem der Standardmethode. Das Q_{25} zeigt für beide Testsets mit den drei Methoden eine Stufenfunktion. Dabei liegt das Q_{25} in etwa auf Höhe des Q_{50} der vorhergehenden Methode. Die Reihenfolge lautet Standard < Normiert < fortlaufend Normiert.

Wie erwartet übertreffen die F_1 -Scores mit vier Merkmalen diejenigen mit nur zwei Merkmalen (siehe Tabelle 5.6).

Die fortlaufende Normierung bleibt im vorherigen Abschnitt bei der Betrachtung von sechs Tagen hinter der Normierung zurück. Dies ändert sich durch das Hinzufügen von weiteren Merkmalen

5 Verifikation und Validierung

wie der ApEn und der AR. So erreicht die fortlaufende Normierung unter Berücksichtigung von sechs Tagen einen F_1 -Score von 96 %, was deutlich über dem Wert der Standardmethode und leicht über dem Wert der normierten Methode liegt.

Die höhere Klassifikationsgüte der Normierungsmethoden zeigt sich auch an den Ergebnissen der Metriken ACC, TPR und TNR (siehe Tabelle 5.7). Es ist zu erkennen, dass alle drei Metriken für einzelne Tage deutlich ansteigen und für die Normierung ein hohes Niveau zwischen 89 % und 95 % erreichen. Die fortlaufende Normierung übertrifft dies noch einmal mit Werten zwischen 96 % und 98 %. Für sechs Tage ist dieser Trend ebenfalls zu beobachten. Durch die Verwendung von vier Merkmalen gelingt eine bessere Klassifikation als mit nur zwei Merkmalen. Beispielfähig sei hier die fortlaufende Normierung erwähnt, welche für die TPR, TNR und ACC Werte zwischen 92 % und 96 % erreicht (siehe Tabelle 5.7).

Zusammenfassend kann festgestellt werden, dass die Klassifikationsgüte von drei Gesten mit vier Merkmalen für alle drei Methoden wie erwartet am höchsten ist. Außerdem bleiben die Werte der Quantile Q_{25} , Q_{50} und Q_{75} zwischen einem Tag und sechs Tagen für die Standard- und die normierte Methode sehr stabil. Für die fortlaufende Normierung steigt zwar der Abstand zwischen Q_{25} und Q_{75} , aber die Standardabweichung reduziert sich, da es zu weniger Ausreißern kommt. Insgesamt erzielt die fortlaufende Normierung die besten Ergebnisse sowohl bei der Betrachtung eines Tages als auch bei sechs Tagen.

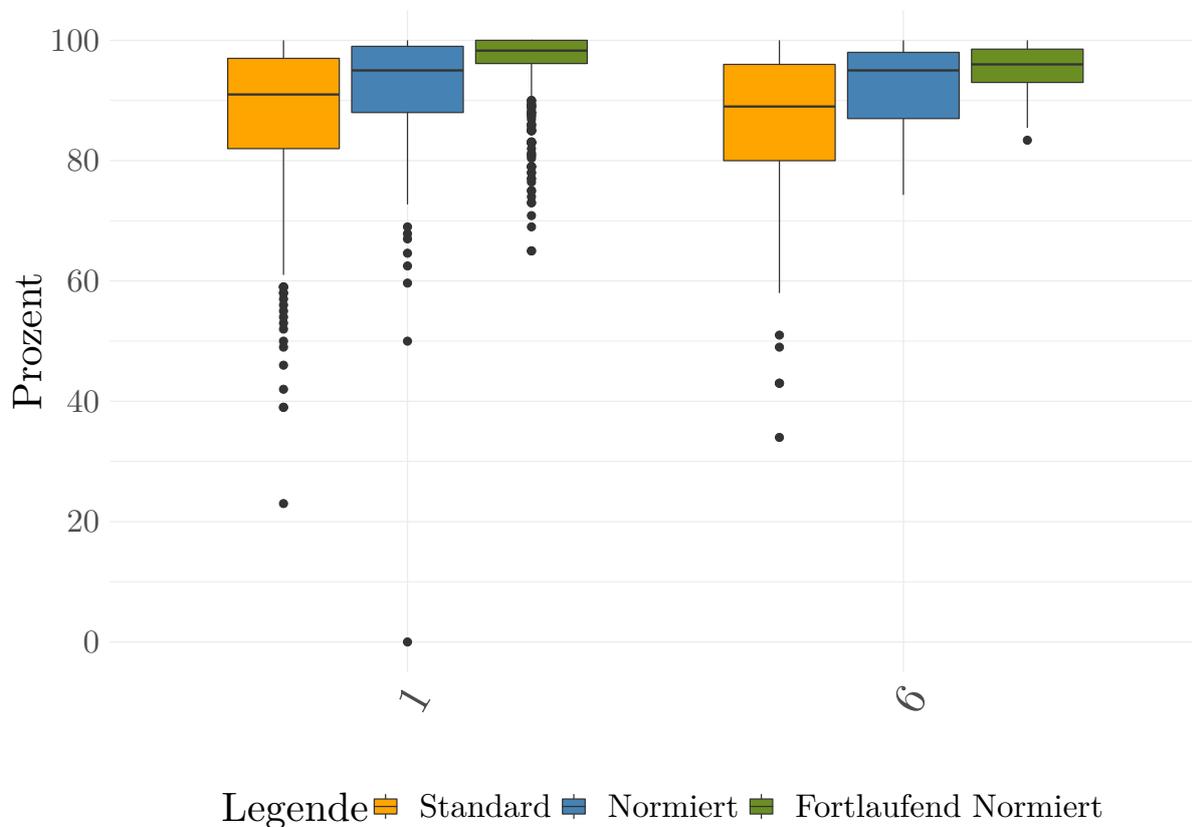


Abbildung 5.20: Erreichter F_1 -Score mit drei unterschiedlichen Methoden für drei Gesten, vier Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: CNN, BaggedTree, SVMCubic, SVMFineGaussian und SVMMediumGaussian

5.4.3 Zeitliche Stabilität von neun Gesten mit zwei Merkmalen

Die normierten Methoden erzielten sowohl für einzelne Tage als auch für alle sechs Tage für neun Gesten einen höheren F_1 -Score als die Standardmethode (siehe Abbildung 5.21). Allerdings zeigt sich über sechs Tage ein deutlicher Abfall aller drei Methoden im Vergleich zu einem Tag. Während die Standardmethode auf 45 % abfällt (siehe Tabelle 5.6), bleiben die Normierungen zwar unter dem 82-%-Schwellwert aus Abschnitt 5.2.1 jedoch deutlich über der 60-%-Marke. Der Median über die Einzeltage überschreitet diesen ebenfalls nicht. Der F_1 -Score liegt hier allerdings nur noch 7 %P unter dem Schwellwert bei 75 %, sodass anzunehmen ist, dass durch Hinzunahme weiterer Merkmale der Schwellwert von 82 % übertroffen werden kann.

Dass sich die Klassifikationsgüte mit neun Gesten insgesamt verschlechtert, ist auch an der Sensitivität in Tabelle 5.7 zu erkennen. Sie fällt auf 57 %, was insbesondere im Vergleich mit dem Stand der Technik (83 % 3 Gesten 2 Merkmale) eine deutlich Verschlechterung ist (siehe Tabelle 5.7). Die Genauigkeit und Spezifität sind hingegen bei neun Gesten fast unverändert oder sogar leicht (1 – 2 %P) verbessert gegenüber der Berücksichtigung von drei Gesten.

5 Verifikation und Validierung

Folglich führen beide Normierungen auch für die Kombination aus neun Gesten und zwei Merkmalen über einen längeren Zeitraum zu einer verbesserten Klassifikationsgüte im Vergleich zur Standardmethode. Die beiden Normierungsmethoden ermöglichen es den Klassifikatoren, eine präzisere und zuverlässigere Trennung zwischen den Gesten vorzunehmen, was zu höheren F_1 -Scores und einer insgesamt besseren Klassifikationsleistung führt. Dies ist besonders bemerkenswert, da die Kombination aus einer erhöhten Anzahl von Gesten und einem reduzierten Merkmalsraum normalerweise eine große Herausforderung darstellt und zum Abfall der Klassifikationsgüte führt. Die fortlaufende Normierung bietet somit eine vielversprechende Methode, um die Genauigkeit und Robustheit von Prothesensystemen über einen längeren Zeitraum zu verbessern und eine präzisere Steuerung von Prothesen für Benutzer zu ermöglichen.

Jedoch lässt die geringere Leistung der Normierungsmethoden im Vergleich zum Schwellwert von 82 % des derzeitigen Stands der Technik vermuten, dass ungeeignete Merkmale zum Einsatz gekommen sind. So könnte z. B. die AR nicht optimal geeignet sein, um die Gesten in ihrer Variabilität und Unterscheidbarkeit adäquat mit der Normierung zu erfassen. Dies könnte zu einer begrenzten Fähigkeit der Normierungsmethoden führen, die Gesten korrekt zu klassifizieren.

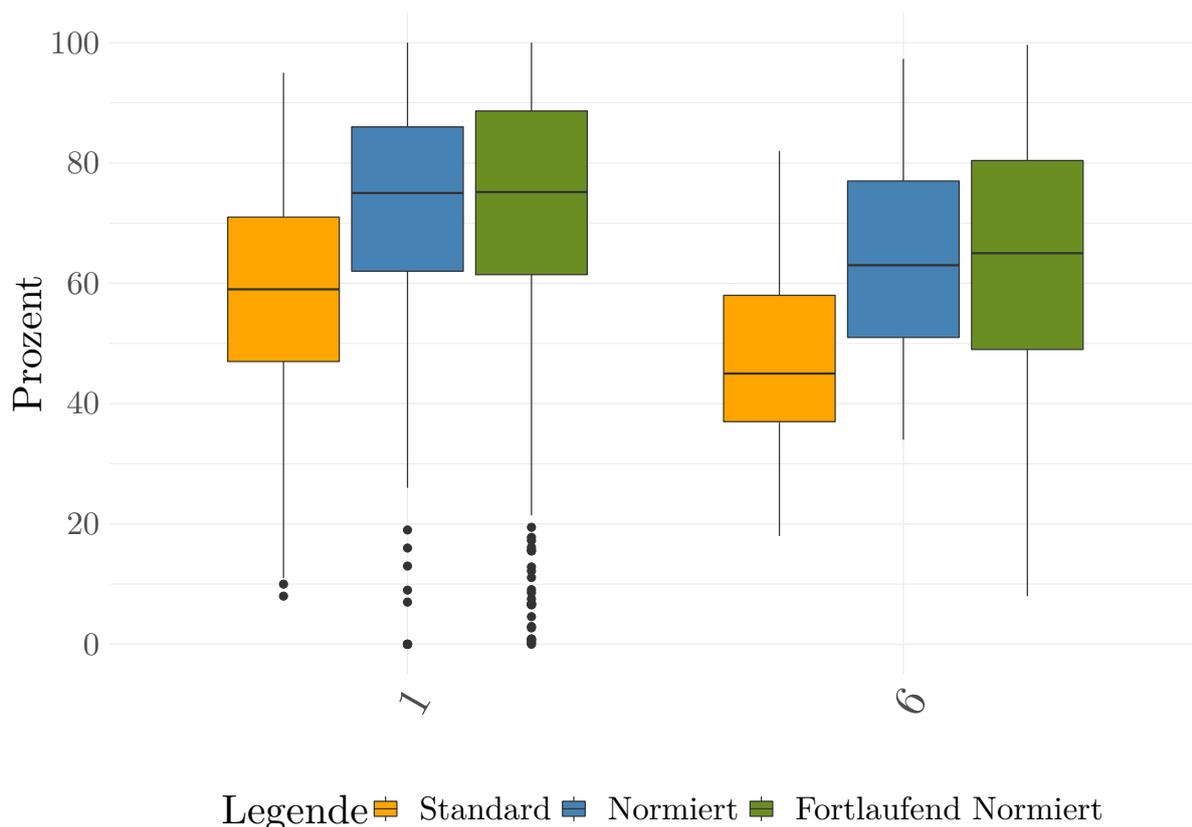


Abbildung 5.21: Erreichter F_1 -Score mit drei unterschiedlichen Methoden für neun Gesten und zwei Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage. Ergebnisse der besten Klassifikatoren: SVMFineGaussian, SVMQuadratic, SVMMediumGaussian, Recur6 und CNN.

5.4.4 Zeitliche Stabilität von neun Gesten mit vier Merkmalen

Durch die Nutzung von vier statt zwei Merkmalen lässt sich eine bessere Trennung von neun Gesten auch über mehrere Tage hinweg erreichen (siehe Abbildung 5.22).

Bei Betrachtung der EMG-Signale von einzelnen Tagen übersteigen die F_1 -Scores der Normierungen (86 % und 83 %) den Schwellwert von 82 %. Jedoch bleiben die Ergebnisse für das Testset mit allen sechs Tagen mit 75 % und 77 % hinter diesen Werten zurück.

Durch beide Normierungen können die ACC-Werte, wie in den vorherigen Untersuchungen, für beide Tagessets verbessert werden. Beim Vergleich zwischen drei und neun Gesten bleibt bei den beiden Normierungsmethoden diese Metrik unverändert (88 %, 6 Tage), obwohl Sensitivität und Spezifität abnehmen.

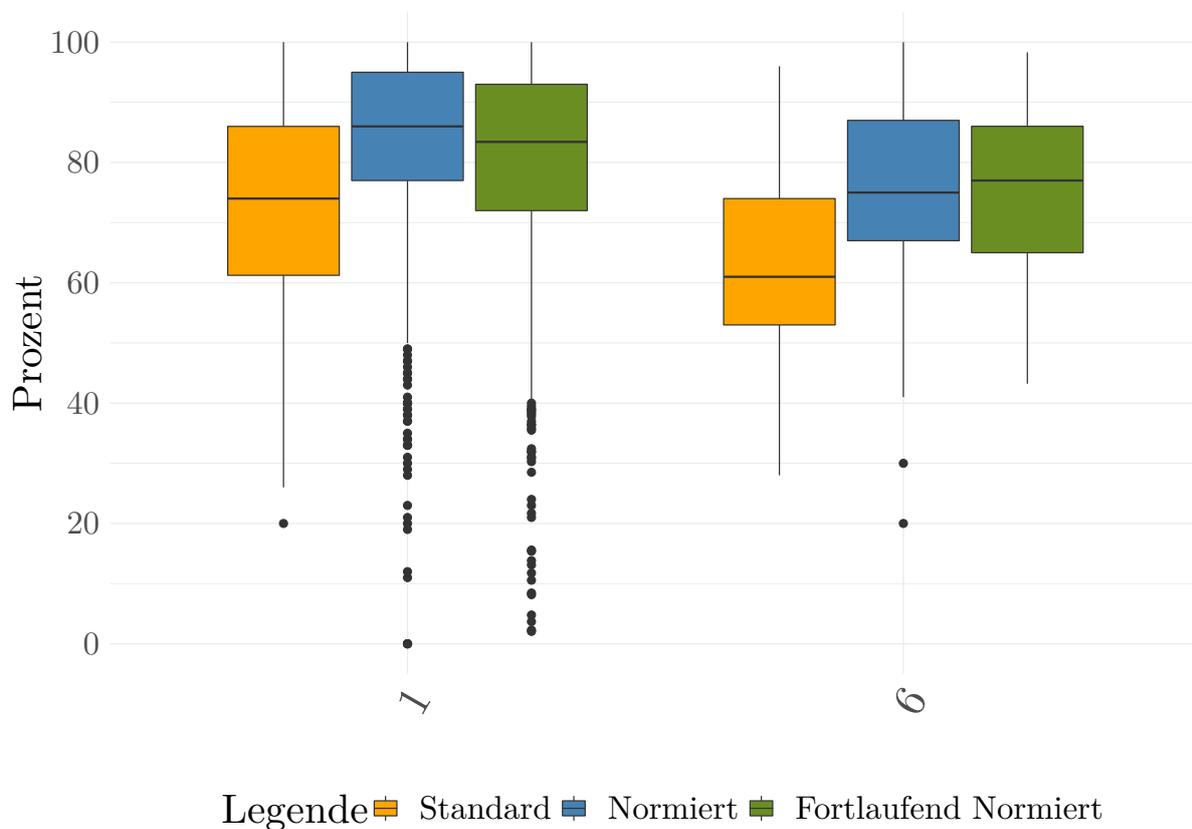


Abbildung 5.22: Erreichter F_1 -Score mit drei unterschiedlichen Methoden für neun Gesten und vier Merkmale über einen Aufnahmetag sowie sechs Aufnahmetage.

Ergebnisse der besten Klassifikatoren: CNN, BaggedTree, SVMCubic, SVMFineGaussian und SVMMediumGaussian.

5.4.5 Zwischenfazit zeitliche Stabilität

Die Ergebnisse zeigen, dass die beiden normierten Methoden in allen vier Untersuchungen besser abschneiden als die Standardmethode. Allerdings stellen neun Gesten bei der Betrachtung eines Zeitraumes von sechs Tagen selbst für die beiden neuen Methoden eine Herausforderung dar. Ein Grund hierfür könnte darin liegen, dass sich einzelne Gesten unterschiedlich gut von einander trennen lassen. Eine Vorauswahl dieser Gesten könnte daher zu einer deutlichen Steigerung der Klassifikationsgüte beitragen. Im nächsten Abschnitt wird dies genauer untersucht.

Tabelle 5.6: Median der besten fünf Klassifikatoren, verglichen mit dem Ergebnis der Standardmethode und dem F_1 -Score der Normierungsmethoden je Tagestestset.

Verfahren	Anz. Tage	Anz. Gesten	Anz. Merkmale	Q_{50}	σ	ΔQ_{50}
Standard	1	3	2	82	7,2	-
		3	4	91	9,9	-
		9	2	59	16,5	-
		9	4	74	15,7	-
	6	3	2	82	7,4	-
		3	4	89	11,7	-
		9	2	45	15,2	-
		9	4	61	15,0	-
Normiert	1	3	2	89	8,7	7
		3	4	95	7,6	4
		9	2	75	17,4	16
		9	4	86	15,3	12
	6	3	2	90	8,5	8
		3	4	95	6,0	6
		9	2	63	15,3	18
		9	4	75	14,6	14
Fortl. Normiert	1	3	2	95	5,8	13
		3	4	98	6,9	7
		9	2	75	19,5	16
		9	4	83	16,2	9
	6	3	2	89	9,1	7
		3	4	96	3,8	7
		9	2	65	20,0	20
		9	4	77	13,3	16

Tabelle 5.7: Durchschnittswerte der Metriken Sensitivität, Spezifität und Genauigkeit sowie dem Δ zur Standardmethode von einem Aufnahmetag und sechs Aufnahmetagen jeweils über alle Probanden. Ergebnisse der fünf besten Klassifikatoren für die Permutation aus Anzahl Gesten und Merkmalen

Anz. Tage	Verfahren	Anz. Merkmale	Anz. Gesten	TPR	TNR	ACC	Δ TPR	Δ TNR	Δ ACC
1	Normiert	2	3	87	94	91	4	3	3
1	Fortl. Normiert	2	3	94	97	96	11	6	8
6	Normiert	2	3	83	91	88	3	1	4
6	Fortl. Normiert	2	3	89	94	92	9	4	8
1	Normiert	4	3	89	95	93	4	3	3
1	Fortl. Normiert	4	3	96	98	97	11	6	7
6	Normiert	4	3	89	95	92	5	3	3
6	Fortl. Normiert	4	3	92	96	93	8	4	4
1	Normiert	2	9	66	96	92	10	2	2
1	Fortl. Normiert	2	9	69	96	92	13	2	2
6	Normiert	2	9	57	95	91	11	2	3
6	Fortl. Normiert	2	9	57	95	90	11	2	2
1	Normiert	4	9	70	96	87	6	0	2
1	Fortl. Normiert	4	9	70	96	88	6	0	2
6	Normiert	4	9	60	96	89	6	1	2
6	Fortl. Normiert	4	9	54	94	88	-1	$-5 \cdot 10^{-1}$	$5 \cdot 10^{-1}$

Ende der Tabelle

5.5 Gesten

In diesem Abschnitt wird untersucht, wie sich die Ergebnisse für die einzelnen Gesten durch die Standard- und die beiden Normierungsmethoden unterscheiden, wenn entweder zwei oder vier Merkmale zur Unterscheidung von drei beziehungsweise neun Gesten verwendet werden. Dabei wird besonders der F_1 -Score berücksichtigt, da dieser eine differenzierte Bewertung ermöglicht und die Unterschiede zwischen den verschiedenen Ergebnissen deutlich hervorhebt. Tabelle 5.8 zeigt den F_1 -Score als Median jeder Geste pro Normierungsmethode sowie das Delta zur Standardmethode mit gleicher Anzahl an Merkmalen und zu klassifizierenden Gesten. Der Median für die Gesten Extension, Faust und Flexion mit zwei Merkmalen reicht von 80 % bis 87 %, was als akzeptabel betrachtet werden kann. Zur Bewertung der erreichten Werte der Gesten wird der Schwellwert auf 80 % gesetzt. Gesten, die diesen Schwellwert nicht erreichen, sind orange hinterlegt, während Werte, die darüber liegen, grün markiert sind. Die Vergleichswerte, die dem Stand der Technik entsprechen, sind blau ausgezeichnet. Die Spalte ΔQ_{50} zeigt das Delta des erreichten F_1 -Scores im Vergleich zur Standardmethode mit gleicher Anzahl an Gesten und Merkmalen.

5 Verifikation und Validierung

Abbildung 5.23 vergleicht den F_1 -Score für drei Gesten bei Verwendung von zwei und vier Merkmalen für die drei Methoden. Es zeigen sich für beide Fälle klare Unterschiede. Die fortlaufende Normierung erzielt bereits mit zwei Merkmalen einen Median- F_1 -Score von 93 – 96 % und mit vier Merkmalen von 98 – 99 %, was eine nahezu perfekte Unterscheidung der Gesten bedeutet. Die Geste Faust lässt sich mit allen Methoden am besten klassifizieren (siehe Tabelle 5.8). Auch die Standardabweichung ist bei allen drei Methoden am geringsten, was diese zur am besten unterscheidbaren Geste macht.

Die fortlaufende Normierung erhöht den Median des F_1 -Scores für alle Gesten, während die Standardabweichung auf einem ähnlich geringen Niveau wie bei der Standardmethode bleibt. Beide Normierungsmethoden übertreffen den Vergleichsmaßstab mit zwei Merkmalen für jede Geste. Dabei sind Zuwächse von bis zu 16 %P zu verzeichnen (siehe Tabelle 5.8). Die Klassifikationsgüte verbessert sich somit deutlich für jede untersuchte Geste.

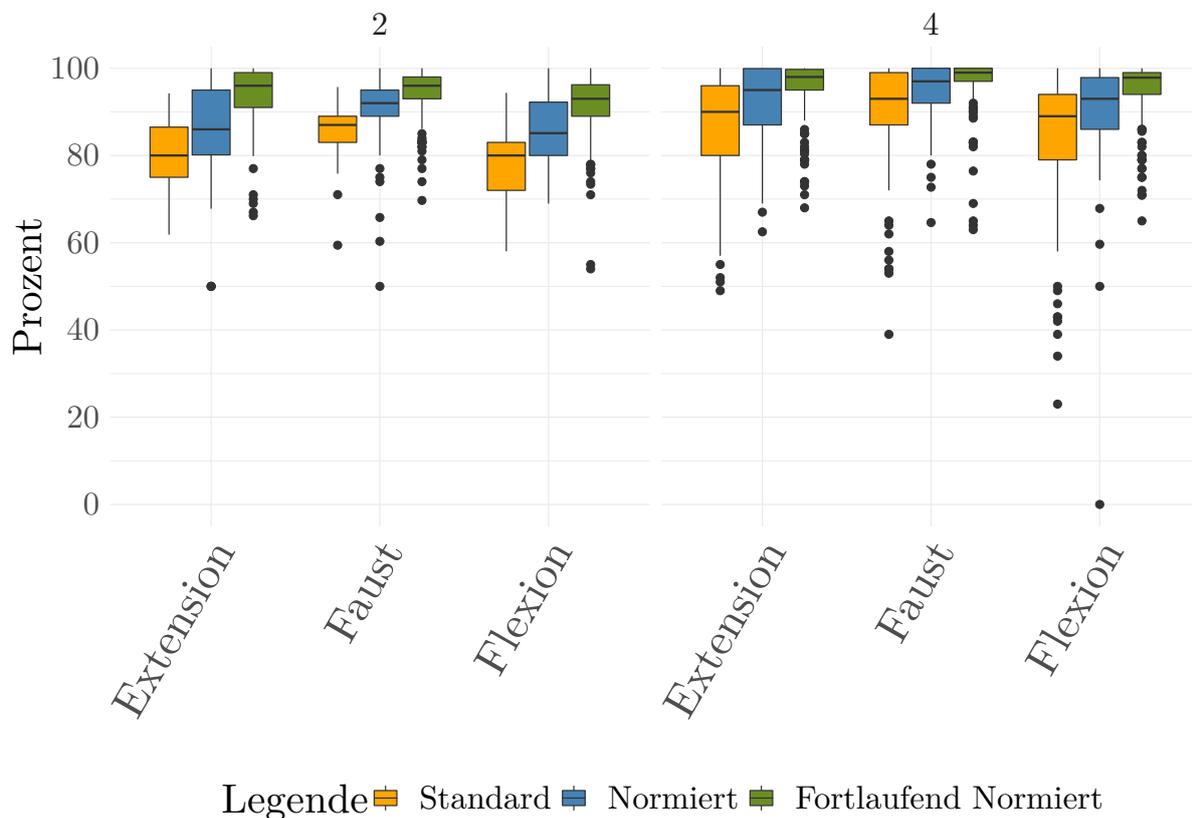


Abbildung 5.23: Gegenüberstellung der erreichten F_1 -Scores von drei unterschiedlichen Methoden, für drei Gesten mit zwei bzw. vier Merkmalen. Verwendete Klassifikatoren: SVMCubic, SVMQuadratic, BaggedTree, NN und CNN.

Die Ergebnisse der Klassifikation von neun Gesten zeigen die gleichen Trends wie die vorherigen Experimente. Die beiden Normierungsmethoden und die Erweiterung der Merkmalsvektoren führen zu einer Verbesserung des F_1 -Scores für jede Geste. Abbildung 5.24 zeigt die Verteilung der F_1 -Scores für jede Methode und jede Geste. Es fällt auf, dass die Geste Faust nicht mehr die beste Klassifikationsgüte aufweist. Stattdessen wurden die Gesten Extension und Flexion deutlich besser unterschieden (siehe Tabelle 5.8). Der Grund dafür besteht darin, dass bei diesen Gesten jeweils nur ein Sensor eine hohe Aktivität zeigt, während bei den anderen Gesten beide Sensoren eine relativ niedrigere Aktivität zeigen. Dies macht es schwieriger, die Gesten voneinander abzugrenzen. Die Normierungsmethoden helfen, die Unterschiede zwischen den Sensoren zu verstärken und somit die Klassifikationsgüte zu erhöhen.

Die Analyse zeigt, dass die Standardmethode zur Erkennung von Gesten mit zwei Merkmalen für die Steuerung von Prothesen nur eingeschränkt geeignet ist. Die Gesten Extension und Flexion erreichten einen F_1 -Score von 72 % und 77 %, während die anderen Gesten bis zu 20 % schlechter abschnitten. Diese beiden Gesten sind daher die einzigen, die für die Prothesensteuerung in Betracht gezogen werden können.

Hingegen erreichen durch Normierung die Gesten Extension und Flexion sowie Faust, OK, Pronation und Supination Werte von über 70 %, wobei Extension und Flexion sogar deutlich über den geforderten 80 % liegen. Dadurch ist eine sichere Klassifikation von zwei Gesten sowie eine Erweiterung auf sechs Gesten möglich. Durch das Entfernen von Gesten, welche 70 % des F_1 -Scores nicht erreichen, ist es möglich, die Klassifikationsgüte für andere Gesten zu erhöhen.

Für die fortlaufende Normierung überschreiten die drei Gesten Extension, Flexion und Supination 80 %. Die Gesten Faust, OK und Pronation erreichen einen über F_1 -Score von über 70 %, während die Geste Kokontraktion knapp darunter liegt. Somit sind drei Gesten sicher klassifizierbar und eine Erweiterung ist möglich. Bei einer Reduktion der Anzahl an Gesten sollte jedoch berücksichtigt werden, dass der erreichte Wert der Kokontraktion nach Entfernen der schlechter zu trennenden Gesten möglicherweise über die 70 %-Marke steigt. Dies ist in zukünftigen Arbeiten zu prüfen.

Die Ergebnisse der Standardmethode zeigen, dass die Gestenklassifikation mit vier Merkmalen für einige Gesten sehr gut funktioniert, während andere Gesten weniger gut erkannt werden. Die Gesten Extension, Flexion und Supination erreichen einen hohen F_1 -Score von über 80 %, was den Erwartungen aus Abschnitt 2.6 entspricht. Drei weitere Gesten liegen bei 70 %, was noch akzeptabel ist.

Die Normierung verbessert die Klassifikationsleistung deutlich. Sieben Gesten überschreiten die 80 %-Schwelle, nur die Geste Thumb-Up bleibt mit 79 % knapp darunter. Die Geste Index schafft es auf 70 %, was eine mögliche Erweiterung des Gestensets auf acht oder neun Gesten nahelegt. Allerdings könnte es nötig sein, weitere Anpassungen vorzunehmen, wie zum Beispiel die Reduktion der Geste Index oder die Hinzufügung weiterer Merkmale.

Die fortlaufende Normierung führt zu einer weiteren Verbesserung der Klassifikationsleistung. Sechs Gesten haben einen F_1 -Score von mehr als 80 % und die restlichen drei Gesten liegen bei mindestens 70 %. Damit ist eine Klassifikation von bis zu neun Gesten möglich, die für eine Steuerung verwendet werden können.

Insgesamt erreichen sowohl die Normierung als auch die fortlaufende Normierung mit neun Gesten Werte, welche die der Standardmethode mit lediglich drei Gesten weit übertreffen.

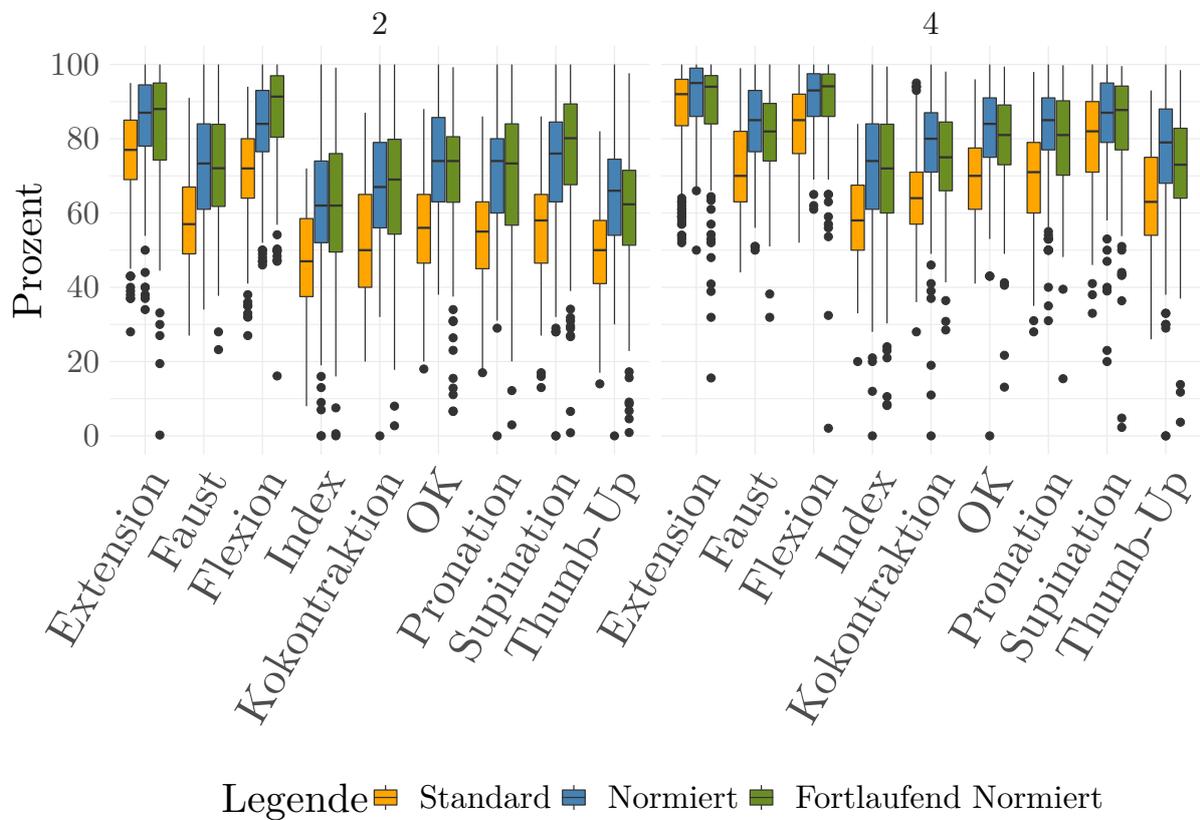


Abbildung 5.24: Erreichter F_1 -Score der Probanden mit den drei unterschiedlichen Methoden. Klassifiziert wurden neun verschiedene Gesten.

Tabelle 5.8: Vergleich des Medians des besten Klassifikators und des Standes der Technik nach F_1 -Score für verschiedene Normierungsmethoden

Verfahren	Anz. Merkmale	Geste	Q_{50}	ΔQ_{50}	σ
Standard	2	Extension	80	-	7,6
		Faust	87	-	4,3
		Flexion	80	-	7,1
Normiert	2	Extension	86	6	9,9
		Faust	92	5	6,6
		Flexion	85	5,1	8,3
Fortl. Normiert	2	Extension	96	16	6,7
		Faust	96	9	5,3
		Flexion	93	13	7,4
Standard	4	Extension	90	-	9,9
		Faust	93	-	8,7
		Flexion	86	-	11
Normiert	4	Extension	95	5	7,2
		Faust	97	4	5,4
		Flexion	93	4	8,7
Fortl. Normiert	4	Extension	98	8	6,5
		Faust	99	6	6,2
		Flexion	98	8,8	6,8
Standard	2	Extension	77	-	14,5
		Faust	57	-	14
		Flexion	72	-	13,5
		Index	47	-	14,1
		Kokontraktion	50	-	15,8
		OK	56	-	14,1
		Pronation	55	-	14,6
		Supination	58	-	14,3
		Thumb-Up	50	-	13,2
		Normiert	2	Extension	87
Faust	73			16,3	14,9
Flexion	84			12	12,8
Index	62			15	19,3
Kokontraktion	67			17	16,7
OK	74			18	15,2
Pronation	74			19	15,5
Supination	76			18	18,3
Thumb-Up	66			16	16,6

Weiter auf nächster Seite

5 Verifikation und Validierung

Tabelle 5.8 fortgeführt von der vorhergehenden Seite

Verfahren	Anz. Merkmale	Geste	Q_{50}	ΔQ_{50}	σ
Fortl. Normiert	2	Extension	88	11	17,5
		Faust	72	15	15,6
		Flexion	91	19,3	14,1
		Index	62	15	19,4
		Kokontraktion	69	19	18,5
		OK	74	18	18,5
		Pronation	73	18,3	19,6
		Supination	80	22,1	18,8
		Thumb-Up	62	12,3	19,5
Standard	4	Extension	92	-	12,6
		Faust	70	-	13,8
		Flexion	85	-	12
		Index	58	-	12,5
		Kokontraktion	64	-	13,9
		OK	70	-	11,7
		Pronation	71	-	13,9
		Supination	82	-	13,9
		Thumb-Up	63	-	15,3
Normiert	4	Extension	95	3	9,2
		Faust	85	15	11,6
		Flexion	93	8	8,3
		Index	74	16	18,4
		Kokontraktion	80	16	16,1
		OK	84	14	13,8
		Pronation	85	14	13,6
		Supination	87	5	14,4
		Thumb-Up	79	16	18,3
Fortl. Normiert	4	Extension	94	2	14,3
		Faust	82	12	11,7
		Flexion	94	9,1	12,4
		Index	72	14	18,1
		Kokontraktion	75	11	14,2
		OK	81	11	13,9
		Pronation	81	10	13,7
		Supination	88	5,7	15,7
		Thumb-Up	73	10	15,9

Ende der Tabelle

5.6 Diskussion

Die Ergebnisse zeigen deutlich, dass sich sowohl durch die einfache als auch durch die fortlaufende Normierung die Klassifikationsgüte für alle Klassifikatoren verbessert. Insbesondere lassen sich neun Gesten mit Hilfe der vier verwendeten Merkmale mit der Normierung besonders erfolgreich klassifizieren. Durch die einfache Normierung entsteht allerdings der Nachteil, dass eine Durchführung erst mit Abschluss der Bewegung einer Geste möglich ist und damit eine deutliche Verzögerung zwischen Ausübung der Geste und der resultierenden Ansteuerung einer Prothese auftritt. Daher ist diese Methode für eine kommerzielle Prothesensteuerung nicht geeignet.

Durch die Normierung bilden Gesten charakteristische Körper im Merkmalsraum, welche sich bei einer geeigneten Visualisierung klar unterscheiden. Dadurch ist es erstmals möglich, die Veränderung einer Geste, die sich bei unterschiedlichen Aufnahmetagen oder durch Muskeler-schöpfung ergibt, anschaulich darzustellen, was zu einem verbesserten Verständnis aber auch zu neuen Forschungsfragen führt. Bei den neuen Verfahren ist besonders bemerkenswert, dass die Berechnung der Normierung nur einen unwesentlich höheren Rechenaufwand als die Standardmethode benötigt. Es kommt nur die Normalisierung der Daten nach Abschluss der Bewegung sowie das Hinzufügen und Berechnen einer fortlaufenden Nummer für die Zeitreihe dazu.

Das neue Verfahren ermöglicht es auch für jeden Probanden eine eigene Normierungsgröße zu bestimmen, was die Klassifikationsergebnisse noch weiter verbessert. Dabei wird für jeden Probanden individuell festgelegt, in wie viele Zeitabschnitte ein Signal zu unterteilen ist. Orthopädiemechaniker könnten so beim individuellen Prothesenfitting die optimale Normierungsgröße berücksichtigen.

Um den Nachteil zu beseitigen, dass durch die Normierung erst am Ende einer Bewegung die Klassifikation durchgeführt werden kann, wurde die fortlaufende Normierung entwickelt. Für diese nimmt die Klassifikationsgüte für Diskriminanzanalysen und einfache Baumklassifikatoren deutlich ab, sodass diese ungeeignet sind. Ein Grund hierfür könnte darin liegen, dass durch die fortlaufende Normierung die Dimensionalität der Daten deutlich ansteigt.

Im Vergleich zur Standardmethode beinhalten die beiden Normierungsmethoden zusätzliche Berechnungsschritte. Zum einen erfolgt die Normierung der Daten auf eine bestimmte Anzahl von Zeitabschnitten, zum anderen werden Informationen für zwei fortlaufende Nummern berücksichtigt. Die erste Nummer identifiziert den Zeitabschnitt, der den berechneten Merkmalen zugeordnet ist, während die zweite Nummer angibt, zu welchem fortlaufenden Normierungsschritt der Datensatz gehört. Die fortlaufende Normierung wird kontinuierlich bis zum Ende einer Bewegung durchgeführt.

Die daraus resultierende Matrix wächst somit nach jedem Normierungsschritt in ihrer Länge an und damit vergrößert sich auch der Datensatz. Dies spricht dafür, dass einfache Klassifikatoren bei der Bestimmung einer Bewegung an ihre Grenzen stoßen (siehe Abschnitt 5.2.3).

Im Vergleich mit der einfachen Normierung führt die fortlaufende Normierung nicht zwingend zu einem höheren F_1 -Score. Sind jedoch nur wenige Gesten zu trennen, so steigt die Klassifikationsgüte mit dieser Methode sehr deutlich gegenüber der Normierung an. Für neun Gesten ist dies nicht mehr für jeden Fall zu beobachten.

Während, wie bereits erläutert, die Rechenleistung für die fortlaufende Normierung kaum höher ist als für die Normierung, steigt der Speicherbedarf für die fortlaufende Normierung deutlich. Für die Standardmethode gilt ein Speicherbedarf von $O(1)$, da die Fenstergröße ws konstant ist. Die Normierung benötigt entsprechend der Normierungsgröße N einen Speicherbedarf von $O(N)$. Da die fortlaufende Normierung alle bisher entstandenen Daten bereit hält, folgt daraus

ein Speicherbedarf von $O(N * b)$.

Solange $b < N$ gilt, wächst die Funktion des Speicherbedarfs jeweils langsamer als $O(N^2)$. In Abschnitt 5.2.4 wurde gezeigt, dass die fortlaufende Normierung bereits nach sieben Intervallen frühzeitig beendet werden kann. Bei einer Verwendung von lediglich drei Gesten kann dies bereits nach drei Intervallen geschehen, sodass $b \leq 7$ gilt. Da für die Normierungsgröße $13 \leq N \leq 16$ gilt (siehe Abschnitt 5.1), ist von der Gültigkeit der getroffenen Annahme $O(N * b) < O(N^2)$ bezüglich des Speicherbedarfs auszugehen.

Jedoch gilt auch $O(N * b) \geq O(1)$, sodass eine kommerzielle Prothese zur Nutzung der fortlaufenden Normierung deutlich mehr Speicherplatz benötigt als bisher, um die Daten bis zum Ende der Bewegung zwischenspeichern zu können.

5.7 Abgrenzung zum Zeitstempelmerkmal

Eine grundlegende Methode zur Klassifikation von Gesten wurde von Attenberger [3] eingeführt. Für die Berechnung bestimmt Attenberger eine fortlaufende ID für jedes Element des Merkmalvektors eines Signals. Anschließend gilt $TS = ID / (n - 1)$, wodurch TS im Wertebereich $[0, 1]$ liegt. Das so bestimmte TS-Merkmal ähnelt der in dieser Arbeit vorgestellten Normierung in dem Sinne, dass beide Verfahren sicherstellen, dass alle Signale nach der Anwendung eine gemeinsame Länge aufweisen. Beide Methoden verwenden Wertepaare von berechneten Merkmalen W_{ID} von W_0 bis W_n .

Der Hauptunterschied besteht in der Interpretation der betrachteten Zeitpunkte. Da die Fenstergröße für TS immer gleich, die Länge (l) eines Signals (S) jedoch von Bewegung zu Bewegung unterschiedlich ist, liegt das $W_{ID}(S_1)$ meistens an einer anderen Position des Bewegungsablaufs einer Geste auf dem Zeitstrahl als das $W_{ID}(S_2)$. Das heißt, dass die Wertepaare von einem Zeitpunkt W_{ID} , welche miteinander verglichen werden, um eine Klassifikation zu ermöglichen, alle an leicht unterschiedlichen Zeitpunkten der eigentlichen Bewegung liegen. Wenn zum Beispiel $n(S_1) = 8$ und $n(S_2) = 7$ ist, dann ist $TS_1(S_1) = 0,125 \neq TS_1(S_2) = 0,142$. Das TS vergleicht daher Wertepaare miteinander, die an unterschiedlichen Stellen der Bewegung liegen. Die vorgestellte Normierungsmethode hingegen verändert die Fenstergröße (w) in Abhängigkeit der Normierungsgröße (N), sodass $w = \lfloor l/N \rfloor$ gilt. Somit befinden sich alle Zeitpunkte der Merkmale von Signalen am gleichen relativen Zeitpunkt.

Die Idee der fortlaufenden Normierung lässt sich auch mit dem TS-Merkmal umsetzen. Dabei sind die einzelnen Zeitbasen jedoch nur ein Ausschnitt des endgültigen Signals, das nach Abschluss der Bewegung vorliegt. Da die Fenstergröße immer gleich bleibt, tritt das erste TS genau nach einer Fensterlänge auf. Im Gegensatz dazu passt die Normierung die Fenstergröße an die Normierungsgröße an, wodurch bereits frühzeitig geeignete Informationen für eine Klassifikation zur Verfügung stehen.

6 Zusammenfassung

Zur Verarbeitung myoelektrischer Signale wurden in dieser Arbeit zwei Verfahren, die Normierung und die fortlaufende Normierung entwickelt und bewertet. Dabei zeigte sich, dass acht bzw. neun Gesten so gut unterschieden werden können, wie dies mit etablierten Methoden für drei Gesten möglich ist. Hierzu werden bei beiden Methoden die abgeleiteten Myosignale zeitlich auf gleiche Länge normiert und somit schnell und langsam ausgeführte Bewegungen gleichermaßen klassifizierbar. Dadurch wird ein zeitlicher Zusammenhang zwischen den einzelnen Messungen der Bewegung einer Geste hergestellt und damit mehr Informationen für die Klassifikation der Gesten nutzbar.

Die Auswertung zahlreicher Versuchsreihen mit 25 Klassifikatoren zeigt, dass beide Verfahren die Klassifikationsgüte für jeden der untersuchten Klassifikatoren, unabhängig davon, ob nur zwei oder mehr Merkmale zur Verfügung stehen, deutlich verbessern.

Zusätzlich bieten die Normierungsmethoden die Grundlage, um Gesten zu visualisieren und Veränderungen sichtbar zu machen. Darüber hinaus lassen sich mit beiden Verfahren EMG-Signale für Gesten und Bewegungen, welche an unterschiedlichen Tagen abgeleitet wurden, deutlich besser klassifizieren als dies mit Standardmethoden derzeit möglich ist. Dies schließt auch Beeinträchtigungen durch Einlagerungen und Muskelermüdungseffekte ein.

Für den Einsatz auf Prothesen ist die Normierung jedoch ungeeignet, da das Ende einer Bewegung festgestellt werden muss, bevor die Normierung berechnet werden kann. Für Fälle, in denen ein Effektor bereits nach ca. 100 Millisekunden ein Steuersignal erhalten soll, wurde die fortlaufende Normierung entwickelt. Dabei wird nach einem festgelegten Zeitraum die erste Normierung der bis dahin gemessenen Daten vorgenommen. Die normierten Daten werden zwischengespeichert und nach einem zweiten Zeitraum um die bis dahin neu gemessenen Daten erweitert. Darauf hin findet eine erneute Normierung und Klassifikation der erweiterten Daten statt.

Im Vergleich zur Normierung verbessert die fortlaufende Normierung nicht jeden Klassifikator, führt aber generell zu einem robusteren Klassifikationsverhalten mit kleiner Standardabweichung und einer Steigerung der Klassifikationsgüte für jeden Probanden verglichen mit der Standardmethode.

Bei der Betrachtung über mehrere Tage zeigt sich, dass die Klassifikatoren durch beide Normierungen bessere Ergebnisse erzielen als bei Verwendung der Standardmethode. Insbesondere weisen das deutlich höhere 75. Perzentil und der gesteigerte Median darauf hin, dass sowohl die einfache als auch die fortlaufende Normierung zu einer allgemein verbesserten Klassifikationsgüte über einen längeren Zeitraum führen. Dies bedeutet, dass beide Methoden auf einer Prothese über einen längeren Zeitraum ohne erneutes Training eingesetzt werden können, da sie eine größere Robustheit gegenüber tagesabhängigen Schwankungen aufweisen. Die Klassifikatoren sind in der Lage, effektivere Trennfunktionen aufzustellen, die weniger von individuellen Unterschieden oder kurzfristigen Schwankungen beeinträchtigt werden. Somit bieten sowohl die normierte Methode als auch die fortlaufende Normierung vielversprechende Ansätze zur Verbesserung der Klassifikationsgüte in der Prothesensteuerung über mehrere Tage hinweg.

6 Zusammenfassung

Auch bei der Analyse der einzelnen Gesten zeigt sich, dass sowohl einfache als auch die fortlaufende Normierung zu einer Verbesserung der Klassifikation führen. Diese neuen Methoden können auf aktuellen Prothesen eingesetzt werden, um die Genauigkeit der Klassifikation erheblich zu steigern, da alle drei Gesten (Flexion, Faust, Extension) einen signifikanten Anstieg des F_1 -Scores aufweisen. Zudem ermöglichen die beiden Normierungsmethoden den Einsatz auf neuen Prothesen, um bis zu sechs Gesten auf einem ähnlichen Niveau zu unterscheiden, wie es der derzeitige Standard für drei Gesten ermöglicht. Besonders bemerkenswert ist, dass durch die Normierungsmethoden neun unterschiedliche Gesten so gut klassifiziert werden können, wie es bisher mit der Standardmethode nur für drei Gesten möglich war. Dadurch eröffnet sich die Möglichkeit, die Anzahl der unterscheidbaren Gesten von derzeit zwei bis drei deutlich auf sechs bis neun zu erhöhen.

Diese Arbeit zeigt, dass beide Normierungsverfahren einen deutlichen Vorteil gegenüber den etablierten Standardmethoden bieten. Dies gilt sowohl für Fälle mit begrenzten Möglichkeiten zur Merkmalsberechnung als auch für die Stabilität der Klassifikation über einen längeren Zeitraum und die Klassifikation von deutlich mehr Gesten, als es mit der Standardmethode möglich ist. Die beiden Normierungsmethoden können auf allen derzeitig verfügbaren Prothesen mit zwei Sensoren eingesetzt werden, sofern diese über ausreichende Rechen- und Speicherkapazität verfügen, da hierzu keine zusätzliche Hardware oder weitere Sensoren erforderlich sind.

7 Ausblick

Weitere Untersuchungen und studentische Arbeiten haben gezeigt, dass die Klassifikationsgüte von der gewählten Normierungsgröße abhängig ist. Dabei scheint die optimale Normierungsgröße im Bereich zwischen 11 und 16 zu liegen, wobei anzunehmen ist, dass diese von den Probanden abhängig sein kann und diesbezüglich weitere Untersuchungen notwendig sind. Somit bleibt offen, ob es eine allgemeingültige Normierungsgröße für alle Probanden gibt. Ebenso bleibt zu untersuchen, ob die Normierungsgröße von der Tagesform bzw. der Muskelererschöpfung abhängt. Es ist ebenfalls anzunehmen, dass die Klassifikatoren unterschiedlich auf einzelne Normierungsgrößen reagieren.

Ein weiteres Untersuchungsfeld besteht in der Zuverlässigkeit der Klassifikation von Gesten bei Muskelermüdung und den daraus resultierend veränderten EMG-Signalen, welche tendenziell zu einer Verschlechterung der Klassifikation führen. Diese Veränderung ist auf Grundlage der Normierung besser visualisierbar. Bislang unbeantwortet ist die Frage, ob die Veränderung der EMG-Signale durch Ermüdung einem Muster folgt. Daraus ergebend kann untersucht werden, ob sich Regeln ableiten lassen, die für die Ermüdung gültig sind, um so die Klassifikation auch bei beanspruchten Muskeln mit einer hohen Klassifikationsgüte zu ermöglichen.

Neben der Veränderung, die durch die Muskelererschöpfung hervorgerufen wird, ändern sich auch die Signale und damit die normierten Körper über die verschiedenen Aufnahmetage. Die Normierung ist in der Lage, diese Veränderung aufzuzeigen. Bestünde die Möglichkeit der Vorhersage oder eine Einschränkung des Bereichs innerhalb dessen sich der Körper bewegt, so ließe sich hierdurch auch die Klassifikation noch weiter verbessern.

Ein weiterer zu untersuchender Aspekt ist, wie viele Sensoren notwendig oder sinnvoll sind, um die Anzahl an erkennbaren Gesten weiter zu erhöhen. Es bleibt zu untersuchen, welche Klassifikationsgüte die beiden normierten Methoden erreichen, wenn mehr als zwei Sensoren verwendet oder anderer Sensorprinzipien wie NIRS oder EEG einbezogen werden. Erste Versuche mit Myo-Armbändern und acht Sensoren haben einen weiteren Anstieg der Klassifikationsgüte gezeigt. Auch ein direkter Vergleich zwischen dem TS-Merkmal und den beiden Normierungen dieser Arbeit steht noch aus und ist somit Bestandteil möglicher zukünftiger Forschung.

8 Anhang

8.1 Parameter der Klassifikatoren

- Lineare Diskriminanzanalyse (LDA)

LinearDiscriminant: 'DiscrimType': 'diagLinear'; Verwendet eine möglichst diagonale lineare Trennfunktion.

QuadraticDiscriminant: 'DiscrimType': 'diagQuadratic'; Verwendet eine möglichst diagonale quadratische Trennfunktion.

SubspaceDiscriminant: Method: 'Subspace'; Aus der übergebenen Menge sind Untermengen zu bilden.

NLearn: 30; Es werden 30 Untermengen gebildet. Für jede dieser Mengen wird eine LDA erzeugt. Somit stehen am Ende 30 Klassifikatoren zur Verfügung, welche mithilfe eines Mehrheitsentscheids das Ergebnis bestimmen.

Learners: 'Discriminant'; Definiert die schwachen Lerner als LDA.

Type: 'Classification'; Da die Methode 'Subspace' angegeben wurde, muss spezifiziert werden, dass eine Klassifikation vorzunehmen ist.

- Support Vector Machine (SVM)

SVMLinear: KernelFunction: 'linear'; Es wird eine lineare Kernelfunktion genutzt.

PolynomialOrder: []; Da die Funktion linear ist, wird keine höhere Polynomordnung benötigt.

KernelScale: 'auto'; Der Matlab[®] Algorithmus für SVMs versucht hier, einen möglichst optimalen Skalierungswert zu finden.

BoxConstraint: 1; Ist ein Maß für die Bestrafung bei einer Randverletzung, um eine Überanpassung an die Trainingsdaten zu vermeiden. Je höher der Wert ist, desto weniger Unterstützungsvektoren werden verwendet. Der Standardwert ist 1.

Standardize: true; Die Spalten der Prädiktoren werden standardisiert.

SVMQuadratic: KernelFunction: 'polynomial'; Es wird eine polynomiale Kernelfunktion genutzt.

PolynomialOrder: 2; Die polynomiale Ordnung beträgt zwei.

KernelScale: 'auto'; s. o.

BoxConstraint: 1; s. o.

Standardize: true; s. o.

SVMCubic: KernelFunction: 'polynomial'; Es wird eine polynomiale Kernelfunktion genutzt.

PolynomialOrder: 3; Die polynomiale Ordnung beträgt drei.

KernelScale: 'auto'; s. o.

BoxConstraint: 1; s. o.

Standardize: true; s. o.

SVMFineGaussian: KernelFunction: gaussian; SVM basiert auf einem RBF Kernel.

PolynomialOrder: []; Gibt den Grad der Ordnung an. Da keine polynomiale Funktion genutzt wird, ist keine Angabe nötig.

KernelScale: 0.5; Bei einer RBF Kernel-Funktion wird jeder Wert der Eingabematrix durch den KernelScale-Wert geteilt, um anschließend die Gram-Matrix zu berechnen. Der Standardwert ist 1.

BoxConstraint: 1; Ist ein Maß für die Bestrafung bei einer Randverletzung, um eine Überanpassung an die Trainingsdaten zu vermeiden. Je höher der Wert ist, desto weniger Unterstützungsvektoren werden verwendet. Der Standardwert ist 1.

Standardize: true; Gibt an, ob jedes Eingabemerkmale zentriert und skaliert werden soll.

SVMMediumGaussian: KernelFunction: 'gaussian'; s. o.

PolynomialOrder: []; s. o.

KernelScale: 2; s. o.

BoxConstraint: 1; s. o.

Standardize: true; s. o.

SVMCoarseGaus: KernelFunction: 'gaussian'; s. o.

PolynomialOrder: []; s. o.

KernelScale: 8; s. o.

BoxConstraint: 1; s. o.

Standardize: true; s. o.

- Entscheidungs bäume:

SimpleTree: SplitCriterion: 'gdi'; Der Übergabeparameter 'gdi' steht für Gini's Diversity Index (GDI). Dieser wird, wie in der Formel (8.1) dargestellt berechnet [92]. Dabei läuft i über alle Klassen C . Die Wahrscheinlichkeit, ob eine Klasse über diesen Knoten läuft, gibt $p(i)$ an. Der GDI ist 0, wenn an dem Knoten nur eine Klasse hängt. Daraus folgt: Je niedriger der GDI ist, desto sicherer lässt sich eine Klassifikation über diesen Knoten herbeiführen. Der GDI ist daher auch ein Maß für die Unreinheit (engl. impurity) eines Knoten.

Der GDI wird für jedes Merkmal berechnet. Anschließend wird das Merkmal an dem Knoten zum Teilen des Baumes verwendet, welches den niedrigsten GDI besitzt, der mit

$$1 - \sum_{i=0}^C p(i)^2, \quad (8.1)$$

zu bestimmen ist.

MaxNumSplits: 4; Gibt die Tiefe des Entscheidungsbaumes an. Default-Wert ist $n - 1$, mit n als Größe des Trainingssets.

Surrogate: 'off'; Der Parameter Surrogate stellt die Anzahl der zu verwendenden Surrogate-Splits ein. Ein Surrogate-Split wird vor allem dann benutzt, wenn Daten fehlen [93]. Default-Wert ist 'off'.

MediumTree: SplitCriterion: 'gdi'; s. o.

MaxNumSplits: 20; Maximale Baumtiefe von 20.

Surrogate: 'off'; s. o.

ComplexTree: SplitCriterion: 'gdi'; s. o.

MaxNumSplits: 100; s. o.

Surrogate: 'off'; s. o.

BaggedTree: Method: 'Bag'; Als Ensemble soll ein Bagging-Algorithmus verwendet werden.

NLearn: 30; Es werden 30 Durchläufe durchgeführt. Da in jedem Durchlauf ein Entscheidungsbaum trainiert wird, stehen am Ende 30 davon zur Verfügung.

Learners: 'Tree'; Definiert die schwachen Lerner als Entscheidungsbäume.

Type: 'Classification'; Da die Methode 'Bag' angegeben wurde, muss spezifiziert werden, dass eine Klassifikation vorgenommen werden soll.

BoostedTree: Method: 'AdaBoostM2'; Der Parameter AdaBoostM2 wird für Klassifikationsprobleme mit mehr als drei Klassen gewählt [93].

NLearn: 30; Anzahl an Durchläufen.

'MaxNumSplits': 20; Die maximale Tiefe der einzelnen Bäume beträgt 20.

Type: 'Classification'; s. o.

'LearnRate': 0.1; Rate, in der die Gewichtung angepasst wird.

RUSBoostedTrees: Method: 'RUSBoost';

NLearn: 30; s. o.

'MaxNumSplits': 20; s. o.

Type: 'Classification'; s. o.

'LearnRate': 0.1; s.o.

▪ *k*-Nächste Nachbarn (k-NN):

KNNFine: 'Distance': 'Euclidean'; Distanz Metrik zwischen einzelnen Datenpunkten. Siehe auch Abschnitt 2.4.5.

'Exponent': []; Der Exponent wird für die euklidische Distanz nicht benötigt.

'NumNeighbors': 1; Anzahl der Nachbarn, welche zur Klassifikation eines Datenpunktes betrachtet werden.

'DistanceWeight': 'Equal'; Die Distanzgewichtung von Equal entspricht keiner Gewichtung.

'Standardize': true; Die Eingabewerte werden standardisiert.

KNNMedium: 'Distance': 'Euclidean'; Distanz Metrik zwischen einzelnen Datenpunkten. Siehe auch Abschnitt 2.4.5.

'Exponent': []; s. o.

'NumNeighbors': 10; s. o.

'DistanceWeight': 'Equal'; s. o.

'Standardize': true; s. o.

KNNCoarse: 'Distance': 'Euclidean'; s. o.

'Exponent': []; s. o.

'NumNeighbors': 100; s. o.

'DistanceWeight': 'Equal'; s. o.

'Standardize': true; s. o.

KNNCubic: **'Distance':** 'Minkowski'; Als Distanzmaß wird die Minkowski-Metrik verwendet. Siehe auch Abschnitt 2.4.5

'Exponent': 3; s. o.

'NumNeighbors': 10; s. o.

'DistanceWeight': 'Equal'; s. o.

'Standardize': true; s. o.

KNNCosine: **'Distance':** 'Cosine'; Als Distanzmaß wird der Winkel zwischen den Datenpunkten verwendet.

'Exponent': []; s. o.

'NumNeighbors': 10; s. o.

'DistanceWeight': 'Equal'; s. o.

'Standardize': true; s. o.

KNNWeighted: **'Distance':** 'Euclidean'; s. o.

'Exponent': []; s. o.

'NumNeighbors': 10; s. o.

'DistanceWeight': 'SquaredInverse'; Die Distanzgewichtung von SquaredInverse entspricht der Gewichtung $w = \frac{1}{\text{Distanz}^2}$.

'Standardize': true; s. o.

SubSpaceKNN: **Method:** 'Subspace'; Es werden zufällige Räume erzeugt.

NLearn: 30; Es werden 30 schwache Lerner trainiert.

Learners: 'KNN'; Als schwache Lerner wird die k-NN verwendet.

Type: 'Classification'; s. o.

'NPredToSample': subspaceDimension; Anzahl der Merkmale für die Stichprobe. Die subspaceDimension ist wie folgt definiert: $\text{subspaceDimension} = \max(1, \min(2, \text{width}(\text{predictors}) - 1))$.

- **Künstliche-Neuronale-Netze (KNN):**

NN: activation: softmax; Erzeugt einen Vektor entsprechend der kategorialen Wahrscheinlichkeiten mit $p \in [0, 1]$.

optimizer: 'rmsprop'; Verwendet als Optimierer auf den Root Mean Square Propagation (RMSProb)-Algorithmus. Dieser gehört zu den Gradientenabstiegsverfahren [33].

recur6: activation: softmax; s. o.

optimizer: 'adam': Verwendet als Optimierer auf den Adaptive moments (Adam)-Algorithmus. Dieser gehört ebenfalls zu den Gradientenabstiegsverfahren und kann als eine Kombination des RMSProb-Algorithmus mit Momentum verstanden werden [33].

CNN: activation: softmax; s. o.

optimizer: 'adam': s. o.

8.2 Metriken in tabellarischer Form für die Verifikation und Validierung

8.2.1 Pro Verfahren

Tabelle 8.1 stellt den Median, das arithmetische Mittel, das Minimum sowie das Maximum und die Standardabweichung des erreichten F_1 -Scores dar. Sie ist eine Erweiterung der Tabelle 5.2 und vergleicht die Werte aller drei Methoden miteinander. Nicht berücksichtigt werden dabei die Ergebnisse der Klassifikatoren CNN und Recur6, da diese ohne Anpassungen keine EMG-Signale der Standardmethode klassifizieren können.

Tabelle 8.1: Vergleich des erreichten F_1 -Scores der drei Vorverarbeitungsmethoden. Es werden drei sowie neun Gesten und sowohl zwei als auch vier Merkmale berücksichtigt. Nicht berücksichtigt sind die beiden Klassifikatoren CNN und Recur6, welche keine Daten für die Standardmethode geliefert haben.

Verfahren	Anz. Merkmale	Anz. Gesten	Median	Arithmetisches Mittel	Minimum	Maximum	Standardabweichung
Standard	2	3	80 %	79 %	19 %	95 %	8,7 %
Normiert	2	3	84 %	83 %	38 %	100 %	8 %
Fortlaufend	2	3	92 %	90 %	41 %	100 %	7,5 %
Standard	4	3	84 %	83 %	10 %	100 %	10,9 %
Normiert	4	3	88 %	87 %	0 %	100 %	10,3 %
Fortlaufend	4	3	93 %	88 %	6 %	100 %	13,2 %
Standard	2	9	52 %	52 %	0 %	95 %	20,3 %
Normiert	2	9	64 %	62 %	0 %	100 %	20,5 %
Fortlaufend	2	9	62 %	59 %	0 %	99 %	22 %
Standard	4	9	58 %	56 %	0 %	100 %	23,6 %
Normiert	4	9	70 %	66 %	0 %	100 %	22,5 %
Fortlaufend	4	9	64 %	62 %	0 %	100 %	23,4 %

8.2 Metriken in tabellarischer Form für die Verifikation und Validierung

Tabelle 8.2 stellt die Metriken KKR, Sensitivität und Spezifität dar. Damit ist sie eine Erweiterung der Tabelle 5.3 um die Werte der fortlaufenden Normierung.

Tabelle 8.2: Vergleich der KKR, der Sensitivität und der Spezifität der drei Verfahren. Es wurden drei sowie neun Gesten berücksichtigt und zwischen zwei und vier Merkmalen unterschieden.

Verfahren	Anz. Merkmale	Anz. Gesten	KKR	Sensitivität	Spezifität
Standard	2	3	86 %	79 %	90 %
Normiert	2	3	87 %	82 %	91 %
Fortlaufend	2	3	91 %	88 %	94 %
Standard	4	3	89 %	83 %	92 %
Normiert	4	3	91 %	87 %	93 %
Fortlaufend	4	3	91 %	88 %	94 %
Standard	2	9	88 %	50 %	90 %
Normiert	2	9	89 %	64 %	96 %
Fortlaufend	2	9	89 %	63 %	95 %
Standard	4	9	89 %	58 %	95 %
Normiert	4	9	91 %	68 %	96 %
Fortlaufend	4	9	90 %	64 %	96 %

8.2.2 Pro Proband

Tabelle 8.3: Durchschnittlicher F_1 -Score in Prozent der jeweils fünf besten Klassifikatoren aus den Permutationen von Geste und Anzahl an Merkmalen

Proband	Verfahren	Anz. Merk- male	Anz. Ges- ten	Q_{25}	Q_{50}	Q_{75}	ΔQ_{25}	ΔQ_{50}	ΔQ_{75}
Proband 1	Normiert	2	3	85	89	95	4	7	8
	Fortl. Normiert	2	3	93	94	97	12	11	10
Proband 2	Normiert	2	3	90	94	96	5	6	6
	Fortl. Normiert	2	3	92	97	99	7	9	9
Proband 3	Normiert	2	3	76	82	91	6	5	6
	Fortl. Normiert	2	3	84	90	95	14	13	10
Proband 4	Normiert	2	3	86	89	94	6	7	9
	Fortl. Normiert	2	3	92	96	98	12	14	13
Proband 5	Normiert	2	3	82	87	94	5	6	8
	Fortl. Normiert	2	3	90	95	98	13	14	12
Proband 1	Normiert	4	3	87	96	99	5	5	3
	Fortl. Normiert	4	3	97	99	99	15	8	3
Proband 2	Normiert	4	3	92	96	100	3	5	1
	Fortl. Normiert	4	3	96	99	100	7	7	1
Proband 3	Normiert	4	3	86	94	99	6	8	3
	Fortl. Normiert	4	3	88	94	98	8	8	2
Proband 4	Normiert	4	3	88	96	99	7	3	2
	Fortl. Normiert	4	3	97	99	100	16	6	3
Proband 5	Normiert	4	3	88	93	97	9	6	5
	Fortl. Normiert	4	3	96	99	100	17	12	8
Proband 1	Normiert	2	9	58	73	86	12	17	16
	Fortl. Normiert	2	9	62	74	89	16	18	19
Proband 2	Normiert	2	9	57	76	87	13	20	16
	Fortl. Normiert	2	9	58	74	89	14	18	18
Proband 3	Normiert	2	9	58	74	85	12	15	17
	Fortl. Normiert	2	9	55	70	83	9	11	15
Proband 4	Normiert	2	9	62	77	87	11	18	18
	Fortl. Normiert	2	9	65	79	89	14	20	20
Proband 5	Normiert	2	9	55	72	87	15	16	14
	Fortl. Normiert	2	9	53	67	85	13	11	12
Proband 1	Normiert	4	9	73	85	96	10	10	11

Fortsetzung auf der nächsten Seite

8.2 Metriken in tabellarischer Form für die Verifikation und Validierung

Tabelle 8.3 fortgeführt von der vorhergehenden Seite

	Fortl. Normiert	4	9	71	80	91	8	5	6
Proband 2	Normiert	4	9	69	82	97	9	11	5
	Fortl. Normiert	4	9	66	82	94	6	11	2
Proband 3	Normiert	4	9	76	84	93	14	11	12
	Fortl. Normiert	4	9	70	79	89	8	6	8
Proband 4	Normiert	4	9	77	90	96	12	14	7
	Fortl. Normiert	4	9	77	88	95	12	12	6
Proband 5	Normiert	4	9	69	84	93	10	13	9
	Fortl. Normiert	4	9	67	80	92	8	9	8

Ende der Tabelle

Tabelle 8.4: Durchschnittlich erreichte TPR, TNR, sowie KKR. Der Durchschnitt wurde jeweils mit den für die Permutation aus Anzahl Gesten und Anzahl Merkmale besten fünf Klassifikatoren gebildet. Das Delta der Metrik wird jeweils in Bezug auf den Wert der Standardmethode gebildet.

Proband	Verfahren	Anz. Merkmale	Anz. Gesten	TPR	TNR	ACC	Δ TPR	Δ TNR	Δ ACC
Proband 1	Normiert	2	3	88	94	92	4	2	3
	Fortl. Normiert	2	3	94	97	96	10	5	7
Proband 2	Normiert	2	3	93	96	95	5	2	4
	Fortl. Normiert	2	3	96	98	97	8	4	6
Proband 3	Normiert	2	3	81	91	88	4	3	4
	Fortl. Normiert	2	3	89	94	92	12	6	8
Proband 4	Normiert	2	3	89	95	92	7	4	4
	Fortl. Normiert	2	3	96	98	96	14	7	8
Proband 5	Normiert	2	3	87	93	90	6	2	3
	Fortl. Normiert	2	3	94	97	95	13	6	8
Proband 1	Normiert	4	3	89	95	93	4	3	3
	Fortl. Normiert	4	3	98	99	98	13	7	8
Proband 2	Normiert	4	3	94	97	95	3	1	2
	Fortl. Normiert	4	3	96	98	97	5	2	4
Proband 3	Normiert	4	3	89	95	93	6	3	5
	Fortl. Normiert	4	3	90	95	92	7	3	4
Proband 4	Normiert	4	3	90	95	93	6	3	4
	Fortl. Normiert	4	3	97	99	98	13	7	9

Fortsetzung auf der nächsten Seite

Tabelle 8.4 fortgeführt von der vorhergehenden Seite

Proband 5	Normiert	4	3	89	95	93	8	4	6
	Fortl. Normiert	4	3	97	98	97	16	7	10
Proband 1	Normiert	2	9	65	96	91	11	2	1
	Fortl. Normiert	2	9	69	96	91	15	2	1
Proband 2	Normiert	2	9	71	96	91	18	2	1
	Fortl. Normiert	2	9	72	97	91	19	3	1
Proband 3	Normiert	2	9	69	96	92	16	2	2
	Fortl. Normiert	2	9	65	96	90	12	2	0
Proband 4	Normiert	2	9	69	96	92	15	2	2
	Fortl. Normiert	2	9	74	97	91	20	3	1
Proband 5	Normiert	2	9	67	96	91	14	2	2
	Fortl. Normiert	2	9	66	96	90	13	2	$5 \cdot 10^{-1}$
Proband 1	Normiert	4	9	72	97	93	9	2	7
	Fortl. Normiert	4	9	78	97	86	15	2	$1 \cdot 10^{-1}$
Proband 2	Normiert	4	9	71	96	93	10	1	6
	Fortl. Normiert	4	9	72	96	84	11	1	-4
Proband 3	Normiert	4	9	73	97	94	11	2	8
	Fortl. Normiert	4	9	70	96	84	8	1	-3
Proband 4	Normiert	4	9	75	97	93	10	2	7
	Fortl. Normiert	4	9	80	97	88	15	2	1
Proband 5	Normiert	4	9	72	96	93	12	1	7
	Fortl. Normiert	4	9	70	96	87	10	1	1

Ende der Tabelle

8.2.3 Pro Tagesset

Tabelle 8.5: Durchschnittlicher F_1 -Score von einem Aufnahme-tag über alle Probanden gegen sechs Aufnahme-tage über alle Probanden. Berechnet jeweils aus den fünf besten Klassifikatoren der Permutationen von Geste und Anzahl an Merkmalen. Angegeben ist der Median und die Standardabweichung.

Anz.Tage	Verfahren	Anz.Merkmale	Anz.Gesten	Q_{50}	σ	ΔQ_{50}	$\Delta\sigma$
1	Normiert	2	3	89	8,8	6	1,6
	Fortlaufend Normiert	2	3	95	6	12	-1,3
6	Normiert	2	3	89,4	8,4	7,5	1,1
	Fortlaufend Normiert	2	3	90	6,2	8,1	-1,2
1	Normiert	4	3	95	7,6	4	-2,7
	Fortlaufend Normiert	4	3	98,3	6	7,3	-4,3
6	Normiert	4	3	95	6	6	-6,6
	Fortlaufend Normiert	4	3	96	3,9	7	-8,7
1	Normiert	2	9	75	21,2	16	4,7
	Fortlaufend Normiert	2	9	74,9	19,9	15,9	3,3
6	Normiert	2	9	63	18,4	19	2,6
	Fortlaufend Normiert	2	9	65,1	18,6	21,1	2,9
1	Normiert	4	9	86	20	11	4,8
	Fortlaufend Normiert	4	9	83	16,4	8	1,2
6	Normiert	4	9	76	15,9	14	1,4
	Fortlaufend Normiert	4	9	77	13,1	15	-1,4

Ende der Tabelle

Literaturverzeichnis

- [1] A. H. Ali. „An Investigation of Electromyographic (EMG) Control of Dextrous Hand Protheses for Transradial Amputees“. Doctoral Thesis. University of Plymouth, 2013. URL: <http://hdl.handle.net/10026.1/2860> (Stand: 01.11.2023).
- [2] J. A. Anderson, Herausgeber. *Neurocomputing*. 5. Ausgabe. Cambridge, Mass.: MIT Press, 1990.
- [3] A. Attenberger und K. Buchenrieder. „Modeling and Visualization of Classification-Based Control Schemes for Upper Limb Protheses“. In: *2012 IEEE 19th International Conference and Workshops on Engineering of Computer-Based Systems*, Seiten 188–194.
- [4] A. Attenberger. „Time Analysis for Improved Upper Limb Movement Classification“. Doctoral Thesis. Universität der Bundeswehr München, 2016.
- [5] K. Backhaus; B. Erichson; W. Plinke und R. Weiber. *Multivariate Analysemethoden*. 14. überarbeitete und aktualisierte Auflage. Berlin Heidelberg: Springer, 2016.
- [6] D. Bandara; J. Arata und K. Kiguchi. „Towards Control of a Transhumeral Prosthesis with EEG Signals“. In: *Bioengineering (Basel, Switzerland)*, Band 5, Nummer 2, 2018.
- [7] U. Baspinar; H. S. Varol und K. Yildiz. „Classification of Hand Movements by Using Artificial Neural Network“. In: *2012 International Symposium on Innovations in Intelligent Systems and Applications*, Seiten 1–4.
- [8] R. Baumgartner und B. Greitemann. *Grundkurs Technische Orthopädie*. 3. unveränderte Auflage. Stuttgart: Thieme, 2015.
- [9] C. Beierle. *Methoden wissensbasierter Systeme: Grundlagen Algorithmen Anwendungen*. Vieweg+Teubner Verlag, 2000.
- [10] M. R. Berthold. *Intelligent Data Analysis: An introduction*. 2. überarbeitete und erweiterte Auflage. Berlin und Heidelberg: Springer, 2003.
- [11] C. Bischoff. *EMG NLG: Elektromyographie Nervenleitungsuntersuchungen*. Referenz-Reihe Neurologie. Stuttgart und New York: Thieme, 2003.
- [12] C. Bischoff; W. J. Schulte-Mattler und B. Conrad. *Das EMG-Buch: EMG und periphere Neurologie in Frage und Antwort*. 2. vollst. überarb. Aufl. Stuttgart: Thieme, 2009.
- [13] R. Brause. *Neuronale Netze: Eine Einführung in die Neuroinformatik*. Leitfäden und Monographien der Informatik. Wiesbaden: Vieweg+Teubner Verlag, 1991.
- [14] L. Breiman. „Random Forests“. In: *Machine Learning*, Band 45, Nummer 1, 2001, Seiten 5–32.
- [15] D. Bright; A. Nair; D. Salvekar und S. Bhisikar. „EEG-Based Brain Controlled Prosthetic Arm“. In: *Conference on Advances in Signal Processing (CASP-2016)*. Piscataway, NJ: IEEE, 2016, Seiten 479–483.

- [16] P. Bruce und A. Bruce. *Practical statistics for data scientists: 50 essential concepts*. Sebastopol: O'Reilly Media, 2017.
- [17] Bundesministerium der Justiz. *Sozialgesetzbuch Neuntes Buch: SGB IX*. 23.12.2016.
- [18] A. Burkov. *Machine Learning kompakt: Alles, was Sie wissen müssen*. 1. Auflage, Deutsche Ausgabe. MITP, 2019.
- [19] F. Chollet u. a. *Keras*. Herausgegeben von GitHub. 2015. URL: <https://github.com/fchollet/keras>.
- [20] J.-U. Chu; I. Moon und M.-S. Mun. „A Supervised Feature Projection for Real-Time Multifunction Myoelectric Hand Control“. In: *2006 International Conference of the IEEE Engineering in Medicine and Biology Society*, Band 2006, 2006, Seiten 2417–2420.
- [21] A. Delgado-Bonal und A. Marshak. „Approximate Entropy and Sample Entropy: A Comprehensive Tutorial“. In: *Entropy (Basel, Switzerland)*, Band 21, Nummer 6, 2019.
- [22] Delsys Incorporated. *Bagnoli™ EMG System: User's Guide*. URL: <https://www.delsys.com/downloads/USERSGUIDE/bagnoli-emg-system.pdf> (Stand: 30. 10. 2023).
- [23] Destatis. *Statistik der schwerbehinderten Menschen: Kurzbericht 2019*. Herausgegeben von Statistisches Bundesamt. 2019.
- [24] J. Diederich. *Rule Extraction from Support Vector Machines*. Band 80. Studies in Computational Intelligence. Berlin, Heidelberg: Springer-Verlag, 2008. URL: <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10223223>.
- [25] R. O. Duda; P. E. Hart und D. G. Stork. *Pattern Classification*. 2. Auflage. Wiley & Sons Ltd, 2000.
- [26] Dudenredaktion. *Prothese*. o. D. URL: <https://www.duden.de/node/115775/revision/1002325> (Stand: 25. 11. 2023).
- [27] K. Englehart; B. Hudgins und P. A. Parker. „A wavelet-based continuous classification scheme for multifunction myoelectric control“. In: *IEEE Transactions on Biomedical Engineering*, Band 48, Nummer 3, 2001, Seiten 302–311.
- [28] D. Farina und R. Merletti, Herausgeber. *Surface electromyography: Physiology, engineering, and applications*. IEEE Press Series on Biomedical Engineering. Piscataway, NJ: IEEE Press, 2016. URL: <https://onlinelibrary.wiley.com/doi/book/10.1002/9781119082934>.
- [29] Y. Freund; R. Schapire und N. Abe. „A short introduction to boosting“. In: *Journal-Japanese Society For Artificial Intelligence*, Band 14, 1999, Seiten 771–780.
- [30] P. Gaßner und K. Buchenrieder. „Improved Classification of Myoelectric Signals by Using Normalized Signal Trains“. In: *Computer Aided Systems Theory - EUROCAST 2019*. Herausgegeben von R. Moreno-Díaz. Band 12014. Lecture Notes in Computer Science Ser. Cham: Springer International Publishing AG, 2020, Seiten 372–379.
- [31] P. Gaßner und K. Buchenrieder. „Continuous Time Normalized Signal Trains for a Better Classification of Myoelectric Signals“. In: *Computer Aided Systems Theory – EUROCAST 2022*. Herausgegeben von R. Moreno-Díaz; F. Pichler und A. Quesada-Arencibia. Band 13789. Lecture notes in computer science. Cham: Springer Nature Switzerland und Imprint Springer, 2022, Seiten 479–486.

- [32] G. Gini; L. Cavazzana; F. Mutti; P. Belluco und A. Mauri. „New Results on Classifying EMG Signals for Interfacing Patients and Mechanical Devices“. In: *New Trends in Medical and Service Robots*. Herausgegeben von A. Rodić; D. Pisla und H. Bleuler. Band 20. Mechanisms and Machine Science. Cham: Springer International Publishing, 2014, Seiten 125–139.
- [33] I. Goodfellow; Y. Bengio und A. Courville. *Deep Learning*. Adaptive Computation and Machine Learning Series. Cambridge, Mass.: MIT Press Ltd, 2017.
- [34] B. Graimann; G. Pfurtscheller und B. Allison. *Brain-Computer Interfaces: Revolutionizing Human-Computer Interaction*. The Frontiers Collection. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg, 2010. URL: <http://site.ebrary.com/lib/alltitles/docDetail.action?docID=10427834>.
- [35] B. Greitemann. *Technische Orthopädie*. 4. vollständig überarbeitete und erweiterte Auflage. Stuttgart: Georg Thieme Verlag, 2018.
- [36] W. Guo; X. Sheng; H. Liu und X. Zhu. „Development of a Multi-Channel Compact-Size Wireless Hybrid sEMG/NIRS Sensor System for Prosthetic Manipulation“. In: *IEEE Sensors Journal*, Band 16, Nummer 2, 2016, Seiten 447–456.
- [37] L. J. Hargrove; K. Englehart und B. Hudgins. „A Comparison of Surface and Intramuscular Myoelectric Signal Classification“. In: *IEEE transactions on bio-medical engineering*, Nummer 5, 2007, Seiten 847–853.
- [38] L. J. Hargrove; L. A. Miller; K. Turner und T. A. Kuiken. „Myoelectric Pattern Recognition Outperforms Direct Control for Transhumeral Amputees with Targeted Muscle Reinnervation: A Randomized Clinical Trial“. In: *Scientific reports*, Band 7, Nummer 1, 2017, Seite 13840.
- [39] L. J. Hargrove; E. J. Scheme; K. B. Englehart und B. S. Hudgins. „Multiple Binary Classifications via Linear Discriminant Analysis for Improved Controllability of a Powered Prosthesis“. In: *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, Band 18, Nummer 1, 2010, Seiten 49–57.
- [40] A. E. Hassaniien und A. T. Azar. *Brain-computer interfaces: Current trends applications*. Band 74. Intelligent Systems Reference Library. Cham: Springer, 2015.
- [41] S. Herrmann; A. Attenberger und K. Buchenrieder. „Prostheses Control with Combined Near-Infrared and Myoelectric Signals“. In: *Computer Aided Systems Theory – EUROCAST 2011*. Herausgegeben von R. Moreno-Díaz; F. Pichler und A. Quesada-Arencibia. Band 6928. Lecture notes in computer science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2012, Seiten 601–608.
- [42] K. K. Ho; G. B. Moody; C. K. Peng u. a. „Predicting Survival in Heart Failure Case and Control Subjects by Use of Fully Automated Methods for Deriving Nonlinear and Conventional Indices of Heart Rate Dynamics“. In: *Circulation*, Band 96, Nummer 3, 1997, Seiten 842–848.
- [43] S. Hochreiter und J. Schmidhuber. „Long Short-Term Memory“. In: *Neural computation*, Band 9, Nummer 8, 1997, Seiten 1735–1780.
- [44] B. Hudgins; P. Parker und R. N. Scott. „A New Strategy for Multifunction Myoelectric Control“. In: *0018-9294*, Band 40, Nummer 1, 1993, Seiten 82–94.

- [45] N. Jiang; L. Tian; P. Fang; Y. Dai und G. Li. „Motion recognition for simultaneous control of multifunctional transradial prostheses“. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, Band 2013, 2013, Seiten 1603–1606.
- [46] P. Kaufmann; K. Englehart und M. Platzner. „Fluctuating EMG Signals: Investigating Long-Term Effects of Pattern Matching Algorithms“. In: *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, Band 2010, 2010, Seiten 6357–6360.
- [47] K. Kiguchi; T. D. Lalitharatne und Y. Hayashi. „Estimation of Forearm Supination/Pronation Motion Based on EEG Signals to Control an Artificial Arm“. In: *Journal of Advanced Mechanical Design, Systems, and Manufacturing*, Band 7, Nummer 1, 2013, Seiten 74–81.
- [48] S. W. Knox. *Machine learning: a Concise Introduction: Topics and techniques*. Band 285. Wiley series in probability and statistics. Hoboken, New Jersey: John Wiley & Sons, Inc, 2018.
- [49] J. Kostuik und R. Gillespie. *Amputationschirurgie und Rehabilitation: Erfahrungen der Toronto-Gruppe*. Berlin: Springer Berlin Heidelberg, 2013.
- [50] J.-P. Kreiß und G. Neuhaus. *Einführung in die Zeitreihenanalyse: Mit 8 Tabellen*. Statistik und ihre Anwendungen. Berlin und Heidelberg: Springer, 2006.
- [51] R. Leonhart. *Lehrbuch Statistik: Einstieg und Vertiefung*. 5. überarbeitete Auflage. Bern: Hogrefe, 2022.
- [52] T.-S. Lim; W.-Y. Loh und Y.-S. Shih. „A Comparison of Prediction Accuracy, Complexity, and Training Time of Thirty-Three Old and New Classification Algorithms“. In: *Machine Learning*, Band 40, Nummer 3, 2000, Seiten 203–228.
- [53] C. J. de Luca; L. Donald Gilmore; M. Kuznetsov und S. H. Roy. „Filtering the Surface EMG Signal: Movement Artifact and Baseline Noise Contamination“. In: *Journal of Biomechanics*, Band 43, Nummer 8, 2010, Seiten 1573–1579.
- [54] P. Markworth. *Sportmedizin: Physiologische Grundlagen*. 25. Auflage. Band 17049. Rororo Sport. Reinbek b. Hamburg: Rowohlt, 2013.
- [55] A. Martin; A. Ashish; B. Paul u. a. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. URL: <https://www.tensorflow.org/>.
- [56] J. M. Meredith; J. E. Uellendahl und R. D. Keagy. „Successful voluntary grasp and release using the cookie crusher myoelectric hand in 2-year-olds“. In: *The American journal of occupational therapy : official publication of the American Occupational Therapy Association*, Band 47, Nummer 9, 1993, Seiten 825–829.
- [57] L. Mou und Z. Jin. *Tree-Based Convolutional Neural Networks: Principles and Applications*. SpringerBriefs in computer science. Singapore: Springer Singapore, 2018. URL: <http://dx.doi.org/10.1007/978-981-13-1870-2>.
- [58] E. Mutschler; G. Thews; H.-G. Schaible und P. Vaupel. *Anatomie, Physiologie, Pathophysiologie des Menschen*. 6. völlig überarb. und erw. Aufl. Stuttgart: Wiss. Verl.-Ges, 2007.

- [59] A. Muzumdar, Herausgeber. *Powered Upper Limb Prostheses: Control, Implementation and Clinical Application*. Berlin, Heidelberg: Springer, 2004.
- [60] D. Nauck; F. Klawonn und R. Kruse. *Neuronale Netze und Fuzzy-Systeme: Grundlagen des Konnektionismus, Neuronaler Fuzzy-Systeme und der Kopplung mit wissensbasierten Methoden*. Band 1. Artificial Intelligence / Künstliche Intelligenz. Wiesbaden: Vieweg+Teubner Verlag, 1994.
- [61] J. Ning und F. Dario. „Myoelectric Control of Upper Limb Prosthesis: Current Status, Challenges and Recent Advances“. In: *Frontiers in Neuroengineering*, Band 7, 2014.
- [62] A. V. Oppenheim und R. W. Schaffer. *Discrete-Time Signal Processing*. Third Edition. Ltd., London u. a.: Pearson, 2010.
- [63] M. A. Oskoei und H. Hu. „GA-based Feature Subset Selection for Myoelectric Classification“. In: *2006 IEEE International Conference on Robotics and Biomimetics*, Seiten 1465–1470.
- [64] M. A. Oskoei und H. Hu. „Myoelectric control systems—A survey“. In: *Biomedical Signal Processing and Control*, Band 2, Nummer 4, 2007, Seiten 275–294. URL: <http://linkinghub.elsevier.com/retrieve/pii/S1746809407000547>.
- [65] Össur. *i - LIMB®HAND: Instructions for Use*. URL: https://media.ossur.com/image/upload/pi-documents-global/iLimb_Quantum.pdf (Stand: 21.08.2022).
- [66] Otto Bock HealthCare Deutschland GmbH. *bebionic Hand*. URL: https://media.ottobock.com/_web-site/prosthetics/upper-limb/bebionic-hand/files-2019/bebionic_prothesenhand_information_f%C3%BCr_anwender_en.pdf (Stand: 01.11.2023).
- [67] Otto Bock HealthCare Deutschland GmbH. *Michelangelo Hand*. URL: https://media.ottobock.com/prosthetics/arms/michelangelo-axon-bus/files/646d592_de_03_1308w.pdf&attachment=true (Stand: 01.11.2023).
- [68] Otto Bock Healthcare Products GmbH. *bebionic: Gebrauchsanweisung*. URL: <https://www.ottobock.com/en-us/product/8E70> (Stand: 05.08.2022).
- [69] Ottobock. *bebionic user guide: The World's Most Lifelike Bionic Hand*. Herausgegeben von Ottobock US. URL: https://www.ottobockus.com/media/local-media/prosthetics/upper-limb/files/14112_bebionic_user_guide_lo.pdf (Stand: 30.10.2023).
- [70] Ottobock. *Myo Plus*. URL: https://www.ottobock.de/media/lokale-medien-de_de/prothesen/armprothetik/files/646d1345-de_de-01-1902_w.pdf (Stand: 30.10.2023).
- [71] OYMotion. *gForce-Octopus*. URL: <http://www.oymotion.com/product17/81> (Stand: 30.10.2023).
- [72] OYMotion. *gForce100: Armband*. URL: https://oymotion.github.io/assets/downloads/gForce100_manual_v1.1-eng.pdf (Stand: 30.10.2023).
- [73] C. Panagiotakis und G. Tziritas. „A Speech/Music Discriminator Based on RMS and Zero-Crossings“. In: *IEEE Transactions on Multimedia*, Band 7, Nummer 1, 2005, Seiten 155–166.
- [74] D. W. Patterson. *Künstliche neuronale Netze: Das Lehrbuch*. 2. Aufl. Haar bei München: Prentice Hall, 1997.

- [75] A. Phinyomark; F. Quaine; S. Charbonnier u. a. „EMG Feature Evaluation for Improving Myoelectric Pattern Recognition Robustness“. In: *Expert Systems with Applications*, Band 40, Nummer 12, 2013, Seiten 4832–4840.
- [76] S. Pincus. „Approximate Entropy (ApEn) as a Complexity Measure“. In: *Chaos: An Interdisciplinary Journal of Nonlinear Science*, Band 5, Nummer 1, 1995, Seiten 110–117.
- [77] R. Reiter. „Eine neue Elektrokunsthand“. In: *Grenzgebiete der Medizin*, Band 1, Nummer 4, 1948, Seiten 133–135.
- [78] D. Rothman. *Artificial Intelligence by Example: Acquire advanced AI, machine learning, and deep learning design skills*. Second edition. Birmingham und Mumbai: Packt, 2020. URL: <https://ebookcentral.proquest.com/lib/kxp/detail.action?docID=6126529>.
- [79] Y. Sasaki. „The truth of the F-measure“. In: *Teach Tutor Mater*, 2017. URL: <https://www.cs.odu.edu/~mukka/cs795sum09dm/Lecturenotes/Day3/F-measure-YS-26Oct07.pdf> (Stand: 23.10.2023).
- [80] F. Sauerbruch; W. Felix; G. Ruge und A. Stadler. *Die willkürlich bewegbare künstliche Hand: Eine Anleitung für Chirurgen und Techniker*. Berlin: Springer, 1916.
- [81] J. D. Sayali und P. H. Channe. „Comparative Study of K-NN, Naive Bayes and Decision Tree Classification Techniques“. In: *International Journal of Science and Research (IJSR)*, Band 5, Nummer 1, 2016, Seiten 1842–1845.
- [82] M. Schünke; E. Schulte und U. Schumacher. *Kopf, Hals und Neuroanatomie*. 5. vollständig überarbeitete Auflage. Prometheus. Stuttgart und New York: Georg Thieme Verlag, 2018.
- [83] F. Sebelius; M. Axelsson; N. Danielsen; J. Schouenborg und T. Laurell. „Real-Time Control of a Virtual Hand“. In: *Technology and Disability*, Band 17, Nummer 3, 2005, Seiten 131–141. URL: <https://content.iospress.com/articles/technology-and-disability/tad00176>.
- [84] P. Shenoy; K. J. Miller; B. Crawford und R. N. Rao. „Online Electromyographic Control of a Robotic Prosthesis“. In: *IEEE Transactions on Biomedical Engineering*, Band 55, Nummer 3, 2008, Seiten 1128–1135.
- [85] A. Shigeo. *Support Vector Machines for Pattern Classification*. London: Springer-Verlag, 2005.
- [86] D. Silver; A. Huang; C. J. Maddison u. a. „Mastering the Game of Go With Deep Neural Networks and Tree Search“. In: *Nature*, Band 529, Nummer 7587, 2016, Seiten 484–489.
- [87] L. H. Smith; L. J. Hargrove; B. A. Lock und T. A. Kuiken. „Determining the Optimal Window Length for Pattern Recognition-Based Myoelectric Control: Balancing the Competing Effects of Classification Error and Controller Delay“. In: *IEEE transactions on neural systems and rehabilitation engineering : a publication of the IEEE Engineering in Medicine and Biology Society*, Band 19, Nummer 2, 2011, Seiten 186–192.
- [88] SPECTARIS Deutscher Industrieverband für Optik, Photonik, Analysen- und Medizintechnik e.V. *Die deutsche Medizintechnik-Industrie: SPECTARIS Jahrbuch 2020/2021*. 2020. URL: https://www.spectaris.de/fileadmin/Content/Medizintechnik/Zahlen-Fakten-Publikationen/SPECTARIS_Jahrbuch2020-21_11-2020_Lesezeichen_3.pdf (Stand: 30.10.2023).

- [89] W. Strampp und E. V. Vorozcov. *Mathematische Methoden der Signalverarbeitung*. Oldenbourg Lehrbücher für Ingenieure. München: Oldenbourg, 2010. URL: <http://www.oldenbourg-link.com/doi/book/10.1524/9783486598797>.
- [90] K. Team. *Keras Documentation: Layer Activation Functions*. 3.06.2020. URL: <https://keras.io/api/layers/activations/> (Stand: 11.06.2020).
- [91] THALMICLABS. *Myo: Myo Gesture Control Armband: Webseite*. 26.06.2018. URL: <https://support.getmyo.com/hc/en-us>.
- [92] The MathWorks. *Fit Binary Decision Tree for Multiclass Classification - MATLAB fitctree - MathWorks Deutschland*. URL: <https://de.mathworks.com/help/stats/fitctree.html> (Stand: 28.04.2020).
- [93] The MathWorks. *Fit k-Nearest Neighbor Classifier - MATLAB fitcknn - MathWorks Deutschland: fitcknn*. URL: https://de.mathworks.com/help/stats/fitcknn.html#bt6cr91_sep_shared-Distance (Stand: 19.05.2020).
- [94] The MathWorks. *k-Nearest Neighbor Classification - MATLAB - MathWorks Deutschland*. URL: <https://de.mathworks.com/help/stats/classificationknn.html> (Stand: 13.05.2020).
- [95] The MathWorks. *Support Vector Machines for Binary Classification - MATLAB & Simulink - MathWorks Deutschland*. URL: <https://de.mathworks.com/help/stats/support-vector-machines-for-binary-classification.html> (Stand: 26.04.2020).
- [96] The MathWorks. *Train Support Vector Machine (SVM) Classifier for One-Class and Binary Classification - MATLAB fitcsvm - MathWorks Deutschland*. URL: <https://de.mathworks.com/help/stats/fitcsvm.html> (Stand: 27.04.2020).
- [97] A. J. Thurston. „Paré and Prosthetics: the Early History of Artificial Limbs“. In: *ANZ journal of surgery*, Band 77, Nummer 12, 2007, Seiten 1114–1119.
- [98] D. Tkach; H. Huang und T. A. Kuiken. „Study of Stability of Time-Domain Features for Electromyographic Pattern Recognition“. In: *Journal of NeuroEngineering and Rehabilitation*, Band 7, Nummer 1, 2010, Seite 21. URL: <https://doi.org/10.1186/1743-0003-7-21> (Stand: 01.11.2023).
- [99] Touch Bionics Inc. *i-limb Quantum User Manual*. 2016. URL: <https://www.manualslib.com/download/3025418/Ssur-I-Limb-Hand.html> (Stand: 01.11.2023).
- [100] Touch Bionics Inc. *i-limb ultra Touch Bionics: TOUCH SOLUTIONS*. URL: https://media.ossur.com/ossur-dam/image/upload/product-documents-global/i-Limb_Ultra_gb_en_PN20267.pdf (Stand: 01.11.2023).
- [101] D. van der Riet; R. Stopforth; G. Bright und O. Diegel. „An Overview and Comparison of Upper Limb Prosthetics“. In: *2013 Africon*, Seiten 1–8.
- [102] Vincent Systems GmbH. *Griffschema VINCENTevolution3*. URL: https://vincentssystem.de/workspace/vs/docs/g3p01d03de02_state_machine_evo3.pdf (Stand: 11.12.2019).
- [103] Vincent Systems GmbH. *Multiartikulierende Handprothese: evolution3*. URL: https://www.vincentssystem.de/_files/ugd/e71ff6_d2ce8e093bf949eda036f450b361ec67.pdf (Stand: 30.10.2023).

- [104] G. Wang; Y. Zhang und J. Wang. „The Analysis of Surface EMG Signals with the Wavelet-Based Correlation Dimension Method“. In: *Computational and mathematical methods in medicine*, Band 2014, 2014, Seite 284308.
- [105] A. Waris; I. K. Niazi; M. Jamil u. a. „Multiday Evaluation of Techniques for EMG-Based Classification of Hand Motions“. In: *IEEE journal of biomedical and health informatics*, Band 23, Nummer 4, 2019, Seiten 1526–1534.
- [106] Wikipedia. *Eiserne Hand (Götz von Berlichingen)* — *Wikipedia, die freie Enzyklopädie*. 2022. URL: [https://de.wikipedia.org/w/index.php?title=Eiserne_Hand_\(G%C3%B6tz_von_Berlichingen\)&oldid=221616997](https://de.wikipedia.org/w/index.php?title=Eiserne_Hand_(G%C3%B6tz_von_Berlichingen)&oldid=221616997) (Stand: 10.06.2023).
- [107] R. Winau. *Technik und Medizin*. Band 4. Technik und Kultur. Berlin und Heidelberg: Springer, 1993. URL: <http://dx.doi.org/10.1007/978-3-662-01060-0>.
- [108] R. W. Wirta; D. R. Taylor und F. R. Finley. „Pattern-Recognition Arm Prosthesis: A Historical Perspective - A Final Report“. In: *Bull Prosthet Res.*, 1978, Seiten 8–35.
- [109] P. Wojtczak; T. G. Amaral; O. P. Dias; A. Wolczowski und M. Kurzynski. „Hand Movement Recognition Based on Biosignal Analysis“. In: *Engineering Applications of Artificial Intelligence*, Band 22, Nummer 4-5, 2009, Seiten 608–615.
- [110] T. Yanagisawa; M. Hirata; Y. Saitoh u. a. „Electrocorticographic Control of a Prosthetic Arm in Paralyzed Patients“. In: *Annals of neurology*, Band 71, Nummer 3, 2012, Seiten 353–361.
- [111] D. Yang; J. Zhao; Y. Gu; L. Jiang und H. Liu. „EMG Pattern Recognition and Grasping Force Estimation: Improvement to the Myocontrol of Multi-DOF Prosthetic Hands“. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems, 2009*. Piscataway, NJ: IEEE, 2009, Seiten 516–521.
- [112] M. Zardoshti-Kermani; B. C. Wheeler; K. Badie und R. M. Hashemi. „EMG Feature Evaluation for Movement Control of Upper Extremity Prostheses“. In: *IEEE Transactions on Rehabilitation Engineering*, Band 3, Nummer 4, Seiten 324–333.
- [113] M. Zia ur Rehman; S. O. Gilani; A. Waris; I. K. Niazi und E. N. Kamavuako. „A Novel Approach for Classification of Hand Movements Using Surface EMG Signals“. In: *2017 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. Piscataway: IEEE, 2017, Seiten 265–269.
- [114] K. J. Zuo und J. L. Olson. „The Evolution of Functional Hand Replacement: From Iron Prostheses to Hand Transplantation“. In: *Plastic Surgery*, Band 22, Nummer 1, 2014, Seiten 44–51.