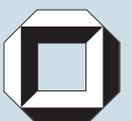
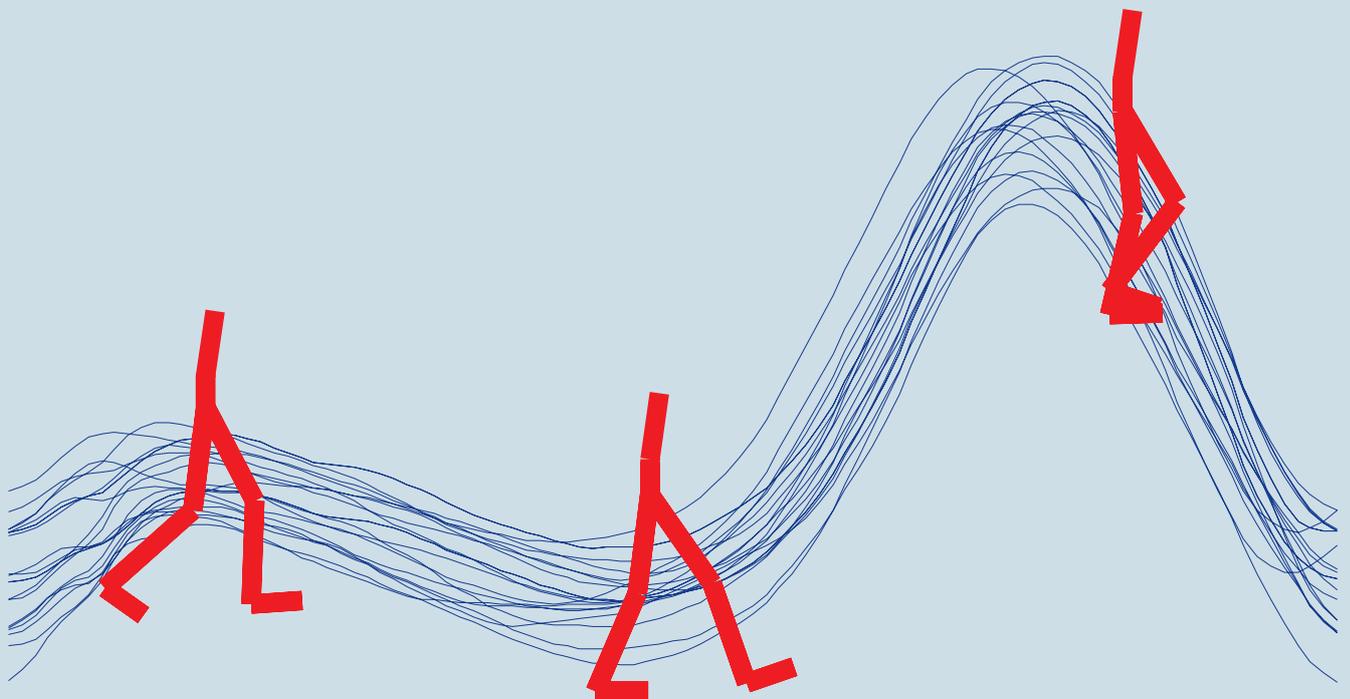


Dipl.-Ing. Tobias Sebastian Loose

# **Konzept für eine modellgestützte Diagnostik mittels Data Mining am Beispiel der Bewegungsanalyse**



Dissertation, Universität Karlsruhe (TH), Fakultät für Maschinenbau, 2004

## **Impressum**

Universitätsverlag Karlsruhe  
c/o Universitätsbibliothek  
Straße am Forum 2  
D-76131 Karlsruhe

[www.uvka.de](http://www.uvka.de)

© Universitätsverlag Karlsruhe 2004  
Print on Demand

ISSN 1614-5267  
ISBN 3-937300-11-2

# Konzept für eine modellgestützte Diagnostik mittels Data Mining am Beispiel der Bewegungsanalyse

Zur Erlangung des akademischen Grades eines  
**Doktors der Ingenieurwissenschaften**  
von der Fakultät für Maschinenbau der  
Universität Karlsruhe

genehmigte  
Dissertation

von

**Dipl.-Ing. Tobias Sebastian Loose**

geboren am 22. Juni 1976 in Karlsruhe

Tag der mündlichen Prüfung:	23. Juli 2004
Hauptreferent:	Prof. Dr.-Ing. habil. G. Bretthauer
Korreferenten:	Prof. Dr. med. habil. H.J. Gerner Prof. Dr. med. Dr.-Ing. R.-P. Franke

Für Gudrun



## Danksagung

Die vorliegende Dissertation entstand während der drei Jahre meiner Tätigkeit am Institut für Angewandte Informatik des Forschungszentrums Karlsruhe.

Professor Bretthauer danke ich für die Möglichkeit, am Institut für Angewandte Informatik des Forschungszentrums Karlsruhe zu promovieren und für die Übernahme des Hauptreferates. Er legte zusammen mit Professor Gerner von der Orthopädischen Universitätsklinik Heidelberg den Grundstein für das gesamte Thema und unterstützte mich durch fachliche Diskussionen und kritische Hinweise. Die in der vorliegenden Arbeit erzielten Ergebnisse sind als Zuarbeiten in die von der Deutschen Forschungsgemeinschaft DFG geförderten Projekte (GE 1139-1, BR 1303-6) eingeflossen. Mein herzlicher Dank gilt Professor Gerner und Professor Franke für das der Arbeit entgegengebrachte Interesse und für die Übernahme der Korreferate und den damit verbundenen Mühen.

Für die Zeit meiner Promotion danke ich besonders meinem Gruppenleiter und Mentor Dr. Ralf Mikut für die exzellente Ausbildung. Mein Dank gilt ebenso Rüdiger Rupp für sein Engagement als Laborleiter in der Orthopädie Heidelberg, der oft das Unmögliche möglich macht. Beiden verdanke ich zahlreiche Anregungen. Sie haben mich und das gesamte Projekt immer sehr unterstützt.

Für die vielen anregenden Diskussionen und die angenehme Arbeitsatmosphäre danke ich Frau Jung, Professor Saile, Joachim Dieterle, Matthias Schablowski, Leonhard Döderlein, Rainer Abel, Joachim Schweidler, Sebastian Wolf, Jens Jäkel, Lutz Gröll, Denise Bartel, Séverine Mounier, Jan Martin, Sebastian Beck, Markus Reischl, Arne Lehmann, Stephan Zipser, Jörg Matthes, Andreas Gommlich und Peter Lücke.

Mein herzlicher Dank gilt schließlich meiner Familie und meiner Freundin für die besondere Unterstützung.

Karlsruhe, April 2004

Tobias Loose



# Inhaltsverzeichnis

Symbol- und Abkürzungsverzeichnis	IV
<b>1 Einleitung</b>	<b>1</b>
1.1 Motivation . . . . .	1
1.2 Darstellung des Entwicklungsstandes . . . . .	2
1.2.1 Einführung in die ‘Instrumentelle Ganganalyse’ . . . . .	2
1.2.2 Automatisierte Analyse von Gangdaten . . . . .	8
1.3 Offene Fragen . . . . .	15
1.4 Ziele und Aufgaben . . . . .	17
<b>2 Datenbeschreibung und empirische Analyse</b>	<b>20</b>
2.1 Beschreibung der Datensätze und Krankheitsbilder . . . . .	20
2.1.1 Referenzdaten . . . . .	21
2.1.2 Infantile Cerebralparese (ICP) Patienten . . . . .	23
2.1.3 Inkomplett querschnittgelähmte (SCI) Patienten . . . . .	24
2.2 Schwierigkeiten und Analysevoraussetzungen . . . . .	26
2.3 Empirische Analyse von Gangdaten . . . . .	27
2.3.1 Merkmalsextraktion und Vorgehensweise . . . . .	28
2.3.2 Krankheitsbild ICP . . . . .	29
2.3.3 Krankheitsbild SCI . . . . .	31
<b>3 Neues Data Mining Konzept zur Entscheidungsunterstützung</b>	<b>32</b>
3.1 Überblick . . . . .	32
3.2 Neue Strategie zur Formalisierung klinischer Problemstellungen . . . . .	35
3.3 Vorverarbeitung und neues Konzept zum Speichern der Daten . . . . .	37
3.4 Verallgemeinerter Merkmalsraum mit zusätzlichen Zeitreihen . . . . .	41
3.5 Verallgemeinerter Merkmalsraum mit interpretierbaren Einzelmerkmalen . . . . .	47
3.6 Bewertung von Einzelmerkmalen . . . . .	52

3.6.1	Verfahren zur Relevanzbewertung . . . . .	52
3.6.2	Modifikation der Verfahren . . . . .	56
3.6.3	Verfahren zur Regressionsanalyse . . . . .	58
3.7	Klassifikation mit bekannter Klasseneinteilung . . . . .	59
3.8	Struktursuche ohne bekannte Klasseneinteilung . . . . .	61
3.8.1	Verallgemeinerte empirische Bewertung von Subgruppen . . . . .	63
3.8.2	Automatisiertes Finden von Subgruppen . . . . .	64
3.8.3	Ableitung modifizierter Verfahren und Erprobung . . . . .	71
3.9	Verallgemeinerte Kombination der Verfahren . . . . .	90
3.10	Visualisierung . . . . .	91
<b>4</b>	<b>Erweitertes Programmsystem „Gait-CAD“</b>	<b>92</b>
4.1	Überblick . . . . .	92
4.2	Verallgemeinertes Anlegen von Datenprojekten . . . . .	94
4.3	Neue Funktionen in „Gait-CAD“ . . . . .	99
<b>5</b>	<b>Anwendung des neuen Data Mining Konzeptes</b>	<b>100</b>
5.1	Überblick . . . . .	100
5.2	Infantile Cerebralparese (ICP) . . . . .	101
5.2.1	Neues Auswerteverfahren für die Diagnose . . . . .	102
5.2.2	Neues Auswerteverfahren für die Therapie . . . . .	128
5.2.3	Zusammenfassung und Wertung . . . . .	134
5.3	Inkomplette Querschnittlähmung (SCI) . . . . .	135
5.3.1	Neues Auswerteverfahren für die Diagnose . . . . .	136
5.3.2	Neues Auswerteverfahren für die Therapie . . . . .	148
5.3.3	Zusammenfassung und Wertung . . . . .	153
<b>6</b>	<b>Zusammenfassung und Ausblick</b>	<b>154</b>
<b>A</b>	<b>Begriffe</b>	<b>157</b>
<b>B</b>	<b>Tabellarischer Literaturüberblick</b>	<b>165</b>
<b>C</b>	<b>Methoden und Theoriegrundlagen</b>	<b>169</b>
C.1	Hauptkomponentenanalyse über Zeitreihen . . . . .	169
C.2	Proximitätsmaße . . . . .	170
C.3	Cluster-Verfahren . . . . .	174
<b>D</b>	<b>Funktionen von Gait-CAD</b>	<b>177</b>

---

<b>E Ergänzungen zu den Datensätzen</b>	<b>181</b>
E.1 Bezeichnungen . . . . .	181
E.2 ICP-Daten . . . . .	182
E.3 SCI-Daten . . . . .	191
<b>Literaturverzeichnis</b>	<b>192</b>

## Symbol- und Abkürzungsverzeichnis

### Symbole

$B_{sc}$	Klassenterm der $s$ -ten Klassenart, z.B. „Untersuchungszeitpunkt“ mit den $c = 1..2$ Klassen als Terme „PRE“, „POST“
$c = 1..C$	Zählvariable für Klassen oder Cluster, z.B. für PRE, POST oder Cluster 1, Cluster 2
$\mathbf{G}_{S_{ZR}+S_{EM} \times L}$	Kategorieneinteilungsmatrix mit Anzahl Zeitreihen und Einzelmerkmalen $S_{ZR} + S_{EM}$ und Anzahl Kategorienarten $L$
<b>I</b>	Einheitsmatrix
$i, j$	allgemeine Zählvariablen
$k = 1..K$	Zählvariable für Abtastzeitpunkte
$l = 1..L$	Zählvariable für Kategorien, z.B. Gelenkebene
$\lambda_i$	Eigenwerte
$M_s$	Merkmalsrelevanzen
$M_{s,ap}$	Apriori-Merkmalsrelevanzen
$M_{s,ges}$	Gesamt-Merkmalsrelevanz
$M_{s,uk}$	Merkmalsrelevanz nach Rückstufung korrelierter Merkmale
$n = 1..N$	Zählvariable für Datensätze
$\Phi = [\phi_1, \dots, \phi_i]$	Eigenvektormatrix, Eigenvektoren
<b>S</b>	Kovarianzmatrix aller Datensätze
$\mathbf{S}_c$	Klassenspezifische Kovarianzmatrix
$\mathbf{S}'_c$	Clusterspezifische Fuzzy-Kovarianzmatrix
$s = 1..S_{ZR}$	Zählvariable für Zeitreihen, z.B. rechtes Knie, sagittal
$s = 1..S_{EM}$	Zählvariable für Einzelmerkmale, z.B. Maximum Schritt rechtes Knie, sagittal
$s = 1..S_Y$	Zählvariable für Klassenarten, z.B. Untersuchungstermin oder Patient
<b>T</b>	Gesamtvariationsmatrix, Total Variance
$\mathbf{U}[k] = ((u_{nsk})) = U_{ns}[k]$	originale Zeitreihen OZR
$\dot{\mathbf{U}}[k] = ((\dot{u}_{nsk})) = \dot{U}_{ns}[k]$	Geschwindigkeitszeitreihen GZR

$\ddot{\mathbf{U}}[k] = ((\ddot{u}_{nsk})) = \ddot{U}_{ns}[k]$	Beschleunigungszeitreihen BZR
$u_{n,c}$	Cluster-Zugehörigkeit
$\mathbf{V}_{s \times C}$	Cluster-Zentren
$\mathbf{X}_{N \times S_{EM}} = ((x_{ns}))$	Einzelmerkmale mit Anzahl Datensätze $N$ und Anzahl Einzelmerkmale $S_{EM}$
$\mathbf{Y}_{N \times S_Y} = ((y_{ns}))$	Klasseneinteilungsmatrix mit Anzahl Datensätze $N$ und Anzahl Klassenarten $S_Y$
$\hat{y}_n$	Klasseneinteilung des $n$ -ten Datensatzes zu allen Klassenarten, z.B. ICP,PRE
$\mathbf{Z}_{N \times S_{ZR}}[k] = ((z_{nsk})) = Z_{ns}[k]$	allgemein Zeitreihen, im Feld dritter Ordnung mit Anzahl Datensätze $N$ und Anzahl Zeitreihen $S_{ZR}$ , z.B. $\mathbf{Z}[k] = (\mathbf{U}[k], \dot{\mathbf{U}}[k])$
$\bar{\mathbf{Z}}[k] = ((\bar{z}_{nsk})) = \bar{Z}_{ns}[k]$	Mittelwertzeitreihen MZR, z.B. $\bar{\mathbf{U}}[k]$ oder $\bar{\dot{\mathbf{U}}}[k]$
$\tilde{\mathbf{Z}}[k] = ((\tilde{z}_{nsk})) = \tilde{Z}_{ns}[k]$	Streuungszeitreihen SZR, z.B. $\tilde{\mathbf{U}}[k]$ oder $\tilde{\dot{\mathbf{U}}}[k]$
$\hat{\mathbf{Z}}[k] = ((\hat{z}_{nsk})) = \hat{Z}_{ns}[k]$	Referenzabweichungszeitreihen RZR, z.B. $\check{\mathbf{U}}[k]$ RZR oder $\check{\dot{\mathbf{U}}}[k]$ RZR GZR

## Abkürzungen

EM	Einzelmerkmal
GZ	Gangzyklus
GZR	Geschwindigkeitszeitreihe
IC	Initial Contact
ICP	Infantile Cerebralparese (ICP) Patienten
ICP,POST	ICP-Patienten zur post-therapeutischen Untersuchung
ICP,PRE	ICP-Patienten zur pre-therapeutischen Untersuchung
ISw	Initial Swing
LR	Loading Response
MAPO	Position Maximum in % des Gangzyklus
MAX	Maximum
MGZR	Mittelwertzeitreihe von Geschwindigkeitszeitreihen
MIN	Minimum
MIPO	Position Minimum in % des Gangzyklus
MSt	Mid Stance
MSw	Mid Swing
MW	Mittelwert
MZR	Mittelwertzeitreihe

POST	Post-therapeutische Untersuchung
PRE	Pre-therapeutische Untersuchung, z.B. ICP,PRE
PSw	Pre Swing
REF	Referenzkollektiv
REF,K	Referenzkollektiv (Kinder) ohne Laufband, mittlere Gehgeschwindigkeit
REF,L	Referenzkollektiv mit Laufband, langsame Gehgeschwindigkeit
REF,M	Referenzkollektiv mit Laufband, mittlere Gehgeschwindigkeit
REF,S	Referenzkollektiv mit Laufband, schnelle Gehgeschwindigkeit
RZR	Referenzabweichungszeitreihe
SCI	Inkomplett querschnittgelähmte (SCI) Patienten
SCI,POST	SCI- Patienten zur post-therapeutischen Untersuchung
SCI,PRE	SCI- Patienten zur pre-therapeutischen Untersuchung
SGZR	Standardabweichungszeitreihe von Geschwindigkeitszeitreihen
SpW	Spannweite
ST	Stand
STRI	Schritt
SW	Schwung
SZR	Standardabweichungszeitreihe
TSt	Terminal Stance
TSw	Terminal Swing
ZGH	Zugehörigkeit
ZR	Zeitreihe

# 1 Einleitung

## 1.1 Motivation

Rechnergestützte Systeme gewinnen für Diagnoseaufgaben und Therapieentscheidungen bei komplexem pathophysiologischen Verhalten im klinischen Einsatz zunehmend an Bedeutung [8, 137].

Ein derart komplexes Anwendungsgebiet ist die medizinische Untersuchung von pathologischem Gangverhalten als Teilbereich der Orthopädie. Bereits das physiologische aufrechte Gehen ist derzeit nicht vollständig erforscht, da eine Vielzahl von Parametern wirksam werden, um den Gang aufrecht (stabil) und effizient zu halten. So wird die Stabilität und Effizienz des Ganges durch dynamisches Zusammenwirken von Bodenreaktionskräften, Trägheitskräften und -momenten sowie Gravitationseinflüssen erreicht [61, 173]. Darüber hinaus stellt die Untersuchung des pathologischen Ganges eine zusätzliche Herausforderung dar. Zur Unterstützung der Mediziner dient die ‘Instrumentelle Ganganalyse’ als ein etabliertes Verfahren zur Quantifizierung von Bewegungsabläufen beim Gehen (z.B. Aufzeichnung der Gelenkwinkelverläufe und -momente). Die klinische Auswertung der Daten (Bestimmung der Gangqualität, Diagnose von Bewegungsstörungen, Therapieplanung und -validierung) erfolgt derzeit allerdings lediglich durch erfahrene Experten [121]:

*„How that [gait analysis] information is interpreted depends heavily on the experience and intuition of the clinicians looking at the data.“*

Aufgrund rein subjektiver Situationseinschätzungen und dem daraus empirisch extrahierten Wissen sind die Gefahren gravierender Fehlentscheidungen mit folgenreichen Konsequenzen für den Patienten unausweichlich. Wegen der Komplexität der Zusammenhänge zwischen den Bewegungsgrößen und vieler ungeklärter Fragen konnte bei der Instrumentellen Ganganalyse bisher keine objektive, standardisierte Basis zur Datenanalyse erstellt werden. Für eine Unterstützung der subjektiven Auswertungsprozedur besteht daher ein großer Bedarf an computerbasierten Datenanalysen [30, 57, 146]. Hierbei können Vorteile beim Einsatz derartiger Methoden genutzt werden, wie die Möglichkeiten zur

- simultanen Betrachtung einer sehr großen Anzahl von Merkmalen,
- Datenauswertung für gesamte Patientengruppen,
- Quantifizierung der Ergebnisse,
- generalisierten objektiveren Auswertungsprozedur sowie
- untersucher- und zeitunabhängigen Entscheidungsfindung.

Schwierigkeiten beim datenbasierten Entwurf und bei der Anwendung solcher Methoden resultieren aus den teilweise großen Rohdatenmengen, die beispielsweise aus mehreren simultan aufgezeichneten Zeitreihen entstehen. Eine weitere Herausforderung ist die Verbesserung der Akzeptanz für eine klinische Anwendung derartiger Entwürfe. Sie kann als zweiseitig gerichtetes Schnittstellenproblem „Mensch (Kliniker)  $\leftrightarrow$  Maschine (Computer)“ formuliert werden. Für die eine Richtung „Mensch  $\rightarrow$  Maschine“ ist eine geeignete klinische Problemformulierung wichtig. Hierbei ist sowohl die mathematische Formulierung von Problemen und die Herangehensweise zur rechnergestützten Lösung entscheidend als auch die Überlegung, auf welche Probleme die Daten prinzipiell Antwort liefern können. Die andere Schnittstellenrichtung „Maschine  $\rightarrow$  Mensch“ setzt die klinische Nachvollziehbarkeit der Herangehensweise voraus, so dass die erhaltenen Ergebnisse validierbar und verständlich sind. In der vorliegenden Arbeit soll ein Beitrag geleistet werden, diese Schnittstelle zu verbessern, um die subjektive Datenanalyse durch computerbasierte Methoden zu unterstützen.

## 1.2 Darstellung des Entwicklungsstandes

### 1.2.1 Einführung in die ‘Instrumentelle Ganganalyse’

Die ‘Instrumentelle Ganganalyse’ ist ein etabliertes Verfahren zur messtechnischen Erfassung von menschlichen und tierischen Bewegungen. Dadurch kann ein besseres Verständnis des physiologischen und pathologischen (krankhaften) Gehens aufgebaut werden [100, 157, 171, 172, 177], um damit neurogene Bewegungsstörungen (z.B. ICP: Infantile Cerebralparese, SCI: Spinal Cord Injury/ Querschnittlähmung) differenzierter zu untersuchen und gezielter zu therapieren [17, 55, 120, 147]. Weitere Anwendungen sind die Anpassung von Beinprothesen und -orthesen [9, 126, 133] oder die Gewinnung von Erkenntnissen in der Robotik [27, 143].

In dieser Arbeit steht die Analyse des menschlichen pathologischen Ganges im Vordergrund. Eine Bewertung und Einschätzung des Gangverhaltens von Patienten

dient der Diagnose und daraus einer Therapieentscheidung sowie einer Kontrolle des Behandlungserfolgs (Therapievalidierung). Um gehbehinderten Menschen mit einer individuellen, optimalen Therapie (z.B. Injektion von Medikamenten in bestimmte Muskeln oder Operationen) zu helfen, muss für die einzelnen Patienten eine möglichst genaue Ursache (Diagnose) des Problems bekannt sein. Durch die Prüfung des Gangverhaltens auf Verbesserung nach einem Therapieeingriff wird die Therapieentscheidung dann im gesamten Behandlungsprozess validiert und ggf. optimiert. Klinische Problemstellungen gliedern sich somit in zwei wesentliche Aufgabenfelder hinsichtlich Diagnose und Therapie, siehe Tabelle 1.1 und [54, 63, 120, 150].

Die Einschätzung einzelner Patienten setzt natürlich Wissen über ein gesamtes Patientenkollektiv voraus. In der medizinischen Praxis werden diese Aufgaben empirisch und iterativ gelöst, indem Erfahrungen von den einzelnen Patienten gesammelt werden, um damit ein Gesamtbild („globales Wissen“) über ein ganzes Kollektiv sukzessiv zu erarbeiten.

Derartige klinische Problemstellungen werden derzeit in der Praxis durch mehr oder minder erfahrene Kliniker anhand visueller Beobachtung (direkte Beobachtung des Patienten) und subjektiver, empirischer Analysen von Gangdaten bearbeitet. Die Bearbeitung wird durch eine klinische Interpretation erreicht, siehe Abbildung 1.1.

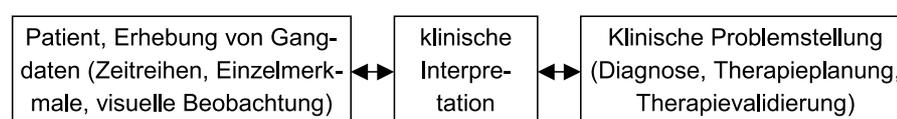


Abbildung 1.1: Klinisches Vorgehen bei der Analyse.

Durch Ganganalyselabors werden klinisch relevante Patienten-Messungen mit dem Ziel durchgeführt, den Experten in seinen Entscheidungen zu unterstützen. Es konnte gezeigt werden, dass derartige Messungen zuverlässig reproduzierbar bestimmte Bereiche des menschlichen Gehens aufnehmen [37, 73]. Dadurch konnten auch Therapieentscheidungen, insbesondere operative Eingriffe, besser getroffen werden als durch eine direkte Beobachtung der Patienten [52, 86, 119, 146].

Die aufgenommenen Messdaten umfassen Bewegungsgrößen, z.B. Kinematikverläufe einzelner Gelenke, Raum-Zeit-Parameter wie Schrittlänge, Kadenz, Gehgeschwindigkeit (Abbildung 1.2) und nicht sichtbare Aktivitäten wie Muskelkontraktion, Bodenreaktionskräfte, Kinetikverläufe, Sauerstoffverbrauch usw. [25, 54, 60, 62, 63, 75, 146].

Ein üblicher Untersuchungsablauf von Patienten wird im Folgenden kurz beschrieben [38, 63, 71, 152]. Die Untersuchung beginnt mit einer Voranalyse, bei der die Personenbasisdaten (z.B. Alter, Gewicht, Beinlänge, maximaler Bewegungs-

<b>Diagnose:</b> Identifikation wesentlicher Gangstörungen, Charakterisierung, Erkennen von Gang-Unterschieden und -Mustern	<b>Therapie:</b> Therapieplanung, -validierung und -prognose
<p>Für ein gesamtes Patientenkollektiv:</p> <ul style="list-style-type: none"> <li>• Was sind die wesentlichen Gangstörungen einer Patientengruppe? Durch welche charakteristischen Merkmale lassen sie sich beschreiben?</li> <li>• Existieren unterschiedliche Subgruppen?</li> <li>• Wie lassen sich diese Subgruppen unterscheiden?</li> </ul> <p>Bei einzelnen Patienten:</p> <ul style="list-style-type: none"> <li>• Was sind die wesentlichen Gangstörungen des Patienten? Wie lässt sich die Gangqualität einschätzen?</li> <li>• Welche Symptome treten auf? Was sind charakteristische Merkmale?</li> <li>• Welche Ursachen (im Gegensatz zur Kompensation) liegen diesen Merkmalen zugrunde?</li> <li>• Wie stark sind die Ursachen ausgeprägt, d.h. ist es ein typischer Patient? Gibt es ausgeprägte Unterschiede zu einem Patientenkollektiv mit einer gleichen Diagnose?</li> </ul>	<p>Für ein gesamtes Patientenkollektiv:</p> <ul style="list-style-type: none"> <li>• Sind charakteristische Veränderungen im Gangbild des Gesamtkollektives oder einzelner Subgruppen zu erwarten?</li> <li>• Bewirkt die Therapie eine Verbesserung?</li> <li>• Lassen sich bestimmte Änderungen/Verbesserungen in einem gesamten Kollektiv oder einzelner Subgruppen als prognostische Aussagen formulieren?</li> </ul> <p>Bei einzelnen Patienten:</p> <ul style="list-style-type: none"> <li>• Welche Therapie empfiehlt sich für den Patienten?</li> <li>• Wird sich der Patient durch diese Therapie voraussichtlich verbessern?</li> </ul>

Tabelle 1.1: Klinische Aufgaben aus Diagnose und Therapie.

bereich einzelner Gelenke) ermittelt werden. Anschließend wird eine herkömmliche Videoaufzeichnung des Patienten beim Gehen durchgeführt. Dadurch kann der Experte den Patienten im Laufe der Therapie subjektiv bewerten. Danach wird die Messung der Gang-Kinematik aufgenommen. Dabei können die Aufzeichnungen auf einem Laufband oder auf festem Boden, d.h. frei durch den Raum gehend, erfolgen.

In darauf folgenden, separaten Untersuchungsdurchgängen werden je nach Krankheitsbild noch zusätzliche Messungen durchgeführt, wie beispielsweise Aufzeichnungen über Muskelaktivitäten (EMG) oder Sauerstoffverbrauch. Die Auswertung für Diagnose und Therapie erfolgt durch rein subjektive Einschätzung von Charts, siehe Abbildung 1.2 und Abschnitt 2.3. Hierbei sind Bewegungsgrößen (insbesondere Gang-Kinematik) der verschiedenen Gelenke auf einen Gangzyklus normiert dargestellt. Ein Gangzyklus beschreibt die Aktivität zwischen zwei Aufsetzpunkten eines Fußes. Dieser ist in funktionelle Phasen gegliedert, z.B. Stand und Schwung, siehe Anhang A.

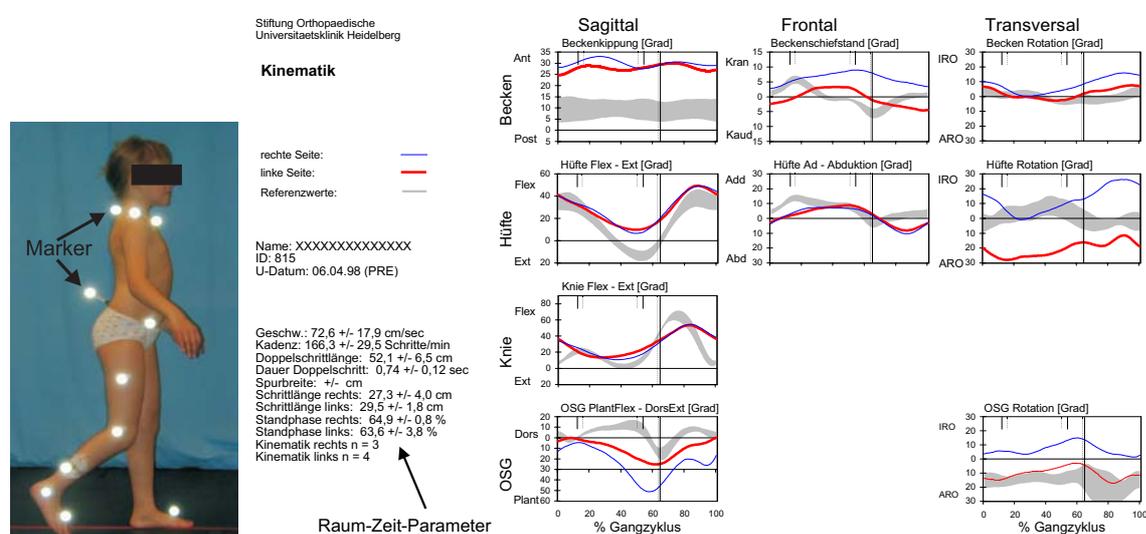


Abbildung 1.2: Links: Patientin während Gangmessung, rechts: rechte (dünn) und linke (dick) Gelenkwinkelverläufe (Becken, Hüfte, Knie, Sprunggelenk bzw. OSG) aus den unterschiedlichen drei körperbezogenen Ebenen (sagittal, von der Seite; frontal, von vorne; transversal, von oben betrachtet).

Weit verbreitet ist die Aufzeichnung der Gelenkwinkelverläufe mit am Patienten befestigten Markern, die Infrarotlicht besonders gut reflektieren [39, 76, 119, 145]. Durch mehrere Infrarotkameras werden die Bewegungskurven (Trajektorien) der Marker im Raum aufgezeichnet und daraus die Gelenkwinkel modellbasiert berechnet, siehe Abbildungen 1.3 und 1.4 sowie [108, 119]. Die Messgenauigkeit ist dabei relativ hoch. Durch das geringe Gewicht der Marker ist der Einfluss auf das Gehen des Menschen klein. Der Nachteil ist das aufwendige Kamerasystem mit der entsprechenden Auswertesoftware und die Schwierigkeit der genauen Markerpositionierung [1].

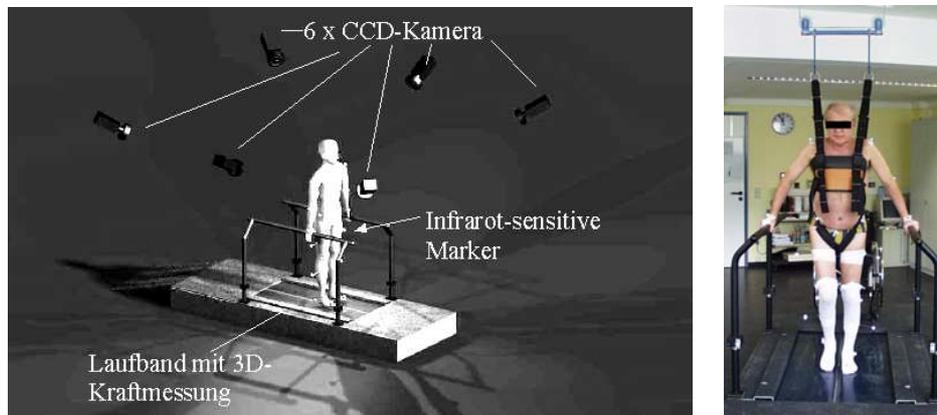


Abbildung 1.3: Links: Prinzip zur Aufnahme von Markertrajektorien während des Gehens auf dem Laufband, rechts: reale Patientenmessung.

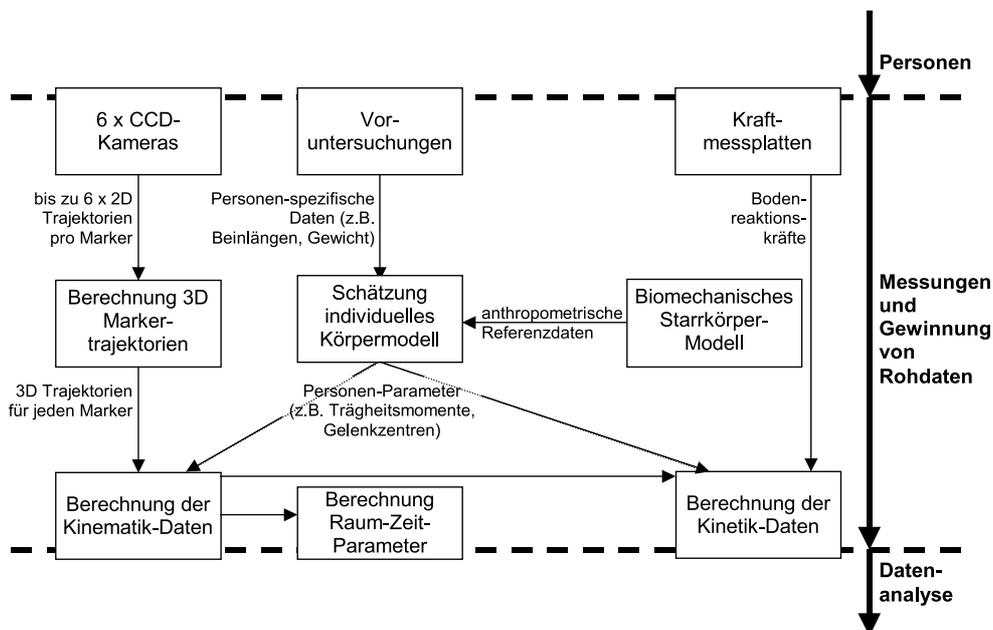


Abbildung 1.4: Schema der Datenaufnahme.

Es existieren weitere Messsysteme, die ohne Marker durch Bildauswerteverfahren die Winkelverläufe berechnen [68, 154], oder frühere Arbeiten, die aus den Videobildern die Winkelverläufe manuell messen [49]. Allerdings sind die schlechte Messgenauigkeit und der hohe individuelle Messaufwand nachteilig. Direkt am Menschen befestigte Sensoren (Goniometer, Beschleunigungssensoren) finden wegen der

zusätzlichen Belastung und damit verfälschten, natürlichen Bewegung seltener Anwendung [171], bieten aber eine einfachere und damit preiswertere Alternative [103].

Die Bodenreaktionskräfte werden durch Fußmesssohlen oder Kraftmessplatten im Boden bzw. Laufband beim Betreten des Patienten bestimmt. Sie dienen zur Erfassung der Druckverteilung während des Abrollvorgangs und zur Schätzung von externen Gelenkmomenten bzw. -leistungen. Die internen Kinetik-Daten (Berücksichtigung der Kräfte und Momente während der Bewegungen) einzelner Gelenke werden derzeit durch Starrkörpermodelle grob geschätzt. Solche Modelle nehmen meist verschiedene Bereiche des Skeletts (z.B. Becken, Ober-, Unterschenkel, Fuß) vereinfacht als einheitliche, starre Körper an, die durch Scharniergelenke verbunden sind [38, 72, 143]. Vernachlässigt werden hierbei Dreh-Gleit-Bewegungen der Gelenke, Gelenkreibung, Einflüsse von Weichteilen wie Haut und Muskulatur, individuelle Ausprägungen wie Muskelkraft, Muskel/Sehnen-Längen und -Positionen usw. [74, 138, 171, 172]. Darüber hinaus sind biomechanische Modelle für Patienten noch weniger fortgeschritten und sehr bedingt verstanden, z.B. das dynamische Verhalten spastischer Muskeln [12, 35, 112, 148, 158, 160].

Muskelaktivitäten werden derzeit durch elektromyographische (EMG) Dünndrahtelektroden an der Hautoberfläche gemessen [146]. Allerdings können hierbei nur die Muskeln erfasst werden, die nahe der Hautoberfläche liegen, tiefer gelegene Muskeln werden nicht gemessen. Weiterhin ist der Zusammenhang zwischen den EMG-Signalen und Muskelkontraktion und -kraft ungeklärt [34, 80]. Hinzu kommen viele patientenindividuelle Unterschiede wie Länge des Muskelstrangs und dessen Ermüdung in Bezug auf die EMG-Signale [34, 63, 80]. Durch Messung des Sauerstoffverbrauchs oder der Herzfrequenz besteht ansatzweise die Möglichkeit, auf die benötigte Energie beim Gehen und damit auf die Effizienz zu schließen (Gangökonomie, [25, 157, 165]).

Für die Erhebung der Gangdaten existieren bereits kommerzielle Softwarelösungen, die die Messdaten wie Markertrajektorien aufbereiten und in Charts als normierte Zeitreihen darstellen [1]. In der praktischen Anwendung müssen allerdings die Daten teilweise noch manuell aufgearbeitet werden, z.B. Löschen von fehlenden Zeitreihen, wie später in Abschnitt 3.3 gezeigt. Eine einheitliche Strukturierung zur automatisierten Analyse existiert noch nicht. Das Exportieren erfolgt durch einzelne Protokolle, in denen die Daten ohne Zusammenhänge gespeichert sind. Der Zugriff auf die Daten muss durch subjektives Auswählen erfolgen. Dazu stehen bereits erste Lösungen zu einer verbesserten Handhabung mit einer grafisch unterstützten Verwaltung der Daten sowie komfortabler Exportschnittstellen zur Verfügung [130]. Die meisten existierenden Arbeiten zur automatisierten Analyse von Gangdaten verwenden kommerzielle Programmlösungen (z.B. Statistica, Microsoft Excel, SPSS), wobei eine subjektive Vorauswahl der Daten und Merkmale erfolgen muss. Eine

Softwarelösung für Gangdaten, die einen vollständigen Analyseprozess unterstützt, existiert noch nicht. Hingegen gibt es erste Ansätze, die subjektives Expertenwissen in Datenbanken speichern, allerdings ohne automatisierte Analyse [77, 167].

## 1.2.2 Automatisierte Analyse von Gangdaten

Ein automatisierter Entwurf basiert auf einem Lerndatensatz, der Beispieldatensätze mit Messwerten (Zeitreihen bzw. bereits daraus extrahierte Merkmale) und evtl. deren bekannte Klassenzuordnung enthält („überwachtes Lernen“ mit Klassenzuordnung, „unüberwachtes Lernen“ ohne Klassenzuordnung). Dabei werden komplexe Zusammenhänge mit mehreren Merkmalen erkannt und quantifiziert. Die im Folgenden vorgestellten Entwürfe werden unter den zwei wichtigen Aspekten mit

- der Merkmalsextraktion und -auswahl sowie
- der Auswertung (Klassifikation)

betrachtet. Die rechnergestützten Arbeiten zur Analyse von Gangdaten basieren meist auf statistischen Verfahren (z.B. Hauptkomponentenanalyse, Signifikanz-Tests), Cluster-Verfahren, Fuzzy-Verfahren oder Methoden, denen ein mechanisches Modell zugrunde liegt. Einen Überblick bietet Tabelle B.1 und [30]. Des Weiteren existieren einige Arbeiten, die auf empirischem Wissen beruhen, das nur durch langjährige Erfahrungen mit bestimmten Patientengruppen aufgebaut werden kann [146].

Automatisierte Verfahren in der Ganganalyse sollen und können den Mediziner nicht ersetzen. Ein Grund ist, dass viele weitere patientenindividuelle Entscheidungen mit berücksichtigt werden müssen, die eine reine computerbasierte Analyse definitiv nicht liefern kann, wie z.B. Einbezug psychischer und physischer Zustände der Patienten bei der Therapieplanung. Allerdings enthalten sie ein großes Potenzial zur Unterstützung bei der Bearbeitung der komplexen Aufgaben aus Diagnose und Therapie. Sie können bei einer Vielzahl von Daten „versteckte Effekte“ mit Gültigkeit für ein gesamtes Kollektiv finden.

Die bisher bekannten Verfahren zur automatisierten bzw. teilautomatisierten Analyse von Gangdaten lassen sich einteilen in:

1. Statistische Verfahren mit empirisch vorausgewählten Merkmalen [3, 35, 36, 60, 136, 152, 162]
2. Verfahren zur Formalisierung von empirischem Wissen und Auswertung von klinischen Tests [33, 43, 44, 67, 76, 77, 101, 128, 129, 167, 179]

3. Cluster-Verfahren [110, 114, 118, 145, 163]
4. Statistische Verfahren ohne empirisch vorausgewählte Merkmale [18, 39, 115, 159]
5. Fourier- und Wavelet-Analysen [69, 87, 134, 159]
6. Fuzzy-Verfahren [97, 108]
7. Künstliche Neuronale Netze [15, 64]
8. Verfahren mit mechanischem Modell [50, 113, 153]

Der gegenwärtige klinische Nutzen nimmt allerdings von oben (1.) nach unten (8.) ab. Ein wesentlicher Grund ist die Interpretierbarkeit der Ergebnisse, die bei den ersten beiden Verfahren von vornherein mit inbegriffen ist. Zu diesen Verfahren existieren zahlreiche Publikationen, die aber oftmals den starken subjektiven Einfluss beklagen [136, 152]. Cluster-Verfahren gewinnen immer mehr an Bedeutung, da unterschiedliche Gangstrategien grundlagenorientiert erforscht werden können. Die Ergebnisse sollen Hinweise für Therapieprognosen geben. Es fehlen allerdings noch Arbeiten, die diese quantitativ dokumentieren [104, 116, 157]. Die klinische Interpretierbarkeit ist sehr hoch, da Kliniker ebenfalls die Patienten in unterschiedliche Subgruppen einteilen [12, 35, 174]. Allerdings existieren derzeit noch wenige Arbeiten zur Analyse der Gangdaten durch Cluster-Verfahren. Zur Verringerung der subjektiven Abhängigkeit werden Merkmale durch explorative statistische Verfahren oder Fourier-Analysen gebildet, allerdings oftmals mit geringer klinischer Relevanz wegen der indifferenten Interpretierbarkeit [30]. Fuzzy-Verfahren beziehen sich auf die natürliche Sprache und bieten somit ein hohes Maß an Interpretierbarkeit. Diese Verfahren sind in der Ganganalyse allerdings noch wenig verbreitet, so dass ein hoher Nachholbedarf besteht. Existierende Arbeiten mit Künstlichen Neuronalen Netzen sind zwar für die gestellten Klassifikationsprobleme (z.B. Erkennung von Patienten) sehr leistungsstark, aber die Ergebnisse sind klinisch nicht zu interpretieren. Verfahren mit mechanischen Modellen versuchen grundlagenorientiert Patientenverhalten zu erklären, jedoch sind sie bei der Beschreibung der Pathologie zu stark vereinfacht und dementsprechend wenig akzeptiert [112]. Die einzelnen Arbeiten zu den Verfahren werden nachfolgend näher beschrieben, wobei die Verfahren auch miteinander kombiniert werden.

**Statistische Verfahren mit empirisch vorausgewählten Merkmalen:** Diese Verfahren extrahieren subjektiv bestimmte Merkmale (z.B. Extrema) aus Kinematikzeitreihen und bewerten in einem weiteren Schritt deren Signifikanz

durch bekannte Verfahren, wie z.B. Univariate Varianzanalyse (ANOVA, siehe Abschnitt 3.6.1), t-Test [3, 35, 36, 129, 136, 152, 162]. Die Erfassung der wesentlichen und meist signifikanten Merkmale (und Kombinationen) für eine bestimmte Patientengruppe kann dadurch nur sehr eingeschränkt erfolgen. Zudem wird der Informationszugewinn aus Kombinationen der vorausgewählten Merkmale oftmals auch methodisch nicht mit berücksichtigt. Die Merkmale werden separat voneinander bewertet. Allerdings ist bei der subjektiven Auswahl die Interpretierbarkeit der Merkmale bereits mit inbegriffen. Sofern sie nicht weiter transformiert werden, ist die Verständlichkeit der Ergebnisse bereits von vornherein gegeben. Prinzipiell ist eine Beschränkung auf wesentliche Merkmale (und Kombinationen) wichtig für die patientenindividuelle Einschätzung der Mediziner. Eine rein subjektive simultane Betrachtung eines derart großen Datenraumes stößt schnell auf Grenzen. Anhand einer methodischen Datenreduktion lassen sich charakteristische Krankheitsbilder kurz umschreiben und eine Suche nach wesentlichen Problemen und Ursachen erleichtern.

Eine Erweiterung dieser Vorgehensweise wurde in [60] anhand von 40 ICP-Patienten<sup>1</sup> gezeigt, indem zu den originalen Kinematikzeitreihen auch die erste zeitliche Ableitung mit berücksichtigt wurde, wobei auch hier die Auswahl von Merkmalen aus allen Zeitreihen auf subjektiven Entscheidungen basiert. Bei zusätzlicher Verwendung dieser Zeitreihen konnte eine bessere Klassifikation zwischen pre-therapeutischem Zustand und einer Referenzgruppe gezeigt werden. Allerdings zeigte diese Patientengruppe keine signifikante Änderung in abgeleiteten Zeitreihen während des Therapieverlaufs. Basierend auf derartigen vorausgewählten Merkmalen wurden in [135] der Informationsverlust zwischen (auf Standperiode) normierten und nicht-normierten Gangdaten mit Künstlichen Neuronalen Netzen untersucht. Der verwendete Datensatz bestand aus 13 weiblichen Probanden mit unterschiedlichen Arten von Schuhen.

Des Weiteren existieren Arbeiten, die quantitative Merkmale bestimmen (Phasenverschiebungen, links/rechts Symmetrie-Indikatoren, ...), um sie auf ihre Aussagekraft zu untersuchen [84, 85]. Die Merkmale werden wie bei den anderen Arbeiten mit statistischen Verfahren auf Relevanz zur Klassentrennung untersucht. Übliche Klasseneinteilungen sind „pathologisch“ und „physiologisch“ oder „Pre“- und „Post“-Zeitpunkte einer Therapie. Allerdings sind derartige Arbeiten lediglich auf die ausgewählten Merkmale begrenzt.

Um das Gangverhalten bezüglich einer Referenz zu charakterisieren, wurde in [182] ein statistischer Ansatz verwendet, der sowohl originale Zeitreihen, als auch die erste zeitliche Ableitung berücksichtigt. Jedoch wurden nur fünf fest ausgewählte

---

<sup>1</sup>Infantile Cerebralparese, siehe auch Kapitel 2 und Anhang A

Abtastzeitpunkte während eines Gangzyklus betrachtet. Für diese Zeitpunkte wurde der zweidimensionale Merkmalsraum aus originaler und abgeleiteter Zeitreihe betrachtet. Anhand von Probanden-Daten lassen sich in diesem zweidimensionalen Raum jeweils Mittelwerte und Kovarianzmatrizen berechnen. Das Ergebnis sind fünf „Referenz-Ellipsen“. Eine vorgeschlagene Klassifikation der Daten hinsichtlich ‘physiologisch’ und ‘pathologisch’ soll mit Abstandsmaßen zu den betreffenden fünf „Norm-Ellipsen“ erfolgen. Allerdings wurde in der Arbeit nur die Idee vorgeschlagen und nicht deren praktische Umsetzung und Funktionalität demonstriert.

**Verfahren zur Formalisierung empirischen Wissens und klinische Tests:** Dazu kommen eine Reihe von Arbeiten, die lediglich die subjektive Vorgehensweise und das Expertenwissen formalisieren, beispielsweise durch Fragenkataloge, klinische Punktelisten, sog. „Functional Assessments“, Bewertungstabellen oder Entscheidungsbäume [67, 76, 77, 167]. Derartige Methoden sind allerdings stark beschränkt auf die jeweils untersuchte Patientengruppe oder basieren auf rein empirischem Wissen. Insbesondere ist bei vielen klinischen Tests nicht die Relation zum eigentlichen Gangverhalten inbegriffen, deren weitere Analyse bleibt dem Kliniker überlassen. Ausgewertet werden beispielsweise Parameter wie Muskelstärken, statische Bewegungsspannen, Schmerz- und Reaktionsempfindlichkeit, verwendete Gehhilfen zur Erreichung bestimmter Strecken usw. [43, 44, 101, 128, 179].

Trotz verbesserter Therapieentscheidungen durch präzisere Messungen mit Ganganalysen verbleibt eine hohe Variabilität (Inter-Untersucher und -Institutionen) bei der Interpretation von Daten durch den hohen subjektiven Anteil [141, 164]. Weitere Nachteile sind die Beschränkung auf bestimmte Patientengruppen oder eingeschränkte Möglichkeiten zur Änderung und Erweiterung [84].

**Cluster-Verfahren:** Fuzzy-Cluster-Verfahren sind in [19, 20, 22, 169] zu finden. Durch ein Abstandsmaß wird eine graduelle Zuordnung zu verschiedenen Cluster-Zentren berechnet. Die Cluster-Zentren können als Ausprägung für ein bestimmtes Krankheitsbild oder physiologische Charakteristik interpretiert werden [104]. Die graduelle Zuordnung der Messwerte (z.B. eines Patienten) zu den Zentren wird hier als Ausmaß eines Krankheitsbildes (oder einer Genesung) gedeutet. Im Gegensatz zu scharfen Gruppeneinteilungen können mit Fuzzy-Verfahren gleiche Krankheitsbilder sogar mit individuellen Ausprägungen erkannt werden. In der Ganganalyse wurden in [118] Einzelmerkmale (Schrittlänge und Kadenz) durch fünf Cluster (eins für gesundes Gehen und vier für pathologische Gangarten) gruppiert. Es wurden 88 ICP-Patienten im Vergleich zu 68 Probanden untersucht. Durch einen unüberwachten Lernalgorithmus<sup>2</sup> konnten die Daten gut unterteilt werden. Eine medizinische Interpretation wurde an die gefundenen Patientengruppen angepasst. Allerdings ba-

---

<sup>2</sup>Überwachte und unüberwachte Lernalgorithmen unterscheiden sich in der Vorgabe einer Klassen- bzw. Gruppeneinteilung, siehe auch Kapitel 3.

siert die Einteilung nur auf zwei Merkmalen, eine differenziertere Aufteilung wurde nicht betrachtet. Ein Behandlungserfolg wurde daran gemessen, wie stark sich der Abstand zum Cluster-Zentrum für gesundes Gehen reduziert. Weiterhin basiert diese Arbeit auf Ansätzen zur Kompensation des Alters und der Beinlänge durch lineare Regression [117]. Sowohl die Kadenz, als auch die Schrittlänge wurden auf das Patientenalter bzw. Beinlänge normiert. Somit sind modifizierte (neue) Merkmale verwendet worden. Diese Betrachtung führte zu einer besseren Zuordnung zu den Clustern, d.h. auch zu einer besseren Trennung zwischen gesundem und pathologischem Verhalten. Allerdings wird dadurch die medizinische Interpretation erschwert.

Vereinzelt abgeleitete Einzelmerkmale (Spannweite, Extrema, Mittelwert bezogen auf den gesamten Gangzyklus) aus sagittalen Kinematikdaten (Hüft-, Knie- und Sprunggelenk-Flexion) wurden in [114] mittels Fuzzy-Cluster-Verfahren untersucht. Hierbei wurden die Daten von insgesamt 146 ICP-Patienten verwendet und in acht Gruppen unterteilt. Sowohl die Merkmalsauswahl als auch die Anzahl der Cluster-Zentren wurde rein subjektiv gewählt. Dennoch liefert die Interpretation des Ergebnisses einen Versuch zur Diagnose, z.B. Einteilung in Gruppen wie starker Kauergang (kleine Hüftflexions-Spannweite bei insgesamt großem Flexionswinkel) oder leichtes Knie-Recurvatum (Hyperextension, Überstreckung, hier vorwiegend in der Standphase, charakterisiert durch negativen Knieflexionswinkel). Durch ähnliche Methoden (wenige, subjektiv ausgewählte Einzelmerkmale, hierarchisches, hartes Clustern) wurden in [163, 176] Unterschiede im Gangverhalten zwischen jungen und alten Menschen untersucht.

Fest definierte Merkmale aus Kinematikzeitreihen (Extrema in den einzelnen Gangphasen) sowie Raum-Zeit-Parameter und EMG-Merkmale wurden in [110] für Cluster-Analysen bei 47 Schlaganfall-Patienten verwendet. Bei 42 Patienten wurde der Verlauf der Rehabilitation untersucht. Die Daten wurden jeweils in vier Gruppen eingeteilt und im Einklang mit klinischer Expertise diskutiert. Allerdings erstreckt sich die Merkmalsextraktion aus den Zeitreihen auf eine beschränkte Auswahl.

In [145] wurden drei verschiedene Kinematikzeitreihen des Fußes (Bewegungen des Hinterfußes, Vorderfußes und Vorderfuß im Verhältnis zum Schienbein) von 10 Patienten mit Sprunggelenk-Arthrodesen (Gelenkversteifung) und 10 gesunden Probanden durch Fuzzy-Cluster graduell zu Gruppen zugeordnet. Hierbei wurden drei „Zeitreihen-Cluster-Zentren“ lediglich über den kompletten Kinematikverlauf des Sprunggelenks berechnet. Ein Cluster-Zentrum repräsentierte den gesunden Gang und zwei Zentren unterschiedliche pathologische Ausprägungen. Zur Überprüfung der Ähnlichkeit von „Zeitreihen-Cluster-Zentren“ mit den realen Zeitreihen wurde eine Korrelationsberechnung durchgeführt. Nun können die Patientengruppen mit Hilfe der Cluster-Zugehörigkeiten eingeteilt werden. Ein Problem stellt in dieser Arbeit allerdings die geringe Anzahl von Patienten dar. Das führte zu hypothetisch

formulierten Patientensubgruppen (acht Patienten wurden einer Subgruppe zugeteilt, zwei einer weiteren, darüber hinaus wurden zwei weitere hypothetische Subgruppen formuliert). Des Weiteren wurde nur separat über die einzelnen Zeitreihen das Cluster-Verfahren durchgeführt, ohne weitere Kombinationen von Merkmalen.

Andere Arbeiten zur Einteilung verschiedener Gangbilder anhand der Kinematikzeitreihen in bestimmte Kategorien basieren auf empirischer Beobachtung und Definitionen [12, 35, 157, 174]. Derartige (vereinzelte) subjektive Erfahrungen sind in der Ganganalyse durchaus sehr anerkannt und neue computerbasierte Methoden werden anhand dieser validiert [136, 150].

**Statistische Verfahren ohne empirisch vorausgewählte Merkmale:** Die Hauptkomponentenanalyse maximiert die Kovarianzinformation (z.B. aus allen Abtastzeitpunkten in Zeitreihen oder daraus extrahierten Merkmalen) durch Linearkombination der Daten in einem unkorrelierten, virtuellen Raum, siehe Anhang C. Durch Gewichtungsfaktoren werden signifikante Bereiche stärker mit einbezogen. Im Idealfall können Klassentrennungen (z.B. Referenzpersonen und Patienten) in dem neuen Raum ermittelt werden. In [39, 40] wurden Kinematikzeitreihen von 13 Patienten, die an Knie-Osteoarthritis (Gelenkentzündung) leiden, im Vergleich zu 37 Probanden ausgewertet. Die Methode wurde auch auf abgeleitete Merkmale aus Zeitreihen wie Extremwerte oder Spannweiten angewandt [115].

Bei Verwendung bekannter Klasseneinteilungen kann mit ähnlicher Mathematik durch die Diskriminanzanalyse die beste Merkmalskombination zur Trennung zwischen den Klassen ermittelt werden [108]. Beispielsweise kann die Klasseneinteilung ‘physiologisch’ und ‘pathologisch’ oder ‘pre’- und ‘post’-therapeutischer Zustand zum Ermitteln von Änderungseffekten durch eine Therapie lauten. Die Anwendung der Methode zielt ebenfalls auf das Ermitteln signifikanter Bereiche und der Reduktion redundanter Information. In [68] wurde die Diskriminanzanalyse verwendet, um aus Video-Bildern gesunde Probanden voneinander zu trennen.

Die Hauptkomponenten- bzw. Diskriminanzanalyse betrachten allerdings nur affine Zusammenhänge (Linearität ohne translatorischen Anteil) in den Daten. Eine klinische Interpretation in dem neuen Raum ist wegen der Merkmalskombination sehr schwierig und wird oftmals vernachlässigt [39, 68]. Zwar werden die Gewichtungsfaktoren aus der Linearkombination fallweise klinisch diskutiert, aber die unterschiedlichen Vorzeichen in der Linearkombination werden oftmals vernachlässigt. Dynamische Zusammenhänge in Zeitreihen (entsprechend zeitlichen Ableitungen), die diese Analyse berücksichtigen kann, werden aufgrund der Vielzahl der Merkmalskombinationen nicht interpretiert [39, 115].

Das Ermitteln wichtiger Merkmale wurde in [18] durch eine heuristische Optimierung gelöst, wobei als Merkmale die Abtastzeitpunkte von drei Kinetik-Zeitreihen verwendet wurden. Untersucht wurden jeweils 28 Plattfuß-Patienten im Vergleich

zu gesunden Probanden mit dem Ziel zwei operative Techniken zu validieren. Das Ergebnis liefert bestimmte Abtastzeitpunkte in Zeitreihen, die zur Trennung der beiden Klassen signifikant sind. Diese Bereiche dienen als Hinweis für die Mediziner im Sinne einer Datenreduktion.

**Fourier- und Wavelet-Analysen:** Auf Basis der Fourier-Koeffizienten und anschließender Hauptkomponentenanalyse wurden Abweichungen von zwei ICP-Patienten in Bezug zu 174 Referenzpersonen anhand der sagittalen Kinematikzeitreihen berechnet [159]. Durch die Methode lässt sich der gesamte Datenraum auf wenige bzw. einen Parameter reduzieren, der das Gangverhalten von Patienten beschreibt. Allerdings richtet sich die Berechnung derartiger Parameter nicht nach dem empirischen Analyseverfahren, so dass eine klinische Diskussion und Interpretation des berechneten Ergebnisses nicht möglich ist. Weiterhin ist eine gezielte Analyse von aussagekräftigen Zeitreihenverläufen durch das Zusammenfassen der ganzen Zeitreihe in einem Parameter nicht möglich.

Durch diskrete Fourier-Analysen lassen sich periodische Zeitreihen durch die Koeffizienten vergleichen. In der Ganganalyse wurden beispielsweise gemessene Bodenreaktionskräfte von 26 gesunden Probanden mit 10 Patienten, die an einer Knieerkrankung leiden, verglichen [134]. Untersuchte Fragestellungen sind hier das Finden wesentlicher Frequenzen zur Unterscheidung von Patienten und Probanden. Problematisch ist allerdings die klinische Interpretation, die hier wenn überhaupt nur in Ansätzen erfolgt. Des Weiteren geht bei der Fourier-Analyse die Zeitinformation verloren. Das ist bei der Wavelet-Analyse nicht der Fall, wobei auch hier die sehr eingeschränkte klinische Interpretation in der Literatur beklagt wird. Daher kommen diese Methoden nur eingeschränkt zur Datenvorverarbeitung zum Einsatz [30, 69, 102].

Zur Beschreibung von Referenzdaten bietet die Berechnung eines Konfidenzintervalls über gesamte Zeitreihen eine Möglichkeit [87]. Hierbei werden die kompletten Zeitreihen mit der Fourier-Transformation im Bildbereich untersucht und verglichen.

**Fuzzy Verfahren:** Die Reduzierung von Messdaten auf wenige linguistische Variablen wurde in [24, 97, 98, 99] vorgeschlagen. Hierbei werden die Daten (Zeitreihen) durch Zugehörigkeitsfunktionen in so genannte Zeitbereiche und darin gemittelte Signalbereiche eingeteilt. Mit einer Faktoranalyse werden die Bereiche gesucht, die die größten Unterschiede zwischen den untersuchten Daten-Gruppen liefern und diese somit „erklären“. Mit der Fuzzifizierung wurde versucht, die Ergebnisse der Faktoranalyse zu interpretieren. Um Schrittphasen zu erkennen, wurden in [5, 108] Fuzzy-Klassifikatoren verwendet. Die Anwendung der Methoden auf Daten der Ganganalyse bezogen sich bei den Arbeiten allerdings nur auf gesunde Menschen.

Um Sport-Bewegungsabläufe zu optimieren, wurden in [131] Fuzzy-Regeln entworfen, um bestimmte nichtlineare, multivariate Zusammenhänge zu formalisieren.

Der Entwurf der Zugehörigkeitsfunktionen und Regeln basierte hier allerdings auf subjektivem Expertenwissen. Das Ziel ist die Erstellung einer allgemein gültigen Regelbasis für spezielle Bewegungsfiguren, die ein Ausgangsverhalten (z.B. Stabilitätskriterien) mit ausgewählten Merkmalen (z.B. Position von Gelenken) maßgeblich beeinflussen. Wegen der verwendeten starken Vereinfachungen und der subjektiven Annahmen konnten die erhaltenen Regeln nur bedingt validiert werden.

**Künstliche Neuronale Netze:** Die Untersuchung der Fourier-Koeffizienten der Knie- und Hüft-Kinematikverläufe wurde in [15] mit Hilfe Künstlicher Neuronaler Netze gezeigt und anhand von Phasendiagrammen (hier Hüft- gegen Knie-Verlauf) angewandt. Hierbei sind allerdings nur die Potenziale von Künstlichen Neuronalen Netzen für die Klassifikation von physiologischem und pathologischem Gang gezeigt. Die Interpretation und charakterisierende Eigenschaften von Patienten konnten nicht bzw. nur sehr eingeschränkt erfolgen [14, 16, 64]. Ein weiteres Problem ist in der Arbeit erwähnt, indem die Strukturen der Künstlichen Neuronalen Netze problem- und anwendungsspezifisch gewählt werden müssen. Daher ist die Methode auf unterschiedliche Patientengruppen oder Fragestellungen nur bedingt übertragbar.

**Verfahren mit mechanischem Modell:** Unter Verwendung eines einfachen mechanischen Modells (Pendel mit einer Punktmasse) wurden in [50] sechs Kinder, die an infantiler Cerebralparese (ICP, Anhang A) leiden, mit sechs gesunden Kindern verglichen. Beide Gruppen wurden bei unterschiedlichen Gehgeschwindigkeiten untersucht. Die bei dieser pathologischen Gangart typische erhöhte Beinsteifigkeit (z.B. durch erhöhte Muskelverkrampfung) und verminderte Muskelkraft (z.B. durch reduzierte Muskelkontraktions-Fähigkeit, größeres Sehnen zu Muskel-Verhältnis) konnte durch das Modell gezeigt werden. Die Quantifizierung der Parameter für das reale Verhalten kann wegen der groben Modellstruktur allerdings nicht erfolgen. Eine Erhöhung der Beinsteifigkeit wird beispielsweise auch bei schnelleren Gehgeschwindigkeiten beim gesunden Menschen festgestellt. So wird oft dieses Krankheitsbild mit dem Gangmuster von rennenden, gesunden Probanden verglichen [52]. Die Variabilität der Beinsteifigkeit wurde in [113] anhand von 24 gesunden Probanden untersucht. Dabei schlangen die Probanden ein Bein im gestreckten Zustand, das anschließend mit einem einfachen Punktmasse-Feder-Pendel mathematisch beschrieben wurde. Dämpfungen wurden hier allerdings nicht berücksichtigt.

## 1.3 Offene Fragen

In der medizinischen Praxis erfolgt – trotz vieler Forschungsarbeiten zu automatisierten Verfahren (siehe z.B. [8, 30, 31]) – der gesamte Entscheidungsprozess fast

immer empirisch ohne eine automatisierte computergestützte Auswertung. Wesentliche Einschränkungen der subjektiven Analysen sind, dass

- die Datenauswertung allein auf erfahrenen Experten beruht,
- die Schlussfolgerungen lediglich subjektiv begründet sind,
- das Wissen auf empirischer Erarbeitung basiert,
- langjährige Erfahrung für bestimmte Patientengruppen notwendig ist und
- nur eine begrenzte Anzahl von Merkmalen simultan betrachtet werden können.

Aus den vorgestellten Arbeiten zur automatisierten Analyse von Gangdaten lassen sich gemeinsame Probleme erkennen. Diese sind:

- Ausrichtung auf nur eingeschränkte Fragestellungen, z.B. lediglich Klassifikation ‘physiologisch’ und ‘pathologisch’, ungeachtet von weiteren Fragestellungen wie Bevorzugung valider oder besser interpretierbarer Merkmale oder einer objektiven Auswahl von Subgruppen [18, 39],
- Ignorieren inhomogener Klassen, die sich aus verschiedenen, oftmals unbekanntem Subklassen zusammensetzen, z.B. Zusammenfassen heterogener Patientenkollektive zu einer Klasse [15, 152],
- Zuschneiden auf bestimmte Patientengruppen und damit mangelnde Übertragbarkeit auf andere Patientengruppen [76, 116, 136] oder Untersuchung nur weniger Patienten, was zu mangelhaften statistischen Absicherungen führt [109, 145],
- Verwendung empirisch ermittelter Merkmale, die erst danach auf Relevanz bezüglich einer Problemstellung untersucht werden [35, 152],
- Betrachtung eines eingeschränkten Teils des gesamten Datenraumes und damit Fokussierung auf nur wenige Merkmale im Vergleich zu empirischen differenzierten Analysen [60, 118],
- Fehlende Transparenz und schwierige Interpretation der Ergebnisse im Hinblick auf klinische Vorgehensweisen, d.h. komplizierte Verknüpfung einer Vielzahl von Merkmalen, z.B. mit Künstlichen Neuronalen Netzen, statistischen Klassifikatoren, Transformation durch Hauptkomponentenanalyse [30, 39, 87, 115, 182].

Insbesondere für den letztgenannten Punkt ist bei der Ganganalyse zu beachten, dass eher die Nachvollziehbarkeit des Lösungsweges zum berechneten Ergebnis als

das Ergebnis selbst im Vordergrund steht. Der Lösungsweg ist durch relevante Merkmale, Wirkungsrichtungen und Zusammenhänge zwischen Merkmalen gekennzeichnet, z.B. Erkennung von Symptomen zur Diagnose → Therapieplanung → Therapievalidierung. Die beiden wichtigen Aspekte bei der automatisierten Datenanalyse mit Merkmalsextraktion/-auswahl und Auswertung/Klassifikation werden in diesen Arbeiten nur bedingt gemeinsam betrachtet und gelöst. Weiterhin fehlt eine Software-Lösung, die eine Anwendung von Data Mining Methoden bei Gangdaten unterstützt.

## 1.4 Ziele und Aufgaben

Durch die vorliegende Arbeit sollen die Gebiete „Ganganalyse“ mit ihren offenen Fragen und „Data Mining Methoden“ zusammengeführt werden. Dazu müssen die klinischen Fragen ermittelt, für Data Mining Methoden geeignet formalisiert und auf die Lösbarkeit untersucht werden. So ist sowohl die klinische Anbindung als auch der methodische Entwicklungsprozess zu integrieren (Beachtung der Schnittstelle „Klinik“ ↔ „Data Mining Methoden“). Dazu müssen sowohl bestehende Methoden weiterentwickelt als auch neue Methoden im Bereich der Ganganalyse eingesetzt und entsprechend angepasst werden. Insbesondere soll eine verbesserte Lösung zu den in Abschnitt 1.3 gezeigten offenen Fragen durch

- die Betrachtung erweiterter klinischer Fragestellungen (z.B. Quantitative Bestimmung des pathologischen Ausmaßes, Charakterisierung eines Patientenkollektives oder der darin enthaltenen Subgruppen, siehe Tabelle 1.1), d.h. die Verbesserung der Schnittstelle „Mensch → Maschine“,
- die Berücksichtigung heterogener Patientenkollektive, worin unbekannte Subgruppen mit unterschiedlichen Symptomen und Therapieaussichten möglicherweise vorhanden sind,
- die Entwicklung von Auswertungsprozeduren, die unabhängig von den gegebenen Patientengruppen sind,
- die objektivere Auswertung der Daten, um den subjektiven Einfluss bei der Datenvorauswahl zu reduzieren,
- die Betrachtung des gesamten Datenraumes sowie
- eine transparente, interpretierbare Vorgehensweise, d.h. die Verbesserung der Schnittstelle „Maschine → Mensch“ durch Einbezug von Apriori-Wissen

gefunden werden. Existierende Verfahren (acht Gruppen aus Abschnitt 1.2.2) sind entweder gut interpretierbar, beschränken aber durch subjektive Vorauswahl den Datenraum, oder erfassen den kompletten Datenraum, sind aber durch kompliziert verknüpfte Rechenschritte nicht interpretierbar, siehe Anhang B.

Die vorliegende Arbeit soll ein Konzept erarbeiten, das die Vorteile aus den acht Einteilungen miteinander verbindet. Dazu sollen existierende Data Mining Verfahren modifiziert und angewendet werden, damit die in Tabelle 1.1 genannten unterschiedlichen klinischen Aufgaben gelöst werden können. Beispielsweise sollen

- wesentliche Gangstörungen als pathologische Abweichung von Patientenkollektiven quantifiziert,
- charakteristische Merkmale ohne subjektiven Einfluss automatisiert erkannt und
- Subgruppen gefunden und charakterisiert werden.

Die Ergebnisse müssen wahlweise das gesamte Kollektiv oder einzelne Patienten beschreiben. Die modifizierten Verfahren sollen sowohl für die Diagnose als auch für die Therapie einsetzbar sein. Somit können Fragestellungen wie „Wodurch ist das Patientenkollektiv vor der Therapie charakterisiert?“, „Wie ändern sich diese Merkmale durch die Therapie?“ oder „Existieren Subgruppen und haben sie eine Auswirkung auf die Therapie?“ untersucht werden.

Grundlegende Voraussetzungen wie z.B. die Robustheit gegen „Ausreißer“ und Messfehler, die Akzeptanz fehlender Daten oder Extraktion relevanter Informationen sind zudem zu erfüllen. Die Vorteile von computerbasierten Analysen, wie z.B. simultane Betrachtung sehr vieler Merkmale oder Auswertung gesamter Patientengruppen, sollen dabei ausgenutzt werden, um den Einschränkungen der subjektiven Analyse entgegenzuwirken.

Die modifizierten Methoden sollen einen Beitrag zur Gewinnung von globalem, quantifizierbarem Wissen über ein ganzes Patientenkollektiv liefern und die subjektive klinische Einschätzung von Patienten unterstützen [8, 31, 146]. Dadurch sollen auch weniger erfahrene Mediziner auf dem Gebiet einen besseren Zugang bei der Einarbeitung in die komplexen Gangpathologien erhalten (Verbesserung der „Lernkurve“).

In dieser Arbeit werden zunächst die zur Verfügung stehenden Datensätze und die Vorgehensweise bei der subjektiven Analyse beschrieben (Kapitel 2). Dabei wird versucht, das eher zerstreute und wenig zusammenhängende empirische Wissen bei der Analyse zu sammeln und Gesetzmäßigkeiten sowie Systematisierungen daraus abzuleiten [88].

Die Systematik wird anschließend als computerbasierte Vorgehensweise nachgebildet (Kapitel 3). Durch eine modulare rechnergestützte Analysemethodik lassen

sich klinische Problemformulierungen lösen, die derzeit nur mit den Einschränkungen aus Abschnitt 1.3 gelöst werden [90, 94, 95].

Um die hier erarbeitete Methodik auch im klinischen Alltag einsetzen zu können, ist ein benutzerfreundlicher Zugang notwendig. Dazu sind alle vorgestellten Methoden in Form einer Softwaretoolbox mit einer grafischen Bedienoberfläche zu implementieren [96] und in MATLAB [156] zu realisieren (Kapitel 4).

Die erfolgreiche Anwendung der Arbeit wird mit Datensätzen verschiedener Krankheitsbilder aufgezeigt (Kapitel 5). Zur Validierung der Arbeit werden die Ergebnisse mit bekannten Ergebnissen aus der Literatur verglichen [136, 152, 159]. Darüber hinaus werden eine Reihe neuer Erkenntnisse in der Ganganalyse vorgestellt [88, 90, 91, 93, 94].

Nach einer Zusammenfassung (Kapitel 6) befinden sich im Anhang Angaben über Begriffe, kompakte Einführungen in weiterführende Analysemethoden sowie Ergänzungen zu den zur Verfügung stehenden Datensätzen.

# 2 Datenbeschreibung und empirische Analyse

## 2.1 Beschreibung der Datensätze und Krankheitsbilder

Die Datensätze (Rohdaten), die für diese Arbeit zur Verfügung standen, setzen sich aus folgenden Gruppen zusammen:

- ein Referenzkollektiv bestehend aus 10 Probanden (Durchschnittsalter  $33 \pm 13$  Jahre) ohne orthopädische Einschränkungen bei drei unterschiedlichen, selbst gewählten Gehgeschwindigkeiten (langsam, REF,L; mittel, REF,M; schnell, REF,S) auf dem Laufband (6 Kameratechnik Motion Analysis, Santa Rosa, CA, USA [1]),
- ein Referenzkollektiv bestehend aus 10 Probanden (REF,K Durchschnittsalter  $10 \pm 6$  Jahre) ohne orthopädische Einschränkungen bei selbst gewählter mittlerer Gehgeschwindigkeit ohne Laufband (6 Kameratechnik, Vicon Motion Systems, Oxford, England),
- 43 infantile Cerebralparese (ICP) Patienten (Durchschnittsalter  $6 \pm 2$  Jahre) mit diplegischem (beidseitigem), dynamischen Spitzfuß zu pre-therapeutischen (ICP,PRE) und post-therapeutischen (ICP,POST) Untersuchungen ca. sechs Wochen (U1) und ca. vier bis sechs Monate (U2) nach einer Botulinum-Toxin-Therapie (6 Kameratechnik, Vicon Motion Systems, Oxford, England), sowie
- 29 inkomplett querschnittgelähmte (SCI) Patienten (Durchschnittsalter  $50 \pm 18$  Jahre) zu mehreren (unterschiedlichen) Untersuchungszeitpunkten vor (SCI,PRE), während und nach einer Therapie (SCI,POST) durch Laufbandlokomotion mit jeweils individuell angepasster Gehgeschwindigkeit und teilweiser Körpergewichtsentlastung (6 Kameratechnik Motion Analysis, Santa Rosa, CA, USA).

Die Rohdaten bestehen aus Zeitreihen und Einzelmerkmalen und dienen hier als Lerndatensatz für die computergestützte Analyse. Der Begriff „Merkmale“ wird als Oberbegriff für Zeitreihen und Einzelmerkmale verwendet<sup>1</sup>. Die Zeitreihen sind Kinematikverläufe einzelner Gelenke aus den drei Raumrichtungen, z.B. sagittale Gelenkwinkelverläufe des Knies oder der Hüfte. Die verschiedenen Gelenkwinkelstellungen und -bewegungen sind orthopädisch unterschiedlich bezeichnet, die allerdings in dieser Arbeit durch die Kategorisierung vereinheitlicht wird, siehe Anhang A, Tabelle Tabelle A.1 und Abschnitt 3.3. Beispielsweise wird die Bewegung des Sprunggelenks von der sagittalen Körperseite als Dorsalflexion (cranial, nach oben „zum Kopf hin“) bzw. Plantarflexion (distal, nach unten „zum Fuß hin“) bezeichnet. Ebenfalls von der sagittalen Ebene (von der Körperseite betrachtet) sind andere Gelenke wie das Knie als Flexion (Beugung) bzw. Extension (Streckung) oder das Becken mit Anterior (nach vorne) Posterior (nach hinten) beschrieben. Aus technischer Sicht lassen sich diese Unterschiede allerdings einheitlich benennen (Drehung um die jeweilige Gelenkachse in sagittaler Ebene, mathematisches Vorzeichen in Anlehnung an orthopädische Richtung). Die Zeitreihen beschreiben einen vollständigen Gangzyklus (GZ), der in funktionelle und standardisierte Abschnitte unterteilt ist, z.B. Stand- und Schwungphase, siehe Anhang A.

Da bei den hier zur Verfügung stehenden Datensätzen nur sehr vereinzelt Kinetikverläufe der Gelenke und Muskelaktivitäten (EMG) vorhanden sind, werden diese im Folgenden nicht weiter betrachtet. Die hier entwickelten Analysemethoden sind allerdings für die allgemeine Auswertung von Gangdaten einsetzbar, so dass sie auch auf weitere Daten anwendbar sind.

Als Einzelmerkmale werden in dieser Arbeit Daten ohne Zeitverlauf bezüglich des Gangzyklus beschrieben. Bei den Rohdaten sind dies entweder Personenbasisdaten (Alter, Gewicht, ...) oder Raum-Zeit-Parameter (Kadenz, Gehgeschwindigkeit, ...) oder bei den SCI-Patienten auch die subjektive, medizinische Einschätzung der Gangqualität. Daneben existieren einige Informationen, die mit Unsicherheiten verbunden, schwer formalisierbar und oftmals unvollständig sind. Diese Informationen können unter Umständen durch „nachfragen“ erhalten werden, wie z.B. klinische Hinweise zur Handhabung der Daten, Bevorzugung bestimmter Merkmalsarten, unterschiedliche Messqualität der Merkmale oder empirisches Wissen.

### 2.1.1 Referenzdaten

Die Daten des Referenzkollektives bestehen aus 10 Probanden ohne orthopädische Einschränkungen, die auf dem Laufband bei drei individuell gewählten Gehgeschwin-

---

<sup>1</sup>Jeder Abtastzeitpunkt einer Zeitreihe kann wiederum als Merkmal aufgefasst werden; eine komplette Zeitreihe als „Sammlung“ mehrerer Merkmale.

digkeiten (langsam, mittel, schnell) aufgezeichnet worden sind, siehe Tabelle 2.1. Es wurden zwischen 14 und 41 Schritten gemessen. Dieses Kollektiv wird hier zum Vergleich der inkomplett querschnittgelähmten Patienten verwendet, da sie unter vergleichbaren Bedingungen im selben Labor vermessen worden sind.

Zeitreihen für linke/rechte Körperseite
<b>Becken</b> (3 Körperebenen: Anterior/ Posterior, Kranial/ Kaudal, Innen-/ Außenrotation), <b>Hüfte</b> (3 Körperebenen: Flex-/ Extension, Ab-/ Adduktion, Innen-/ Außenrotation), <b>Knie</b> (3 Körperebenen: Flex-/ Extension, Ab-/ Adduktion, Innen-/ Außenrotation), <b>Sprunggelenk</b> (3 Körperebenen: Flex-/ Extension, Ab-/ Adduktion, Innen-/ Außenrotation), <b>Ellenbogen</b> (Flex-/ Extension), <b>Schulter</b> (2 Körperebenen: Flex-/ Extension, Ab-/ Adduktion)
Einzelmerkmal
Alter

Tabelle 2.1: Überblick der Referenzdaten auf dem Laufband REF,L; REF,M; REF,S.

Ein weiteres Referenzkollektiv besteht aus 10 Kindern ohne orthopädische Einschränkungen, bei denen die Gangdaten bei selbstgewählter, mittlerer Gehgeschwindigkeit frei gehend durch den Raum erhoben sind, siehe Tabelle 2.2. Die Anzahl der aufgezeichneten Schritte beträgt zwischen 4 und 10. Dieses Kollektiv dient zum Vergleich der ICP-Patienten (Datenerhebung im selben Labor unter vergleichbaren Bedingungen).

Zeitreihen für linke/rechte Körperseite
<b>Oberkörper*</b> (3 Körperebenen), <b>Becken</b> (3 Körperebenen), <b>Hüfte</b> (3 Körperebenen), <b>Knie</b> (3 Körperebenen), <b>Sprunggelenk</b> (2 Körperebenen: Flex-/ Extension, Innen-/ Außenrotation)
Einzelmerkmale
Alter, Kadenz, Gehgeschwindigkeit, Doppelschrittlänge, Dauer Doppelschritt, für jeweils linke/rechte Körperseite: Fußablösung (in % GZ, Standphase), Ende der Einzelunterstützungsphase (in % GZ), Beginn der Einzelunterstützungsphase (in % GZ), Schrittlänge

Tabelle 2.2: Überblick der Referenzdaten ohne Laufband REF,K (GZ=Gangzyklus). \* Unvollständige Daten, die auch durch die Datenvorverarbeitung nicht rekonstruiert werden konnten, da für mehrere Probanden diese Daten nicht aufgezeichnet wurden.

### 2.1.2 Infantile Cerebralparese (ICP) Patienten

Die infantile Cerebralparese beschreibt ein Krankheitsbild, bei dem bestimmte Hirnregionen irreparabel geschädigt wurden, z.B. infolge Sauerstoffmangels während der Geburt, siehe Anhang A und [36, 52, 150, 152, 174]. Ein Resultat dieser Schädigung ist eine motorische Beeinträchtigung, insbesondere das Auftreten einer Hyperaktivität von Muskeln. Diese Muskelspastiken schränken die Patienten z.T. in erheblichem Maße ein und führen langfristig zu Gelenkfehlstellungen, Kontrakturen (Dauerverkürzung eines Muskels mit daraus folgender Gelenkfehlstellung) und zu einem eingeschränkten Längenwachstum. Als Therapiemöglichkeiten stehen irreversible chirurgische Eingriffe am Bewegungsapparat (z. B. Muskel- bzw. Sehnen- transplantationen oder -verlängerungen, Korrekturen am knöchernen Bewegungsapparat) zur Verfügung [161]. Mittels der Injektion von Botulinum-Toxin in die spastische Muskulatur kann die Hyperaktivität vorübergehend vermindert und somit die Progredienz der Problematik verlangsamt werden [59, 81, 152]. Die größten Effekte werden innerhalb der ersten drei Monate erzielt. Dadurch können andere, schwächere Muskelgruppen wirksam werden, die vorher wegen der eingeschränkten Gelenkbewegung durch den spastischen Muskel nicht zum Einsatz kamen [158].

Darüber hinaus kann eine Normalisierung des Gangbildes bei nicht so stark ausgeprägter ICP auch durch den Einsatz von Orthesen oder Gipsverbänden erreicht werden.

Für die Analyse steht in dieser Arbeit ein Datensatz von 43 Spitzfuß-ICP-Patienten (Pes Equinus) zu drei Untersuchungsterminen (PRE - Voruntersuchung, U1 bzw. U2 - nach einer Behandlung) zur Verfügung. Hierbei fanden bei allen Patienten die Nachuntersuchungen U1 bzw. U2 durchschnittlich 6 Wochen bzw. 4 bis 5 Monate nach einer Behandlung statt. Die Anzahl der untersuchten Schritte variiert zwischen 2 und 16 Schritten, da es bei dieser Patientengruppe teilweise schwierig ist, eine einheitliche Anzahl von Schritten aufzunehmen, siehe im Anhang Tabelle E.7. Alle Messungen wurden ohne Laufband aufgezeichnet, d.h. während dem freien Gehen durch den Raum, siehe auch Tabelle 2.3. Behandelt wurden diese Patienten durch eine Botulinum-Toxin-Injektion mit individuellen Dosierungen. Daten für eine Kontrollgruppe, die keine Therapie erhielt, stehen hier nicht zu Verfügung

Wichtige klinische Fragestellungen bei der Datenanalyse sind die Charakterisierung der gesamten Patientengruppe im pre-therapeutischen Zustand sowie das Ermitteln unterschiedlicher Gangmuster (Subgruppen). Weiterhin sind soweit möglich prognostische Einschätzungen durch die Therapie zu geben und deren Änderungseffekte im Gangbild zu ermitteln.

Zeitreihen für linke/rechte Körperseite
<b>Oberkörper*</b> (3 Raumrichtungen) <b>Becken</b> (3 Körperebenen), <b>Hüfte</b> (3 Körperebenen), <b>Knie</b> (3 Körperebenen), <b>Sprunggelenk</b> (2 Körperebenen: Flex-/ Extension, Innen-/ Außenrotation)
Einzelmerkmale
Gewicht, Alter, Kadenz, Gehgeschwindigkeit, Doppelschrittlänge, Dauer Doppelschritt, Botulinum-Toxin-Dosierungen (in <i>patientenindividuelle</i> Muskelgruppen: Gastrocnemius, Soleus, Ischios, Rectus Femoris, Tibialis Anterior, Adductor) für jeweils linke/rechte Körperseite: Fußablösung (in % GZ, Standphase), Ende der Einzelunterstützungsphase (in % GZ), Beginn der Einzelunterstützungsphase (in % GZ), Schrittlänge,

Tabelle 2.3: Überblick der ICP-Daten (GZ=Gangzyklus). \* Unvollständige Daten, die auch durch die Datenvorverarbeitung nicht rekonstruiert werden konnten, da für mehrere Patienten an einem Untersuchungstermin diese Daten nicht aufgezeichnet worden sind.

### 2.1.3 Inkomplett querschnittgelähmte (SCI) Patienten

Im Gegensatz zu komplett Gelähmten sind bei inkomplett Querschnittgelähmten aufgrund einer teilweisen Schädigung des Rückenmarks bestimmte Muskeln nicht oder nur eingeschränkt willkürlich ansteuerbar [56, 90]. Zusätzlich ist die sensorische Rückkopplung gestört. Die Lähmungshöhen in der Wirbelsäule und dessen Ursachen sind sehr patientenindividuell. Je nach Ausmaß der Schädigung können die funktionellen Einschränkungen bis zu einem totalen Verlust von motorischen Grundfunktionen (z.B. Gehen/Stehen) reichen. Eine vielfach eingesetzte Therapie zur Verbesserung des Gehvermögens besteht in der Laufbandlokomotion, bei der die Patienten unter teilweiser Körpergewichtsentlastung mobilisiert werden. Therapieziele sind die Wiederherstellung der Gehfunktion bis zum selbständigen Gehen, das Erreichen einer angemessener Geschwindigkeit und Ausdauer sowie eine Normalisierung des Gangbildes [7, 57]. Aufgrund der individuellen Ausfallmuster ist das Gangbild extrem heterogen.

Zur Analyse steht hier ein Datensatz mit 30 Patienten (19 vor und nach der Laufbandlokomotion, 11 nur vor der Therapie) zur Verfügung. Bei den 19 Patienten wurden zwischen 2 und 8 Nachuntersuchungen zu patientenindividuellen Zeitpunkten bei unterschiedlichen Messmodalitäten durchgeführt (mit/ohne Gewichtsentlastung, Halten am Barren, ...). Die Anzahl der aufgezeichneten Schritte beträgt zwischen 5 und 86. Alle Messungen wurden auf dem Laufband durchgeführt, wobei manche

Patienten durch teilweise Gewichtsentlastung bzw. Halten am Barren unterstützt wurden, siehe auch Tabelle 2.4. Ein Einschlusskriterium für Auswertungen in der vorliegenden Arbeit ist die Verwendung von Patienten mit einem WISCI-Index (s. unten) kleiner 20 zur PRE-therapeutischen Untersuchung (Patienten, die wesentliche funktionelle Beeinträchtigungen haben). Dadurch reduziert sich der Datensatz auf 23 Patienten (15 vor und nach der Therapie, 8 nur vor der Therapie).

Zeitreihen für linke/rechte Körperseite
<b>Oberkörper*</b> (3 Raumrichtungen), <b>Becken</b> (3 Raumrichtungen), <b>Hüfte</b> (3 Raumrichtungen), <b>Knie</b> (3 Raumrichtungen), <b>Sprunggelenk</b> (3 Raumrichtungen), <b>Ellenbogen</b> , <b>Schulter</b> (2 Raumrichtungen)
Einzelmerkmale
Alter, Geschlecht, Größe, Gewicht, Lähmungseintritt, Lähmungshöhe, Ursache, Gewichtsentlastung, Gehdauer, Gehgeschwindigkeit, Halten am Barren, Daten zur Laufbandtherapie (Gehgeschwindigkeit, Gewichtsentlastung), WISCI-Index, ASIA-Index (links/rechts für Arme und Beine), Visuelle Analog Skala (VAS, von drei Experten A, B, C), Hilfsmittel linker/rechter Fuß

Tabelle 2.4: Überblick der SCI-Daten. \* Unvollständige Daten, die auch durch die Datenvorverarbeitung nicht rekonstruiert werden konnten, da für mehrere Patienten an einem Untersuchungstermin diese Daten nicht aufgezeichnet worden sind.

Zur klinischen Untersuchung und Dokumentation dieser Patienten werden zusätzlich Skalen verwendet. Diese beurteilen beispielsweise die motorischen und sensorischen Fähigkeiten (z.B. ASIA, American Spinal Injury Association, zum Ermitteln der Berührungs- und Schmerzempfindlichkeit sowie aktive Bewegungsfähigkeit [33, 57]), spezielle Leistungsfähigkeiten (WISCI, Walking Index for Spinal Cord Injury, bewertet Abhängigkeit von Gehhilfen und erreichte Gehstrecke [43]) oder die visuelle Gesamteinschätzung durch Experten (VAS, visuelle analog Skala [41, 127]), siehe Anhang A. Diese Skalen dokumentieren aber nur bedingt die funktionelle Gehfähigkeit anhand der Gang-Kinematik (Gangqualität). Weiterhin sind sie untersucherabhängig [127, 141].

Eine wichtige klinische Fragestellung bei SCI-Patienten ist die Bestimmung einer globalen, quantitativen Gangqualität, die den Grad der Pathologie aus der Gang-Kinematik in einem übergreifenden Gütemaß beschreibt. Die Bestimmung einer Gangqualität dient beispielsweise der Dokumentation von Rehabilitationsverläufen. Weitere klinische Fragestellungen sind die Charakterisierung des Patientenkollektives (inkl. zunächst unbekannter Subklassen) und die quantitative Beschreibung

relevanter Änderungen. Von besonderem Interesse ist die quantitative Prognose der zu erwartenden Therapieauswirkungen aus einer Ganganalyse vor der Therapie. Das mittelfristige klinische Ziel besteht darin, für jeden Patienten die individuell aussichtsreichste Therapieoption auszuwählen und aussichtslose und langwierige Therapien zu vermeiden. Wegen der Komplexität des Sachverhalts und ungelöster Fragen (z.B. lässt sich die Gangqualität quantifizieren, existieren charakteristische Merkmale der Patienten die sich durch die Therapie normalisieren) dazu ist eine Entscheidungsunterstützung notwendig.

## 2.2 Schwierigkeiten und Analysevoraussetzungen

Die Erhebung der Messdaten erfolgt während des klinischen Alltages mit dem unmittelbaren Ziel einer konkreten Nutzung (subjektive, gezielte Analyse). Dabei fehlen oftmals standardisierte Datenbanken. Erste Lösungen hierzu sind bereits vorgeschlagen und sind in Erprobung [130]. Messungen werden dabei untersucherabhängig mit Variationen durchgeführt oder sind manuell dokumentiert (z.B. Botulinum-Toxin-Dosierungen). Messungen für reine Forschungsarbeiten können kaum geleistet werden, deren Qualitätsansprüche werden nur bedingt eingehalten (z.B. vollständige Datenaufnahme). Für eine subjektive Analyse sind derartige Messaufnahmen selten problematisch, da der Untersucher Vorwissen über die Patienten nutzt oder logisches Modellverständnis einbezieht (z.B. Nichtbeachtung fehlender Daten). Dies kann bei der reinen computerbasierten Analyse nicht genutzt werden. Daher müssen bestimmte Voraussetzungen erfüllt sein, indem typische Schwierigkeiten klinischer Daten behoben werden. Diese und insbesondere die der hier zur Verfügung stehenden Gangdaten sind [82, 90, 123]:

**Heterogenität:** Individuell unterschiedliche Laufmuster und Kompensationsmechanismen innerhalb einer Patientengruppe gleichen Krankheitstyps (Überlagerung des Grundmusters und individuelle Effekte), unterschiedliche Grundmuster bei gleichen Krankheitstypen (heterogenes Patientenkollektiv), intra-individuelle Unterschiede (schlechte Reproduzierbarkeit der einzelnen Schritte bei einem Patienten), unterschiedliche Motivation der Patienten (psychologische Hemmungen, insbesondere bei Kindern, individuelle Therapiefortschritte).

**Messfehler:** Subjektives (ungleiches) Anbringen von Messapparaturen an Personen (z.B. fehlerhaftes Bekleben oder Verrutschen der Marker, dadurch entsteht ein zusätzlicher Offset in Gelenkwinkel-Zeitreihen), verdeckte Marker oder ungünstige Winkel der Marker-Trajektorien zu den Kameras während

des Gehens (dadurch fehlen einzelne Gelenkwinkel-Zeitreihen), pathologische Ausfallerscheinungen (z.B. Ermittlung von Fersenaufsetzpunkt bei Spitzfußgängern, Verfälschung des Gangbildes durch unpräzises Auftreten auf Kraftmessplatten).

**Messmodalitäten, fehlende Daten:** Unterschiedliche Datenerfassung (an den Patienten angepasste Messbedingungen wie Gehgeschwindigkeit, Gehhilfen, Körpergewichtsentlastung, usw.), klinische Untersuchungsvarianten (zusätzliche individuelle Messungen, z.B. verschiedener Muskelgruppen, Sauerstoffverbrauch-, Kinetik-Daten), unterschiedliche Anzahl von Messaufnahmen (mehrere Untersuchungszeitpunkte zu unterschiedlichen zeitlichen Abständen während des Rehabilitationsverlaufs, unterschiedliche Anzahl aufgezeichneter Gangzyklen, wenn z.B. Patient nicht länger laufen kann).

**Unsicherheiten, schwer formalisierbare Einschätzungen:** Subjektive klinische Einschätzung der Gangcharakteristik, -qualität, usw., Bevorzugung von Messungen, wie sagittale Körperseite, höhere Verlässlichkeit von Messungen bestimmter Bereiche in Winkelverläufen.

Oftmals entstehen solche Schwierigkeiten aus Zeit- und Kostendruck im klinischen Alltag. Allerdings sind die Schwierigkeiten auch bei einer computerbasierten Analyse zu beachten und möglichst zu beheben. Die Ergebnisse dürfen dadurch nicht beeinflusst werden.

## 2.3 Empirische Analyse von Gangdaten

Bei der Analyse von Gangdaten im klinischen Alltag sind gewisse Unklarheiten und unpräzise formalisierbare Expertenregeln Stand der Technik. Das Wissen wird durch praktische Erfahrungen erarbeitet oder weitergegeben, ist allerdings nirgends in Fachliteratur gebündelt zusammengefasst [127, 136, 146]. Der Bedarf derartiger Formalisierungen durch computerbasierte Analysen ist hoch [77, 157].

Um Data Mining Methoden für die vorliegende Arbeit zur Auswertung von Gangdaten zu modifizieren, ist eine Formalisierung der klinischen Vorgehensweise bei der Merkmalsextraktion notwendig. Dadurch soll die klinische Auswertung rechnergestützt nachgebildet werden, siehe Abschnitt 1.4.

Anhand der zur Verfügung stehenden Krankheitsbilder (ICP und SCI) wird anschließend demonstriert, welche Aussagen und Regeln darüber durch Experteninterviews und Fachliteratur erhalten werden können. Auf derartige Aussagen wird später beim Vergleich der Ergebnisse durch Anwendung der modifizierten Data Mining Methoden Bezug genommen.

### 2.3.1 Merkmalsextraktion und Vorgehensweise

Durch eine Literaturanalyse [30, 120, 149, 159, 174] und Interviews [4, 89, 108, 175] wurde versucht, allgemeine Gesetzmäßigkeiten bei der Art der Merkmalsextraktion aus Zeitreihen zur klinischen Interpretation zu finden. Dabei fiel auf, dass sich erfahrene Ärzte an Merkmalsarten wie

1. minimalen und maximalen Werten sowie deren Positionen in der Zeitreihe,
2. Spannweiten und Mittelwerten,
3. Kurvensteigungen,
4. (intra-)individuellen Streuungen (Reproduzierbarkeit der Zeitreihe bei mehreren Schritten),
5. charakteristischen Unterschieden zu Zeitreihen bei einem normalen Gangbild,
6. Unterschieden zwischen der linken und der rechten Körperseite sowie
7. bestimmten charakteristischen Kurvenformen

orientieren [88]. Die Merkmale werden global über die gesamte Zeitreihe oder lokal in semantisch definierten Abschnitten (Stand- und Schwung- sowie weitere sieben Schrittphasen) erhoben, siehe Anhang A. Darüber hinaus konnte festgestellt werden, dass bestimmte Merkmale unterschiedlich bevorzugt werden, wie z.B. Merkmale von der sagittalen vor den anderen beiden Körperseiten [60]. Weiterhin werden auch Raum-Zeit-Parameter (siehe Abschnitt 1.2.1) bei der klinischen Analyse mit einbezogen. Sie können als weitere Gruppe aufgeführt werden. Der Fokus bei der Entwicklung von Data Mining Methoden liegt hier allerdings auf extrahierten Merkmalen aus den Kinematikzeitreihen. Erst in der Anwendung in Kapitel 5 werden die Raum-Zeit-Parameter mit verwendet.

Je nach Pathologie und Aufgabenstellung (Diagnose, Beschreibung der typischen Eigenschaften eines Patientenkollektives, Therapieentscheidungen, Beurteilung von Therapieerfolgen) werden neben dem eher unterbewusst wirkenden „Gesamtbild“ nur wenige informationstragende Merkmale aus diesen sieben Merkmalsarten betrachtet. Für andere Pathologien sind diese spezifischen Merkmale nicht verwendbar. Eine weitere Auswahl erfordert wiederum langjährige Erfahrung. Bei redundanten Informationen werden bestimmte Merkmale bevorzugt, z.B. wegen ihrer besseren Interpretierbarkeit oder einer höheren Messgenauigkeit. Arbeiten auf dem Gebiet der statistischen, quantitativen Ganganalyse stützen sich meist auf empirisch ausgewählte Merkmale aus den ersten drei Merkmalsarten, siehe Kapitel 1.2.2 und [30, 60].

Der Vorteil eines empirischen Entwurfes besteht darin, dass Apriori-Wissen und logisches Problemverständnis einbezogen werden und der Experte eine hohe Kreativität und Flexibilität bei der Merkmalsextraktion beisteuert. Die interpretierba-

re Erklärung des Lösungsweges zur Klassifikation ist somit von vornherein gesichert. Dadurch können Ursache-Wirkungs-Prinzipien, logische, modellbasierte Zusammenhänge oder auch Ausreißer gefunden und erklärt werden. Der Experte sucht eher einfache Zusammenhänge mit wenigen Merkmalen, wobei er u.U. kompliziertere Zusammenhänge übersieht. Weitere Probleme sind der langwierige Aufbau von Erfahrungswissen, unvollständiges Wissen und die Quantifizierung. Somit hängt der Erfolg bei der Bearbeitung der Problemstellungen wesentlich von der Erfahrung des jeweiligen Kliniklers ab [4]. Große Variabilität besteht bei Aussagen unterschiedlicher Klinikler (Untersucherabhängigkeiten). Insbesondere bei weniger bereichserfahrenen Klinikern treten unter Umständen Fehleinschätzungen der komplexen biomechanischen und neurologischen Auswirkungen einer Therapie auf [111, 141, 164]. Fehleinschätzungen können ernste Auswirkungen für die einzelnen Patienten bei irreversiblen Therapien wie Operationen haben. Es existieren einige Fälle, bei denen Patienten nach der Operation nicht mehr lauffähig waren. Selbst erfahrene Operateure können dies dann nicht mehr korrigieren.

Neben der Datenanalyse wird der Patient visuell beobachtet und beurteilt (z.B. mittels Videoaufzeichnungen). Beispielsweise werden Standstabilität, Bodentreue in der Schwungphase, Fußaufsetzverhalten (Winkel beim Initial Contact, IC), adäquate Schrittlänge sowie Gangökonomie (mühsam/flüssig) betrachtet, ohne diese jedoch quantitativ zu bewerten [51].

### 2.3.2 Krankheitsbild ICP

Durch ein Experteninterview<sup>2</sup> konnten einige qualitative Aussagen über Spitzfuß-ICP-Patienten erhalten werden mit folgender kurzen Darstellung.

Patienten setzen Kompensationsmechanismen zum Ausgleich der Behinderung ein. Primäre Ziele sind das Halten des (dynamischen) Gleichgewichts und das Vorwärtstreten unter den neurologischen und biomechanischen Einschränkungen. Dabei müssen Fehlstellungen und -ansteuerungen eines oder mehrerer Gelenke durch weitere Gelenke kompensiert werden. Jeder Patient läuft für sich mehr oder weniger optimal. Sekundäre Ziele wie Gangökonomie (effizientes, energiesparendes Gehen) oder Schonung von Gelenken können dabei nicht erfüllt werden. Dadurch verschlechtert sich bei den heranwachsenden ICP-Patienten das Gangbild mit zunehmendem Alter aufgrund des nicht mehr zu tragenden eigenen Körpergewichts oder Versagens der Gelenke. Eine Therapievariante stellt die Injektion von Botulinum-Toxin dar, um Gelenkfehlstellungen zu verbessern oder chirurgische Eingriffe hinauszuzögern.

---

<sup>2</sup>Das Interview wurde mit Herrn Dr. med. L. Döderlein, leitender Oberarzt an der Orthopädischen Universitätsklinik Heidelberg geführt.

Diese ICP-Patienten haben immer eine Fehlstellung im Sprunggelenk, die kompensiert werden muss. Die Fehlstellung betrifft sowohl den Beginn des Gangzyklus (erhöhte Abweichung als auch zunehmende Dorsalflexion anstatt abnehmende im Vergleich zum gesunden Gangverhalten) als auch insgesamt die Stand- und Schwungphase. Eine Bewegung im Sprunggelenk kann dabei auch lediglich passiv, d.h. durch das Körpergewicht nach Aufsetzen des Fußes, erfolgen. Das erklärt die umgekehrte Änderung des Verlaufes zum gesunden Gangverhalten. Ein besonders spitzer Aufsetzwinkel hängt möglicherweise mit einer eingeschränkten Bewegung zusammen (ausgeprägte Spastik mit reduziertem Hebelarm für passive Bewegung). Betrachtete Merkmale in der Sprunggelenk-Kinematik sind beispielsweise Winkelstellung beim Fußaufsetzen (IC), Minimum in der Stand- und Schwungphase [136]. In der klinischen Praxis wird das Ausmaß des Spitzfußes anhand des gemittelten Verlaufes des Sprunggelenks in vier Gruppen eingeteilt [124, 174]: Plantarflexion größer als  $20^\circ$  (stark ausgeprägter Spitzfuß), zwischen  $10^\circ$  und  $20^\circ$ , zwischen  $10^\circ$  und  $0^\circ$  (leicht ausgeprägter Spitzfuß) und kleiner als  $0^\circ$ , also Dorsalflexion (Bereich des gesunden Gangverhaltens). Der Bereich, über den gemittelt wird, ist allerdings nicht eindeutig (je nach Ermessen des Untersuchers z.B. nur Stand- oder Schwungphase). Die Fußrotation wird hingegen bei Spitzfuß-ICP-Patienten eher untergeordnet betrachtet, zumal die derzeitige Messtechnik für die Fußrotation ungenau ist [140]. Wichtiger ist die Hüftrotation, die aufgrund der Biomechanik in Zusammenhang mit der Fußrotation steht. Hierbei sind drei Typen von ICP-Verhalten durch verstärkte Innen- bzw. Außenrotation oder keine wesentliche Abweichung vom Referenzverhalten zu unterscheiden.

Ein Zusammenhang zwischen der Flexion des Fußes und Knies wird vermutet. Ein Problem bei manchen dieser Patienten ist dabei das Recurvatum (Knieüberstreckung), das wiederum Auswirkungen auf Hüfte und Becken hat. Im Gegensatz dazu gibt es Spitzfuß-ICP-Patienten, die permanent mit gebeugtem und steifem Knie laufen, was wiederum als eine Kompensation zum Spitzfuß beurteilt werden kann (starke Spastik, damit hohe Plantarflexion, die kompensiert werden muss). Das gebeugte Knieverhalten kann seinerseits Auswirkungen auf weitere Gelenke haben, wie Hüfte und Becken, das insgesamt zum sog. Kauergang führen kann (eingeschränkter Bewegungsumfang zwischen  $12^\circ$  und  $47^\circ$  im Knie, Knieflexion während des gesamten Schrittes größer  $20^\circ$  und permanent erhöhter Beckenwinkel [162]). Eine veränderte Hüftflexion, insbesondere in der Standphase, ist häufig ein weiteres charakteristisches Merkmal, das mit der Knieflexion zusammen hängt. Zusätzlich sollen die Knie- und Sprunggelenkflexion (Plantarflexion) miteinander gekoppelt sein.

Ein weiterer typischer Kompensationsmechanismus kann der Beckenschiefstand (erhöhte Adduktion) sein. Dadurch wird das Bein auf der Spitzfußseite während der Schwungphase angehoben. Damit verbunden ist möglicherweise eine Kopplung zur Beckenkipfung und Hüftflexion. Bei diesen Patienten tritt aber eine erhöhte Beckenkipfung nur gelegentlich auf. Eine schnelle Beckenkipfungsänderung ist eine

Kompensationsbewegung für distale (zum Fuß hin) Spastik und muss über mehrere Gelenke kompensiert werden. Die charakteristische Kennzeichnung der Beckenkipfung durch zwei ausgeprägte Maxima in jeweiliger Stand- und Schwungphase wird hierbei klinisch als „double bump“ bezeichnet.

Aufgrund der Komplexität sind weitere derartige systematische und quantifizierte Regeln durch Experten kaum formulierbar. Viele Zusammenhänge sind oftmals nicht bekannt, so dass präzise Aussagen und Regeln nicht getroffen werden können [121, 152, 167]. Die Forderung und der Bedarf nach derartigen präzisen, quantitativen Regeln ist allerdings sehr groß [30, 146]. Beispielsweise sind Zusammenhänge der Hüftbewegungen in den drei Raumkoordinaten oder Zusammenhänge zwischen den Gelenken wie Beckenkipfung mit Hüft- und Fußrotation unklar. Dazu existieren viele Regeln und Aussagen, die mehr oder weniger intuitiv durch den Experten während der subjektiven Analyse einzelner Patienten verwendet werden. Der Experte kann das allerdings nicht auf Anhieb verallgemeinert beschreiben. Eine Quantifizierung der Spastik ist bisher nicht möglich [161].

### 2.3.3 Krankheitsbild SCI

Die inkomplett querschnittgelähmten Patienten sind im Vergleich zu den ICP-Patienten weniger gut dokumentiert erforscht [4, 41]. Fallspezifische Regeln und Aussagen sind wenig etabliert, die Übertragbarkeit ist aufgrund unterschiedlicher Pathologien nicht möglich. Existierendes, klinisches Wissen auf diesem Gebiet ist neurologisch und physiologisch ausgerichtet [57] und nicht auf die funktionellen Auswirkungen auf das Gangbild. Erst in den letzten Jahren gewinnt die Forschung mit der Untersuchung von SCI-Patienten in GanganalySELabors an Bedeutung. Es wird vermutet, dass ein Gangmuster-Generator im Rückenmark existiert, der die gezielte Ansteuerung der Beinmuskeln übernimmt [32, 47]. Das bedeutet, dass trotz der neurologisch gestörten Verbindung zum Gehirn gewisse Restfunktionen für ein Gangmuster vorhanden sind [42].

Wegen des Forschungsrückstandes der funktionellen Auswirkungen steht daher die Einschätzung der Gehfähigkeit im Vordergrund, die zunächst der besseren Dokumentation von Therapieverläufen dient. Die Unterteilungen in Subgruppen und deren charakteristische Merkmale sind weiterführende Fragestellungen, um den Rückstand aufzuholen. Weiterhin kann mit derartigem globalen Wissen zusätzlich die Gehfähigkeit detaillierter eingeschätzt werden.

Neben den bereits erwähnten Indizes (neurologisch, funktionell, . . .) wird im klinischen Alltag die Gehfähigkeit durch subjektive Indizes (VAS, visuelle Analogskala) ermittelt. Hierbei vergibt der Experte bei direkter Patientenbeobachtung Punkte, z.B. zwischen 0 und 10, die die Qualität des Gehens einschätzen. Neben der Variabilität der Untersucher existiert kein Standard, der angibt, wie der Gang (z.B. Auswahl bestimmter Kriterien) zu bewerten ist.

# 3 Neues Data Mining Konzept zur Entscheidungsunterstützung

## 3.1 Überblick

Für eine Anwendung computerbasierter Systeme in der Ganganalyse ist die Interpretierbarkeit des Lösungsweges Voraussetzung. Durch ein neues Konzept wird daher die klinische Vorgehensweise systematisiert, siehe Abbildungen 1.1 und 3.1. Im folgenden Kapitel wird die computergestützte Analyse durch modifizierte Data Mining Methoden vorgestellt, siehe unterer Teil in Abbildung 3.1. Die einzelnen Blöcke und die Verbindungen zu einem gesamten neuen Konzept werden in den einzelnen Abschnitten beschrieben.

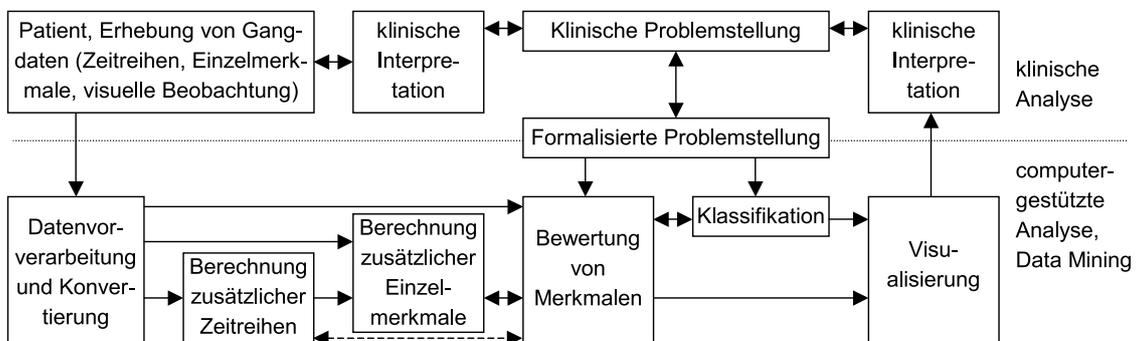


Abbildung 3.1: Neues Konzept für den Prozess der Datenauswertung.

Hierzu ist zunächst eine Formalisierung der in den Kapiteln 1 und 2 genannten klinischen Problemstellungen notwendig (Abschnitt 3.2).

Zur computerbasierten Lösung der Problemstellungen müssen die Daten konvertiert und vorverarbeitet werden (Abschnitt 3.3). Das ist ein Übergang von der klinischen Seite zur computergestützten Analyse. Hierbei sind notwendige Voraus-

setzungen zur Analyse durch die Entwicklung einer geeigneten Systematisierung, Strukturierung und Aufbereitung zu lösen (z.B. einheitliche Datenanlage, -zugriff und Merkmalsbezeichnung, Umgang mit fehlenden Daten).

Der empirische Auswerteprozess wird systematisiert und quantifiziert nachgebildet, d.h. der Rechner soll die „Sprache“ der Mediziner lernen. Das wird durch die Berechnung zusätzlicher Zeitreihen (Abschnitt 3.4) und zusätzlicher Einzelmerkmale (Abschnitt 3.5) erreicht, die sich eng an den in Abschnitt 2.3.1 diskutierten Gesetzmäßigkeiten der empirischen Analyse orientieren. Zwar enthalten die beiden Vorgänge keine direkten Übergänge von der klinischen Seite, weil sie für alle folgenden Problemstellungen und für weitere Daten gleichermaßen durchgeführt werden. Aber die Vorgänge beinhalten Transferwissen aus der empirischen, klinischen Analyse, das durch die Literaturrecherche und Interviews extrahiert wurde.

Ein wesentlicher methodischer Neuheitswert ist die systematische und strukturelle Bereitstellung eines verallgemeinerten Merkmalsraumes, der zur Lösung von Problemstellungen zur Verfügung steht. Durch die Formalisierung der klinischen Problemstellungen (direkte Umsetzung klinischer Fragen aus offenen Problemen in der Literatur) besteht hier die Möglichkeit, in das gesamte System benutzerdefiniert einzugreifen. Aus Sicht der Datenanalyse ist hierzu je nach Problemstellung ein geeignetes Verfahren zu wählen.

Zur eigentlichen Lösung unterschiedlicher, formalisierter klinischer Problemstellungen werden überwachte und unüberwachte Klassifikationsverfahren eingesetzt, die auch als Lernen mit bzw. ohne „Lehrer“ bezeichnet werden [22, 46, 168]. Sie gliedern sich für die klinische Anwendung beispielsweise in die Teilaufgaben der Charakterisierung bekannter Gruppen und dem Finden von unbekanntem Subgruppen. Die Vor- und Nachteile der hier verwendeten Methoden werden kurz diskutiert (Abschnitte 3.6, 3.7 und 3.8).

Überwachte und unüberwachte Verfahren unterscheiden sich, ob eine Klasseneinteilung gegeben ist [46, 70, 106, 155]. Die Klasseneinteilungen sind in dieser Arbeit für alle Datensätze  $N$  in  $\mathbf{Y}_{N \times S_Y}$  für unterschiedliche Klassenarten  $S_Y$  (z.B. Patient, Untersuchungszeitpunkt) gespeichert. Eine Klasseneinteilung kann semantisch (durch Vorwissen) gegeben sein, wie beispielsweise die Einteilung in Referenz- und Patienten-Datensätze, siehe Anhang A und [22]. Des Weiteren kann eine formale Klasseneinteilung rein datenbasiert berechnet werden, die auf definierten Abständen basiert. Während der Lernphase ist bei beiden Verfahrensarten ein Ziel anhand gegebener Datensätze zu erreichen, z.B. fehlerfreie Einteilung in gegebene Klassen. Generell gilt, dass nach der Lernphase eine Arbeitsphase folgt. Hierbei werden die angelernten Klassifikationsmethoden auf neue Datensätze angewandt. Für die Ganganalyse allerdings stehen die Ergebnisse aus der Lernphase im Vordergrund, Tabelle 3.1.

Methoden	gegeben	gesucht
überwachte Bewertung von Merkmalen	Datensätze $\mathbf{X}$ , Klasseneinteilung $\mathbf{y}$ , Apriori-Relevanzen $\mathbf{m}_{ap}$	Merkmalsrelevanzen $M_{i,ges}, i = 1..S$
überwachte Klassifikation	Datensätze $\mathbf{X}$ , Klasseneinteilung $\mathbf{y}$ , Apriori-Relevanzen $\mathbf{m}_{ap}$	Merkmalskombinationen mit $s_F$ Merkmalen incl. Wertebereichen zur Unterscheidung der Klassen, Charakterisierung von Klassen
unüberwachtes Clustern	Datensätze $\mathbf{X}$	Cluster-Merkmale $s_C$ , Anzahl Cluster $C$ , Cluster-Zentren $\mathbf{V}$ , Zugehörigkeit $u_{j,i}$ eines Datensatzes $j$ zum Cluster $i$

Tabelle 3.1: Entwurf der Methoden (Lernphase).

Bei der *überwachten Bewertung von Merkmalen* sind Merkmale oder Merkmalskombinationen gesucht, mit denen sich die Klassen unterscheiden lassen. Sie dient insbesondere der Datenreduktion. Eine wesentliche Weiterentwicklung der Relevanzbewertung für Einzelmerkmale ist in dieser Arbeit durch Einbezug von Apriori-Relevanzen  $\mathbf{m}_{ap}$  ( $S \times 1$ ) geleistet, siehe Abschnitt 3.6. Dadurch kann beispielsweise empirisches, schwer greifbares und quantifizierbares Apriori-Wissen zur verbesserten Nachbildung der subjektiven Analyse-Herangehensweise formalisiert mit einbezogen werden. Die verwendeten Verfahren sind multivariate bzw. univariate Varianzanalysen (M)ANOVA, informationstheoretische Maße, Korrelations- und Regressionsanalysen. Die ersten beiden Verfahren werden verwendet, um diskrete Klassen zu unterscheiden. Die letzten beiden Verfahren dienen hier weiterhin zur Beschreibung kontinuierlicher Klassen (bzw. Merkmale, die in diesem Kontext als Klassen betrachtet werden können).

Die Relevanzbewertung wird hier zudem als Vorstufe zum Klassifikatorentwurf genutzt. Bei der *überwachten Klassifikation* sind die genauen Wertebereiche zur Unterscheidung (und Beschreibung) der Klassen gesucht, siehe Abschnitt 3.7. Für die klinische Anwendung können dadurch die Unterschiede zwischen den Klassen gezielter beschrieben und charakterisiert werden. Dazu werden hier Fuzzy-Klassifikatoren eingesetzt.

Bei der *unüberwachten Klassifikation* (hier sind Fuzzy-Cluster-Verfahren verwendet) ist keinerlei Klasseneinteilung bekannt. Diese Verfahren dienen weiteren klinischen Problemstellungen wie z.B. dem Finden von unbekanntem Patientensub-

gruppen, siehe Abschnitt 3.8. Für eine Anwendung der Verfahren wurden in der vorliegenden Arbeit entsprechende Weiterentwicklungen geleistet, wie z.B. eine verbesserte Merkmalsauswahl oder das Finden bekannter Gruppen.

Die Intention der Arbeit besteht in der Anwendung der überwachten Fuzzy-Klassifikatoren auf die Gangdaten und die Auswertung der Ergebnisse. Hierfür konnten bereits entwickelte Entwurfsverfahren für Fuzzy-Klassifikatoren eingesetzt werden [108]. Für den Einsatz unüberwachter Klassifikatoren bei den Gangdaten zur Lösung weiterer klinischer Fragestellungen werden zusätzliche methodische Entwicklungsarbeiten geleistet.

Zur Bearbeitung verschiedener klinischer Problemstellungen sind in dieser Arbeit zudem die vorgestellten Verfahren miteinander kombiniert, siehe Abschnitt 3.9. Durch verschiedene Visualisierungstechniken können die Ergebnisse präsentiert werden, Abschnitt 3.10.

## 3.2 Neue Strategie zur Formalisierung klinischer Problemstellungen

Die unterschiedlichen klinischen Problemstellungen aus Tabelle 1.1 müssen in formalisierte Problemstellungen modifiziert werden, damit sie mit Data Mining Methoden gelöst werden können, siehe Abbildung 3.1.

Zur Extraktion relevanter Informationen muss ein Problem präzise formuliert werden, damit zum einen die entsprechenden klinischen Fragen gelöst und zum anderen die erhaltenen Ergebnisse für die Anwendung (hier der klinische Kontext) einsetzbar sind. In dieser Arbeit werden die drei methodischen Ansätze aus Tabelle 3.1 für Problemstellungen in der Ganganalyse bearbeitet. Durch Kombination der verschiedenen Ansätze kann mit dem hier neu entwickelten strukturellen Konzept der Datenauswertung eine gesteigerte Universalität und Betrachtung erweiterter klinischer Fragestellungen erreicht werden.

Die unterschiedlichen klinischen Problemstellungen werden jeweils geeignet formalisiert, wie die nachfolgenden Abschnitte zeigen. Die Ergebnisse müssen anhand der Formalisierung richtig interpretiert werden. An einer klinischen Problemstellung wird dies exemplarisch kurz erläutert, siehe erstes Beispiel in unten stehenden Aufzählungen: „Gibt es charakteristische Merkmale, die das Patientenverhalten beschreiben?“, d.h. auf welche Merkmale muss der Kliniker im Wesentlichen achten, wenn er den Patienten durch die Charts einschätzt, siehe Tabelle 1.1. Mit dem durch das neue methodische Konzept zur Verfügung stehenden verallgemeinerten Merkmalsatz wird eine überwachte Relevanzbewertung angewendet. Hierzu wird die Klasseneinteilung in Referenz und Patientendatensätze verwendet, d.h. ein 2-

Klassenproblem wird gelöst. Als Ergebnis wird eine Liste von relevanten Merkmalen erhalten, die die Patienten im Wesentlichen charakterisieren. Durch Verwendung von interpretierbaren Merkmalen und Modifikation der Relevanzbewertung durch Apriori-Relevanzen kann zudem die Interpretierbarkeit erhöht werden, wie später gezeigt wird.

Durch Ausnutzung verschiedener Kombinationen lassen sich in ähnlicher Weise zudem weitere Problemstellungen lösen, die für einen klinischen Einsatz von Belang sind [4, 41, 88, 93, 95, 127, 175], wie z.B.:

- Gibt es charakteristische Merkmale, die das Patientenverhalten beschreiben? Wie unterscheiden sich die Patienten in diesen Merkmalen vom Referenzverhalten?  
Lösung: Überwachte Relevanzbewertung bzw. Klassifikation.  
Beispiele:
  - 2-Klassenproblem: Eine Referenzklasse mit mittlerer Gehgeschwindigkeit REF, LM und eine Patientenklasse PRE-therapeutisch PRE.
  - 2-Klassenproblem: Eine Referenzklasse mit verschiedenen Gehgeschwindigkeiten (langsam, mittel, schnell) als REF zusammengefasst und eine Patientenklasse POST-therapeutisch POST.
- Wie lässt sich die Gangqualität in Anlehnung an die subjektive Einschätzung objektiviert beschreiben?  
Lösung: Regressionsanalysen zwischen Merkmalen.  
Beispiel: Nachbildung der VAS (subjektive Experteneinschätzung der Gangqualität) durch geeignete Merkmale aus den gemessenen Zeitreihen.
- Welche Zusammenhänge existieren zwischen Merkmalen? Lassen sich Merkmale durch andere Merkmale beschreiben?  
Lösung: Korrelation zwischen Merkmalen und/ oder Klassen.  
Beispiel: Verwendung besser interpretierbarer Merkmale aus einer Vielzahl von Merkmalen, die ähnliche Information beinhalten.
- Welche Merkmale ändern sich während einer Therapie?  
Lösung: Überwachte Relevanzbewertung bzw. Klassifikation  
Beispiele:
  - 2-Klassenproblem PRE-POST.
  - Merkmalsrelevanzproblem PRE-POST.
- In welchen Merkmalen (Zeitreihen oder Einzelmerkmale) existieren bei den Patienten wesentliche, verschiedene Subgruppierungen? Wo existieren nur Tendenzen? Wie viele Gruppierungen gibt es? Wie sehen die Subgruppen qualitativ aus?

Lösung: Struktursuche mit unbekannter Klasseneinteilung.

Beispiel: Suche nach Merkmalen, die Subgruppeninformation beinhalten, Bestimmung der Anzahl von Subgruppen, Visualisierung von Subgruppen.

- Wodurch unterscheiden sich Gruppen im Wesentlichen? Wie lassen sich die Unterschiede klinisch interpretieren?

Lösung: Kombination unüberwachte/überwachte Verfahren.

Beispiel: Überwachte Relevanzbewertung und Klassifikation, anhand unüberwacht gefundener Subgruppen.

- Gibt es Aussagen über Therapieverläufe der verschiedenen Subgruppen?

Lösung: Kombination aller Verfahren.

Beispiele:

- Änderung der Gangqualität anhand berechneter Cluster-Zugehörigkeiten oder als Prädiktion: Suche nach Subgruppen im PRE-therapeutischen Zustand, anschließend Vergleich im POST-therapeutischen Zustand.
- Anwendung überwachter Verfahren zur PRE-POST Auswertung der einzelnen Subgruppen.

Es ist darauf zu achten, dass die einzelnen methodischen Ansätze bestimmte Probleme lösen. Beispielsweise sind charakteristische Merkmale zur Unterscheidung REF-PRE nicht unbedingt am besten geeignet, um die Patienten in Subgruppen aufzuteilen.

Durch die gezeigte Formalisierung lassen sich somit klinische Problemstellungen in Klassifikationsaufgaben modifizieren, um sie wie in den nächsten Abschnitten gezeigt zu lösen.

### 3.3 Vorverarbeitung und neues Konzept zum Speichern der Daten

Daten, die in den Ganganalyselabors erhoben werden, sind in einzelnen Protokollen gespeichert. Um ein gesamtes Kollektiv von Patienten und Referenzpersonen über alle gemessenen Daten auswerten zu können, müssen die Daten geeignet strukturiert werden, siehe Abbildung 3.1. Das wird durch eine neue Strategie zur Speicherung der Daten in diesem Abschnitt gezeigt.

Wegen der Periodizität der Schritte sind alle Zeitreihen eines Schrittes nachfolgend auf 100% des Gangzyklus normiert [145, 146, 174]. Dabei haben alle Zeitreihen der verschiedenen Gelenke und Datensätze die gleiche Anzahl von  $K = 101$  Abtastzeitpunkten. Das hat bei der Analyse den Vorteil, dass die Zeitreihen der einzelnen

Datensätze (=alle einzelnen Schritte aller Personen) miteinander verglichen werden können.

Wie in Abschnitt 1.2 gezeigt, existiert kein Konzept zum Speichern von Gangdaten, das zur weiteren computerbasierten Analyse geeignet ist. Daher ist nachfolgend eine neue Strategie zum Speichern der Daten gezeigt mit der ein automatisierter Zugriff auf die Datensätze und Merkmale möglich ist, siehe Abbildung 3.2.

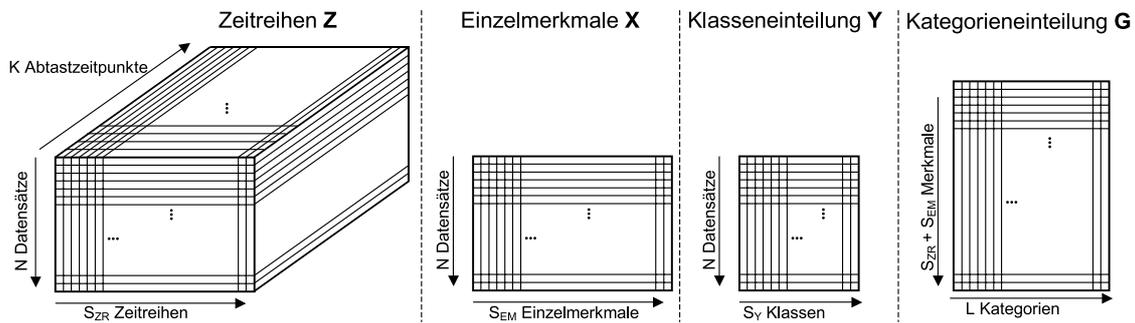


Abbildung 3.2: Veranschaulichung einer neuen Strategie zur Speicherung der Daten.

Die Zeitreihen werden in einem Feld dritter Ordnung ( $n = 1..N$  Datensätze,  $k = 1..K$  Abtastzeitpunkte,  $s = 1..S_{ZR}$  Zeitreihen) gespeichert. Zeitreihen sind hier die zur Verfügung stehenden Gelenkwinkelverläufe aus den drei Raumrichtungen, z.B. Hüft-Flexion-Extension, Hüft-Ab-Adduktion, Knie-Flexion-Extension. In dem Feld bestehen die  $1..N$  Datensätze aus allen Schritten aller Personen. Hierzu gehören beispielsweise Patientenschritte, die an verschiedenen Untersuchungszeitpunkten im Laufe einer Therapie aufgezeichnet wurden oder Schritte von Referenzpersonen mit unterschiedlichen Gehgeschwindigkeiten. Um die einzelnen Datensätze zu kennzeichnen, werden  $S_Y$  Klassenarten verwendet und in einer  $\mathbf{Y}_{(N \times S_Y)}$  Matrix kodiert. Durch die  $S_Y$  Klassenarten sind beispielsweise die verschiedenen Patienten, deren Untersuchungszeitpunkte oder die unterschiedlichen Referenzpersonen enthalten.

Zu jedem einzelnen  $n \in N$  Datensatz sind  $S_{EM}$  Einzelmerkmale zugeordnet. Dadurch können für alle Datensätze verschiedene Einzelmerkmale aus den unterschiedlichen Zeitreihen generiert werden, z.B. das Maximum der Knie-Zeitreihe über den gesamten Schritt. Einzelmerkmale, die sich auf mehrere Schritte beziehen, wie Personen-Basisdaten (z.B. Alter), werden mehrfach über die betreffenden Datensätze gespeichert.

Beispiel: In den Datensätzen  $n = 1..2$  sind zwei Schritte des ersten Patienten (Alter=9 Jahre) zum ersten Untersuchungszeitpunkt abgelegt, in dem Datensatz  $n = 3$  ein Schritt des gleichen Patienten zum zweiten Untersuchungszeitpunkt, danach in  $n = 4..6$  drei Schritte eines weiteren Patienten (Alter=5 Jahre) zum ersten Untersuchungszeitpunkt. Betrachtet wird die Zeitreihe der rechten Knieflexion und über den ganzen Schritt extrahierte Einzelmerkmale „Minimum“ und „Maximum“. Die Einzelmerkmalsmatrix  $\mathbf{X}$  und Klassenmatrix  $\mathbf{Y}$  beinhalten:

$$\mathbf{X} = \begin{pmatrix} 9 & -14.0 & 61.2 \\ 9 & -12.1 & 59.7 \\ 9 & 16.9 & 56.4 \\ 5 & 25.0 & 60.7 \\ 5 & 28.2 & 57.0 \\ 5 & 10.2 & 61.00 \end{pmatrix} \quad \mathbf{Y} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \\ 1 & 2 \\ 2 & 1 \\ 2 & 1 \\ 2 & 1 \end{pmatrix}$$

Die erste Spalte ( $s = 1$ ) in  $\mathbf{X}$  gibt das Alter an,  $s = 2$  das Minimum der Knieflexion bzw.  $s = 3$  das Maximum. Die erste Spalte ( $s = 1$ ) in  $\mathbf{Y}$  kodiert die Patienten,  $s = 2$  den Untersuchungszeitpunkt.

Zur Kodierung der unterschiedlichen Zeitreihen  $S_{ZR}$  und Einzelmerkmale  $S_{EM}$  wird entsprechend der Klasseneinteilungsmatrix eine Kategorieneinteilungsmatrix  $\mathbf{G}_{S_{ZR}+S_{EM} \times L}$  verwendet. Kategorien sind z.B. „Gelenk“ mit den unterschiedlichen Einträgen „Becken“, „Hüfte“, „Knie“ und „Sprunggelenk“ oder „Art des Merkmals“ mit den Einträgen „Zeitreihe“, „Maximum“, „Minimum“ usw., siehe Tabelle 3.2 und Anhang A für die Erklärung der Zeitbereiche. Anhand der Kategorien lassen sich die Zeitreihen und Einzelmerkmale einheitlich und eineindeutig beschreiben und automatisiert handhaben, wie z.B. die Verwendung der Apriori-Relevanzen oder die hierarchische Bewertung des Gangverhaltens in unterschiedlichen Abstraktionsebenen.

Beispiel: Die ganze Zeitreihe (vollständiger Schritt) der linken Knieflexion wird durch „ZR STRI Knie sag LI“ beschrieben oder in der Kategorienmatrix  $\mathbf{G}$  als Zeilenvektor durch  $\mathbf{g}_s = [1 \ 1 \ 3 \ 1 \ 2]$  kodiert. Wird aus der Standphase dieser Zeitreihe das Einzelmerkmal „Maximum“ extrahiert, so ist es durch „MAX ST Knie sag“ bzw.  $\mathbf{g}_s = [2 \ 2 \ 3 \ 1 \ 2]$  beschrieben.

Aufgrund messtechnischer Probleme in den Labors fehlen für einzelne Datensätze manchmal Zeitreihen, meist für eine komplette Körperseite, siehe Abschnitt 2.2 und [70]. Die fehlenden Zeitreihen werden in dem Feld dritter Ordnung zunächst mit Nullelementen aufgefüllt, „Nullzeitreihen“. Drei Arten werden hier für fehlende Daten verwendet:

Art ( $l = 1$ )	Zeitbereich ( $l = 2$ )	Gelenk ( $l = 3$ )	Raumrichtung ( $l = 4$ )	Körperseite ( $l = 5$ )
Zeitreihe (ZR), Maximum (MAX), Minimum (MIN), ...	Schritt (STRI): $k = 1..100$ , Stand (ST): $k = 1..60$ , Schwung (SW): $k = 61..100$ , weitere Zeitbereiche wie Loading Response (LR) $k = 1..10$ , Initial Swing (ISw) $k = 61..73$ , ...	Becken, Hüfte, Knie, Sprung- gelenk (OSG)	sagittal (sag), frontal (fro), transversal (tra)	rechts, (RE) links, (LI)

Tabelle 3.2: Bezeichnungen für Zeitreihen und Einzelmerkmale anhand von Kategorien  $l = 1..5$ , die Kategorien werden später in den Abschnitten 3.4 und 3.5 erweitert.

- Nullzeitreihen werden ersetzt, indem für den betreffenden Datensatz  $n$  entsprechend gemittelte Zeitreihen

$$Z_{ns}[k] = \frac{1}{N_j} \sum_j Z_{js} \text{ mit } \mathbf{y}_n = \mathbf{y}_j \text{ und } Z_{js} \neq \mathbf{0} \quad (3.1)$$

verwendet werden, vgl. Gl. (3.6). Die gemittelten Zeitreihen berechnen sich aus allen Datensätzen für jeweils identische Klassen  $y = 1..Y$  (z.B. selbe Person zum selben Untersuchungszeitpunkt), die keine Nullzeitreihen sind.

- Der Datensatz  $n$  wird gelöscht, bei dem mindestens eine Nullzeitreihe existiert.
- Sind alle Zeitreihen identischer Klassen  $y = 1..Y$  (z.B. Patient zu einem Untersuchungszeitpunkt) Nullzeitreihen, ein Kopieren von gemittelten Zeitreihen ist somit nicht möglich, so werden die Zeitreihen für alle  $N$  Datensätze gelöscht. Das ist beispielsweise bei den Oberkörperdaten der Fall, die nur bei vereinzelt Personen vorliegen.

Die erste Art reduziert zwar nicht die Anzahl von Datensätzen bzw. Merkmalen, verfälscht aber durch die gemittelten Zeitreihen unter Umständen den gesamten Datensatz. Analog zu den Zeitreihen wurden die Einzelmerkmale auf fehlende Messungen überprüft. Es ist offensichtlich, dass ein Löschen von einzelnen Elementen in dem Feld (oder der Matrix) nicht möglich ist, da so entweder die komplette Zeitreihe (Einzelmerkmal), oder der komplette Datensatz gelöscht werden muss. Fehlende Daten verfälschen eine Klassifikation oder Relevanzbewertungen (z.B. irreführende Diagnose von Patienteneffekten aufgrund fehlender Daten) oder erhöhen hier

inadäquat den Aufwand beim Entwurf von Klassifikatoren. Eine Beschreibung zur Realisierung von Datenprojekten mit dem konkreten Umgang mit fehlenden Daten ist in Kapitel 4 gezeigt.

Mehrere Lösungsansätze zur Behandlung von Ausreißern bzw. fehlenden Messwerten sind in der Literatur bekannt [11, 46, 70]. Allerdings müssen sie wie eben gezeigt problemspezifisch ausgewählt und entsprechend der neuen Strategie zur Speicherung der Daten modifiziert werden.

Durch die neu entwickelte Strategie zur Speicherung der Daten ist der Zugriff auf alle erhobenen Messdaten möglich und die zusätzliche Berechnung und Einbindung eines verallgemeinerten Merkmalsraumes möglich, wie in den nächsten Abschnitten gezeigt wird. Dadurch lassen sich die computerbasierten Verfahren verallgemeinert anwenden, weil der gesamte Datenraum ohne subjektive Vorauswahl erfasst ist.

### 3.4 Verallgemeinerter Merkmalsraum mit zusätzlichen Zeitreihen

Die Berechnung zusätzlicher Zeitreihen dient zur verallgemeinerten und schematisierten Nachbildung der empirischen Analyse (Abschnitt 2.3) und Erweiterung der originalen Daten, um weitere potenziell relevante Merkmale zur Lösung einer Problemstellung bereit zu stellen, siehe Abbildung 3.1 und [88, 90]. Dadurch können

- dynamische Verhaltensweisen,
- „versteckte“ Effekte,
- zusätzliche Informationen oder
- pathologische Ausmaße

erfasst und quantifiziert werden. Alle zusätzlichen Zeitreihen sind wiederum auf 100% des Gangzyklus normiert und in dem Feld dritter Ordnung  $\mathbf{Z}[k]$  als weitere Zeitreihen abgelegt.

Zusätzliche Zeitreihen sind die Geschwindigkeitszeitreihen (GZR)

$$\dot{U}_{ns}[k] = \frac{\Delta U_{ns}[k]}{\Delta k} = \frac{U_{ns}[k+1] - U_{ns}[k-1]}{(k+1) - (k-1)} = \frac{U_{ns}[k+1] - U_{ns}[k-1]}{2} \quad (3.2)$$

bzw. Beschleunigungszeitreihen (BZR)

$$\ddot{U}_{ns}[k] = \frac{\Delta \dot{U}_{ns}[k]}{\Delta k} = \frac{\dot{U}_{ns}[k+1] - \dot{U}_{ns}[k-1]}{2}, \quad (3.3)$$

für  $k=2..K-1$ , d.h. die erste bzw. zweite Ableitung bezogen auf die Abtastzeitpunkte ( $K = 100$  ist zweckmäßig, da dann die einzelnen Abtastzeitpunkte  $k$  der prozentualen Aufteilung des Gangzyklus entsprechen). Um die Anfälligkeit auf Ausreißer zu reduzieren, wurde ein Tiefpass aus den Abtastzeitpunkten  $k-1$  und  $k+1$  verwendet. Der erste bzw. letzte Abtastzeitpunkt  $K$  sind extrapoliert, siehe Abbildung 3.3:

$$\dot{U}_{ns}[1] = \dot{U}_{ns}[2] - (\dot{U}_{ns}[3] - \dot{U}_{ns}[2]) = 2 \cdot \dot{U}_{ns}[2] - \dot{U}_{ns}[3], \quad (3.4)$$

$$\dot{U}_{ns}[K] = 2 \cdot \dot{U}_{ns}[K-1] - \dot{U}_{ns}[K-2]. \quad (3.5)$$

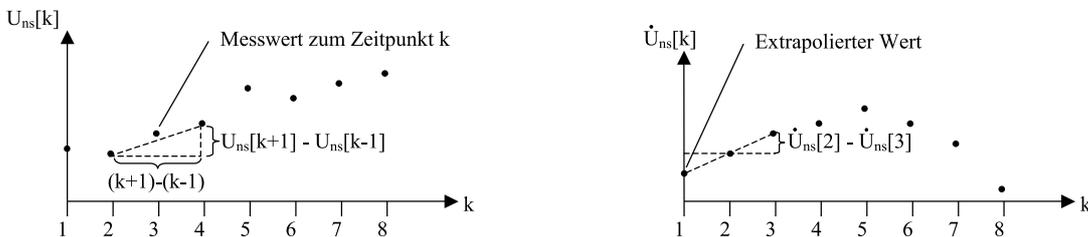


Abbildung 3.3: Berechnung von zeitlichen Ableitungen am Beispiel der GZR (links) und Extrapolation der Randwerte (rechts).

Mit  $\dot{U}_{ns}[k]$  bzw.  $\ddot{U}_{ns}[k]$  kann das dynamische Verhalten später ausgewertet und beispielsweise über Anstiege von Zeitreihen interpretiert werden. Aufgrund der Normierung aller Zeitreihen auf 100% des Gangzyklus können die eigentlichen Gangeffekte in den Bewegungsabläufen einheitlich verglichen werden, trotz individuell unterschiedlicher Gehgeschwindigkeiten, siehe Abbildung 3.4. Beispielsweise beschreibt das Minimum der normierten Geschwindigkeitszeitreihen (rechte Diagramme in Abbildung 3.4) den gleichen funktionellen Zusammenhang mit dem Strecken des Knies: Zu erkennen sind ähnliche Werte (ca. -3) in der gleichen Gangphase (ca. 90% des Gangzyklus). Bei der Betrachtung der Verläufe auf die zeitbezogene Geschwindigkeit (mittlere Diagramme in Abbildung 3.4) erscheinen die Minima wegen des unterschiedlich schnellen Gehens verschieden (Werte und Positionen in den Zeitreihen). Wichtig ist aber, die funktionellen Unterschiede zu erkennen. Mit der Geschwindigkeitszeitreihe  $\dot{U}_{ns}[k]$  (bzw.  $\ddot{U}_{ns}[k]$ ) werden daher nicht die gehgeschwindigkeitsabhängigen zeitlichen Winkeländerungen, sondern normierte Winkelgeschwindigkeiten und -beschleunigungen berechnet.

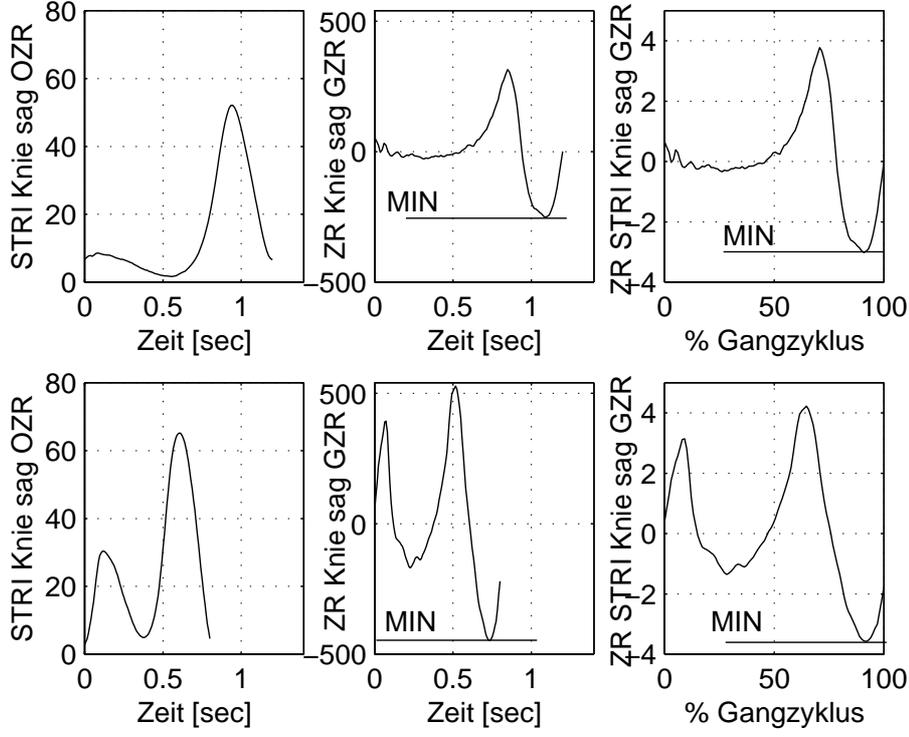


Abbildung 3.4: Veranschaulichung der Geschwindigkeitsverläufe am Beispiel des Kniegelenkwinkels eines Probanden mit langsamer (oben) und schneller (unten) Gehgeschwindigkeit sowie Originalzeitreihen (links), auf Zeit bezogene Geschwindigkeit (Mitte) und (normierte) Geschwindigkeitszeitreihe (rechts).

Weitere zusätzliche Zeitreihen sind Mittelwert-

$$\bar{Z}_{ns}[k] = \frac{1}{N_J} \sum_{n \in J} Z_{ni}[k] \quad (3.6)$$

(Mittelung erfolgt zu festem Zeitpunkt  $k$  über  $N_J$  Datensätze) und Standardabweichungszeitreihen

$$\tilde{Z}_{ns}[k] = \sqrt{\frac{1}{N_J - 1} \sum_{n \in J} (Z_{ni}[k] - \bar{Z}_{ns}[k])^2} \quad (3.7)$$

für  $N_J$  Datensätze. Diese Zeitreihen werden mit  $Z_{ns}[k] = U_{ns}[k]$  über die originalen Zeitreihen (MZR bzw. SZR) oder über die GZR mit  $Z_{ns}[k] = \dot{U}_{ns}[k]$  (MGZR bzw. SGZR) berechnet. Hieraus lassen sich charakteristische Kurvenformen für

- Personengruppen ( $N_J$  Datensätze, z.B. alle Schritte eines Referenzkollektives  $J = \text{REF}$  mit resultierender Mittelwert-  $\bar{Z}_{\text{REF } s}[k]$  und Standardabweichungszeitreihe  $\tilde{Z}_{\text{REF } s}[k]$ , siehe Abbildung 3.5) oder
- eine Person (z.B. alle  $N_J$  Schritte eines Patienten bei einer Untersuchung zur Erfassung der intra-individuellen Reproduzierbarkeit von Bewegungen als zusätzliche Information)

ermitteln. Da bei der konventionellen, empirischen Datenanalyse lediglich die Mittelwertzeitreihen eines Patienten anhand der Charts ausgewertet werden, wird dadurch die intra-individuellen Reproduzierbarkeit vernachlässigt. Lediglich durch direkte Beobachtung der Patienten (auch mittels Videoaufzeichnungen) wird in der klinischen Praxis dieser Aspekt mit berücksichtigt, siehe Abschnitt 2.3 und [51, 147, 162]. Der Experte erkennt ungleichmäßiges Gehen eines Patienten, allerdings ohne es zu quantifizieren. Erst neuere Arbeiten versuchen die Variabilität zu quantifizieren [4, 6]. In Kapitel 5 wird gezeigt, dass die intra-individuelle Reproduzierbarkeit eine wichtige Charakterisierung von Patienten ist und als Standstabilität und Gangökonomie interpretiert werden kann [175].

Für einen relativen Vergleich von Datensätzen zu einem Referenzkollektiv werden Referenzabweichungszeitreihen (RZR)

$$\hat{Z}_{ns}[k] = \frac{1}{\gamma} \cdot \frac{|Z_{ns}[k] - \bar{Z}_{\text{REF } s}[k]|}{\tilde{Z}_{\text{REF } s}[k]} \quad (3.8)$$

verwendet, die in der vorliegenden Arbeit neu entwickelt wurden. Die Idee ist die Abweichung zwischen der MZR eines Referenzkollektives und einer Patientenzeitreihe durch die SZR des Referenzkollektives zu gewichten. Es findet eine Normierung bezüglich des Referenzkorridors statt, siehe Abbildung 3.5: Dabei liegt der dünn dargestellte Referenzkorridor in dem Wertebereich zwischen  $[0,1]$ , siehe untere Diagramme mit RZR bzw. RGZR. Beispielsweise ist die PRE und POST Kniezeitreihe des Patienten ID 50324 zwischen ca. 70 und 90% des Gangzyklus innerhalb des Referenzkorridors, siehe Diagramm links oben. In der Referenzzeitreihe im Diagramm links unten sind daher in diesem Bereich des Gangzyklus die Werte zwischen  $[0,1]$ . Je größer die pathologische Abweichung bezüglich der Referenz, desto größer sind die Werte der Referenzzeitreihen, z.B. bei ca. 50% des Gangzyklus in den linken Diagrammen. Analog dazu sind die Geschwindigkeitszeitreihen zu interpretieren.

Mit dem Gewichtungsfaktor  $\gamma$  kann zusätzlich die Korridorbreite eingestellt werden, er ist im Folgenden allerdings auf  $\gamma = 1$  gesetzt. Werte zwischen Null und Eins bedeuten eine Funktionalität im Referenzbereich. Werte größer als Eins deuten auf erhebliche Abweichungen hin (pathologisches Ausmaß). Die Referenzabweichung

wird über originale (RZR) oder über die Geschwindigkeitszeitreihen (RGZR) berechnet.

Weitere Alternativen zur RZR bestehen in dem Weglassen des Betrags

$$\hat{Z}_{ns}^*[k] = \frac{1}{\gamma} \cdot \frac{Z_{ns}[k] - \bar{Z}_{REF\ s}[k]}{\tilde{Z}_{REF\ s}[k]} \tag{3.9}$$

(zusätzliche Berücksichtigung der Patientenmesswerte „ober- bzw. unterhalb“ des Referenzkorridors) oder damit nur die Berücksichtigung des Vorzeichens  $\hat{Z}_{ns}^{**}[k] = \text{sign}(\hat{Z}_{ns}^*[k])$  oder alleinige Bewertung des pathologischen Ausmaßes (mit  $\max(0, \hat{Z}_{ns}[k] - \gamma)$ , Berücksichtigung lediglich der Abtastzeitpunkte außerhalb des Referenzkorridors).

Die Akzeptanz bei den Klinikern ist allerdings für die RZR bzw. RGZR aus der Gleichung (3.8) höher, da eine abstrakte und skalierte Bewertung des pathologischen Gehens verlangt ist [4, 41, 127]. Das bedeutet, es soll darin ein Wertebereich als Relativeinschätzung zum Referenzverhalten erkennbar und keine weiteren Informationen enthalten sein (wie ober- und unterhalb des Referenzkorridors). Insbesondere die zusätzliche Information kann auf anderem Wege besser interpretierbar und detaillierter erhalten werden, wie durch die Extraktion charakteristischer Einzelmerkmale.

Tabelle 3.3 gibt einen Überblick über die verwendeten Zeitreihen. Die „Art der Zeitreihe“ dient als weitere Kategorie zur systematischen und eindeutigen Bezeichnung. Die vollständige Kategorisierung wird zusammen mit den Einzelmerkmalen in Abschnitt 3.5 beschrieben.

Abk.	Symbol	Einh.	Art der Zeitreihe
OZR	$U_{ns}[k]$	[°]	originale Zeitreihe
GZR	$\dot{U}_{ns}[k]$	[°/k]	(auf 100% Gangzyklus normierte) Geschwindigkeitszeitreihe
BZR	$\ddot{U}_{ns}[k]$	[°/k <sup>2</sup> ]	(auf 100% Gangzyklus normierte) Beschleunigungszeitreihe
MZR	$\bar{Z}_{ns}[k]$	[°]	Mittelwertzeitreihe, z.B. $\bar{U}[k]$ oder $\bar{\dot{U}}[k]$
SZR	$\tilde{Z}_{ns}[k]$	[°]	Streuungszeitreihe, z.B. $\tilde{U}[k]$ (OZR SZR) oder $\tilde{\dot{U}}[k]$ (GZR SZR)
RZR	$\hat{Z}_{ns}[k]$	∅	Referenzabweichungszeitreihe, z.B. $\hat{U}_{ns}[k]$ (OZR RZR) oder $\hat{\dot{U}}_{ns}[k]$ (GZR RZR)

Tabelle 3.3: Abkürzungen, Symbole und Einheiten der Zeitreihen. Einheiten sind hier Winkel in ° bzw. Abtastzeitpunkt  $k$ .

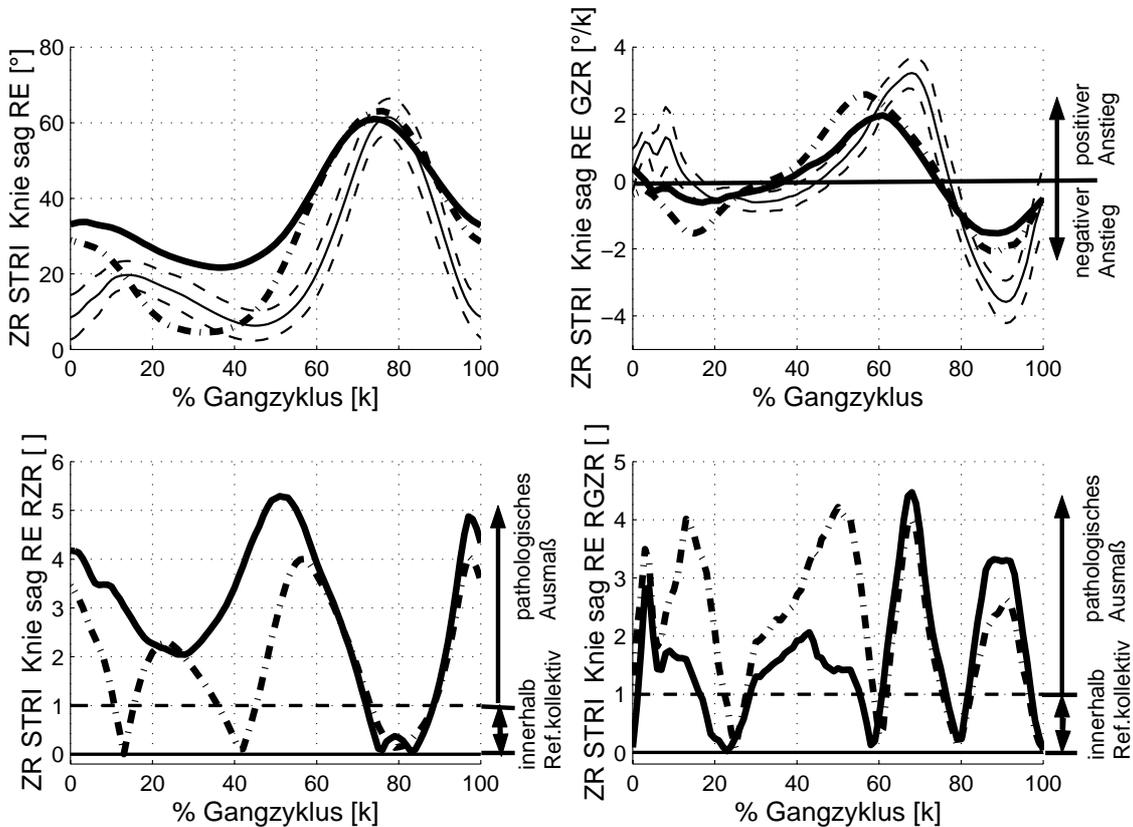


Abbildung 3.5: Knieflexion (OZR, links oben) und zusätzliche Zeitreihen (GZR, rechts oben; RZR links unten; RGZR rechts unten) der rechten Körperseite eines Patienten ID 50324 zur PRE-therapeutischen (fett, durchgezogen) und POST-therapeutischen (fett, strichpunktiert) Untersuchung. Weiterhin ist der Referenzkorridor durch  $\bar{Z}_{\text{REF } s}[k] \pm \tilde{Z}_{\text{REF } s}[k]$  (dünn durchgezogen bzw. gestrichelt) dargestellt.

Beispiel zur Interpretation zusätzlicher Zeitreihen, vgl. Abbildung 3.5: Der maximale Anstieg zum PRE-therapeutischen Zustand ist gegenüber dem Referenzverhalten reduziert (in der originalen Zeitreihe empirisch nur schwer feststellbar, „versteckter“ Effekt, besser in GZR oder RGZR), Ursache ist ein reduziertes Vermögen, den Muskel schnell zu kontrahieren, möglicherweise durch Spastik. Das maximale pathologische Ausmaß ist bei ca. 50% des Gangzyklus. Eine geringfügige Verbesserung ist durch die Therapie erzielt. Dynamisches Verhalten verschlechtert sich im Laufe der Therapie, die motorischen Abläufe können nicht gezielt eingesetzt werden, möglicherweise durch Ausschalten verantwortlicher Muskeln durch Botulinum-Toxin.

Selbstverständlich ist die Berechnung weiterer zusätzlicher Zeitreihen möglich, wie z.B. Auto- oder Kreuzkorrelationsfunktionen bezüglich  $\bar{U}_{REF\ s}[k]$ , siehe Anhang C. Allerdings ist hierbei die klinische Akzeptanz besonders gering.

### 3.5 Verallgemeinerter Merkmalsraum mit interpretierbaren Einzelmerkmalen

Die Berechnung von Einzelmerkmalen dient

- der Zusammenfassung von Aussagen über die gesamte Zeitreihe (global) oder über die funktionellen bzw. standardisierten Bereichen in Zeitreihen (lokal) sowie
- der verallgemeinerten, systematischen Nachbildung der klinischen Interpretation.

Sie werden als potenziell relevante Einzelmerkmale aus den originalen und den zusätzlichen Zeitreihen berechnet und in  $\mathbf{X}$  abgelegt, siehe Abbildung 3.1 und Tabelle 3.4.

Abk.	Einzelmerkmal	Berechnung
MIN	Minimum	$x_{ns} = \min(Z_{ns}[k]), k \in K$
MAX	Maximum	$x_{ns} = \max(Z_{ns}[k]), k \in K$
MIPO	Position Minimum in % des Gangzyklus	$x_{ns} = k^*$ , mit $Z_{ns}[k^*] = \min(Z_{ns}[k]), k \in K$
MAPO	Position Maximum in % des Gangzyklus	$x_{ns} = k^*$ , mit $Z_{ns}[k^*] = \max(Z_{ns}[k]), k \in K$
MW	Mittelwert	$x_{ns} = \frac{1}{K} \cdot \sum_k Z_{ns}[k], K = \sum_k 1, k \in K$
SpW	Spannweite	$x_{ns} = \max(Z_{ns}[k]) - \min(Z_{ns}[k]), k \in K$

Tabelle 3.4: Abkürzungen der Einzelmerkmale zur klinisch interpretierbaren Datenauswertung (oben) und zur weiteren Datenvorverarbeitung (unten).

Aus den Zeitreihen werden somit interpretierbare Einzelmerkmale wie Extrema, deren Positionen, Mittelwerte und Bewegungsspannen berechnet, siehe Abbildung 3.6. Das erfolgt systematisch sowohl über die ganze Zeitreihe (Schritt) als auch über bestimmte Zeitbereiche (Tabelle 3.5). Die Zeitbereiche sind an funktionelle Unterteilungen in der Ganganalyse angepasst, wie z.B. die Einteilung in Stand- (ST) und Schwungphase (SW). In der Arbeit sind sie sowohl als standardisierte Gangphasen angenommen (in Anlehnung an Referenzpersonen, Tabelle 3.5) als auch personenindividuell durch Ereignismessungen berechnet (individuelle Phaseneinteilung).

Die Ereignismessungen beinhalten beispielsweise für jede Person den Zeitpunkt der Fußablösung im Gangzyklus, wodurch die Stand- und Schwungphase definiert sind, siehe Anhang A. Die Zeitreihen werden entsprechend der Phasen interpoliert. Allerdings sind teilweise die Daten nicht vorhanden oder unvollständig, so dass sich nicht alle einzelnen Schrittphasen berechnen lassen, wie z.B. Mid Stance (MSt), Terminal Stance (TSt), Initial Swing (ISw), Mid Swing (MSw). Ein Vergleich von standardisierten Gangphasen und individueller Phaseneinteilung ist in Kapitel 5 gezeigt.

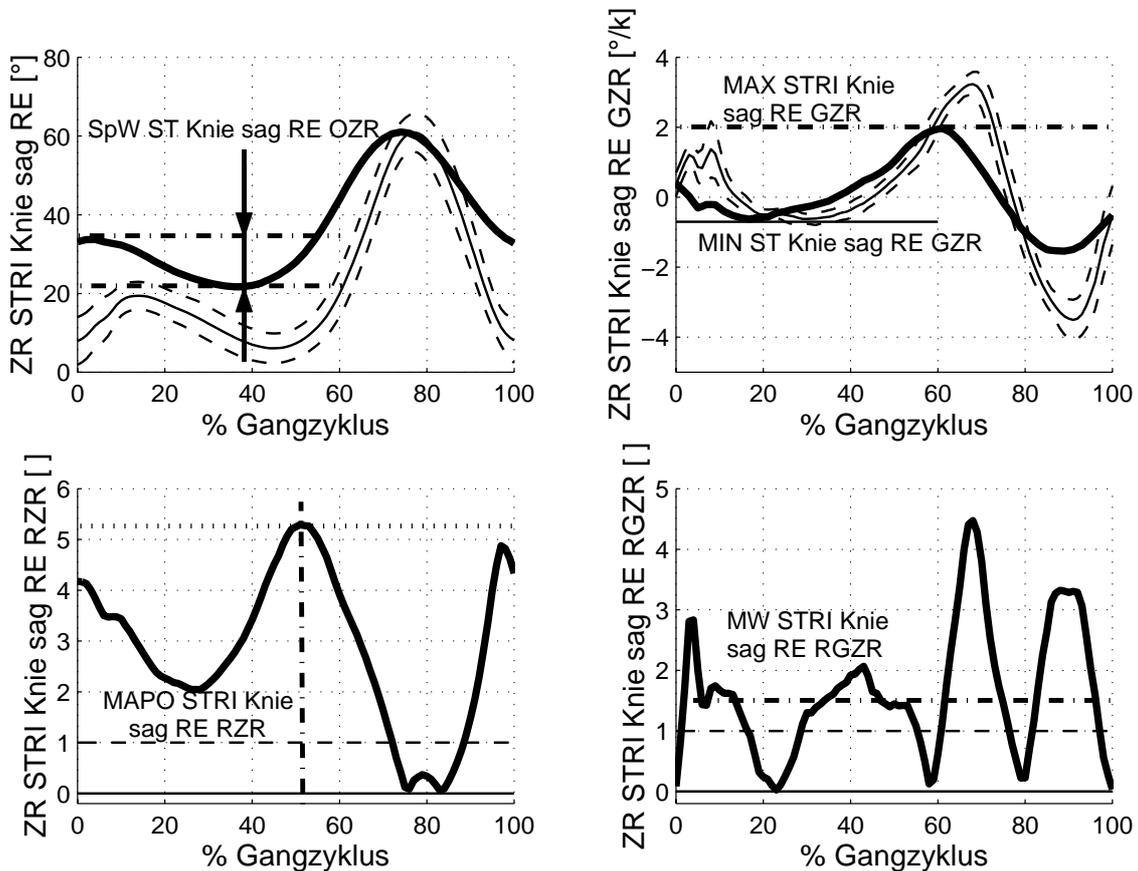


Abbildung 3.6: Beispiele für Einzelmerkmale zur Quantifizierung von Aussagen für einen Patienten ID 50324. Die Zeitreihen des Patienten sind fett durchgezogen und die des Referenzkorridors dünn gestrichelt bzw. durchgezogen dargestellt.

Die eindeutige Zuordnung der Einzelmerkmale erfolgt über ein neu entwickeltes Konzept mit Kategorien (Art Einzelmerkmal, Zeitbereich, Gelenk, Raumrichtung usw.), aus denen u.a. die Bezeichnung hervorgeht. Das Minimum in der Standphase der normierten Geschwindigkeits-ZR des rechten Knies in sagittaler Körperebene wird somit durch „MIN ST Knie sag RE GZR“ abgekürzt, siehe Abbildung 3.6 rechts oben.

Art	Zeitbereich	Gelenk	Raumrichtung	Körperseite	ZR
ZR, MAX, MIN, MIPO, MAPO, MW, SpW	Schritt (STRI): $k = 1..100$ , Stand (ST): $k = 1..60$ , Schwung (SW): $k = 61..100$ , Initial Contact (IC) $k = 1..2$ , Loading Response (LR) $k = 1..10$ , Mid Stance (MSt) $k = 11..30$ , Terminal Stance (TSt) $k = 31..51$ , Pre Swing (PSw) $k = 52..61$ , Initial Swing (ISw) $k = 61..73$ , Mid Swing (MSw) $k = 74..87$ , Terminal Swing (TSw) $k = 88..100$	Becken, Hüfte, Knie, Sprunggelenk (OSG)	sagittal (sag), frontal (fro), transversal (tra)	rechts, (RE) links, (LI)	OZR GZR BZR MZR SZR RZR GZR

Tabelle 3.5: Vollständige Bezeichnungen für Zeitreihen und Einzelmerkmale anhand der Kategorien.

Aufgrund der systematischen Berechnung entsteht eine Vielzahl von teilweise redundanten Einzelmerkmalen, z.B. 63 Zeitreihen aus 9 originalen Zeitreihen mit jeweils 6 zusätzlichen Zeitreihen, 6 Arten von Einzelmerkmalen und 11 Schrittphasen ergibt 4158 Einzelmerkmale. Sie müssen mit geeigneten Methoden problemspezifisch bewertet und ausgewählt werden. Der Sinn dieser Vielzahl von Merkmalen ist, dass somit alle Effekte in der Zeitreihe erfasst werden können und die Vorgehensweise des Klinikern verbessert nachgebildet wird. Der Kliniker achtet bei der subjektiven Analyse neben dem gesamt wirkenden Gangbild auf derartige charakteristische Zeitbereiche. Bestimmte Patientengruppen sind nur in funktionellen Zeitbereichen präzise charakterisiert, z.B. Fußaufsetzbereich, Ende der Schwungphase (MSt), siehe später in Tabellen 5.3 und 5.14. Aus dem Grund werden die Gangdaten in den Labors derart ausführlich aufgenommen.

Beispiel, siehe Referenz, PRE- und POST-Werte in Abbildungen 3.5 und Einzelmerkmale in Abbildung 3.6 sowie in Tabelle 3.6: Die Einzelmerkmale beschreiben die Spannweite in der Standphase der Kniebeugung oder den maximalen Anstieg im gesamten Schritt. Durch die Therapie wurde eine Verschlechterung in Kauf genommen, um z.B. das Sprunggelenkverhalten zu verbessern. Im Gegensatz zur empirischen Analyse lassen sich auch weniger offensichtliche Merkmale finden, die dennoch interpretierbar bleiben, z.B. Position des maximalen Anstiegs von Winkelverläufen oder von Referenzabweichungen oder durchschnittliche Referenzabweichung der normierten Geschwindigkeit. Die Position von Maxima und Minima sind allerdings lediglich der Vollständigkeit berechnet, weil sie fester Bestand in der empirischen Analyse sind. Sie werden in der Praxis aus den Zeitreihen interaktiv und mit Modellverständnis extrahiert, z.B. individuelle, lokale Positionen. Diese Art von Extraktion ist rechnerbasiert schwer systematisierbar.

Einzelmerkmal	PRE	POST	REF
SpW ST Knie sag RE OZR	22.2	37.9	$16.5 \pm 3.2$
Max STRI Knie sag RE GZR	2.0	2.6	$3.3 \pm 0.3$
MAPO STRI Knie sag RE RZR	52.0	98.0	$58.7 \pm 32.3$
MW STRI Knie sag RE RGZR	1.6	2.2	$0.6 \pm 0.2$
MW STRI OSG sag RE OZR	-19.3	2.2	$2.5 \pm 2.2$
MW STRI OSG sag RE RZR	7.2	1.1	$0.7 \pm 0.4$
MW STRI OSG sag RE RGZR	1.3	1.1	$0.4 \pm 0.1$
MW STRI OSG sag RE SZR	4.3	4.6	$1.5 \pm 0.1$

Tabelle 3.6: Beispiele von Einzelmerkmalen für einen Patienten ID 50324, die aus den originalen und zusätzlichen Zeitreihen extrahiert werden, vgl. Abbildung 3.6.

Bei manchen Einzelmerkmalen entstehen durch die Kombination aus zusätzlichen Zeitreihen **Besonderheiten bei der Interpretation**, die im Folgenden erläutert werden. Unter der Annahme, dass ein Schritt reproduzierbar ist (Anfangs- $Z_{ns}[1]$  und Endwert  $Z_{ns}[K]$  in einer Zeitreihe sind gleich) ist das Einzelmerkmal „MW STRI ZR GZR“ Null. Allerdings ist die Annahme insbesondere bei Patienten falsch (siehe Kapitel 5, die Patientenschritte sind schlecht reproduzierbar) und kann durch Messfehler verstärkt werden.

Von besonderem klinischem Interesse bei der Bestimmung einer globalen Gangqualität ist der Mittelwert über die Referenzabweichungs-ZR „MW STRI ZR RZR“ bzw. „MW STRI ZR GRZR“. Durch die Gewichtung mit der Referenzstreu-

ung  $\tilde{Z}_{\text{REF } s}$  in Gl. (3.8) bestehen zwei wesentliche Vorteile bei der Bestimmung einer Gangqualität durch

- Vergleichen und
- Verknüpfen.

Dadurch lassen sich beispielsweise die gemittelte Referenzabweichung aus der Standphase und Schwungphase einer Zeitreihe vergleichen. Oder es lassen sich auch die gemittelten Referenzabweichungen aus verschiedenen Zeitreihen (z.B. Knie und Hüfte) miteinander vergleichen, da sie bezüglich der Referenz normiert sind. Durch die Normierung lassen sich zur Bestimmung einer globalen Gangqualität die Mittelwerte über mehrere Zeitreihen miteinander verknüpfen.

Anhand des Mittelwerts wird auch deutlich, dass bei anderen Varianten bei der Berechnung einer Referenzabweichungs-ZR Nachteile entstehen. Beispielsweise heben sich in  $\hat{Z}_{ns}^*[k]$  durch unterschiedliche Vorzeichen die Werte auf, trotz großer Referenzabweichung ober- und unterhalb des Referenzkorridors.

Weiterhin wurde zur Schätzung von Kurvenähnlichkeiten in dieser Arbeit der Korrelationskoeffizient zwischen Zeitreihen eines Patienten und dem Mittelwert des Referenzkollektives mit

$$x_{ns'} = \frac{\sum_{k=1}^K (Z_{ns}[k] - \text{MW}(Z_{ns})) \cdot (\bar{Z}_{\text{REF } s}[k] - \text{MW}(\bar{Z}_{\text{REF } s}))}{\sqrt{\sum_{k=1}^K (Z_{ns}[k] - \text{MW}(Z_{ns}))^2 \cdot \sum_{k=1}^K (\bar{Z}_{\text{REF } s}[k] - \text{MW}(\bar{Z}_{\text{REF } s}))^2}} \quad (3.10)$$

vorgeschlagen. Der Wertebereich liegt im Intervall  $[-1, +1]$ , betragsmäßig große Werte beschreiben eine hohe Ähnlichkeit und umgekehrt [132].

Die klinische Akzeptanz ist zwar gering, da ähnliche Informationen durch die oben vorgestellten interpretierbaren Einzelmerkmale erhalten werden, wie z.B. über die GZR oder RGZR. Darüber hinaus lässt sich die Kurvenform detaillierter mit den später vorgestellten Cluster-Verfahren beschreiben. Hierbei wird sogar die Heterogenität der Daten berücksichtigt und die Akzeptanz ist relativ hoch (7. Merkmalsart in Abschnitt 2.3).

Selbstverständlich können weitere Einzelmerkmale berechnet werden, wie z.B. Parameter aus Schätzungen von Systemidentifikationen [28, 58, 142] oder transformierte Einzelmerkmale durch die Hauptkomponentenanalyse [83, 132], siehe auch Abschnitt 3.8.2. Allerdings besteht bei der Ganganalyse dafür keinerlei klinische Akzeptanz [30, 77, 127].

## 3.6 Bewertung von Einzelmerkmalen

Die Bewertung von Einzelmerkmalen gliedert sich hier in die Relevanzbewertung und Regression. Dabei werden die Aufgaben

- Finden informationstragender Merkmale für eine bestimmte Problemstellung,
- Aussortieren redundanter Information,
- Bevorzugung besonders interpretierbarer Merkmale und
- Berücksichtigung zuverlässiger Merkmale

gelöst. Bei der Relevanzbewertung werden im Folgenden diskrete Klasseneinteilungen aus Abschnitt 3.2 vorausgesetzt. Für die klinische Anwendung werden hierbei aus der Vielzahl von Einzelmerkmalen diejenigen herausgefunden, die zu Lösung einer gegebenen klinischen Problemstellung beitragen (auf welche Merkmale muss der Kliniker insbesondere achten, um Patienten zu charakterisieren, Therapiefortschritte einzuschätzen usw.?). In Abbildung 3.1 ist der in diesem Abschnitt beschriebene Teilprozess der Datenauswertung mit „Bewertung von Merkmalen“ dargestellt. Hierbei werden insbesondere die zusätzlich berechneten interpretierbaren Einzelmerkmale aus Abschnitt 3.5 als auch gemessene Einzelmerkmale (wie Alter, Schrittlänge, Kadenz, ...) einbezogen.

Die diskrete Klasseneinteilung zur Relevanzbewertung wird aus der Klassenmatrix  $\mathbf{Y}_{\mathbf{N} \times \mathbf{S}_Y}$  problemspezifisch gewählt. Beispielsweise können Veränderungen durch eine Therapie durch Wahl des Klassenterms „Untersuchung“ und der entsprechenden Spalte  $\mathbf{y}$  als Klasseneinteilung herangezogen werden. Durch eine Datenauswahl lediglich der PRE-therapeutischen und der ersten POST-therapeutischen Untersuchung ergibt das ein 2-Klassenproblem.

Bei der Regression ist die Vorgabe eines „Zielmerkmals“ notwendig (als „kontinuierliche Klasse“). Sie dient für spezielle Teilaufgaben wie z.B. das Ermitteln einer Gangqualität in Bezug auf eine Experteneinschätzung (welche quantitative Merkmalskombination beschreibt ein Zielmerkmal wie die VAS Experteneinschätzung, d.h. auf welche Merkmale achtet ein Experte unbewusst).

### 3.6.1 Verfahren zur Relevanzbewertung

Statistische Standardverfahren zur Relevanzbewertung sind die univariate (ANOVA: ein Merkmal) oder multivariate (MANOVA: Gruppe von Merkmalen) Varianzanalyse, (**M**ultivariate) **A**nalysis of **V**ariance [70, 155]. Basierend auf klassenspezifischen

Kovarianzmatrizen

$$\mathbf{S}_c = \frac{1}{N_c} \left( \mathbf{X}_c^T - \left( \frac{1}{N_c} \mathbf{1}_{(N_c \times N_c)} \mathbf{X}_c \right)^T \right) \cdot \left( \mathbf{X}_c^T - \left( \frac{1}{N_c} \mathbf{1}_{(N_c \times N_c)} \mathbf{X}_c \right)^T \right)^T \quad (3.11)$$

$$= \frac{1}{N_c} \sum_{n \in N_c} (\mathbf{x}_n^T - \bar{\mathbf{x}}_{N_c}^T) \cdot (\mathbf{x}_n^T - \bar{\mathbf{x}}_{N_c}^T)^T \quad (3.12)$$

mit  $\mathbf{X}_c$  Matrix der Einzelmerkmale von  $N_c$  Datensätzen aus einer Klasse  $c$  (z.B. ICP,PRE; ICP;U1 usw.) bzw. deren Mittelwerte  $\bar{\mathbf{x}}_{N_c}$ . Entsprechend wird über alle Datensätze  $N_c = N$  die Gesamtkovarianzmatrix  $\mathbf{S}_c = \mathbf{S}$  berechnet. Mit der Gesamtvariationsmatrix  $\mathbf{T}$ , der Innerklassenkovarianzmatrix  $\mathbf{W}$  und dem Streuungszerlegungssatz  $\mathbf{T} = \mathbf{B} + \mathbf{W}$  wird das Eigenwertproblem [11, 155]

$$(\mathbf{W}^{-1} \mathbf{B} - \lambda_i \mathbf{I}) \boldsymbol{\phi}_i \quad \text{mit} \quad \mathbf{T} = N \cdot \mathbf{S} \quad \text{und} \quad \mathbf{W} = \sum_c N_c \cdot \mathbf{S}_c \quad (3.13)$$

gelöst. Das Ziel besteht darin Einzelmerkmale (oder Kombinationen) zu finden, die kleine Streuungen innerhalb der Klassen im Vergleich zu Streuungen zwischen den Klassen aufweisen. Auf den geordneten Eigenwerten ( $\lambda_1 \geq \lambda_2 \geq \dots \lambda_{S_{EM}}$ ) baut beispielsweise das Likelihood-Quotientenmaß

$$M_s = 1 - \prod_{i=1}^{S_{EM}} \frac{1}{1 + \lambda_i} \quad (3.14)$$

auf [108]. Dadurch werden große Eigenwerte favorisiert.  $M_s$  nimmt Werte zwischen Null (keine Relevanz, die Klassen lassen sich mit den Einzelmerkmalen nicht unterscheiden) und Eins (eindeutige Relevanz) an. Dabei wird die Merkmalskombination aller  $S_{EM}$  Einzelmerkmale für MANOVA und lediglich ein Einzelmerkmal mit  $S_{EM} = 1$  für ANOVA verwendet. Ein suboptimaler aber dafür praktikabler und recheneffizienter Lösungsweg für MANOVA beginnt mit der Suche nach dem besten Einzelmerkmal ( $S_{EM} = 1$ ). Iterativ wird nun die Merkmalskombination mit einem weiteren Einzelmerkmal ergänzt, das den Wert von Gl. (3.14) maximiert.

Weitere statistische Verfahren sind Signifikanztests, wie z.B. der Student- $(t)$ -Test, der eng mit ANOVA verwandt ist. Diese Tests werden hier allerdings wegen der schwierigeren Erweiterung bzw. Modifikation in den Hintergrund gestellt.

Die Vorteile bei der Anwendung der multivariaten Varianzanalyse (MANOVA) sind die geschlossene Lösbarkeit, die relativ einfache Implementierung sowie der geringe Rechenaufwand. Auf den Relevanzwertebereich zwischen Null und Eins baut zudem eine Modifikation auf, die in der vorliegenden Arbeit entwickelt worden ist

(Abschnitt 3.6.2), um zusätzlich zur Datenrelevanz weitere Priorisierungen einzu- beziehen (z.B. empirisch bevorzugte Merkmalskategorien, zuverlässigere Messqua- litäten). Nachteile sind die Voraussetzung einer Normalverteilung (ist aber oftmals in der Praxis näherungsweise erfüllt) und das Berücksichtigen linearer Trennbarkei- ten. Um auch nichtlineare Trennbarkeiten zu suchen, existieren weitere Verfahren wie informationstheoretische Maße [166].

Informationstheoretische Maße bewerten den Informationszugewinn, der für die Verwendung eines Merkmals (oder zusätzliche Verwendung bei Merkmalskombina- tionen) zur Trennung von Klassen erreicht wird. Zur Verwendung der informati- onstheoretischen Maße werden zunächst für jedes Einzelmerkmal dreieck- bzw. tra- pezförmige Zugehörigkeitsfunktionen entworfen, die den jeweiligen Wertebereich in  $m_s$  linguistische Terme  $A_{si}, i = 1..m_s$  transformiert<sup>1</sup> (z.B. für s=„MAX ST Hüfte sag GZR“ sind die Stützpunkte der Zugehörigkeitsfunktion  $\mathbf{a}_s = [0; 0.4; 0.8; 1.2; 3]$  mit einer Zugehörigkeit  $\mu(a_{si}) = 1$  zum jeweiligen linguistischen Term  $A_{si}$ , siehe y- Achse des linken Diagramms in Abbildung 3.7). Beim automatischen Entwurf wer- den dabei die Datenverteilung und die Randwerte sowie Interpretierbarkeitsaspekte berücksichtigt [105]. Die Benennung der Terme orientiert sich an den Werten der Stützpunkte (Tabelle 3.7). Ein Term mit  $a_{si} = 0$  wird mit NU bezeichnet. Die Be- zeichnung von Termen mit  $a_{si} > 0$  richtet sich nach deren Anzahl (1 Term: POS, 2 Terme: PK-PG, 3 Terme PK-PM-PG, 4 Terme PK-PM-PG-PSG, 5 Terme PSK-PK- PM-PG-PSG). Bei Termen mit  $a_{si} < 0$  wird analog vorgegangen. Allerdings geht bei diesem automatischen Entwurf die subjektiv empfundene, intuitive Zuordnung u.U. teilweise verloren. Die Alternative einer manuellen Zuordnung ist aber nicht akzeptabel.

$\mu(a_{si}) = 1, a_{si} > 0$	$\mu(a_{si}) = 1, a_{si} < 0$	$\mu(a_{si}) = 1, a_{si} = 0$
POS: positiv	NEG: negativ	NU: ungefähr null
PSK: sehr klein	NSK: etwas kleiner als null	
PK: klein	NK: leicht negativ	
PM: mittel	NM: mäßig negativ	
PG: groß	NG: stark negativ	
PSG: sehr groß	NSG: sehr stark negativ	

Tabelle 3.7: Kurz- und Langbezeichnung der linguistischen Terme in Abhängig- keit von den Stützpunkten der Zugehörigkeitsfunktionen  $a_{si}$  [89].

<sup>1</sup>In dieser Arbeit ist  $m_s = 5$  für alle wertekontinuierlichen Einzelmerkmale.

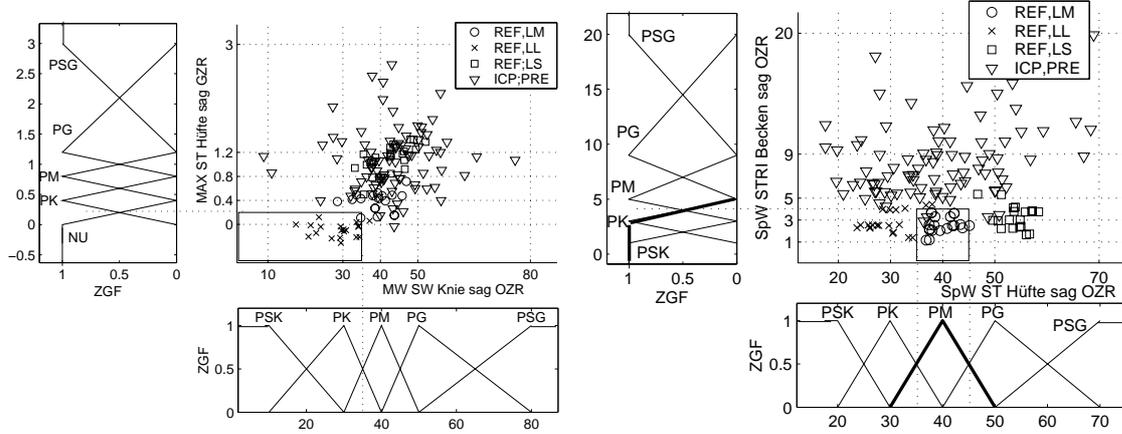


Abbildung 3.7: Beispielregeln für ein 4-Klassenproblem (REF,LM; REF,LL; REF,LS; ICP,PRE) mit automatisch entworfenen Zugehörigkeitsfunktionen (ZGF) für  $m_s = 5$  linguistische Terme, siehe auch Abschnitt 3.7.

Anschließend erfolgt eine Diskretisierung<sup>2</sup> durch  $\alpha$ -cuts mit  $\alpha = 0.5$  in  $m_s = 5$  Intervalle (z.B. in  $[-\infty, +0.2], ] + 0.2, +0.6], ] + 0.6, +1.0], ] + 1.0, +2.1], ] + 2.1, +\infty]$ ). Dadurch lassen sich relative Häufigkeiten bzw. bedingte relative Häufigkeiten

$$\hat{p}(x_s = A_{si}) = \frac{N(x_s = A_{si})}{N}, \quad (3.15)$$

$$\hat{p}(y = B_c) = \frac{N(y = B_c)}{N}, \quad (3.16)$$

$$\hat{p}(x_s = A_{si} \cap y = B_c) = \frac{N(x_s = A_{si} \cap y = B_c)}{N}. \quad (3.17)$$

mit der Anzahl von Datensätzen in einem Intervall  $N(x_s = A_{si})$ , der Anzahl von Datensätzen zu einem Klassenterm  $N(y = B_c)$  bzw. der Anzahl von Datensätzen in einem Intervall und einem Klassenterm  $N(x_s = A_{si} \cap y = B_c)$  und der Gesamtanzahl  $N$  schätzen [108].

Die Relevanz der Einzelmerkmale der informationstheoretischen Maße

$$M_s = \frac{H(x_s; y)}{H(y)} \quad (3.18)$$

<sup>2</sup>Der Entwurf von Zugehörigkeitsfunktionen dient der späteren Verwendung beim Fuzzy-Klassifikator.

wird durch die Transformation  $H(x_s; y) = H(x_s) + H(y) - H(x_s, y)$  sowie Eingangs-, Ausgangs- und Gesamtentropie

$$H(x_s) = - \sum_{i=1}^{m_s} p(x_s = A_{si}) \cdot \log_2 p(x_s = A_{si}) \quad (3.19)$$

$$H(y) = - \sum_{c=1}^C p(y = B_c) \cdot \log_2 p(y = B_c) \quad (3.20)$$

$$H(x_s, y) = - \sum_{i=1}^{m_s} \sum_{c=1}^C p(x_s = A_{si} \cap y = B_c) \cdot \log_2 p(x_s = A_{si} \cap y = B_c) \quad (3.21)$$

berechnet [139].

### 3.6.2 Modifikation der Verfahren

Bei der Bewertung von Einzelmerkmalen wird zusätzlich zur problembezogenen Merkmalsrelevanz  $M_s$  auch eine problemunabhängige Apriori-Merkmalsrelevanz  $M_{s,ap}$  in die Berechnung der Gesamt-Merkmalsrelevanz  $M_{s,ges}$  einbezogen. Die Motivation besteht darin, im Falle problembezogen nahezu gleichwertiger Merkmale diejenigen Merkmale zu bevorzugen, die sich beispielsweise durch eine bessere Interpretierbarkeit, einen geringeren Messaufwand, eine bessere Berechnungseffizienz oder eine höhere messtechnische Zuverlässigkeit auszeichnen. Die Verknüpfung beider Komponenten erfolgt multiplikativ:

$$M_{s,ges} = M_s \cdot M_{s,ap}. \quad (3.22)$$

Dieser Berechnungsschritt wird mit in die Merkmalsselektion integriert [89]. Die Relevanz der Einzelmerkmale  $M_s$  nimmt Werte zwischen Null und Eins an, siehe Abschnitt 3.6.1. Die Apriori-Merkmalsrelevanz  $M_{s,ap}$  soll ebenfalls Werte zwischen Null und Eins annehmen, so dass bei der multiplikativen Verknüpfung die Gesamt-Merkmalsrelevanz  $M_{s,ges}$  wiederum Werte zwischen Null und Eins ergeben.

In der Ganganalyse dominieren die klinische Akzeptanz (Erhöhung der Interpretierbarkeit) und die Zuverlässigkeit der Messungen bei der Festlegung der Apriori-Merkmalsrelevanzen, z.B. die Bevorzugung der sagittalen Raumrichtung vor den anderen beiden [60] oder die Unterdrückung schwer interpretierbarer lineartransformierter Merkmale [30]. Um diese nicht für jedes Merkmal manuell festlegen zu müssen, wird das neu entwickelte Konzept der Kategorien zur Einteilung von Merkmalen herangezogen:

1. Art des Merkmals (Minimum, Maximum, Mittelwert usw.):  $M_{ap,AM}$ ,

2. zeitlicher Abschnitt (ganzer Schritt, nur Stand- oder Schwungperiode, Schrittphasen):  $M_{ap,Zeit}$ ,
3. Gelenke (wie Becken, Hüfte, Knie, Fuß):  $M_{ap,Gel}$ ,
4. Raumrichtung (sagittal, frontal, transversal):  $M_{ap,Eb}$ ,
5. Art der Zeitreihe (originale oder zusätzliche Zeitreihe, z. B. Gelenkwinkel, -winkelgeschwindigkeiten, Referenzabweichungen):  $M_{ap,ZR}$ .

Die Apriori-Merkmalrelevanzen der Werte aller Kategorien sind Eins mit Ausnahme

- der Merkmalsart „MAPO“ und „MIPO“, wegen der heuristischen, empirischen Extraktion, die schwer formalisierbar ist (diese Einzelmerkmale sind nur bei Zeitreihen mit einem ausgeprägten Extremwert interpretierbar, problematisch bei Zeitreihen mit mehreren lokalen Extremwerten, wird später in Kapitel 5 näher erläutert),
- der zeitlichen Abschnitte der Stand- und Schwungperiode mit je  $M_{ap,Zeit} = 0.8$  und der Schrittphasen mit je  $M_{ap,Zeit} = 0.6$ , die aufgrund der automatischen Zeiteinteilung fehleranfälliger sind,
- der frontalen und transversalen Ebene mit je  $M_{ap,Eb} = 0.8$ , die bei der klinischen Analyse eine etwas geringere Rolle als die sagittale Ebene spielen (da die sagittale Ebene für das Vorwärtslaufen maßgebend ist) sowie
- der in der klinischen Praxis weniger gebräuchlichen Geschwindigkeitszeitreihen mit  $M_{ap,ZR} = 0.8$ , Beschleunigungszeitreihen mit  $M_{ap,ZR} = 0.3$  oder Streuungszeitreihen  $M_{ap,ZR} = 0.4$ .

Zusätzlich werden Merkmale mit einer messtechnisch unzuverlässigeren Kombination von Kategorien  $M_{ap,Kombi}$  unterdrückt (ungünstige Signal-Stör-Verhältnisse, die durch klinische Erfahrung eingeschätzt werden). Beispielsweise sind Messwerte in der frontalen und transversalen Ebene für das Knie (Knie kann als Scharniergelenk, genauer Roll-Gleitlager für Drehungen in einer Ebene angenommen werden) und in der frontalen Ebene für das Fußgelenk aus anatomischer Sicht während des Gehens nahezu irrelevant (originale Zeitreihen der Gelenkwinkel jeweils  $M_{ap,Kombi} = 0.6$  sowie deren Winkelgeschwindigkeiten jeweils  $M_{ap,Kombi} = 0.1$ ). Somit kann auch die Auswahl von klinisch kaum akzeptierten Merkmalen wie Spannweite (SpW) oder Mittelwerten (MW) von Geschwindigkeiten vermieden werden ( $M_{ap,Kombi} = 0.1$ ). Die Verknüpfung erfolgt für jedes Merkmal über eine Multiplikation

$$M_{s,ap} = M_{ap,Art}(l) \cdot M_{ap,Zeit}(l) \cdot M_{ap,Gel}(l) \cdot M_{ap,Eb}(l) \cdot M_{ap,ZR}(l) \cdot M_{ap,Kombi}(l) \quad (3.23)$$

der jeweiligen Apriori-Merkmalrelevanzen der Kategorien.

Beispiel: Das berechnete Merkmal „Mittlere Winkelgeschwindigkeit der Knieflexion in der Schwungperiode“ („MW SW Knie sag GZR“) nimmt in den Kategorien folgende Werte an: Art des Merkmals: Mittelwert ( $M_{ap,AM} = 1$ ), zeitlicher Abschnitt: Schwungperiode ( $M_{ap,Zeit} = 0.8$ ), Gelenk: Knie ( $M_{ap,Gel} = 1$ ), Ebene: sagittal ( $M_{ap,Eb} = 1$ ), Art der Zeitreihe: Geschwindigkeit ( $M_{ap,ZR} = 0.8$ ), spezielle Kombinationen von Kategorien: keine ( $M_{ap,Kombi} = 1$ ). Daraus folgt mit Gl. (3.23) die Apriori-Merkmalsrelevanz  $M_{s,ap} = 0.64$ .

In der Praxis werden mit den informationstheoretischen Maßen oder univariaten Varianzanalysen (ANOVA) auch voneinander abhängige Merkmale im Ergebnis mit einbezogen. Das hat zur Folge, dass innerhalb der relevanten Merkmale teilweise hohe Korrelationen auftreten können. Um eine Liste charakteristischer, unabhängiger Merkmale zu erhalten, wird zudem eine Abstufung der Relevanz

$$M_{s,uk} = M_{s,ges} \cdot M_{s,ko} \quad (3.24)$$

bei korrelierten Merkmalen mit einem Korrelationskoeffizienten  $\rho_{s,s^*}$  und  $\rho_{krit} = 0.7$  einbezogen. Die zusätzliche Relevanz

$$M_{s,ko} = \begin{cases} 0 & \text{für } \rho_{s,s^*} > \rho_{krit} \text{ und } M_{s,ges} < M_{s^*,ges} \\ 1 & \text{sonst} \end{cases} \quad (3.25)$$

hat für alle Merkmale den Faktor Eins und Null für korrelierte Merkmalspaare mit einem Korrelationskoeffizienten größer 0.7 und der kleineren Relevanz  $M_{s,ges}$ . Dieser Rechenschritt erfolgt nach dem Einbezug der Apriori-Merkmalsrelevanzen.

Bei der Anwendung der Relevanzbewertungen werden einzelne Merkmale bewertet und direkt zur klinischen Anwendung zur Verfügung gestellt. Dazu besteht noch die Möglichkeit, die bewerteten Merkmale gemäß den Kategorien zusammenzufassen. Dadurch können globale, abstrahiertere Aussagen getroffen werden, wie z.B. die Patientengruppe ist durch wesentliche Charakteristiken in der Standphase oder in der sagittalen Körperebene geprägt. Dadurch kann ein hierarchisches Konzept zur Beurteilung von Patienten erreicht und in der klinischen Praxis eingesetzt werden [127].

### 3.6.3 Verfahren zur Regressionsanalyse

Um Zusammenhänge zwischen Einzelmerkmalen zu finden, kann die Regressionsanalyse eingesetzt werden. Sie wird insbesondere dazu verwendet, eine subjektive, formalisierte Experteneinschätzung mit mehreren quantitativen Merkmalen zu erklären.

Die Regressionsanalyse sucht nach funktionalen Zusammenhängen von Einzelmerkmalen  $\mathbf{X}_{N \times S_{EM}}$ , die ein „Zielmerkmal“  $\mathbf{x}_s$  am besten beschreiben [29, 132]. Die Zusammenhänge sind beispielsweise linear oder quadratisch durch die Regressionsgleichung

$$\mathbf{x}_s = \alpha_0 + \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2 + \dots + \alpha_{s-1} \mathbf{x}_{s-1} + \alpha_{s+1} \mathbf{x}_{s+1} + \dots + \beta_0 + \beta_1 \mathbf{x}_1^2 + \dots \quad (3.26)$$

mit den Regressionskoeffizienten  $\alpha_i, \beta_i, i = 0 \dots I$  beschrieben. Die Auswahl der Einzelmerkmale  $\mathbf{x}_i$  erfolgt durch Schätzung eines multiplen Korrelationskoeffizienten. Dieser soll zwischen dem Zielmerkmal  $\mathbf{x}_s$  und der Auswahl gemäß Gl. (3.26) maximiert werden. Berechnet wird das über die Summe der quadrierten Abweichungen zwischen Schätzung und Zielmerkmal der Regressionsgleichung.

### 3.7 Klassifikation mit bekannter Klasseneinteilung

Das Ziel in der Ganganalyse besteht in der Interpretation des erreichten Klassifikationsergebnisses und nicht in der automatisierten Klassifikation von Datensätzen („der Weg ist das Ziel“). Eine automatisierte Klassifikation ist beispielsweise die Einteilung in Referenz- und Patientendaten. Eine derartige Aufgabe ist bereits subjektiv für klinische Laien einfach lösbar, d.h. das Erkennen von krankhaftem Gehen ist intuitiv leicht zu erkennen. Die Frage nach einer Charakterisierung und Differenzierung hingegen, anhand welcher Kriterien ein Patient krankhaft läuft, ist bei komplexen Krankheitsbildern nicht so einfach lösbar. Hierbei ist die Extraktion und Auswahl geeigneter Merkmale oftmals wichtiger für den Erfolg als die Art des Klassifikationsverfahrens. Eine reine Verbesserung der Klassifikationsgüte, z.B. mit anderen Merkmalen oder anderen Klassifikationsverfahren, unter Reduzierung bei der Interpretierbarkeit führt daher zu einem Misserfolg bei der Anwendung in der Ganganalyse.

In den Gesamtprozess der Datenauswertung aus Abbildung 3.1 ordnet sich dieser Abschnitt als „Klassifikation“ ein. Dabei werden die bewerteten Einzelmerkmale aus Abschnitt 3.6.1 verwendet, um die Klassifikationsprobleme aus den formalisierten Problemstellungen (Abschnitt 3.2) zu lösen.

Auf Basis der gefundenen Merkmalsrelevanzen können nun überwachte Klassifikatoren automatisiert entworfen werden. Beispiele sind Bayes-Klassifikatoren mit einer vorgeschalteten linearen Merkmalstransformation durch eine Diskriminanzanalyse bzw. Fuzzy-Klassifikatoren [46, 106, 108]. Beide Typen liefern oftmals ähnliche Klassifikationsgüten mit tendenziellen Vorteilen für die Bayes-Klassifikatoren. Hingegen können Fuzzy-Klassifikatoren mit nichtlinearen Zusammenhängen und nicht-

kompakten Klassenbereichen umgehen. Dazu sind Fuzzy-Klassifikatoren meist besser interpretierbar, weil die Einzelmerkmale nicht weiter transformiert werden. Daher werden im Folgenden Fuzzy-Klassifikatoren angewendet, die bereits aus der Literatur bekannt sind [106, 108].

Beim Entwurf des Fuzzy-Klassifikators werden zunächst die Werte der Einzelmerkmale durch linguistische Terme verbalisiert [22, 169, 180, 181]. Durch die informationstheoretischen Maße, den Einbezug von Apriori-Relevanzen sowie die Induktion von Entscheidungsbäumen werden die Einzelmerkmale bewertet und ausgewählt. Anschließend werden aus den Entscheidungsbäumen Regelhypothesen extrahiert, durch ein Pruning verallgemeinert und geeignete Regeln als Regelbasis zur Lösung des Klassifikationsproblems ausgewählt. Die Regeln  $R_k$  haben die Struktur

$$R_k : \text{WENN } \underbrace{x_1 = A_{1,Rk}}_{\text{Teilprämisse } P_{k1}} \text{ UND } \cdots \text{ UND } \underbrace{x_s = A_{s,Rk}}_{\text{Teilprämisse } P_{ks}} \text{ DANN } \underbrace{y = B_{Rk}}_{\text{Konklusion } C_k},$$

Prämisse  $P_k$

z.B. “WENN (SpW ST Hüfte sag OZR = PM) UND (SpW STRI Becken sag OZR=PSK ODER PK) DANN REF, LM“. Die Regeln können zusätzlich durch den Bereich von Zugehörigkeiten der Teilprämissen  $\mu > 0.5$  visualisiert werden (siehe Rechteck im rechten Diagramm in Abbildung 3.7, dabei werden die Datensätze von REF,LM als  $\circ$  symbolisiert erfasst). Sie können weiterhin durch die Generierung von Erklärungstexten angegeben werden. Hierbei werden zusätzliche Informationen verbalisiert, die bestenfalls aus Grafiken abgeschätzt werden können. Weitere Ziele sind die Annäherung an den natürlichen Sprachgebrauch sowie die sprachliche Komprimierung unter Beibehaltung des Informationsgehalts.

Die zusätzlichen Informationen stützen sich auf relative Häufigkeiten und informationstheoretische Maße und geben z.B. die Anzahl abgedeckter Datensätze durch eine Regel, den Bezug zu anderen Klassen oder die verursachten Fehlklassifikationen an [89, 107].

Automatisiert generierter Erklärungstext, vgl. Abbildung 3.7 rechts: Die Beispiele für Referenzpersonen mit mittlerer Gehgeschwindigkeit (REF,LM) sind dadurch charakterisiert, dass die Spannweite der Hüftflexion während der Standphase (SpW ST Hüfte sag OZR) häufig anders als sonst ist: meistens mittel (zwischen  $35^\circ$  und  $45^\circ$ ). Weiterhin gilt für die Beispiele, dass die Spannweite der Beckenkipfung während des Schrittes (SpW STRI Becken sag OZR) häufig kleiner als sonst ist: meistens klein (zwischen  $2^\circ$  und  $4^\circ$ ).

Aus den Aussagen lässt sich eine Regel aufbauen, die fast alle Fälle von Referenzpersonen mit mittlerer Gehgeschwindigkeit (REF,LM) beschreibt: WENN die Spannweite Hüftflexion während der Standphase (SpW ST Hüfte sag OZR) mittel (zwischen  $35^\circ$  und  $45^\circ$ ) ist UND die Spannweite der Beckenkipfung während des Schrittes (SpW STRI Becken sag OZR) sehr klein bis klein (kleiner als  $4^\circ$ ) ist, DANN FOLGT DARAUS meistens Referenz mit mittlerer Gehgeschwindigkeit (REF,LM).

Dabei werden die Zahlenwerte der bedingten Häufigkeiten in linguistische Terme umgesetzt, siehe Tabelle 3.8 und [23, 122]. Hierbei wird zwischen der geschätzten Wahrscheinlichkeit und der relativen Anzahl der Beispiele unterschieden.

Relative Häufigkeit $\hat{p}$	linguistischer Term (geschätzte Wahrscheinlichkeit)	linguistischer Term (relative Anzahl von Beispielen)
[0, 0.025]	nie	keine
(0.025, 0.20]	selten	wenige
(0.20, 0.50]	gelegentlich	einige
(0.50, 0.80]	häufig	viele
(0.80, 0.975]	meistens	fast alle
(0.975, 1.00]	immer	alle

Tabelle 3.8: Linguistische Terme zur Beschreibung der relativen Häufigkeiten [89, 107].

In [89, 107, 108] sind Fuzzy-Klassifikatoren und die Generierung von Erklärungstexten ausführlich beschrieben. In dieser Arbeit stehen der Einsatz und die Auswertung der Ergebnisse im Vordergrund.

### 3.8 Struktursuche ohne bekannte Klasseneinteilung

Der in diesem Abschnitt durchgeführte Teilprozess verbindet mehrere Blöcke im Gesamtprozess aus Abbildung 3.1. Die klinische Problemstellung mit der Suche nach unbekanntem Subgruppen (Abschnitt 3.2) bedeutet formalisiert eine Klassifikationsaufgabe ohne Vorgabe von Klassen (unüberwachtes Lernen). Hierbei sollen die Datensätze von Patienten in bestimmten Merkmalen (Zeitreihen oder Einzelmerkmale) zusammengefasst werden, die eine hohe Ähnlichkeit haben. Dazu ist die Bewertung der Merkmale erforderlich, die geeignet sind, um die Subgruppen zu finden. Als Ergebnis werden weitere zusätzliche Zeitreihen bzw. Einzelmerkmale berechnet, die die

Subgruppen als Cluster-Zentren repräsentieren. Die Zugehörigkeiten der Datensätze zu den Cluster-Zentren sind weitere Einzelmerkmale. Somit erstreckt sich der Teilprozess mit der Struktursuche über mehrere rückgekoppelte Teilschritte.

Existierende Unterteilungen sind hier als Subgruppen bezeichnet, wie z.B. unterschiedliche pathologische (krankhafte) Ausfallerscheinungen innerhalb einer Patientengruppe. Als Cluster werden hier die berechneten Unterteilungen der Daten bezeichnet. Die Cluster dienen dem Ziel, die unterschiedlichen realen Gruppierungen zu finden. Der Begriff „Klassen“ bzw. „Gruppen“ wird wie bereits beschrieben für semantische Einteilungen verwendet [22], z.B. Referenzpersonen und Patienten. Die Cluster wiederum können als eine formale Klasseneinteilung interpretiert werden, sofern sie klinisch akzeptiert sind, d.h. Subgruppen beschreiben.

Das Zusammenfassen von Objekten in Cluster dient der explorativen Datenanalyse<sup>3</sup> zum Finden von Strukturen bzw. Gruppen. Ein primäres Ziel der Cluster-Analyse ist, Datensätze in homogene Gruppen (Klassen, Cluster, Typen) zusammenzufassen. Dabei soll eine Homogenität (oder hohe Ähnlichkeit, kleine Distanzen, hohe Datendichte) innerhalb der Cluster und eine Heterogenität (Unähnlichkeit, große Distanzen, geringe Datendichte) zwischen den Clustern erreicht werden [10, 48, 70]. Die Begriffe sind durch unterschiedliche Distanzen oder Ähnlichkeitsmaße formalisiert [21, 46]. Es existiert keine exakte Theorie, die diese Ziele für beliebige Anwendungsfälle und Fragestellungen erfüllt, so dass die meisten Verfahren heuristischer Natur sind. In der vorliegenden Arbeit sind dazu für die Anwendung in der Ganganalyse zunächst empirische Bewertungen von Subgruppen formuliert. Die Bewertungen stützen sich einerseits auf Angaben in der technischen Literatur zum Erkennen intuitiver Einteilungen<sup>4</sup> und andererseits auf Hinweise in der medizinischen Literatur zu bereits bekannten Subgruppierungen. Weiterhin muss methodischer Entwicklungsaufwand geleistet werden, um Cluster-Algorithmen für die Anwendung bei den Gangdaten einzusetzen (Vergleich, Auswahl und Modifikation geeigneter Algorithmen und Merkmalsräume, wie nachfolgend gezeigt wird).

Anschließend werden Fuzzy-Cluster-Verfahren vorgestellt und miteinander verglichen, um sie auf die Zeitreihenanalyse in der Ganganalyse anzupassen. Wegen Störeffekten, z.B. Rauschen oder partielle, individuelle Patientenausprägungen, ist der Einbezug von Unsicherheiten in die Analyse unvermeidbar. Daher beschränkt sich in dieser Arbeit die Anwendung auf Fuzzy-Cluster-Verfahren zur Analyse der Gangdaten. Fuzzy-Cluster-Verfahren basieren auf der Optimierung einer Zielfunktion („Objective-Function“) und bestimmen graduelle Zugehörigkeiten (ZGH) der Da-

---

<sup>3</sup>Explorative Datenanalyse beschreibt hier die Untersuchung der Daten, ohne ein vorgewähltes mathematisches Modell anzunehmen, das das Auftreten der Daten und deren Strukturen erklärt.

<sup>4</sup>Intuitive Einteilung, beschreibt hier Einteilungen, wie sie von Menschen vorgenommen werden könnten.

tensätze zu Cluster-Zentren [46, 65]. Die Positionen der Cluster-Zentren ergeben sich aus den Datensätzen entsprechend der ZGH. Die meisten Cluster-Verfahren lösen ihre gestellte Aufgabe gut, wie z.B. derartige Minimierungsaufgaben. Schlechte Ergebnisse im Sinne einer intuitiven Einteilung gehen daher oftmals auf eine unpräzise formulierte Aufgabenstellung an die Cluster-Analyse zurück. Um die Ergebnisse automatisiert zu bewerten, werden Validierungsmaße eingesetzt und entsprechend modifiziert. Die Anwendung der verwendeten Methoden soll die Merkmalsextraktion, die Bewertung der Existenz von Subgruppen in einer oder mehreren Zeitreihen und die Festlegung der Cluster-Anzahl automatisieren.

### 3.8.1 Verallgemeinerte empirische Bewertung von Subgruppen

Um ein berechnetes Analyseergebnis (Einschätzung von Cluster-Güten zum Erkennen guter Cluster-Ergebnisse) bewerten zu können, müssen Kriterien festgelegt werden, die an intuitiven Ergebnisinterpretationen und teilweise vorhandenem empirischen Wissen angelehnt sind, wie z.B.

1. Bevorzugung überwiegend eindeutiger Zugehörigkeiten der Datensätze zu den Clustern (Gewinnung von Information, Gegenbeispiel: Alle Datensätze sind gleichermaßen zu allen Cluster-Zentren zugeordnet),
2. Cluster-Zentren sollen weitgehend getrennt und nicht eng benachbart sein (Ermittlung funktionell unterschiedlicher Subgruppen, Gegenbeispiel: Alle Cluster-Zentren liegen übereinander),
3. Vermeidung des Anlernens einzelner Datensätze, d.h. Einhaltung einer „gewissen Abstraktion“ (Generalisierung) in einem Cluster-Zentrum als Zusammenfassung von mehreren Datensätzen,
4. Bestimmung einer geeigneten Cluster-Anzahl,
5. Finden bekannter Klassen als Cluster (z.B. bereits ermittelte Cluster im eingeschränkten Suchraum oder empirisch bekannte Gruppen, wie Referenzgruppe oder Beschreibung von Datensätzen mit unterschiedlichen, semantischen Eigenschaften durch separates Cluster-Zentrum) und
6. plausible Zuordnung einzelner Datensätze zu Clustern.

Das Ziel besteht darin, Zeitreihen mit ausgeprägten Gruppen zu finden und sie durch Cluster zu beschreiben. Dabei sind die Anzahl der Gruppen sowie Zusammenhänge zwischen den Zeitreihen meist unbekannt. Insbesondere das Finden von

Zusammenhängen über mehrere Zeitreihen ist wünschenswert. Aber oftmals lassen sich derartige Fragestellungen nicht eindeutig lösen, so dass mit einer gewissen Unschärfe zu rechnen ist.

### 3.8.2 Automatisiertes Finden von Subgruppen

Zur Struktursuche mit unbekannter Klasseneinteilung wird im Folgenden die Cluster-Analyse zum Finden unbekannter Subgruppierungen eingesetzt. Der Einsatz sowie die Auswahl und Anpassung geeigneter Methoden für die Gangdaten wird im Folgenden detaillierter beschrieben, da für diese Daten bisher keine universellen Entwicklungen zur Verfügung stehen.

#### Cluster-Algorithmen

Viele Fuzzy-Cluster-Verfahren [20, 66] finden Cluster-Zentren  $\mathbf{V}_{s \times C} = (\mathbf{v}_1 \cdots \mathbf{v}_C)$  ( $s$  = Anzahl Merkmale,  $C$  = Cluster-Anzahl) durch Lösen des Optimierungsproblems

$$J_q(\mathbf{U}, \mathbf{V}) = \sum_{n=1}^N \sum_{c=1}^C (u_{n,c})^q \cdot d_c^2(\mathbf{x}_n, \mathbf{v}_c) \rightarrow \min_{\mathbf{U}, \mathbf{V}}, \quad (3.27a)$$

$$\sum_{c=1}^C u_{n,c} = 1, \forall n = 1 \dots N, \text{ mit } u_{n,c} \geq 0, \quad (3.27b)$$

$$\sum_{n=1}^N u_{n,c} > 0, \forall c = 1 \dots C. \quad (3.27c)$$

Die Nebenbedingungen erzwingen eine probabilistische (Summe aller ZGH für festen Datensatz  $n$  ist Eins) Cluster-Einteilung Gl. (3.27b) und fordern, dass kein Cluster leer ist Gl. (3.27c). Sie vermeiden die Trivillösung mit  $u_{n,c} \rightarrow 0$  [66]. Bei possibilistischen Cluster-Einteilungen entfällt die Nebenbedingung Gl. (3.27b), so dass ein Datensatz  $n$  zu mehreren Cluster-Zentren eine ZGH von Eins erlangen kann<sup>5</sup>. Die Minimierung der Optimierungsfunktion  $J_q$  wird für eine große Zugehörigkeit  $u_{n,c}$  eines Datensatzes  $n = 1 \dots N$  zu einem Cluster-Zentrum  $c = 1 \dots C$  mit einer kleinen quadratischen Distanz  $d_c^2$  und umgekehrt erreicht. Durch den Fuzzifizierungsgrad  $q$  können „harte“ ( $q = 1$ ) oder einheitlich „weiche“ Zugehörigkeiten  $q \rightarrow \infty$  eingestellt werden. Mit der Nebenbedingung Gl. (3.27b), Nullsetzen der Ableitung von

<sup>5</sup>Diese Einteilung kann für Bildauswertungen zweckmäßig sein. Allerdings ist sie für die klinische Anwendung, bei der die Patienten eindeutig zu einer Subgruppen zugeordnet werden sollen, nicht praktikabel und wird nicht weiter verfolgt.

Gl. (3.27a) für  $q > 1$  nach  $\mathbf{U}$  bzw.  $\mathbf{V}$  ergibt sich die Zugehörigkeit (ZGH)

$$u_{n,c} = \frac{[d_c^2(\mathbf{x}_n, \mathbf{v}_c)]^{\frac{1}{1-q}}}{\sum_{i=1}^C [d_i^2(\mathbf{x}_n, \mathbf{v}_i)]^{\frac{1}{1-q}}} \quad (3.28)$$

bzw. die Lage der Cluster-Zentren, z.B. für Euklidische Distanzen

$$\mathbf{v}_c = \frac{\sum_{n=1}^N (u_{n,c})^q \mathbf{x}_n}{\sum_{n=1}^N (u_{n,c})^q}. \quad (3.29)$$

Datensätze mit einer großen Zugehörigkeit ziehen das Cluster-Zentrum stärker in ihre Richtung als Datensätze mit kleinen Zugehörigkeiten. Da Gl. (3.27) nicht geschlossen lösbar ist, werden nach einer Wahl von Start-Clustern Gl. (3.28) und Gl. (3.29) iterativ berechnet, siehe auch im Anhang Abbildung C.5. Start-Cluster können beispielsweise zufällig sein (wird in Kapitel 5 zur Validierung der Ergebnisse eingesetzt), wobei wegen der besseren Vergleichbarkeit der Methoden hier Start-Cluster entsprechend der (reziproken) Datendichte verteilt sind. Die Iteration wird beendet, wenn die Änderung aller Zugehörigkeiten in aufeinanderfolgenden Iterationsschritten  $u_{n,c}^*$  nach  $u_{n,c}$  eine bestimmte Schranke  $\varepsilon$  mit  $\sum_{n=1}^N \sum_{c=1}^C (u_{n,c}^* - u_{n,c})^2 < \varepsilon$  unterschreitet. Ein Wert von  $\varepsilon = 10^{-3}$  hat sich hier bewährt, wobei sich die Cluster-Zentren meist schon nach wenigen Iterationsschritten an die endgültigen Positionen annähern. Freiheitsgrade für eine problemspezifische Anpassung der hier vorgestellten automatisierten Verfahren bestehen in der Wahl

- des Algorithmus zur Festlegung der Cluster-Anzahl  $C$ ,
- der Distanz  $d_c$ ,
- der Merkmale  $\mathbf{X}$  und
- dem Fuzzifizierungsgrad  $q$ .

Die Literatur empfiehlt oftmals einen Fuzzifizierungsgrad von  $q = 2$  [66, 118, 145]. Er wird nachfolgend einheitlich auf  $q = 2$  eingestellt, Arbeiten zur Optimierung finden sich z.B. unter [79]. Für  $q = 2$  konnten die bereits empirisch gefundenen Subgruppen ebenfalls gefunden werden. Bei größeren Werten sind die Zugehörigkeiten der Datensätze zu den Clustern nicht mehr eindeutig, bei kleineren Werten sind Patienten-individuelle Ausprägungen zu stark gewichtet.

### Validierungen von Cluster-Ergebnissen und Festlegung Cluster-Anzahl

Die Cluster-Anzahl  $C$  sowie die Merkmalsselektion lassen sich allerdings nicht aus dem Wert von Gl. (3.27a) bestimmen, da  $J_q(\mathbf{U}, \mathbf{V})$  für steigende Cluster-Anzahl monoton fällt. Für eine gleiche Anzahl von Clustern und Datensätzen ergibt die Funktion Null. Daher werden anwendungsspezifisch Validierungsmaße verwendet, die bei wiederholter Cluster-Berechnung mit verschiedener Cluster-Anzahl bestimmt werden [66, 78]. Sie beurteilen die Qualität lokal (von einzelnen Clustern) oder global (über alle Cluster). Zu den globalen Validierungsmaßen gehört der Partitionskoeffizient (partition coefficient) [20]

$$PC(u) = \frac{\sum_{n=1}^N \sum_{c=1}^C u_{n,c}^2}{N} \quad (3.30)$$

mit  $\frac{1}{C} \leq PC(u) \leq 1$  für eine gleichmäßige (informationslose,  $\frac{1}{C}$ ) bis scharfe Cluster-Einteilung (1). Die Partitionsentropie [65, 166]

$$PE(u) = \frac{-\sum_{n=1}^N \sum_{c=1}^C u_{n,c} \ln(u_{n,c})}{N} \quad (3.31)$$

die der Shannon-Entropie [139] nachempfunden ist, drückt den mittleren Informationsgehalt mit  $0 \leq PE(u) \leq \ln(C)$  aus, d.h. von einem maximalen Informationszugewinn (Entropie=0) bis hin zur Gleichverteilung. Ein aus diesen Ansätzen entwickelter Verhältnis-Repräsentant (proportion exponent)

$$PX(u) = -\ln \left( \prod_{n=1}^N \left( \sum_{i=1}^{[\mu_n^{-1}]} (-1)^{i+1} \binom{C}{i} (1 - i\mu_n)^{C-1} \right) \right) \quad (3.32)$$

verwendet maximale Cluster-ZGH  $\mu_n = \max(u_{n,c})$  über  $c = 1..C$  und die größte ganze Zahl  $[\mu_n^{-1}]$  kleiner gleich  $\frac{1}{\mu_n}$  [170]. Je größer die Werte des  $PX$ , desto besser ist das Analyseergebnis bewertet ( $0 \leq PX \leq \infty$ ). Der Trennungsgrad (separation)

$$S(u) = \frac{J_q(\mathbf{U}, \mathbf{V})}{C \cdot \min_{i,j=1..C, i \neq j} (d_c^2(\mathbf{v}_i, \mathbf{v}_j))} \quad (3.33)$$

erweitert Gl. (3.27a) um die Cluster-Anzahl  $C$  und die minimale quadratische Distanz zwischen zwei benachbarten Clustern [178]. Dadurch werden eng benachbarte Cluster-Zentren bestraft. Eine gute Anzahl von Clustern wird durch das erste lokale Minimum angegeben [66]. Bei steigender Cluster-Anzahl existieren zwar oftmals weitere lokale Minima, stellen aber unzufriedene Ergebnisse dar.

Darüber hinaus existieren weitere Validierungsmaße und deren spezifische Anwendungen [22, 66, 78, 118, 145]. Beispiele sind das Fuzzy-Hypervolumen  $FHV(u) = \sum_{i=1}^C \sqrt{\det(\mathbf{A}_i)}$  oder Partitionsdichten von Clustern. Diese Maße sind für die Einschätzung von Punkthäufungen nahe des Cluster-Zentrums gut geeignet. Derartige konzentrierte Datenhäufungen kommen aber gerade bei heterogenen Patientenausprägungen in der Praxis nicht vor (in Abbildung 3.7 sind die Datensätze der Patienten ICP,PRE als  $\nabla$  symbolisiert und sehr heterogen verteilt, im Gegensatz zu kompakten und homogenen Gruppen wie REF,LL als  $\times$  symbolisiert). Weiterhin bauen derartige Maße auf spezielle Algorithmen (Gath-Geva, siehe unten) auf, der für die Gangdaten nicht geeignet ist, wie später gezeigt wird. Lokale Validierungsmaße bewerten einzelne Cluster und versuchen gezielt, Cluster zu vereinen oder trennen. Sie sind insbesondere für die Erkennung bestimmter Formen, z.B. Linien oder Kreise wie in der Bildverarbeitung üblich, ausgelegt. In der Ganganalyse ist die Erkennung vorgegebener, gezielter Formen nicht Gegenstand, so dass die lokalen Maße nicht weiter verfolgt werden.

Eine Übersicht der hier untersuchten und vorgestellten Validierungsmaße zeigt Tabelle 3.9.

Maß	Ziel	beste Cluster-Güte	schlechteste Cluster-Güte
$PC(u)$	maximieren	1	$\frac{1}{c}$
$PE(u)$	minimieren	0	$\ln(C)$
$PX(u)$	maximieren	$\rightarrow \infty$	0
$S(u)$	minimieren, erstes lokales Minimum	$\rightarrow 0$	$\infty$

Tabelle 3.9: Zusammenfassung verschiedener Validierungsmaße.

### Wahl der Distanz

Der Fuzzy-C-Means-Algorithmus (FCM)<sup>6</sup> verwendet eine einheitliche Distanz  $d(\mathbf{x}_n, \mathbf{v}_c)$  mit

$$d_c^2(\mathbf{x}_n, \mathbf{v}_c) = d^2(\mathbf{x}_n, \mathbf{v}_c) = (\mathbf{x}_n - \mathbf{v}_c)^T \cdot \mathbf{M} \cdot (\mathbf{x}_n - \mathbf{v}_c). \quad (3.34)$$

Die Matrix  $\mathbf{M}$  muss eine positiv definite Matrix sein<sup>7</sup>. Beispiele sind die Euklidische (EU,  $\mathbf{M} = \mathbf{I}_s$ : Einheitsmatrix) oder Mahalanobis-Distanz (MA,  $\mathbf{M} = \mathbf{S}^{-1}$ : inverse

<sup>6</sup>FCM steht für eine verallgemeinerte Mittelwertbildung mit fester Cluster-Anzahl  $c$ .

<sup>7</sup>Symmetrische Matrizen  $\mathbf{M}$  für die  $\mathbf{x}^T \mathbf{M} \mathbf{x} > 0, \forall \mathbf{x} \in \mathbb{R}^n, \mathbf{x} \neq \mathbf{0}$  gilt, heißen positiv definit. Charakteristisch für diese Matrizen sind ihre positiven Eigenwerte. Damit ist eine Definition des Abstandes gewahrt, der nur positive Werte annehmen kann.

Kovarianzmatrix über alle Datensätze). Der FCM erkennt kugelförmige Punktwolken in  $S$ -dimensionalen (transformierten) Räumen. Die ZGH zu den Cluster-Zentren ergeben sich direkt aus den Distanzen, so wird bei der iterativen Berechnung lediglich die Cluster-Position optimiert. Der Fuzzifizierungsgrad  $q$  in Gl. (3.28) ist ein Gewichtungsexponent für die Distanz (z.B. bedeutet  $q = 1.5$  eine mit vier potenzierte Differenz, siehe Gl. (3.28) durch formales Einsetzen von  $q$ ).

Der Gustafson-Kessel-Algorithmus (GK) basiert auf cluster-spezifischen Distanzen  $d_c(\mathbf{x}_n, \mathbf{v}_c)$  mit

$$d_c^2(\mathbf{x}_n, \mathbf{v}_c) = (\mathbf{x}_n - \mathbf{v}_c)^T \cdot \mathbf{M}_c \cdot (\mathbf{x}_n - \mathbf{v}_c). \quad (3.35)$$

Dabei ist das Cluster-Volumen (positiv definite Matrix)

$$\mathbf{M}_c = \sqrt[s]{\det(\mathbf{S}'_c)} \mathbf{S}'_c^{-1} \quad (3.36)$$

konstant, hier durch den Term  $\sqrt[s]{\det(\mathbf{S}'_c)}$  einheitlich Eins<sup>8</sup>. Sonst wird die Minimierung der Funktion aus Gl. (3.27a) lediglich durch Vergrößerung der Cluster-Volumen erzielt. Die Cluster-Form ist allerdings durch die „Fuzzy-Kovarianzmatrix“ [66]

$$\mathbf{S}'_c = \frac{\sum_{n=1}^N u_{n,i}^q (\mathbf{x}_n - \mathbf{v}_c)(\mathbf{x}_n - \mathbf{v}_c)^T}{\sum_{n=1}^N u_{n,c}^q}. \quad (3.37)$$

variabel<sup>9</sup>. Die „Fuzzy-Kovarianzmatrix“ modifiziert die Berechnung der Kovarianzmatrix aus Gl. (3.11) für jedes Cluster durch Verwendung der Zugehörigkeiten  $u_{n,c}^q$  (mit Werten aus dem Intervall  $[0, 1]$ ). Für große  $N$  und einheitlich hohe ZGH  $u_{n,c} = 1$  können sie ineinander übergeführt werden. Die Cluster-Zentren entsprechen klassenspezifischen Mittelwerten (für einheitliche ZGH  $u_{n,c} = 1$ ).

Der Gath-Geva-Algorithmus (GG) nimmt eine mehrdimensionale Normalverteilung der Datensätze in einem Cluster an. Die Distanz  $d_c$  ergibt sich aus der geschätzten reziproken Wahrscheinlichkeit, dass ein Datensatz zu einem Cluster gehört<sup>10</sup>:

$$d_c^2(\mathbf{x}_j, \mathbf{v}_c) = \frac{(2\pi)^{\frac{s}{2}} \sqrt{\det(\mathbf{S}'_c)}}{\hat{p}_c} \exp\left(\frac{1}{2}(\mathbf{x}_j - \mathbf{v}_c)^T \mathbf{S}'_c^{-1} (\mathbf{x}_j - \mathbf{v}_c)\right) \quad (3.38)$$

$$\text{mit } \hat{p}_c = \frac{\sum_{j=1}^N u_{j,c}^q}{\sum_{j=1}^N \sum_{l=1}^C u_{j,l}^q}.$$

<sup>8</sup>Erweiterungen des GK-Algorithmus lassen konstante Cluster-Volumen  $\det(\mathbf{A}_i) = \text{const.}$  zu.

<sup>9</sup>Der Nennerterm  $\sum_{j=1}^N u_{j,i}^q$  hat beim GK-Algorithmus keinen Einfluss, wird aber für den Gath-Geva-Algorithmus erforderlich.

<sup>10</sup>Da der Term  $(2\pi)^{\frac{s}{2}}$  für alle cluster-spezifischen Distanzen konstant bleibt, hat er keinen Einfluss auf das Ergebnis des GG-Algorithmus und kann weggelassen werden. Der Term stellt hier aber den Bezug zur Normalverteilung besser dar.

Die geschätzte Wahrscheinlichkeit für ein Auftreten eines Datensatzes in einem Cluster  $\hat{p}_c$  ergibt sich aus den relativen Zugehörigkeiten zum Cluster  $c$ . Der Unterschied zur  $s$ -dimensionalen Wahrscheinlichkeitsdichte ist die Verwendung der „Fuzzy-Kovarianzmatrizen“ und die Schätzung der Wahrscheinlichkeiten  $\hat{p}_c$  anhand der ZGH, siehe Anhang C und [46, 66]. Beim GK- und GG-Algorithmus wird in jedem Iterationsschritt für jedes Cluster die Kovarianzmatrix aller Datensätze im Cluster neu geschätzt.

### Merkmale

Für die Cluster-Algorithmen werden hier entweder alle  $K$  Abtastzeitpunkte einer oder mehrerer Zeitreihen  $Z_{ns}[k]$  oder daraus extrahierte Einzelmerkmale aus Abschnitt 3.5 als Merkmale  $\mathbf{X} = ((x_{ns}))$  verwendet. Bei der Cluster-Berechnung gilt

$$\mathbf{x}_n = (Z_{ns}[1], \dots, Z_{ns}[K]) \quad (3.39)$$

für eine Zeitreihe  $s$  bzw.

$$\mathbf{x}_n = (Z_{ns}[1], \dots, Z_{ns}[K], Z_{ni}[1], \dots, Z_{ni}[K]) \quad (3.40)$$

für die Zeitreihen  $s$  und  $i$  usw..

Weitere Einzelmerkmale  $\mathbf{X}$  entstehen durch eine dimensionsreduzierende Lineartransformation der Zeitreihe  $s \in S_{ZR}$  (nach einer Normierung auf ein Intervall  $[-1, +1]$ ):

$$\begin{aligned} \mathbf{x}_n &= \mathbf{z}_{ns} \cdot \Phi \text{ mit } \mathbf{z}_{ns} = (Z_{ns}[1], \dots, Z_{ns}[k], \dots, Z_{ns}[K]) \\ \mathbf{x}_n &= (x_{n1}, \dots, x_{nI}), \Phi = (\phi_1, \dots, \phi_I). \end{aligned} \quad (3.41)$$

Die  $(K \times I)$ -dimensionale Transformationsmatrix  $\Phi$  wird so entworfen, dass die jeweils interessierende Information möglichst gut erhalten und komprimiert wird [70, 155], z.B. durch Lösen eines Eigenwertproblems

$$(\mathbf{A} - \lambda_i \mathbf{I}_{K \times K}) \phi_i = \mathbf{0}, \quad \lambda_1 \geq \dots \geq \lambda_i \geq \dots \geq \lambda_I \geq \dots \geq \lambda_K. \quad (3.42)$$

( $\mathbf{I}_{K \times K}$ : Einheitsmatrix,  $\lambda_i$ : Eigenwerte,  $\phi_i$ : Eigenvektoren). Dabei maximiert die Hauptkomponentenanalyse (HKA) mit  $\mathbf{A} = \mathbf{T}$  ( $\mathbf{T} = N \cdot \mathbf{S}$ , Total Variance = Gesamtstreuung aller Datensätze) die Kovarianzinformation für einen  $I$ -dimensionalen Unterraum. Die Kovarianzmatrix  $\mathbf{S}$  berechnet sich aus allen  $N$  Datensätzen, vgl. Gl. (3.11). Für praktische Anwendung bei den Gangdaten erwies sich eine Anzahl der Hauptkomponenten (HK) mit  $I = 2$  als sinnvoll und wird daher nachfolgend verwendet. Voraussetzungen für die Verwendung von HK sind

1. valides Bestimmen anhand der gegebenen Daten und
2. Unterscheidung der Gruppen in Bereichen maximaler Streuung.

Die erste Voraussetzung konnte durch eine Cross-Validierung gezeigt werden (mehrmaliges Berechnen der HK durch unterschiedliche Teilmengen der gesamten Datensätze). Die zweite Voraussetzung ist bei den Gangdaten meistens erfüllt, muss aber ggf. durch Interpretation der Ergebnisse geprüft werden, wie später gezeigt wird.

Strukturell passen Hauptkomponenten ebenfalls in die „Berechnung zusätzlicher Einzelmerkmale“ aus Abbildung 3.1. Sie erhalten aber wegen der schlechten klinischen Interpretierbarkeit eine sehr kleine Apriori-Merkmalrelevanz  $M_{ap,AM} = 0.01$ . Sie dienen hier lediglich zur weiteren Verwendung durch die Cluster-Algorithmen, um bessere Ergebnisse zu erzielen, wie später gezeigt wird [70]. Die Interpretation ist dann möglich, wenn mit den Zugehörigkeiten nach abgeschlossener Optimierung (bei den Hauptkomponenten in  $\mathbf{X}$ ) die Cluster-Zentren für die Zeitreihen  $Z_{ns}[k]$  berechnet werden. Die Bezeichnung für Merkmalsart ist „i. HK“ für die i-te Hauptkomponente. Die weiteren Bezeichnungen richten sich nach der bereits eingeführten Kategorisierung, siehe Tabelle 3.5.

### Typische Probleme

Die bisher diskutierten Algorithmen liefern gute Ergebnisse, wenn alle Merkmale relevante Subgruppen enthalten, die sowohl in der Projektion als auch im höherdimensionalen Raum existieren. Abbildung 3.8a verdeutlicht diesen Fall anhand eines illustrativen Beispiels mit zwei Merkmalen und zwei klar ausgeprägten Clustern, deren Cluster-Zentren sowohl separat für jedes Merkmal (Darstellung auf den jeweiligen Achsen) als auch für die Kombination beider Merkmale (2D-Darstellung inkl. Achsenprojektion) ermittelt wurden (kompatible Cluster).

Komplizierter ist der Fall, wenn zwar für jedes Merkmal wenige Subgruppen existieren, aber im höherdimensionalen Raum eine höhere Cluster-Anzahl erforderlich ist. Diesen Fall zeigt Abbildung 3.8b, bei dem jedes Merkmal je zwei, deren Kombination aber drei Cluster aufweist. Zu niedrige Cluster-Anzahlen führen dann zu irreführenden Ergebnissen bei der Projektion der Cluster-Zentren ( $\diamond$ ). Der Effekt ist durch  $\rightarrow$  visualisiert. Deshalb werden die zwei Cluster für diese Merkmale als nichtkompatible Cluster bezeichnet. Bei einer Vielzahl solcher unterschiedlicher Zusammenhänge in hochdimensionalen Datenräumen führt das u.U. zu sehr hohen Cluster-Anzahlen, die mit einer limitierten Anzahl von Datensätzen  $N$  nicht valide ermittelbar sind und dem Ziel einer Abstraktion widersprechen.

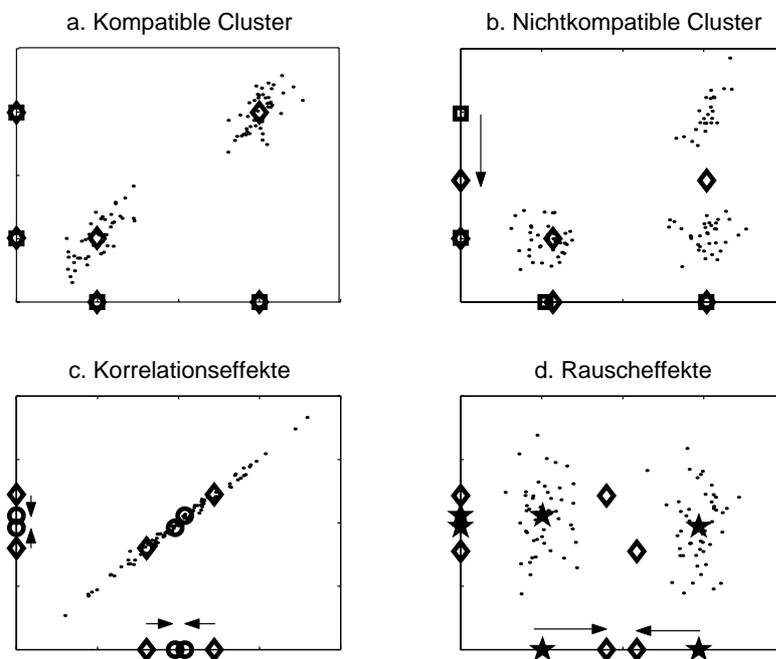


Abbildung 3.8: Typische Effekte bei der Cluster-Berechnung: a. Kompatible Cluster, b. Nichtkompatible Cluster, c. Korrelationseffekte, d. Rauscheffekte.

Einige Metriken verursachen Probleme bei korrelierten und z.T. informationslosen Merkmalen. Abbildung 3.8c illustriert das für zwei korrelierte Merkmale, bei denen die Mahalanobis-Distanz ( $\circ$ ) im Gegensatz zur Euklidischen Distanz ( $\diamond$ ) die Cluster-Zentren „zusammenzieht“. Ähnlich wirken zusätzliche informationslose Merkmale (Abbildung 3.8d), die für größere Distanzen zum jeweiligen Cluster-Zentrum sorgen. Das führt beim FCM-Algorithmus zu weniger ausgeprägten Zugehörigkeiten, weshalb auch entfernte Datensätze die Cluster-Zentren beeinflussen und sie somit deutlich in Richtung eines gemeinsamen Schwerpunktes verschieben ( $\diamond$ ). Bei Metriken wie beim GK- und GG-Algorithmus ( $\star$ ) oder separatem Clustern über einzelne Merkmale tritt der Effekt kaum auf.

### 3.8.3 Ableitung modifizierter Verfahren und Erprobung

Die vorgestellten Verfahren zur Struktursuche ohne bekannte Klasseneinteilung werden nun anhand exemplarischer, realer Daten verglichen. Dabei werden beispielhaft die Kniebeugung (ZR STRI Knie sag OZR), die Beugung des oberen Sprunggelenks (ZR STRI OSG sag OZR) und deren normierte Winkelgeschwindigkeit (ZR

STRI OSG sag GZR) sowie die seitliche Neigung des Oberkörpers (ZR STRI Becken fro OZR) verwendet, siehe Abbildung 3.9. Die  $N = 106$  Datensätze stammen von der Referenzgruppe (REF,LM, 20 Datensätze) und einer ICP-Patientengruppe (ICP,PRE, 86 Datensätze). Die unterschiedlichen Zeitreihen und Datensätze sind notwendig, da sich verschiedene Effekte der Methoden unterschiedlich auswirken. Aus klinischer Sicht existieren zwischen Referenzgruppe und Patientengruppe wesentliche Unterschiede über die meisten Bereiche des Gangbildes [152, 174]. Die Patienten weisen wiederum teilweise bekannte Subgruppen auf, mit denen die Methoden verglichen werden können, z.B. Recurvatum- (starke Knieüberstreckung), Kauergang- oder Spitzfuß-Subgruppen, siehe Abschnitt 2.3. Neben diesen eindeutig ausgeprägten Gruppierungen existieren in allen Zeitreihen allerdings auch sehr starke Übergänge, was den Einsatz von Fuzzy-Cluster-Verfahren prädestiniert: In Abbildung 3.9 rechts sind die Datensätze der Patienten mit  $\bullet$  symbolisiert und in einer zusammenhängenden Punktwolke verteilt, wobei eindeutige Subgruppen existieren, wie später noch gezeigt wird. Allerdings gibt es einige Datensätze die zwischen den Subgruppen lokalisiert sind, d.h. es existieren „fließende“ Übergänge. Zusätzlich gibt es Zeitreihen mit versteckte Subgruppen, z.B. in der Winkelgeschwindigkeit des Sprunggelenks. Aus Sicht der Datenanalyse unterscheiden sich die Gruppen durch unterschiedliche Datendichten, die subjektiv nur schwer zu erkennen sind. Das begründet auch die wenig etablierten empirischen Subgruppen, die lediglich eindeutig ausgeprägte Subgruppen beschreiben. In Kapitel 5 werden die methodischen Ergebnisse auf alle Daten angewendet.

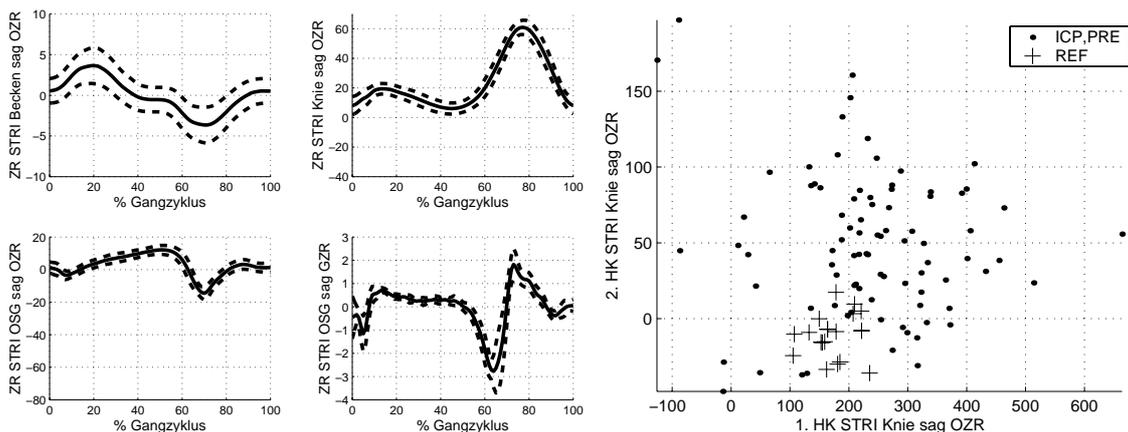


Abbildung 3.9: Links: Referenzdaten REF,LM der exemplarischen Daten ( $\bar{Z}_{\text{REF } s}[k]$  durchgezogen,  $\bar{Z}_{\text{REF } s}[k] \pm \tilde{Z}_{\text{REF } s}[k]$  gestrichelt), rechts: Hauptkomponenten der Kniebeugung.

Zur methodischen Entwicklung der Cluster-Verfahren wird nachfolgend zunächst jeweils nur ein Parameter untersucht, wie das Validierungsmaß, die Distanz, die Merkmalsart oder die Festlegung der Cluster-Anzahl. Mit den gefundenen methodischen Ergebnissen werden dann Subgruppen über mehrere Zeitreihen und bei unbekannter Cluster-Anzahl gesucht. In der Praxis ist die methodische Entwicklung meistens iterativ [10, 66]. Ein Ziel dieses Teilprozesses ist die empirischen Bewertungen von Subgruppen aus Abschnitt 3.8.1 zu erreichen. Das wird erreicht, indem die klinischen Problemstellungen zur Suche nach Subgruppen formalisiert werden, wie nachfolgend gezeigt wird, siehe auch Abbildung 3.1. Während der Cluster-Berechnung werden Zeitreihen (Merkmale) bewertet und ausgewählt, falls sie Subgruppen enthalten. Bei abgeschlossener Cluster-Berechnung sind die Daten anhand der gefundenen Zugehörigkeiten  $u_{n,c}$  klassifiziert. Die Zugehörigkeiten und die gefundenen Cluster-Zentren sind Einzelmerkmale bzw. Zeitreihen. Somit erstreckt sich die Struktursuche mit unbekannter Klasseneinteilung über mehrere Blöcke im Prozess der Datenauswertung.

Im Folgenden wird die Auswahl geeigneter Algorithmen mit dem zuvor beschriebenen Beispieldatensatz aus Abbildung 3.9 bezüglich

- Validierungsmaße und -kennzahlen
- Distanzen bei  $K$  Abtastzeitpunkten als Merkmale
- Vergleich Merkmalsraum ( $K$  Abtastzeitpunkte gegen zwei HK-Merkmale)
- Bestimmung Cluster-Anzahl bei zwei HK-Merkmalen
- Erweiterung des Suchraums auf mehrere Zeitreihen: Simultanes Clustern

durchgeführt. Das Ziel ist es zu jedem der aufgeführten Punkte den besten Algorithmus zu finden, mit dem in dem Beispieldatensatz enthaltene Subgruppen erkannt werden.

### Validierungsmaße und -kennzahlen

Validierungsmaße und -kennzahlen sind wichtig, um die verschiedenen Methoden miteinander zu vergleichen, Zeitreihen nach Subgruppen zu bewerten und die Anzahl der Cluster festzulegen.

Bei Verwendung des FCM mit Euklidischer Distanz über die 1. und 2. Hauptkomponente der Kniebeugung mit den  $N = 86$  ICP,PRE-Datensätze<sup>11</sup> werden die

---

<sup>11</sup>Die Verwendung lediglich der Patientendaten dient dem späteren Verweis auf diese Ergebnisse. Für die Auswahl der Validierungsmaße hat das keinen Einfluss. Bei anderen Datensätzen und anderen Merkmalen werden qualitativ die gleichen Ergebnisse erhalten.

unterschiedlichen Validierungsmaße untersucht. Im Einzelnen sind das:

1. Partitionskoeffizient  $PC(u)$ ,
2. Partitionsentropie  $PE(u)$ ,
3. Verhältnis-Repräsentant  $PX(u)$  und
4. Trennungsgrad  $S(u)$ .

Die Cluster-Anzahl ist hierbei variabel. Die erhaltenen Ergebnisse sind in Abbildung 3.10 dargestellt.

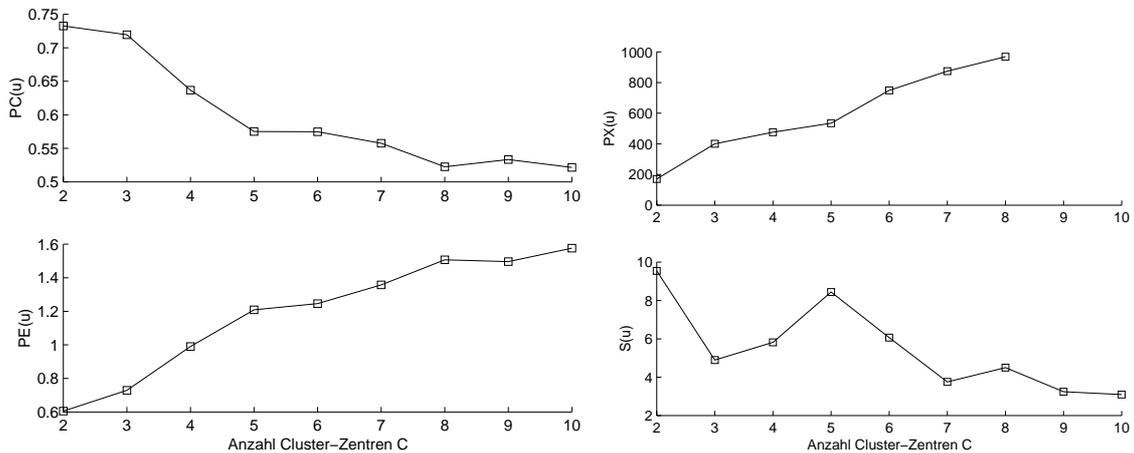


Abbildung 3.10: Validierungsmaße, links: Partitionskoeffizient  $PC(u)$  und Partitionsentropie  $PE(u)$ , rechts: Verhältnis-Repräsentant  $PX(u)$  und Trennungsgrad  $S(u)$ . Für eine Cluster-Anzahl von  $C \geq 9$  strebt  $PX(u) \rightarrow \infty$ .

Der Partitionskoeffizient  $PC(u)$  bzw. die Partitionsentropie  $PE(u)$  liefern keine befriedigenden Ergebnisse, da sie für steigende Cluster-Anzahl monoton fallend bzw. steigend sind. In der Literatur sind diese Eigenschaften mit der Abhängigkeit von der Cluster-Anzahl  $C$  für viele reale Daten bereits bemängelt [66]. Der Grund ist, dass in der Regel die ZGH zu den einzelnen Clustern bei steigender Cluster-Anzahl kleiner werden, so dass weitere Kenngrößen in einem Validierungsmaß mit einbezogen werden müssen. In der Literatur wird daher ein kombinatorischer Ansatz mit dem Verhältnis-Repräsentant  $PX(u)$  vorgeschlagen [170]. Allerdings liefert der  $PX$  oftmals nur für große Fuzzifizierungsgrade  $q$  zufriedenstellende Ergebnisse [66, 145]. Bei den Gangdaten liefert dieses Maß nur in seltenen Fällen Ergebnisse. Ein Grund ist, dass die verschiedenen Subgruppen (Cluster) sich stark überlappen

und nicht eindeutig zu trennen sind, siehe Abbildung 3.9. Lediglich für sehr eindeutige Gruppierungen (z.B. homogene Referenzgruppe gegen eine homogene aber stark abweichende Patientengruppe) liefert  $PX(u)$  für große Fuzzifizierungsgrade  $q$  ordentliche Ergebnisse (ausgeprägtes Maximum). Allerdings können in der Praxis viele Subgruppen in den Gangdaten mit einer Erhöhung von  $q$  nicht gefunden werden, so dass der  $PX(u)$  nicht weiter verfolgt wird.

Der Trennungsgrad  $S(u)$  erfüllt noch am besten die Zielstellung aus Abschnitt 3.8.1, da sehr eng benachbarte Cluster-Zentren und sehr große Cluster-Anzahlen bestraft werden. Die Ergebnisse von  $S(u)$  stimmen mit bereits gesammeltem empirischem klinischem Wissen überwiegend überein, wie noch später gezeigt wird (Abbildungen 3.11 und 3.12). In diesem Beispiel empfiehlt der Trennungsgrad eine Cluster-Anzahl von  $C = 3$ , die mit den Subgruppen Recurvatum, milder und starker Kauergang übereinstimmen. Nach heuristischen Überprüfungen sind Werte von  $S(u) < 50$  in der Ganganalyse akzeptabel, gute Ergebnisse bei Werten von  $S(u) < 20$  bis sehr gute Ergebnisse von  $S(u) < 10$ , die insbesondere bei der Kombination von Zeitreihen später eingesetzt wird.

Allerdings existieren Beispiele, die den Einbezug weiterer Kenngrößen erfordern, insbesondere bei der Festlegung des Merkmalsraumes, der Distanz und der Cluster-Anzahl. Bei der Auswahl der Methoden in Einklang mit klinischer Plausibilität haben sich daher folgende Kennzahlen im praktischen Einsatz bewährt, siehe Abschnitt 3.8.1:

- die mittlere maximale Zugehörigkeit zu einem Cluster-Zentrum ( $\bar{u}_{\max,c} \rightarrow 1$  bei eindeutiger Zugehörigkeiten der Datensätze),
- die minimale quadratische Euklidische Distanz zwischen zwei Cluster-Zentren ( $d_{\min,ZR}^2 = \min(d^2(\mathbf{v}_c, \mathbf{v}_i))$  mit  $c, i = 1 \dots C, c \neq i$ , maximal für gut getrennte Cluster-Zentren),
- der Trennungsgrad  $S(u)$  (minimal für eine geeignete Cluster-Anzahl und valide Cluster),
- die Anzahl zugeordneter Datensätze zu den Clustern (Anzahl DS, nicht zu klein zum Erzielen eines angemessenen Abstraktionsniveaus) und
- die maximale Zugehörigkeit des Mittelwerts der Referenzgruppe zu einem Cluster ( $u_{\text{REF}}$ , groß zum Finden dieser bekannten Gruppe).

Dabei berechnet sich die maximale Zugehörigkeit zu einem Cluster-Zentrum

$$\bar{u}_{\max,c} = \frac{1}{N_c} \sum_{n \in I_c} u_{n,c} \quad \text{mit } n \in I_c \text{ für } u_{n,c} = \max_{i=1..C}(u_{n,i}) \quad (3.43)$$

und  $N_c$  als Anzahl der Element in  $I_c$  sowie die maximale Zugehörigkeit des Mittelwerts der Referenzgruppe zu einem Cluster

$$u_{\text{REF}} = \max_{c=1..C}(u_{\text{REF},c}). \quad (3.44)$$

Für  $u_{\text{REF},c}$  wird in der Berechnung der ZGH aus Gl. (3.28) für die Daten in  $\mathbf{x}_n$  der Mittelwert der Referenz verwendet, z.B. bei den Zeitreihen mit  $\mathbf{x} = (\bar{Z}_{\text{REF } s}[1], \dots, \bar{Z}_{\text{REF } s}[K])$ . Werte für  $u_{\text{REF}} > 0.9$  werden im Folgenden als akzeptabel eingestuft (Referenzverhalten kann eindeutig gefunden werden).

### Distanzen bei $K$ Abtastzeitpunkten als Merkmale

Anhand der sagittalen Knie-Zeitreihe mit  $K = 101$  Abtastzeitpunkten („ZR STRI Knie sag OZR“) als Merkmalsraum und vier Cluster-Zentren trennt lediglich der FCM-Algorithmus mit Euklidischer Distanz die Datensätze in klinisch plausible Cluster auf (Abbildung 3.11a).

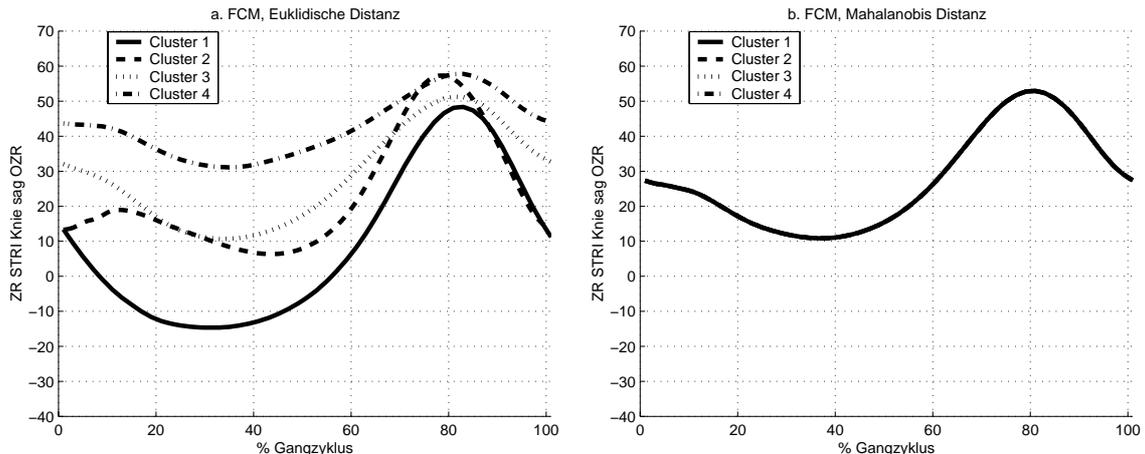


Abbildung 3.11: Cluster-Ergebnis für die sagittale Knie-Zeitreihe durch a. FCM-Algorithmus mit Euklidischer Distanz und b. FCM-Algorithmus mit Mahalanobis-Distanz, wobei die Cluster-Zentren 1 bis 4 übereinander liegen.

Probleme beim FCM-Algorithmus mit Mahalanobis-Distanz, GK- und GG-Algorithmus resultieren aus Problemen bei der Inversion von Kovarianzmatrizen zur Berechnung der Distanzen. Die vergleichsweise geringe Anzahl von Datensätzen führt hier zu einem Rangabfall der Kovarianzmatrizen, der beim Invertieren nur durch Berechnung von Pseudoinversen zu behandeln ist. Dadurch werden alle Datensätze zu den Clustern nahezu gleichverteilt zugeordnet (Abbildung 3.11b und

Tabelle 3.10). Die Zentren liegen somit beim gemeinsamen Mittelwert über alle Datensätze.<sup>12</sup>

$d_c$	Art	C	$S$	$u_{\text{REF}}$	$\bar{u}_{\text{max},c}$	Anzahl DS	$d_{\text{min},ZR}^2$	Abb.
EU	ZR	4	15.21	0.92	0.69 0.67 0.59 0.63	11 26 45 24	7588.22	a.
MA	ZR	4	$5 \cdot 10^8$	0.25	0.25 0.25 0.25 0.25	27 27 26 26	$8 \cdot 10^{-7}$	b.
GK	ZR	4	6.62	0.25	0.25 0.25 0.25 0.25	27 27 26 26	$10^{-10}$	–
GG	ZR	4	6.62	0.25	0.25 0.25 0.25 0.25	27 27 26 26	$10^{-10}$	–
EU	HK	4	9.24	0.97	0.77 0.73 0.72 0.71	11 37 35 23	8319.63	–

Tabelle 3.10: Vergleich verschiedener Distanzen  $d_c$  für „ZR STRI Knie sag OZR“, vgl. Abbildung 3.11 ( $s = K = 101$  Abtastzeitpunkte bzw. dessen Transformation „HK STRI Knie sag OZR“ mit  $s = 2$  Merkmalen). Die numerischen Probleme auf Grund nahezu gleicher ZGH bei Mahalanobis-Distanz, GK- und GG-Algorithmus wurden geeignet durch eine Grenzwertbeschränkung behandelt.

Die mit dem FCM-Algorithmus und Euklidischer Distanz gefundenen Cluster stimmen mit etablierten klinischen Subgruppen überein [152, 174]. Dabei entspricht „Cluster 2“ nahezu dem Mittelwert der Referenzgruppe ( $u_{\text{REF}} = 0.92$ ), „Cluster 1“ qualitativ dem Recurvatum (Knieüberstreckung), „Cluster 3 und 4“ qualitativ einem starken und milden Kauergang (crouch gait), siehe Cluster-Zentren in Abbildung 3.11a. und die zugehörigen Datensätze zu den Clustern in Abbildung 3.12.

### Vergleich Merkmalsraum ( $K$ Abtastzeitpunkte gegen zwei HK-Merkmale)

Da nur der FCM-Algorithmus mit Euklidischer Distanz bei Zeitreihen gute Ergebnisse liefert, wird er beim Vergleich von Zeitreihen mit  $s = K = 101$  Abtastzeitpunkten und deren dimensionsreduzierende Transformation durch die HKA mit  $s = 2$  Einzelmerkmalen verwendet. Beide Ansätze liefern beim Clustern von „offensichtlichen“

<sup>12</sup>Darüber hinaus gibt es bereits beim Clustern von Zeitreihenabschnitten mit wenigen Abtastzeitpunkten (ab  $K = 3.5$ ) Probleme durch die Korrelationen benachbarter Abtastzeitpunkte. Zwar können (abschnittsweise) die Cluster durch unterschiedliche Steigungen in den Zeitreihen charakterisiert sein, allerdings dominiert der Rauschanteil. Der FCM-Algorithmus mit Mahalanobis-Distanz, GK- und GG-Algorithmus verstärken diese (Ko-)Varianzen und so den Rauschanteil beim Clustern. Die Auswirkungen ähneln Abbildung 3.11b und Tabelle 3.10 mit Clustern beim gemeinsamen Mittelwert über alle Datensätze.

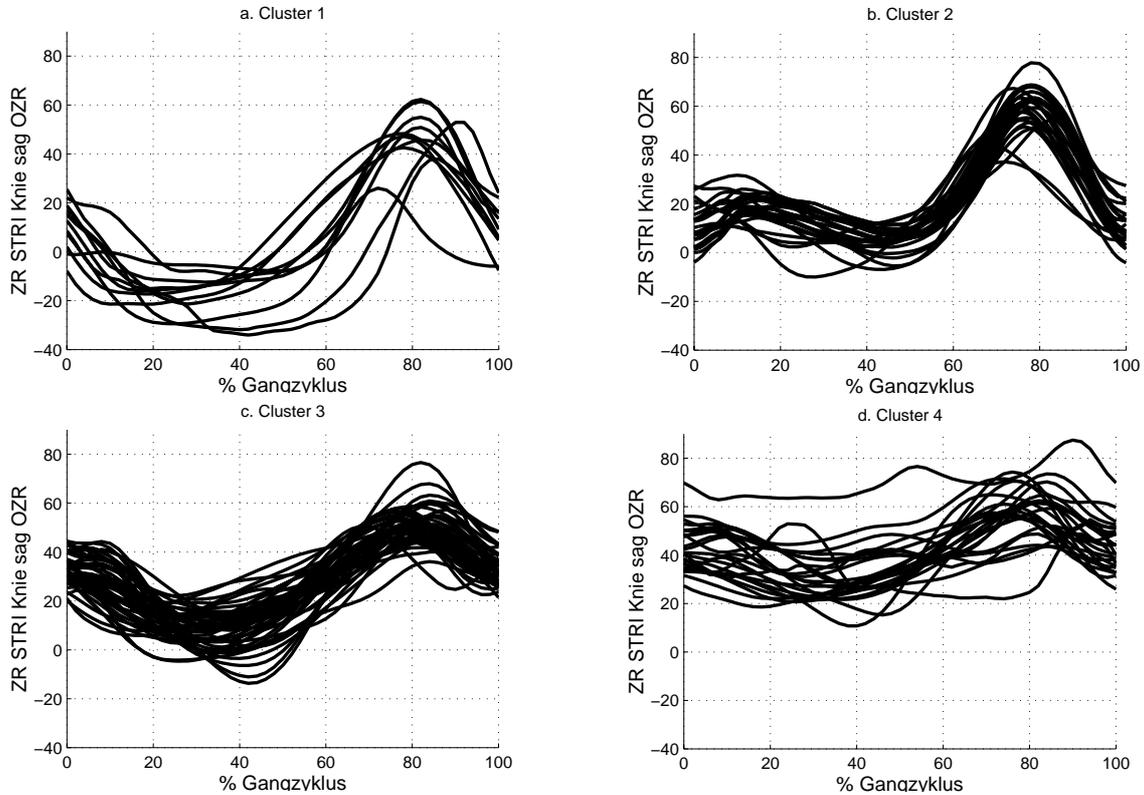


Abbildung 3.12: Cluster-Ergebnis durch FCM-Algorithmus mit Euklidischer Distanz für die sagittale Knie-Zeitreihe mit den jeweiligen Datensätzen der einzelnen Cluster  $c = 1..4$ . Klinische Interpretationen: a. Recurvatum (Knieüberstreckung), b. Referenzverhalten, c. milder Kauergang, d. starker Kauergang.

Gruppierungen, wie z.B. in der sagittalen Knie Zeitreihe, vergleichbar gute Ergebnisse, siehe HK, EU in Tabelle 3.10. Allerdings werden in seltenen Fällen durch die HK manche Datensätze fragwürdig zugeordnet. Anhand des eindeutig erkennbaren Referenzkollektives werden in dem Beispiel manche Patientendatensätze zu diesem Cluster zusätzlich zugeordnet, siehe unplausibel klassifizierte Datensätze in Abbildung 3.13. Aus klinischer Sicht sind sie schlecht zugeordnet aufgrund des stark gebeugten Knies beim Aufsetzen und der leichten Knieüberstreckung, d.h. mangelndes Abfedern des Körpergewichts in den ersten 10% des Gangzyklus (negative Steigung im Kniewinkel während der Phase LR). Im Vergleich dazu zeigt Abbildung 3.12 eine bessere Einteilung der Subgruppen: In a. sind alle Datensätze des Recurvatum (Knieüberstreckung, d.h. negative Winkelstellung in der Standphase); in b. sind die

Referenzdatensätze bzw. zur Referenz sehr ähnliche Datensätze enthalten; c. enthält die Datensätze des milden Kauergangs, die teilweise in Abbildung 3.13 unplausibel klassifiziert sind; in d. sind Datensätze des starken Kauergangs. Der Grund für die bedingt schlechtere Klassifikation mit HKA ist, dass in Bereichen maximaler Streuung nicht immer die verschiedenen Gruppen unterschieden werden. Die erste HK („1.HK STRI Knie sag OZR“), die hier für den Effekt verantwortlich ist, beinhaltet annähernd eine Mittelung der ersten 60% des Gangzyklus (Standphase), weil in dem Bereich alle Datensätze stark streuen, z.B. Recurvatum, Kauergang, siehe Abbildungen 3.9, 3.12 und 3.13. Dadurch werden die Cluster lediglich durch den mittleren Verlauf der Zeitreihe in dem bestimmten Bereich unterschieden, weitere Informationen werden nicht berücksichtigt. Auf diese Art können sich zumindest in der 1. HK zu hohe Werte im Initial Contact (IC, 0%..10% des Gangzyklus) und zu niedrige Werte in der Mid Stance (MSt, 10%..30%) kompensieren. Die 2. HK spielt wegen der geringeren Werte eine untergeordnete Rolle.

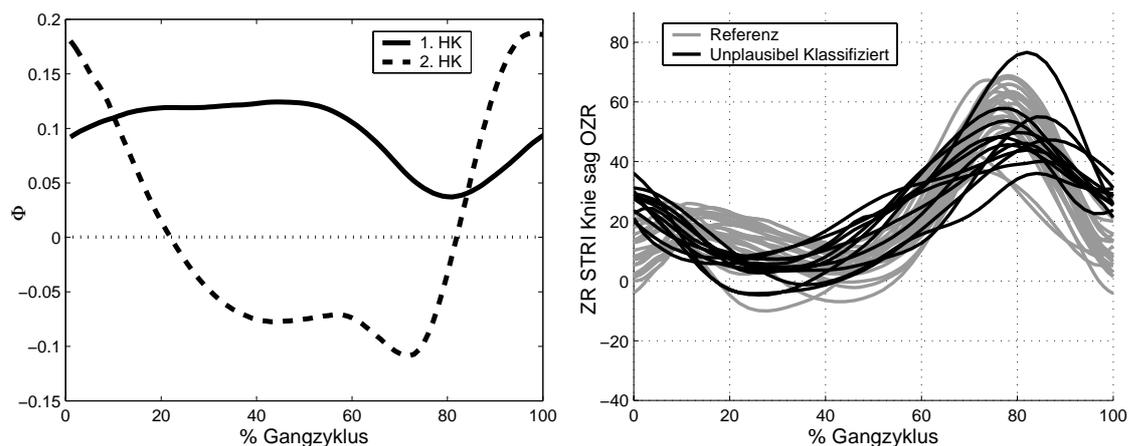


Abbildung 3.13: Links: Transformationsvorschrift der HKA in  $\Phi = (\phi_1, \phi_2)$ , rechts: Cluster mit mehrheitlich Referenzdaten (hellgrau) und klinisch unplausibel zugeordnete Patientendatensätze (schwarz).

Ein komplexes Beispiel ist bei Vorgabe von  $C = 4$  Cluster-Zentren die normierte Geschwindigkeitszeitreihe des oberen Sprunggelenks (ZR STRI OSG sag GZR), die „versteckte“ Subgruppen enthält. Versteckte Subgruppen sind dadurch charakterisiert, dass sie sich über große Bereiche in der Zeitreihe kaum voneinander unterscheiden, z.B. „Cluster 1, 3 und 4“ zwischen 20% bis 50% des Gangzyklus in Abbildung 3.14 a. und b. Die vorhandenen Unterschiede zwischen Datensätzen in diesem Bereich wirken folglich wie Rauscheffekte (vgl. Abbildung 3.8) und erschweren so eine Erkennung mit ZR-Merkmalen und dem FCM-Algorithmus.

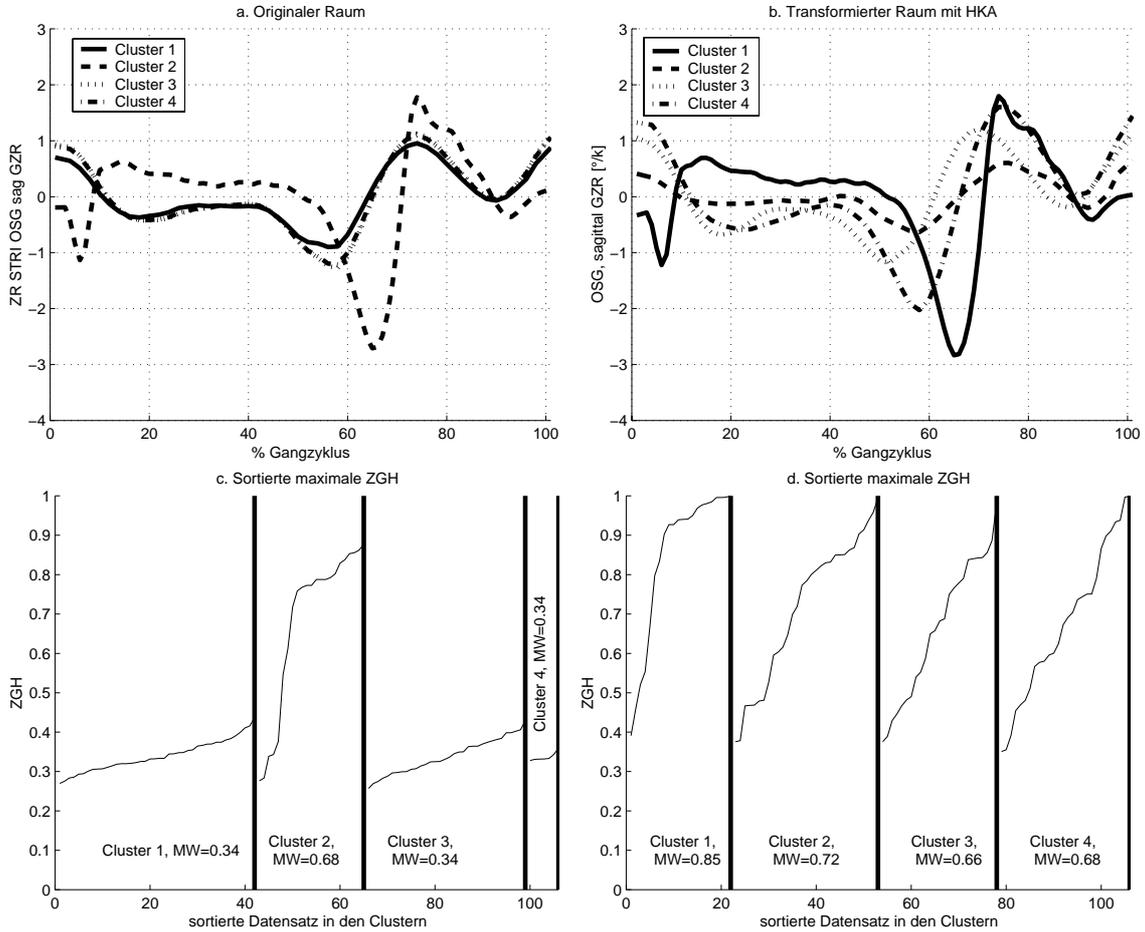


Abbildung 3.14: Cluster-Ergebnisse für die sagittale OSG-Geschwindigkeitszeitreihe in a. und c. ZR-Merkmalraum ( $s = K = 101$ ) bzw. in b. und d. im HK-Merkmalraum ( $s = 2$ ), wobei die Darstellung der Cluster-Zentren als Zeitreihen durch die ZGH erfolgt.

Das Cluster-Ergebnis mit  $K$  Abtastzeitpunkten im Zeitreihen-Merkmalraum trennt lediglich die Referenzgruppe von allen Patienten, siehe Abbildung 3.14 a. und  $u_{\text{REF}} = 0.98$  zu „Cluster 2“ in Tabelle 3.11. Weiterhin sind die maximalen ZGH zu „Cluster 2“ relativ hoch (Abbildung 3.14c, Mittelwert  $\bar{u}_{\text{max},2} = 0.68$ ), was für eine gute Trennung dieses Clusters steht. Das Cluster enthält 19 von 20 Datensätzen der Referenzpersonen in den 23 zugeordneten Datensätzen. Die Patientendaten werden

allerdings zu den restlichen drei Clustern nahezu gleichverteilt zugeordnet<sup>13</sup> ( $\bar{u}_{\max,c} \approx \frac{1}{3}$ ,  $c = 1, 3, 4$  in Tabelle 3.11). Dadurch sind die drei Cluster-Zentren eng benachbart, was zu einer kleinen minimalen quadratischen Euklidischen Distanz in Zeitreihen  $d_{\min,ZR}^2 = 0.07$  führt.

$d_c$	Art	$C$	$S$	$u_{\text{REF}}$	$\bar{u}_{\max,c}$	Anzahl DS	$d_{\min,ZR}^2$	Abb.
EU	ZR	4	6401.65	0.98	0.34 0.68 0.34 0.34	42 23 34 7	0.07	a.
EU	HK	4	8.24	0.99	0.85 0.72 0.66 0.68	22 31 25 28	23.41	b.

Tabelle 3.11: Vergleich von Cluster-Ergebnissen in Zeitreihen (ZR,  $s = K = 101$ ) und in deren transformiertem Raum durch die HK ( $s = 2$ ) für die sagittale OSG-Geschwindigkeitszeitreihe (ZR STRI OSG sag GZR), siehe auch Abbildung 3.14.

Die Trennung der Patienten in Subgruppen ist durch Verwendung der HK mit zwei Merkmalen besser. Deren Interpretation ist möglich, wenn mit den Zugehörigkeiten nach abgeschlossener Optimierung die Cluster-Zentren mit  $Z_{ns}[k]$  für die Zeitreihen berechnet werden. In Abbildung 3.14 b. ist zu erkennen, dass die Cluster 2 bis 4 (das entspricht den Patientendatensätzen) sich nur in bestimmten Zeitbereichen unterscheiden, wie z.B. zwischen 50 und 80% des Gangzyklus. Hier sind die mittleren ZGH zu den einzelnen Cluster-Zentren relativ groß ( $\bar{u}_{\max,c} \gg \frac{1}{C} = \frac{1}{4}$ ,  $c = 2, 3, 4$ , Tabelle 3.11 und Abbildung 3.14d). Die HK bieten somit Vorteile bei „versteckten“ Gruppierungen, weil Bereiche in ZR, in denen sich die Gruppen nicht unterscheiden (und eher wenig streuen), durch die HK unterdrückt werden.

Die Verwendung interpretierbarer Einzelmerkmale aus Abschnitt 3.5 ist für das Clustern nicht geeignet. Ein Grund ist, dass die Einzelmerkmale Zeitreihen-spezifisch ausgewählt werden müssen, z.B. kann in einer Zeitreihe der Mittelwert charakteristisch zur Unterscheidung der Subgruppen sein, in einer anderen Zeitreihe ist es das Maximum [13]. Eine subjektive Vorauswahl fester (oder variabler) Einzelmerkmale widerspricht den Zielen der vorliegenden Arbeit, siehe Kapitel 1. Weiterhin sind Einzelmerkmale wie das Maximum oder das Minimum stark anfällig auf Ausreißer und Messfehler. Beispielsweise existieren in  $\bar{Z}_{ns}[k]$  erhöhte Peaks durch Messfehler in wenigen Datensätzen. Das führt dazu, dass lediglich durch die Ausreißer die Daten in Cluster eingeteilt werden.

<sup>13</sup>Es ist offensichtlich, dass die Cluster-Anzahl im Merkmalsraum ZR STRI OSG sag GZR mit  $C = 4$  falsch ist. Aber zum Vergleich der Merkmalsräume muss die Cluster-Anzahl fest sein. Das Ergebnis für  $C = 2$  ist qualitativ ähnlich und fasst die Cluster 1, 3, 4 zu einem Cluster zusammen.

### Bestimmung Cluster-Anzahl bei zwei HK-Merkmalen

In den bisherigen Abschnitten wurde die Cluster-Anzahl fest gesetzt. Im Folgenden soll nun versucht werden, mit den eingeführten Kennzahlen eine optimale Cluster-Anzahl  $C$  zu finden. Hierbei wird zunächst die Euklidische Distanz mit zwei HK-Merkmalen verwendet und anschließend mit anderen Distanzen verglichen.

Die Ergebnisse für die sagittale Knie-Zeitreihe zeigt Tabelle 3.12. Die Literaturrempfehlung, das erste lokale Minimum des Trennungsgrades  $S(C)$  (hier  $C = 3$ ) zu verwenden, zeigt bezüglich der mittleren maximalen Zugehörigkeiten und der Anzahl der zugeordneten Datensätze sowie der Trennung der Cluster-Zentren befriedigende Ergebnisse. Allerdings findet diese Zuordnung die Referenzgruppe nur unzureichend ( $u_{\text{REF}} = 0.85$ ), was sich auch an einer deutlichen Abweichung des entsprechenden „Clusters 2“ vom Referenzverlauf äußert (Abbildung 3.15a im Vergleich zeigt Cluster 2 in Abbildung 3.15b die präzise gefundene Referenz).

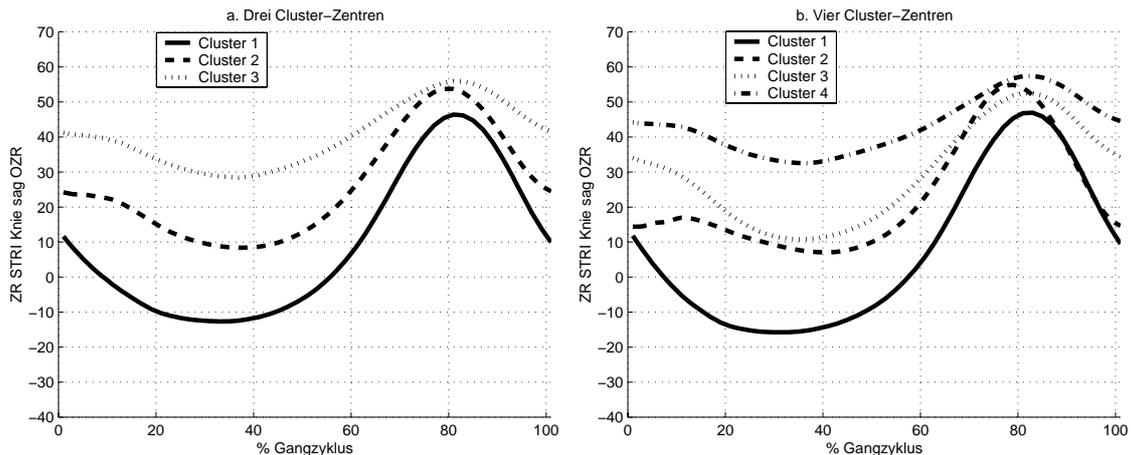


Abbildung 3.15: Vergleich von drei und vier Cluster-Zentren für die sagittale Knie-Zeitreihe.

Der Grund für eine derart „falsche“ Einschätzung durch den Trennungsgrad liegt darin, dass das Ergebnis teilweise durch sehr eindeutige Gruppen (wie die der Referenz) verfälscht wird. Die eindeutige Gruppe verursacht hohe ZGH. In der Nähe liegende, aber abweichende Datensätze von Patienten beeinflussen die Lage des Cluster-Zentrums insbesondere bei einer niedrigen Cluster-Anzahl. Der Trennungsgrad bevorzugt nun hohe ZGH bei niedriger Cluster-Anzahl mit der Folge, dass einige Patienten und die Referenz in einem Cluster (hier „Cluster 2“) beschrieben werden und das eigentliche Gangverhalten der beiden Gruppen vermischt wird.

$d_c$	Art	$C$	$S$	$u_{REF}$	$\bar{u}_{max,c}$	Anzahl DS	$d_{min,ZR}^2$	Abb.
EU	HK	2	12.79	0.92	0.81 0.83	63 43	29633.67	-
EU	HK	3	5.65	0.85	0.80 0.79 0.80	13 64 29	25306.88	-
EU	HK	4	9.24	0.97	0.77 0.73 0.72 0.71	11 37 35 23	8319.63	-
EU	HK	5	5.53	0.96	0.73 0.74 0.66 0.72 0.81	11 29 35 21 10	8391.59	a.
EU	HK	6	6.42	0.71	0.67 0.80 0.68 0.58 0.71 0.77	11 17 24 25 19 10	4644.69	-
EU	HK	7	5.92	0.92	0.61 0.71 0.70 0.66 0.54 0.69 0.74	10 7 16 20 24 19 10	4136.41	-
MA	HK	2	19.88	0.97	0.82 0.77	54 52	8808.20	-
MA	HK	3	7.53	0.99	0.70 0.78 0.69	31 43 32	8734.90	-
MA	HK	4	6.91	0.99	0.66 0.74 0.64 0.67	16 36 24 30	8950.80	-
MA	HK	5	6.31	0.93	0.64 0.75 0.61 0.66 0.61	8 24 30 26 18	4915.86	-
MA	HK	6	2.84	0.96	0.68 0.70 0.64 0.64 0.62 0.64	7 28 18 27 13 13	6191.34	b.
MA	HK	7	4.25	0.70	0.65 0.69 0.71 0.67 0.64 0.58 0.58	7 20 18 14 23 11 13	3372.57	-
GK	HK	2	10.71	0.99	0.85 0.82	60 46	7874.67	-
GK	HK	3	7.43	1.00	0.85 0.71 0.72	41 41 24	4644.46	-
GK	HK	4	5.08	0.98	0.79 0.69 0.76 0.67	33 27 25 21	2832.97	c.
GK	HK	5	14.60	0.75	0.91 0.64 0.77 0.70 0.70	5 33 25 26 17	1644.25	-
GK	HK	6	8.35	0.86	0.90 0.69 0.71 0.76 0.65 0.67	5 18 28 19 20 16	1788.14	-
GK	HK	7	7.43	0.82	0.85 0.76 0.64 0.66 0.58 0.72 0.73	5 18 25 12 22 13 11	3850.51	-
GG	HK	2	789.05	1.00	0.99 0.97	1 105	72248.62	-
GG	HK	3	89.21	1.00	0.87 0.93 0.90	4 48 54	6309.23	-
GG	HK	4	7.63	1.00	0.94 0.86 0.95 0.84	3 20 74 9	9024.21	d.
GG	HK	5	6.81	0.53	0.89 0.80 0.73 0.74 0.81	3 12 41 38 12	6584.36	-
GG	HK	6	0.07	1.00	0.81 0.71 0.00 0.00 0.99 0.99	2 2 0 0 2 100	8176.74	-
GG	HK	7	0.07	1.00	1.00 0.68 0.00 0.00 0.00 0.99 1.00	2 2 0 0 2 100	5330.36	-

Tabelle 3.12: Ergebnisse der Algorithmen anhand von zwei transformierten Merkmalen durch die HK (HK mit  $s = 2$ ) für die sagittale Knie-Zeitreihe (1.HK STRI Knie sag OZR bzw. 2.HK STRI Knie sag OZR), siehe Abbildung 3.16.

Eine praktische und effiziente Lösung ist der Vergleich der Cluster-Ergebnisse mit reduzierten Datensätzen und zwar ohne klar erkannte Gruppierungen, für die Ganganalyse in der Regel die Referenzgruppe. Werden bei dem Beispiel somit nur die Patienten-Datensätze verwendet, so gibt der Trennungsgrad ein  $C = 3$  vor, wodurch die drei beschriebenen Patienten-Subgruppen gut gefunden werden, siehe Abbildung 3.10. Für dieses Beispiel ist davon auszugehen, dass für den gesamten Datensatz mindestens  $C = 4$  Cluster-Zentren vorhanden sind (mit dem klinischen Hintergrund, dass die Patienten abweichend vom Referenzverhalten laufen). Eine Erhöhung der Cluster-Anzahl auf  $C = 4$  bzw.  $C = 5$  verbessert die Kennzahl mit der Ähnlichkeit zur Referenz (Abbildung 3.15b bzw. 3.16a), aber reduziert den Abstand der Cluster-Zentren. Bei  $C = 5$  beschreiben zwei Cluster-Zentren ein ähnliches orthopädisches Gangbild, siehe „Cluster 3 und 4“ in Abbildung 3.16. Ähnliche Effekte treten unter Umständen auch bei anderen Zeitreihen auf. Deshalb fällt es wegen der unterschiedlichen Zielstellungen in einem multikriteriellen Optimierungsproblem schwer, eine richtige Cluster-Anzahl zu empfehlen. Eine finale Entscheidung wird deshalb interaktiv getroffen.

Der FCM-Algorithmus mit Mahalanobis-Distanz, GK- bzw. GG-Algorithmus liefern im transformierten Merkmalsraum durch die HK befriedigende Ergebnisse, siehe Tabelle 3.12 und Abbildung 3.16. Beim FCM-Algorithmus mit Mahalanobis-Distanz weist der Trennungsgrad auf eine Cluster-Anzahl von  $C = 6$  hin, siehe Abbildung 3.16b. Allerdings beschreiben die Cluster-Zentren ähnliche Gangbilder. Eng benachbart sind insbesondere „Cluster 3 und 4“. Eine Reduzierung auf  $C = 5$  verbessert die Situation der eng benachbarten Cluster-Zentren nicht. Eine weitere Reduzierung hat zur Folge, dass die bereits ermittelten Subgruppen nur unbefriedigend gefunden werden.

Der GK-Algorithmus findet bei  $C = 4$  (anhand des Trennungsgrades) nicht die Patienten-Subgruppen (Abbildung 3.16c). Bei Erhöhung auf  $C = 5$  wird die bekannte Gruppe „Referenz“ verfälscht. Zudem treten sehr eng benachbarte Cluster-Zentren auf. Der GG-Algorithmus liefert zwar auf den ersten Blick mit  $C = 4$  „gute Cluster-Zentren“ („Cluster 2“ als Referenzverhalten, „Cluster 1, 3 und 4“ als bereits beschriebene Patienten-Subgruppen). Allerdings ist die Verteilung der Datensätze ungleichmäßig. Für die Gangdaten treten bei diesem Kriterium insbesondere beim GG-Algorithmus oftmals Probleme auf. Der Grund ist, dass der GG-Algorithmus versucht, sehr hohe ZGH zu erreichen. Somit bezieht er gegebenenfalls nur wenige Datensätze in ein Cluster ein.

Das Ziel der Hauptkomponentenanalyse ist, anhand der maximalen Streuung so viel Information wie möglich aus den Zeitreihen zu extrahieren. Der Informationsgehalt fällt somit bei den transformierten Merkmalen mit kleineren Eigenwerten ab. Die transformierten Merkmale haben einen unterschiedlichen Wertebereich entspre-

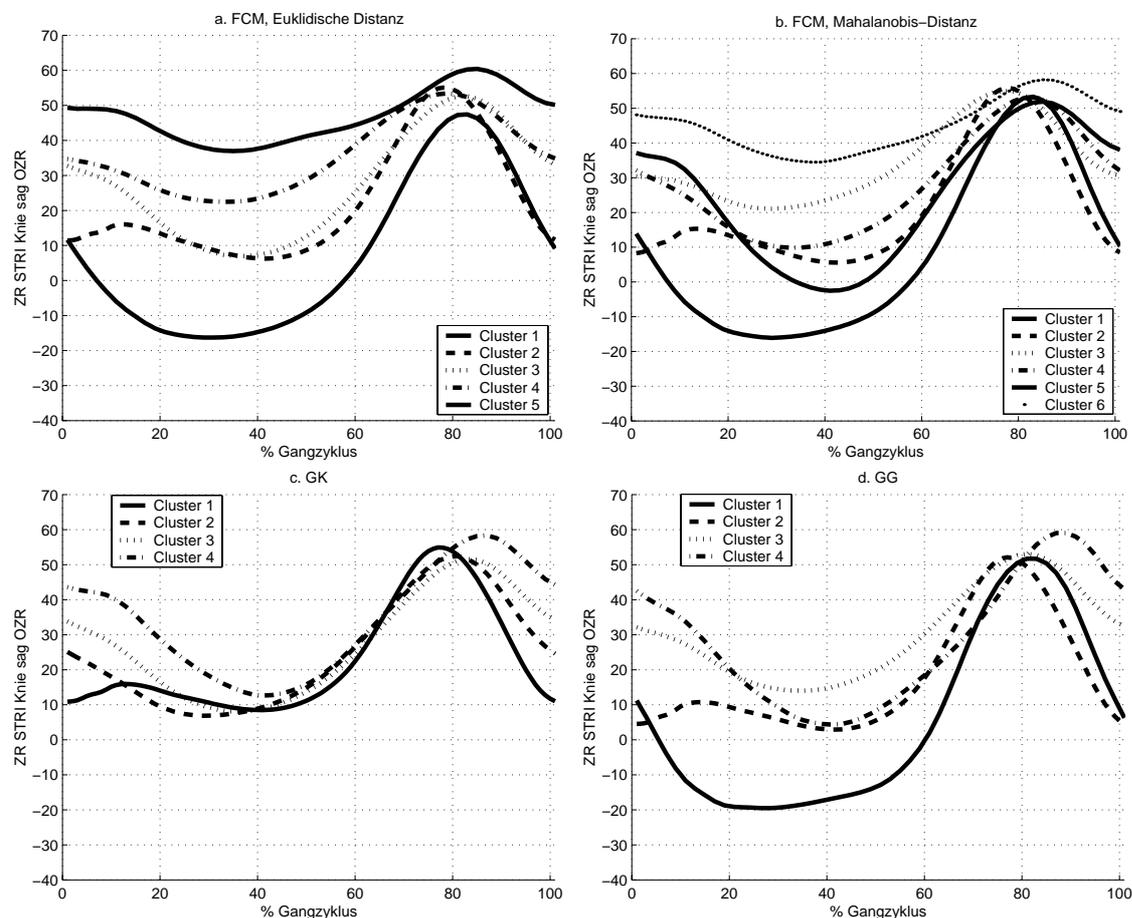


Abbildung 3.16: Visualisierung von Cluster-Zentren bei der sagittalen Knie-Zeitreihe (HK-Merkmalraum).

chend ihrem Informationsgehalt (entlang der größten, zweitgrößten, usw. Streuung innerhalb der normierten Zeitreihen auf ein  $[-1, +1]$  Intervall). Die Mahalanobis-Distanz bewirkt eine einheitliche Skalierung der transformierten Merkmale und zerstört somit die Ziele der Transformation, indem sie weniger wichtige Merkmale verstärkt. Ähnliche Probleme resultieren durch die Fuzzy-Kovarianzmatrizen beim GK- und GG-Algorithmus. Die Ergebnisse hängen stark von den Start-Clustern ab, sind auf die Lerndatensätze angepasst und widersprechen somit der geforderten Generalisierung. Letzteres wird durch Berechnung der „Fuzzy-Kovarianzmatrizen“ entsprechend der Datenverteilung verursacht. Eine starke Abhängigkeit der Start-Cluster ist zudem ein Indiz, dass sehr viele Rauscheffekte existieren (es können keine klaren Gruppierungen gefunden werden, es existieren viele lokale Minima in  $J_q$ ). Der

Rausch-Anteil wächst mit der Anzahl der Hauptkomponenten, der mit diesen Algorithmen zudem (durch die einheitliche Skalierung) verstärkt wird. Insbesondere bei Zeitreihen-Kombinationen liefern diese Algorithmen nur spärliche Ergebnisse. Bei den Gangdaten hängen die Ergebnisse des FCM mit Euklidischer Distanz von den Start-Clustern nicht bzw. nur sehr gering ab. Der Grund ist, dass die Daten keine kleinen, eng benachbarten aber abgetrennten Gruppen aufweisen, die lokale Minima in  $J_q$  verursachen. Die Gruppen unterscheiden sich in unterschiedlichen Datendichten, siehe Abbildung 3.9. Somit ist auch während der iterativen Optimierung von  $J_q$  ein zufälliges „Springen“ von Cluster-Zentren nicht notwendig, das bei Optimierungen im allgemeinen ein Festsetzen in lokalen Minima verhindert.

### Erweiterung des Suchraums auf mehrere Zeitreihen: Simultanes Clustern

Das Problem der multikriteriellen Optimierung erweitert sich, wenn neben der Wahl der Cluster-Zentren auch besonders geeignete Kombinationen von Zeitreihen automatisiert gesucht werden. In der Ganganalyse ist es derzeit völlig unbekannt, welche Zeitreihen sich kombinieren lassen. Dieses Problem ist hier aus klinischer Sicht besonders von Interesse, weil unterschiedliche Gangmechanismen, weitläufigere Zusammenhänge oder Kompensationseffekte über einen erweiterten Suchraum bislang ungeklärt sind [30, 152]. Die Lösung dient einem besseren Verständnis von komplexen Pathologien bei der Diagnose und Therapieplanung.

Ein methodischer Vergleich zur Lösung des Problems ist anhand Kombination A (sagittale Knie-Zeitreihe und sagittale OSG-Zeitreihe) gegen Kombination B (sagittale Knie-Zeitreihe und frontale Becken-Zeitreihe) mit dem FCM-Algorithmus und Euklidischer Distanz gezeigt, siehe Abbildung 3.17 und Tabelle 3.13. Die Anwendung der methodischen Vorgehensweise mit einer klinischen Diskussion über alle Kombinationen ist in Kapitel 5 und teilweise in [88, 93] gegeben.

Die Gründe für die schlechten Ergebnisse bei Kombination B verdeutlicht Abbildung 3.18. Hierbei wurden zunächst für die sagittale Knie-Zeitreihe vier Cluster gesucht (Zentren:  $\square$  in Abbildung 3.18a). Beim Einzeichnen der Zugehörigkeiten in die Merkmale der frontalen Beckenzeitreihe ( $\cdot, \circ, \times, +$  in Abbildung 3.18b) zeigt sich keine Struktur (etwaige Gleichverteilung), obwohl auch hier bei einem separaten Clustern ausgeprägte Cluster gefunden werden ( $\triangleright$ ). Das deutet auf inkompatible Cluster hin, siehe Abbildung 3.8b. Ein simultanes Clustern verschiebt alle Cluster-Zentren in Richtung der Mittelwerte, ohne ausgeprägte Cluster zu finden ( $\star$ ). Somit sinken auch die Zugehörigkeiten zu den simultanen Clustern im Vergleich zu den separaten Clustern, z.B. Datensatz DS 80:  $u_{80,1} = 0.96$  (Knie),  $u_{80,4} = 0.84$  (Becken),  $u_{80,4} = 0.39$  (simultan Knie + Becken).

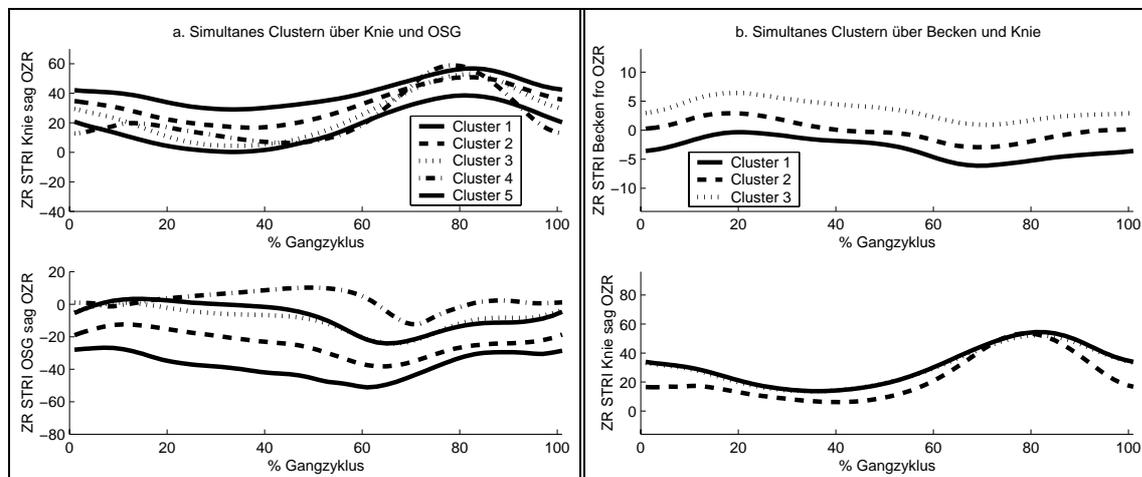


Abbildung 3.17: Simultanes Clustern für a. die Kombination A (sagittale Knie- und OSG-Zeitreihe, links) und b. die Kombination B (sagittale Knie- und frontale Becken-Zeitreihe, rechts).

Bei Darstellung der Cluster-Zentren als Zeitreihen (Abbildung 3.17b) wird der Effekt verdeutlicht. Bei  $C = 3$  werden die bekannten Patienten-Subgruppen im Knie nicht gefunden, d.h. die Cluster-Zentren liegen in der Nähe des Mittelwerts aller Patientendaten (ausgenommen von den Referenzdaten, da diese im Wesentlichen durch das „Cluster 2“ abgedeckt sind). Bei  $C = 4..6$  werden entweder bekannte Subgruppen oder die Referenz nicht gefunden. Erst bei  $C = 7$  werden sowohl die Patienten-Subgruppen als auch die Referenz durch die Form der Cluster-Zentren beschrieben. Allerdings sind die Cluster-Zentren eng benachbart und die Referenz wird durch zwei Cluster beschrieben (das erklärt den niedrigen Wert von  $u_{\text{REF}} = 0.53$ ).

Besser sind die Ergebnisse bei Kombination A. Der Trennungsgrad weist auf eine Cluster-Anzahl von  $C = 4$  hin. Mit dieser Anzahl sind die Patienten-Subgruppen im Knie einigermaßen gut abgebildet und Zusammenhänge zum sagittalen OSG beschrieben. Der Grund, dass das „Recurvatum“ nicht vollständig abgebildet ist, liegt an der starken Heterogenität und Komplexität der Daten. Es existieren keine eindeutigen, klaren Zusammenhänge innerhalb der Daten, lediglich Tendenzen, die mit diesem Vorgehen aufgedeckt werden können. Eine Variation der Cluster-Anzahl  $C$  verbessert die Ergebnisse nicht (keine vollständige Erkennung der Patienten-Subgruppen im Knie bzw. eng benachbarte Cluster-Zentren, siehe Abbildung 3.17a).

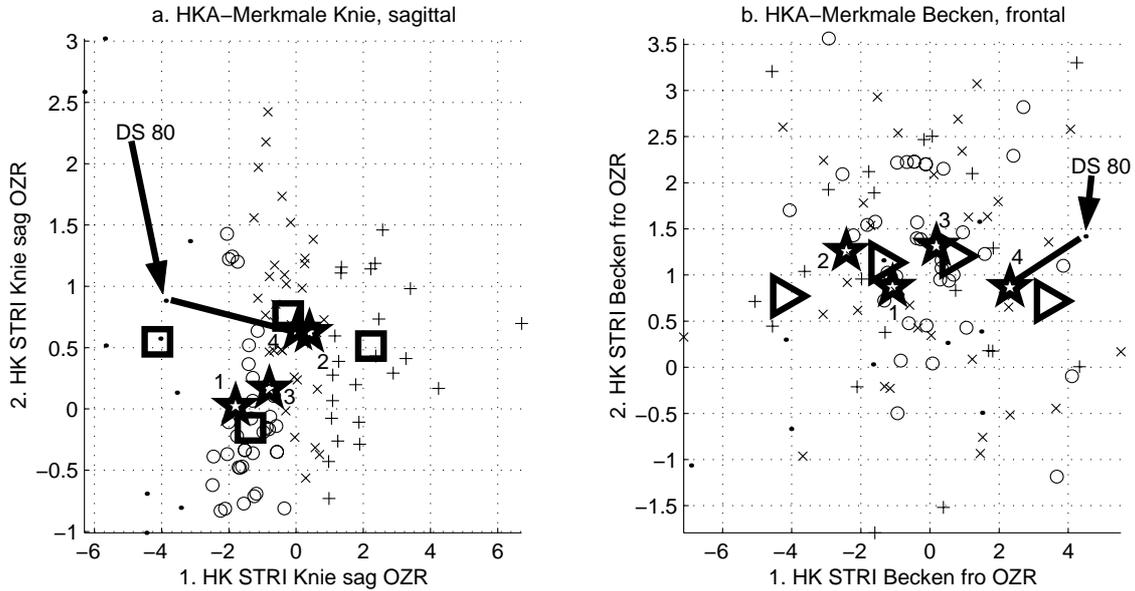


Abbildung 3.18: HK-Merkmale für sagittale Knie-Zeitreihe (links) und frontale Becken-Zeitreihe (rechts) mit eingezeichneten Cluster-Zentren ( $\square$ : separat Knie,  $\triangleright$ : separat Becken,  $\star$ : Kombination B mit simultanem Clustern für Knie und Becken;  $\cdot, \circ, \times, +$ : Datensätze entsprechend maximaler Zugehörigkeit für separate Knie-Cluster).

Zum Einschätzen einer besseren Kombination von Zeitreihen kann zudem der Wert von  $S(C)$  als Vergleichsparameter herangezogen werden, Tabelle 3.13 für Kombination A und B. Das wird in Kapitel 5 zum Finden von Zeitreihenkombinationen über alle Daten verwendet.

$d_c$	$\mathbf{X}$	$C$	S	$u_{\text{REF}}$	$\bar{u}_{\text{max},c}$	Anzahl DS	$d_{\text{min},ZR}^2$	Abb.
EU	A	2	16.07	0.95	0.76 0.81	41 65	57025.79	-
EU	A	3	11.67	0.96	0.66 0.65 0.77	22 38 46	35249.59	-
EU	A	4	10.45	0.97	0.58 0.58 0.59 0.73	20 23 25 38	23945.66	-
EU	A	5	6.52	0.98	0.51 0.61 0.57 0.71 0.59	13 17 24 35 17	23633.81	a.
EU	A	6	11.45	0.99	0.57 0.55 0.50 0.53 0.65 0.52	9 17 19 14 30 17	9888.43	-
EU	A	7	11.81	0.89	0.52 0.51 0.55 0.45 0.68 0.49 0.51	9 12 9 21 20 21 14	7836.88	-
EU	B	2	32.28	0.54	0.72 0.73	54 52	2278.89	-
EU	B	3	19.93	0.94	0.62 0.64 0.63	33 40 33	4676.30	b.
EU	B	4	25.26	0.52	0.49 0.54 0.57 0.56	27 28 25 26	4446.53	-
EU	B	5	23.79	0.44	0.45 0.49 0.45 0.51 0.47	21 24 21 16 24	1068.98	-
EU	B	6	16.71	0.61	0.45 0.46 0.45 0.50 0.43 0.45	19 13 19 17 18 20	1821.21	-
EU	B	7	20.47	0.53	0.53 0.46 0.44 0.47 0.42 0.40 0.49	5 12 18 20 20 19 12	2137.42	-

Tabelle 3.13: Ergebnisse beim simultanen Clustern mit Kombination A bzw. B, die Art der Merkmale sind jeweils HK mit  $s = 4$ .

### Zusammenfassung und Wertung

Bei der Cluster-Analyse existieren keine Standard-Lösungsverfahren, die für alle Anwendungsgebiete einsetzbar sind [20, 66]. Um die Ziele aus Abschnitt 3.8.1 zum Finden von Subgruppen in den Gangdaten zu erreichen, musste daher ein entsprechender Entwicklungsaufwand geleistet werden.

Bei den Gangdaten haben sich folgende Methoden zur Struktursuche ohne bekannte Klasseneinteilung bewährt:

- Der Fuzzy-C-Means (FCM) mit Euklidischer Distanz.
- Merkmalsraum:
  - Die Abtastzeitpunkte der Zeitreihen insbesondere für „offensichtliche“ Subgruppen (Subgruppen unterscheiden sich über nahezu alle Abtastzeitpunkte).
  - Die dimensionsreduzierende Hauptkomponentenanalyse (HKA) insbesondere bei „versteckten“ Subgruppen (dieser Effekt verstärkt sich bei Kombina-

tionen von Zeitreihen in komplexen Gangbilder wie ICP). Voraussetzung der HKA ist die Unterscheidung der Gruppen in Bereichen maximaler Streuung (muss bei der Anwendung separat geprüft werden).

- Der Trennungsgrad  $S(C)$  mit den neuen Modifikationen zum Finden und Erkennen bekannter Gruppen (gefundene Referenz mit  $u_{\text{REF}}$ ) zur Validierung der Cluster-Ergebnisse. In seltenen Fällen müssen weitere Kennzahlen einbezogen werden.

Insbesondere bei der Wahl des Merkmalsraumes empfiehlt sich, Cluster-Ergebnisse zuerst über die Zeitreihen zu erzielen und bei ausbleibendem Erfolg über die HKA erneut nach Strukturen zu suchen. Eine große Differenz der Werte von  $S(u)$  zwischen den beiden Merkmalsräumen hilft zudem versteckte Subgruppen zu erkennen. Dadurch bleibt ein bestimmter Grad an Interaktivität übrig, was auf die Komplexität der Gangdaten zurückzuführen ist.

### 3.9 Verallgemeinerte Kombination der Verfahren

Die einzelnen Methoden wurden in den Abschnitten 3.2 bis 3.8 entsprechend eines einheitlichen strukturellen Vorgehens zur Datenanalyse für klinische Problemstellungen bereit gestellt, siehe Abbildung 3.1. Neben der pauschalen Bereitstellung zusätzlicher Merkmale entstehen auch problemabhängige Merkmale, die aus den verwendeten Daten berechnet werden, wie z.B. Cluster-Zentren und -Zugehörigkeiten. Somit ist der Prozess rückgekoppelt, um detailliertere Problemstellungen zu lösen. Die eigentliche Auswertung mit der Bewertung von Merkmalen und Klassifikation ist von den Daten und der jeweiligen Problemstellung abhängig.

Die vorgestellten methodischen Werkzeuge lassen sich verschieden kombinieren, um unterschiedliche klinische Fragestellungen zu beantworten. Damit steht ein allgemeines Verfahren zur Lösung einer Vielzahl von Problemstellungen zur Verfügung. Beispielsweise lassen sich charakteristische Einzelmerkmale zur Beschreibung einer gesamten Patientengruppe berechnen. Mit einer vorgeschalteten Struktursuche lassen sich charakteristische Einzelmerkmale zum Erkennen unterschiedlicher Subgruppen ermitteln, siehe Abschnitt 3.2.

Aus methodischer Sicht sind die hier verfolgten Ziele mehr oder minder auch mit weiteren Techniken zu erreichen. Jedoch sind die Methoden für die Schwierigkeiten der Ganganalyse ausgewählt, die aber auf andere technische und nicht-technische Daten übertragbar sind [88, 92, 95]. Die Schwierigkeiten bei der Analyse aus Abschnitt 2.2 und deren Lösungen sind z.B.

**Heterogenität:** Cluster-Analyse, modifizierte Datenauswahl durch Ausschlusskriterien (z.B. bestimmte Geschwindigkeit, Untersuchungstermine, klinische Indizes),

**Messfehler, fehlende Daten:** Datenvorverarbeitung, Interpretation und Plausibilitätsprüfung der Ergebnisse, Apriori-Relevanz,

**Messmodalitäten:** Modifizierte Klasseneinteilung und Datenauswahl (z.B. Zusammenfassen und Auswahl von unterschiedlichen Untersuchungszeitpunkten in erste, mittlere und letzte Untersuchung)

**Unsicherheiten, schwer formalisierbare Einschätzungen:** Apriori-Relevanz, Fuzzy-Klassifikatoren.

In Kapitel 5 sind die Lösungsstrategien in der Anwendung verdeutlicht.

## 3.10 Visualisierung

Die Visualisierung ist ein entscheidender Bestandteil bei der Analyse von Daten. Zum einen wird damit die Entwicklung und Auswahl von Analysemethoden geprägt, als auch die verständliche Präsentation und Veranschaulichung der Ergebnisse. Damit können die Ergebnisse für die klinische Interpretation zugeführt werden, siehe Abbildung 3.1.

In dieser Arbeit werden folgende Visualisierungs- und Präsentationstechniken eingesetzt und teilweise für die Ganganalyse modifiziert, siehe [22, 88, 90, 94] und Kapitel 5:

- Einzelmerkmale in ein-, zwei- und dreidimensionalen Grafiken, farblich/symbolisch nach Klassen sortiert.
- Einzelmerkmale entsprechend der Klassen in zweidimensionalen Grafiken, Histogrammen und mit Mittelwerten und Standardabweichungen in Tabellen.
- Nach Relevanz sortierte Tabellen von charakteristischen oder korrelierten Merkmalen.
- Zeitreihen (einzelner Datensätze oder Mittelwerte und Streuungen) farblich/symbolisch nach Klassen sortiert.
- Zeitreihen mit Zusatzinformation, z.B. farblich codierte Gangabweichungen eines gesamten Patientenkollektives.
- Fuzzy-Regeln in kompakter Form und als Erklärungstext.

Die unterschiedlichen Techniken werden in den folgenden Kapiteln verdeutlicht.

# 4 Erweitertes Programmsystem „Gait-CAD“

## 4.1 Überblick

Die Entwicklung und Realisierung eines Programmsystems als Softwaretoolbox ist für die erfolgreiche und praktische Anwendung von Data Mining Methoden unerlässlich. In der Literatur wird der Mangel an derartigen Lösungen oftmals beklagt [30, 77, 127, 146]. Die Gründe beziehen sich einerseits auf die technische Entwicklung und andererseits auf den klinischen Einsatz der Methoden, die im Einzelnen

- Vereinheitlichung aller Data Mining Methoden für Gangdaten (unterschiedliche Methoden, Anwendung auf verschiedene Datensätze),
- Bearbeitung unterschiedlicher Problemstellungen,
- Zugang für Kliniker zu Data Mining Methoden für Problemstellungen in der Ganganalyse und damit
- Anwendung im klinischen Alltag durch benutzerfreundliche Bedienung

bedeuten. Die in dieser Arbeit entwickelte Softwaretoolbox „Gait-CAD“ (Gait – Computer Aided Diagnosis) erfüllt den technischen Teil und bietet eine benutzerdefinierte Schnittstelle zu den klinischen Aufgaben, siehe Abbildungen 3.1 und 4.1 sowie [96]. Der technische Teil beinhaltet alle in Kapitel 3 vorgestellten Methoden und ist durch

- Datenvorverarbeitung (Konvertierung, Strukturierung der Daten, Umgang mit fehlenden Daten, Abschnitt 3.3)
- Informationsextraktion (Berechnung zusätzlicher Zeitreihen und Einzelmerkmale, Abschnitte 3.4 und 3.5)
- Auswertungen (Anwendung Data Mining Methoden, Abschnitte 3.2 sowie 3.6 bis 3.9)

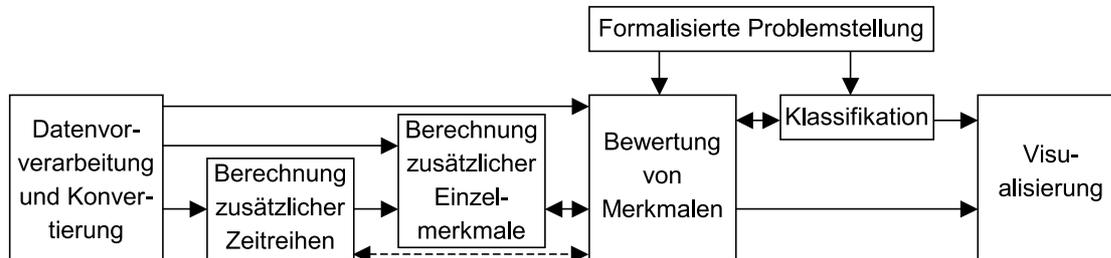


Abbildung 4.1: Funktionen von „Gait-CAD“.

- Visualisierungen (Abschnitt 3.10)

abgedeckt. Die Anwendung ist in Kapitel 5 gezeigt, die durch hohe klinische Akzeptanz und Verwendung der Ergebnisse gekennzeichnet ist [4, 41, 88, 127, 175]. Bedient wird „Gait-CAD“ durch eine graphische und menügesteuerte Benutzeroberfläche, die mit MATLAB [156] realisiert ist, siehe Abbildung 4.2.

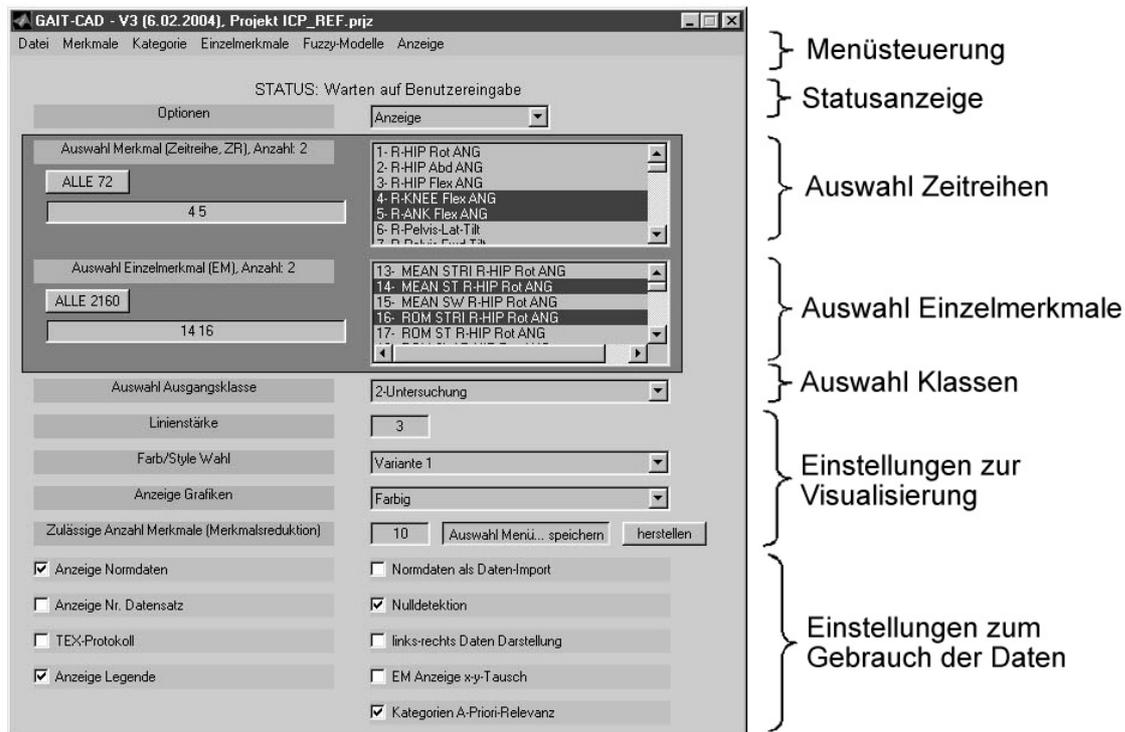


Abbildung 4.2: Hauptfenster von „Gait-CAD“.

## 4.2 Verallgemeinertes Anlegen von Datenprojekten

Eine Voraussetzung für die Anwendung von „Gait-CAD“ ist die Auswahl eines entsprechenden Patientenkollektives mit den entsprechenden Untersuchungszeitpunkten aus einer klinischen Datenbank. Dieser Schritt wird von „Gait-CAD“ nicht unterstützt und muss mit einer externen Software zum Zugriff auf eine klinische Datenbank (wie z.B. HeiDATAProVIT [130]) realisiert werden.

Damit Data Mining Methoden für die Gangdaten anwendbar sind, müssen sie in entsprechende Datenprojekte angelegt werden, siehe Abschnitt 3.3. Mit der entwickelten Softwaretoolbox „Gait-CAD“ können Daten aus Ganglabors importiert und vorverarbeitet werden. Hierzu werden die Merkmale einheitlich bezeichnet und in die Felder zweiter und dritter Ordnung für Einzelmerkmale  $\mathbf{X}$  bzw. Zeitreihen  $\mathbf{Z}$  gespeichert, siehe Abschnitt 3.3. Bekannte Klassen werden in  $\mathbf{Y}$  abgelegt, wie z.B. Kennzeichnung der unterschiedlichen Patienten oder Untersuchungstermine. Die Gangdaten können sowohl aus kommerziellen Archivierungsprotokollen als auch aus neu entwickelten Datensystemen der Ganglabors in „Gait-CAD“ importiert werden [1, 96, 130]. Allerdings ist hierfür ein einheitlicher und klar definierter Ablauf erforderlich. Weiterhin sind für die klinischen Problemstellungen gegebenenfalls verschiedene Varianten beim Anlegen von Datenprojekten notwendig. Die Varianten sind als Funktionen in „Gait-CAD“ implementiert, die im Folgenden beschrieben werden, siehe Abbildung 4.3.

Direkt nach dem Import der Originaldaten aus den Labors werden die Streuungszeitreihen (SZR) über jeweils identische Klassen (z.B. „Person“ und „Untersuchungszeitpunkt“, d.h. alle Datensätze mit identischen Klassen  $\mathbf{y}_i = \mathbf{y}_j$  für alle einzelnen  $i$  =Patienten und  $j$  =Untersuchungszeitpunkte, siehe Abschnitt 3.3) als zusätzliche Zeitreihen berechnet. Somit werden z.B. die Streuungen eines Patienten zu einem Untersuchungszeitpunkt berechnet. In die Berechnung der SZR werden fehlende Zeitreihen („Nullzeitreihen“) nicht mit berücksichtigt, da sie die Streuung in der Regel nach oben abschätzen (Berechnung nur über vorhandene Zeitreihen, hier als „Nulldetektion“ bezeichnet). Anschließend werden die Projekte in zwei Varianten angelegt. Der Unterschied ist die Handhabung der linken und rechten Körperseite. Die eine Variante KAP (Körperseiten abhängige Projekte) verwendet hierzu zwei Merkmale, z.B. linke und rechte Knie-Zeitreihe als „ZR STRI Knie RE OZR“ und „ZR STRI Knie LI OZR“, siehe linke Hälfte in Abbildung 4.3. Die andere Variante KUP (Körperseiten unabhängige Projekte) verwendet ein Merkmal pro Körperseite, z.B. als „ZR STRI Knie OZR“, „links/ rechts Kombination“, siehe rechte Hälfte in Abbildung 4.3. Die Daten der linken und rechten Körperseite werden dabei als unterschiedliche Datensätze  $n \in N$  in  $x_{ns}$  bzw.  $Z_{ns}[k]$  abgelegt. Für einen gezielten

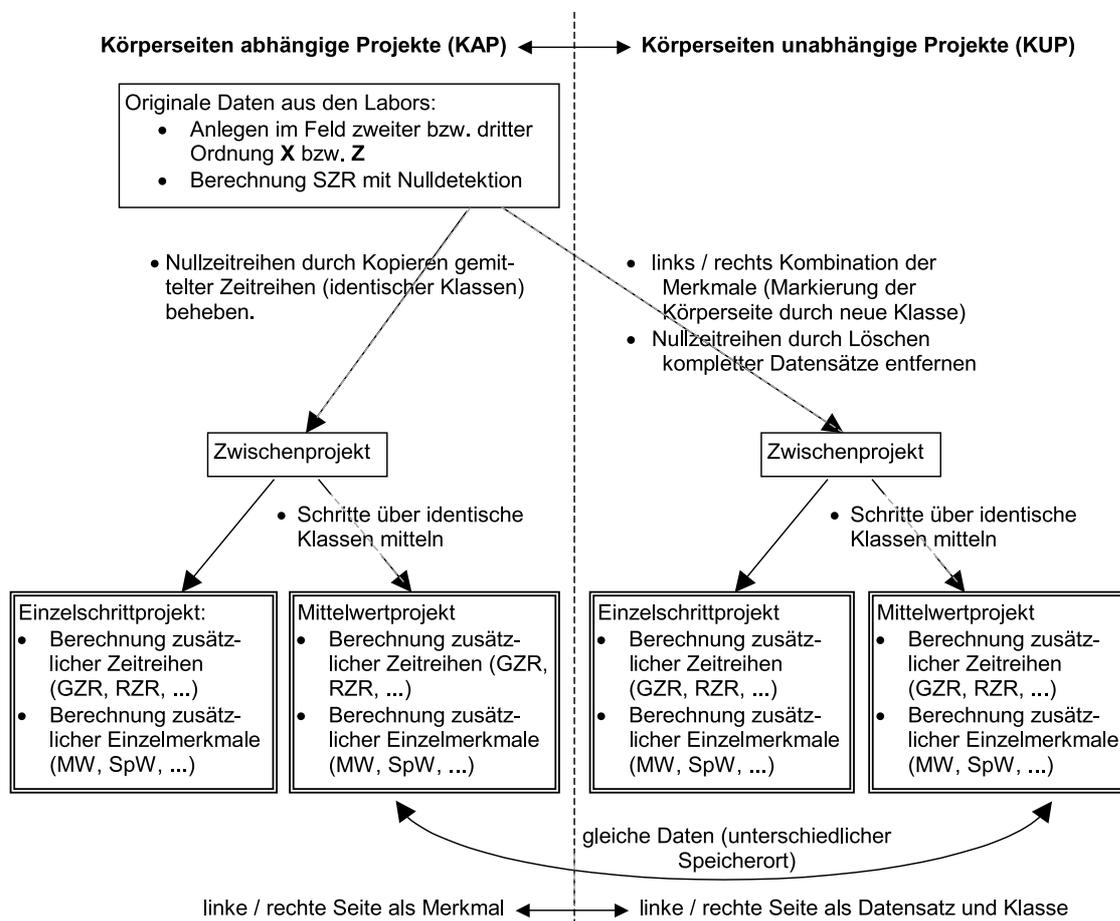


Abbildung 4.3: Erzeugung von Datenprojekten. Die doppelt umrahmten Projekte werden zur weiteren Analyse verwendet.

Zugriff werden die entsprechenden Datensätze als Klassen in **Y** kodiert, z.B. als Klasse „Körperseite“.

Bei KAP werden danach die fehlenden Daten („Nullzeitreihen“) durch Kopieren von gemittelten Zeitreihen über jeweils identische Klassen ersetzt<sup>1</sup>, siehe Abschnitt 3.3. Bei KAP müssen natürlich für jeden Datensatz  $n$  eine Zeitreihe für linke und rechte Körperseite vorhanden sein, das Feld dritter Ordnung **Z** muss vollständig sein, siehe Abbildung 3.2. Bei KUP werden die einzelnen Datensätze  $n$  komplett gelöscht, bei denen mindestens eine „Nullzeitreihe“ vorhanden ist. Dies reduziert

<sup>1</sup>Die Datensätze mit zumindest teilweise ersetzten Zeitreihen werden durch ein Einzelmerkmal kodiert. Dadurch kann später auf die Herkunft des Datensatzes rückgeschlossen werden (originaler oder ersetzter Datensatz).

hier in der Regel nicht die informationstragenden Daten, da fehlende Zeitreihen meistens die komplette Körperseite betreffen, siehe Datensatz  $n = 8$  der rechten Hälfte (KUP) in Abbildung 4.4.

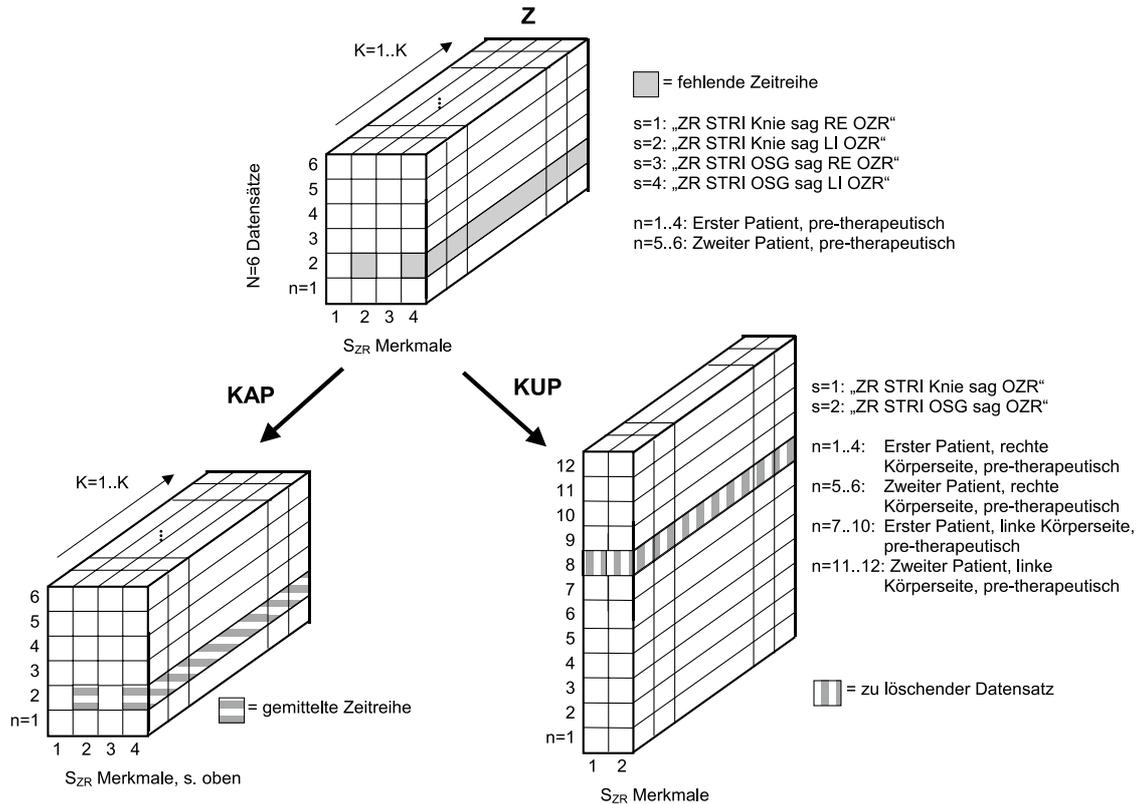


Abbildung 4.4: Beispiele einer Projektanlage.

Aus den Zwischenprojekten der KAP und KUP werden nun Mittelwert- oder Einzelschrittprojekte berechnet, siehe Abbildung 4.3. Dazu werden bei den Mittelwertprojekten Mittelwertzeitreihen (MZR) gemäß Gl. (3.6) für jeweils identische Klassen berechnet, z.B. für gleiche „Person“ und „Untersuchungszeitpunkt“ und „Körperseite“ (bei KUP als Klasse vorhanden). Daraus werden nun alle weiteren zusätzlichen Zeitreihen berechnet, wie Geschwindigkeits-, Beschleunigungs- oder Referenzabweichungszeitreihen (GZR, BZR, RZR). Bei den Mittelwertprojekten ist die Berechnung der zusätzlichen Zeitreihen über die gemittelten Zeitreihen wegen der Reduzierung von Messfehlern insbesondere bei den zeitlichen Ableitungen wie GZR und BZR vorteilhaft. Die Alternative ist, über vollständige Einzelschrittprojekte mit allen originalen und zusätzlichen Zeitreihen zu mitteln. Bei den Einzelschrittprojekten werden

natürlich die zusätzlichen Zeitreihen aus den einzelnen Schritten (Zeitreihen) berechnet. Durch das Ersetzen fehlender Daten durch gemittelte Zeitreihen sind die Mittelwertprojekte der Varianten KAP und KUP von den Daten her identisch, lediglich der Speicherort ist unterschiedlich (als Merkmal bzw. Datensatz).

Vorteil der KAP ist die Möglichkeit zur Auswertung funktionaler Zusammenhänge zwischen linker und rechter Körperseite, z.B. als Fuzzy-Regel „Wenn rechtes Knie und linkes Knie ... dann ...“. Allerdings können beim Einzelschrittprojekt der KAP ersetzte (nicht original gemessene) Datensätze vorkommen. Der Vorteil von KUP ist die simultane Auswertung der rechten und linken Körperseite, insbesondere für Pathologien, die unabhängig von der Körperseite auftreten. In der Orthopädie ist das insbesondere für diplegische Patienten zulässig [152, 159]. Da aber die Streuung eines Patienten (Intra-Streuung) kleiner ist als die zwischen den Patienten (Inter-Streuung), wird die Gesamtstreuung des Datensatzes bei der links/ rechts Kombination kleiner. Allerdings ist ein Vorteil, dass die Anzahl der Datensätze verdoppelt wird und somit die statistische Absicherung steigt. Ein weiterer Grund bezüglich Klassifikation für die links/ rechts Kombination ist die generalisiertere Auswertung unabhängig von der Körperseite, z.B. für Aussagen „die Patienten haben ein Spitzfußproblem“ im Gegensatz zu „die Patienten haben ein Spitzfußproblem der rechten Körperseite“, da sich die Pathologie auch auf beide Körperseiten auswirkt (Diplegie). Durch die beiden Varianten KAP und KUP können somit unterschiedliche klinische Aufgaben gelöst werden.

Der Vorteil der Mittelwertprojekte ist die bessere Recheneffizienz und übersichtlichere klinische Interpretation. Die dabei vernachlässigten Intra-Streuungen der einzelnen Patienten werden durch die SZR beibehalten. Eine übermäßige Reduktion von enthaltenen Informationen wird dadurch vermieden. Die Variabilität kann zudem durch die SZR formuliert werden. Im Folgenden werden vorzugsweise Mittelwertprojekte der KUP verwendet (diplegische Patienten, links-rechts Zusammenhänge sind klinisch eher sekundär).

Durch das einheitliche Anlegen aller Gangprojekte (einheitliche Strukturierung der Daten, einheitliche Merkmalsbezeichnungen, die ansonsten laborspezifisch sind, ...) lassen sich nun unterschiedliche Projekte kombinieren, z.B. Patienten und Referenzpersonen. Das erfolgt durch Anhängen des zusätzlichen Projektes als weitere Datensätze, die Merkmale werden entsprechend zugeordnet. Der gezielte Zugriff auf die so entstandenen Datensätze  $N$  wird durch Modifikation der Klassenmatrix  $\mathbf{Y}$  erreicht. Hierzu wird für die neuen Datensätze bei den bestehenden Klasseneinteilungen ein weiterer Klassenterm ergänzt und umgekehrt, siehe Abbildung 4.5. Die ursprünglichen Klasseneinteilungen bleiben somit erhalten. Beispielsweise wird die Klasse „Untersuchungszeitpunkt“ (die nur für die Patienten existiert) mit den existierenden Klassentermen „PRE“, „U1“ und „U2“ durch einen weiteren Klas-

sentern „unbekannt“ für alle neuen Datensätze ergänzt. Der Zugriff auf die Daten erfolgt durch Und-Verknüpfung (innerhalb einer Klasse) bzw. Oder-Verknüpfungen (zwischen den Klassen).

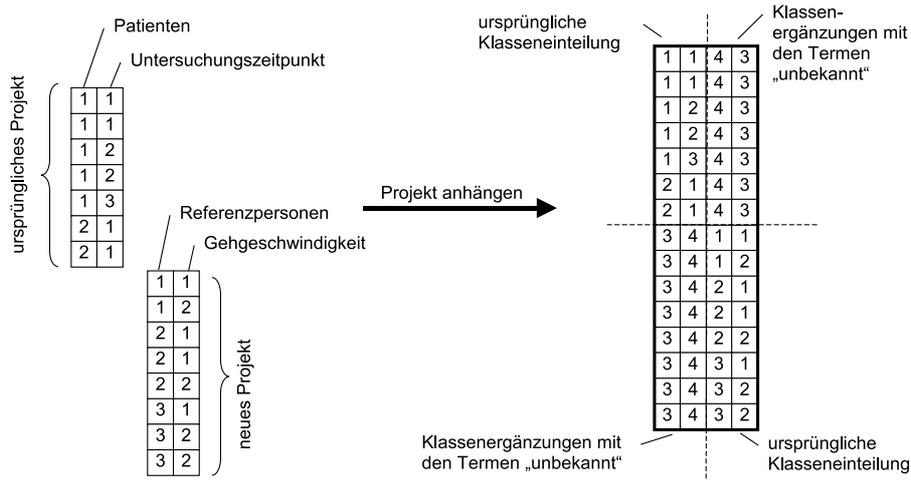


Abbildung 4.5: Beispiel zum Anhängen von Projekten.

Beispiel, siehe Abbildung 4.5: Die Klasseneinteilung  $\mathbf{Y}$  eines ursprünglichen Projektes für  $n = 1..7$  Datensätze beinhaltet „Patienten“ (1 = erster Patient, 2 = zweiter Patient) und „Untersuchungszeitpunkt“ (1 = PRE-therapeutisch, 2 = erste Nachuntersuchung, 3 = zweite Nachuntersuchung). Die Klasseneinteilung eines anzuhängenden Projektes sind „Referenzpersonen“ (1 = erste Person, 2 = zweite Person, 3 = dritte Person) und „Gehgeschwindigkeit“ (1 = langsam, 2 = mittel). Beim Projekt Anhängen werden alle Klassen kombiniert, so dass z.B. die Klasse „Untersuchungszeitpunkt“ mit einem neuen Term (4 = unbekannt) belegt wird.

Ein gezielter Zugriff (durch **und**- bzw. **oder**-Verknüpfungen) auf die Datensätze für die Formulierung eines Klassifikationsproblems „Charakterisierung von Patientenverhalten zum PRE-therapeutischen Zustand im Vergleich zur Referenz mit mittlerer Gehgeschwindigkeit“ lautet: Auswahl („Patienten“ = 1 **oder** 2 **oder** 3) **und** („Untersuchungszeitpunkt“ = 1 **oder** 4) **und** („Referenzpersonen“ = 1 **oder** 2 **oder** 3 **oder** 4) **und** („Gehgeschwindigkeit“ = 2 **oder** 3). Für das Klassifikationsproblem kann nun formal die Klasse „Untersuchungszeitpunkt“ oder „Gehgeschwindigkeit“ ausgewählt werden, da dadurch die Patienten bzw. Referenzpersonen zusammengefasst und voneinander getrennt werden.

## 4.3 Neue Funktionen in „Gait-CAD“

„Gait-CAD“ wird über ein graphisch unterstütztes Hauptfenster und eine Menüsteuerung bedient, siehe Abbildung 4.2. Hierbei konnten existierende Standardfunktionen implementiert werden, wie z.B.:

- Auswahlfunktionen mit sog. MATLAB „Listboxen“ oder direkte Nummerierungseingabe für die Auswahl von Zeitreihen, Einzelmerkmale, Klassen, Einstellungen zum Gebrauch von Daten (Anzeige: Referenz, Legenden, Nummerierung der Datensätze, Tabellen als T<sub>E</sub>X-Standard-Protokolle, Linienstärken, Schwarz/ Weiß Modus, ...),
- Bewertung von Merkmalen: Multi- und univariate Varianzanalysen, (M)ANOVA, informationstheoretische Maße, t-Test, Korrelations- und Regressionsanalysen,
- Überwachter Fuzzy-Klassifikator über eine Export-Schnittstelle zur bestehenden Softwaretoolbox „KAFKA – Karlsruher Fuzzy-Modellbildungs-, Klassifikations- und datengestützte Analyse-Toolbox“ [108],
- unterschiedliche Visualisierungsunterstützungen.

Zudem sind neue Funktionen für die Analyse der Gangdaten erforderlich, die in der vorliegenden Arbeit implementiert und realisiert sind. Die neuen Funktionen stützen sich auf die in Kapitel 3 vorgestellten und modifizierten Verfahren. Diese sind im Einzelnen:

- Vorverarbeitung durch einheitliche Merkmalsbezeichnung (Tabelle 3.5),
- Neue Strategie zum Speichern der Daten und Anhängen von Projekten (Abbildung 3.2 sowie Abschnitte 3.3 und 4.2); dadurch verbesserte Handhabung von Datensätzen und Klassen (Datenauswahl durch alle Klassen mit Und- bzw. Oder-Verknüpfungen, Abschnitt 3.3),
- Erzeugung eines verallgemeinerten Merkmalsraumes mit der Berechnung zusätzlicher Zeitreihen (Gl. (3.2) bis Gl. (3.9)) bzw. interpretierbarer Einzelmerkmale (Tabelle 3.4),
- Handhabung von Merkmalen über neues Konzept der Kategorisierungen: Erstellung von Kategorisierungen, Merkmalsauswahl anhand von Kategorien, Bewertung von Kategorien (Abschnitte 3.3 bis 3.5),
- Einbezug von Apriori-Relevanzen (Abschnitt 3.6.2),
- Unüberwachte Klassifikation mit Fuzzy-Cluster-Verfahren (Gl. (3.27) bis Gl. (3.44) in Abschnitt 3.8).

Im Anhang D sind die in dieser Arbeit realisierten Funktionen (MATLAB m-Files) aufgelistet und es ist ein exemplarischer Auszug einer Funktion gezeigt.

# 5 Anwendung des neuen Data Mining Konzeptes

## 5.1 Überblick

In diesem Kapitel werden die in den vorherigen Kapiteln beschriebenen Methoden auf die Patientendaten angewendet. Die wesentliche Voraussetzung für eine klinische Akzeptanz ist die Interpretierbarkeit der Ergebnisse. Das wurde durch die „Nachbildung der klinischen Sprache“ erreicht. Dadurch findet der Kliniker Zugang zu den Methoden, kann die Ergebnisse interpretieren und validieren sowie erfolgreich anwenden [4, 41, 127, 175]. Je nach Pathologie stehen unterschiedliche klinische Problemstellungen im Vordergrund, die sich eng an den klinischen Aufgaben aus der Diagnose und Therapie orientieren (siehe Tabelle 1.1 und Abschnitt 1.2.1). Es ist ersichtlich, dass die reine automatisierte Klassifikation zur Diagnose mit deren Klassifikationsgütern klinisch absolut nicht im Vordergrund steht, da die Trennung zwischen gesundem und pathologischem Gehen ohne klinisches Wissen bereits durch einen Laien erkannt wird. Schwieriger und klinisch von großem Interesse ist das Erkennen (Auswahl charakteristischer Merkmale), was den Unterschied im Gangverhalten beschreibt. Die Daten sollen auf wenige informationstragende Merkmale bzw. Merkmalskombinationen reduziert werden, d.h. zu fragen ist: Wo sind die größten pathologischen Gangabweichungen der Patienten, was sind die typischen Symptome sowie charakteristische Verläufe in Zeitreihen und auf was muss der Kliniker bei der empirischen Analyse im Wesentlichen achten [125, 136]?

Hierzu wird mit steigendem Detaillierungsgrad das pathologische Gehen analysiert, siehe Abbildung 5.1. Dabei werden drei methodische Schwerpunkte durch

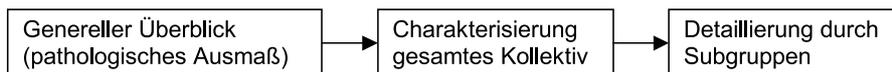


Abbildung 5.1: Überblick der Auswertung bei steigendem Detaillierungsgrad.

- die Quantifizierung des pathologischen Ausmaßes zur Qualitätsbestimmung und abstrakten Einschätzung des Gehens, d.h. wo sind wesentliche Abweichungen in den Kinematikzeitreihen und wie wirkt sich das auf die Dynamik aus (beruhend auf den Referenzabweichungszeitreihen aus Gl. (3.8)),
- die Charakterisierung des Krankheitsbildes zum Finden aussagekräftiger Verläufe in Zeitreihen zur gezielten Beschreibung der Pathologie, d.h. welche gemeinsamen Auswirkungen zeigen sich im Gangverhalten (Anwendung der Relevanzbewertung und Klassifikation anhand gegebener Klasseneinteilung auf den extrahierten Einzelmerkmalen) sowie
- das Finden von Subgruppen zur weiteren differenzierteren Charakterisierung, d.h. existieren unterschiedliche Gangstrategien oder Kompensationsmechanismen, um die Gangstörungen auszugleichen (Einsatz der Struktursuche ohne bekannte Klasseneinteilung)

bearbeitet. Das erfordert die Kombination mehrerer Verfahren wie in Abschnitt 3.9 beschrieben.

Mit diesen Diagnosewerkzeugen kann zudem der Erfolg der Therapie quantitativ dokumentiert und bewertet werden, z.B. wie wirkt sich die Therapie auf die Gangqualität aus, normalisieren sich die Symptome und charakteristischen Verläufe in Zeitreihen für das betreffende Krankheitsbild oder profitieren die Subgruppen unterschiedlich von der Therapie.

Es existieren bereits viele Forschungsarbeiten über ICP-Patienten [60, 136, 152], anhand derer die hier neu entwickelten Methoden zunächst validiert werden können. Darüber hinaus wird der Zugewinn neuer Erkenntnisse gezeigt, z.B. bessere Merkmale zur Beschreibung des Patientenkollektives, Hinweise für prognostische Aussagen, siehe Abschnitt 5.2.

Im Gegensatz dazu sind die SCI-Patienten noch wenig erforscht und erst in den letzten Jahren durch Ganganalysen näher untersucht [7, 57]. Mit den entwickelten Methoden sollen hierfür neue Erkenntnisse gewonnen werden, z.B. Einschätzung einer quantitativen Gangqualität, Auswirkungen der Therapie, siehe Abschnitt 5.3.

## 5.2 Infantile Cerebralparese (ICP)

Die ICP-Patienten (infantile Cerebralparese) sind durch eine gemeinsame Spitzfuß-Gangstörung gekennzeichnet, siehe Kapitel 2. Trotz der gemeinsamen Störung sind die Auswirkungen auf das Gangverhalten stark unterschiedlich. Die nachfolgend bearbeiteten Fragestellungen, wie die Charakterisierung des Kollektives oder das

Finden „offensichtlicher“ Subgruppen [150, 174], stellen in der Literatur große Herausforderungen dar [30, 125, 136, 159] und sind größtenteils mit empirischem Wissen gelöst. Daneben existieren einige ungelöste Vermutungen wie unterschiedliche Entwicklungen bei der Therapie evtl. auch in Zusammenhang mit „versteckten“, unbekanntem Subgruppen [152, 158].

Durch Anwendung der Diagnosewerkzeuge auf das gesamte Kollektiv lassen sich die stärksten pathologischen Ausmaße, wesentliche Charakteristiken und unterschiedliche Subgruppen quantitativ ermitteln. Auswirkungen und Zusammenhänge zwischen den Gelenken werden ebenfalls erkannt sowie Entwicklungen bei der Therapie. Aus den Erkenntnissen des gesamten Kollektives können individuelle Diagnosen abgeleitet werden. Für alle Patienten des hier zur Verfügung stehenden Datensatzes sind Messungen vor ICP,PRE und nach einer Botulinum-Toxin-Therapie ICP,POST erhoben. Dabei ist der klinisch relevante POST-Untersuchungszeitpunkt ca. 6 Wochen nach der Therapie ausgewertet.

### 5.2.1 Neues Auswerteverfahren für die Diagnose

#### Verallgemeinerte Quantifizierung des pathologischen Ausmaßes

Im klinischen Alltag schätzen erfahrene Kliniker durch subjektive Analyse der Gangcharts das pathologische Ausmaß der einzelnen Patienten ab, z.B. muss ein Gelenk gezielt behandelt werden, wenn der Verlauf wesentlich vom Referenzverhalten oder Patientenkollektiv abweicht (ist das ein typischer Patient oder müssen spezielle Maßnahmen eingeleitet werden). Abbildung 5.2 zeigt den sagittalen Knieverlauf einer Körperseite mit der entsprechenden Referenzabweichung eines Patienten mit der Identifizierungsnummer (ID) 50504. Damit kann die offensichtlich erhöhte Abweichung aus dem Referenzkorridor am Beginn, Mitte und Ende des Gangzyklus abgebildet werden. Mit Hilfe der Referenzabweichungszeitreihen aus Gl. (3.8) kann die sonst lediglich qualitativ durch den Experten eingeschätzte pathologische Abweichung quantifiziert werden.

Ein typischer Fehler bei der subjektiven Einschätzung ist das Erfassen der Referenzstreuungen bei unterschiedlichen Steigungen in Zeitreihenabschnitten. Bei starken Anstiegen scheint der Referenzkorridor „enger“ zu sein, obwohl die Streuung groß sein kann, da sie parallel zu den Achsenkoordinaten betrachtet werden muss, siehe Referenzstreuung zwischen 60% und 70% bzw. zwischen 80% und 90% des Gangzyklus in Abbildung 5.3 links. Dadurch ist die Referenzabweichung bei gleicher Distanz zum Referenzmittelwert (z.B. bei 56% und 65% des Gangzyklus) bei größerer Streuung kleiner und umgekehrt. Die gesamte mittlere Abweichung dieses Patienten beträgt für das Knie „MW STRI Knie sag OZR“=2.8, d.h. der Knieverlauf des Patienten weicht im Mittel das 2.8-fache der halben Referenzkorridorbreite ab, siehe auch Tabelle 5.1.

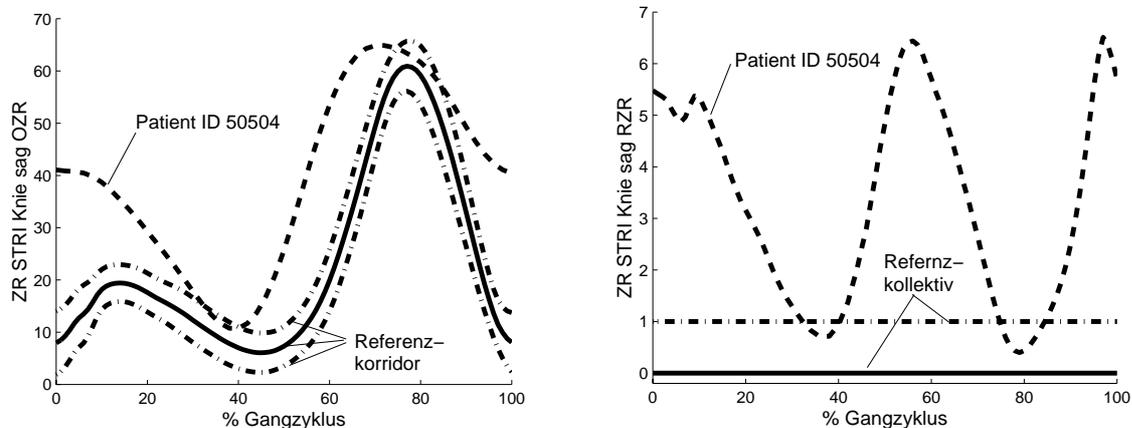


Abbildung 5.2: Sagittale Kniezeitreihe (links) und dessen Referenzabweichungszeitreihe (rechts) eines Patienten (ID 50504, rechte Körperseite). Das Referenzkollektiv ist durch  $\bar{Z}_{REF\ s}[k]$  durchgezogen bzw.  $\bar{Z}_{REF\ s}[k] \pm \tilde{Z}_{REF\ s}[k]$  punktiert-gestrichelt dargestellt.

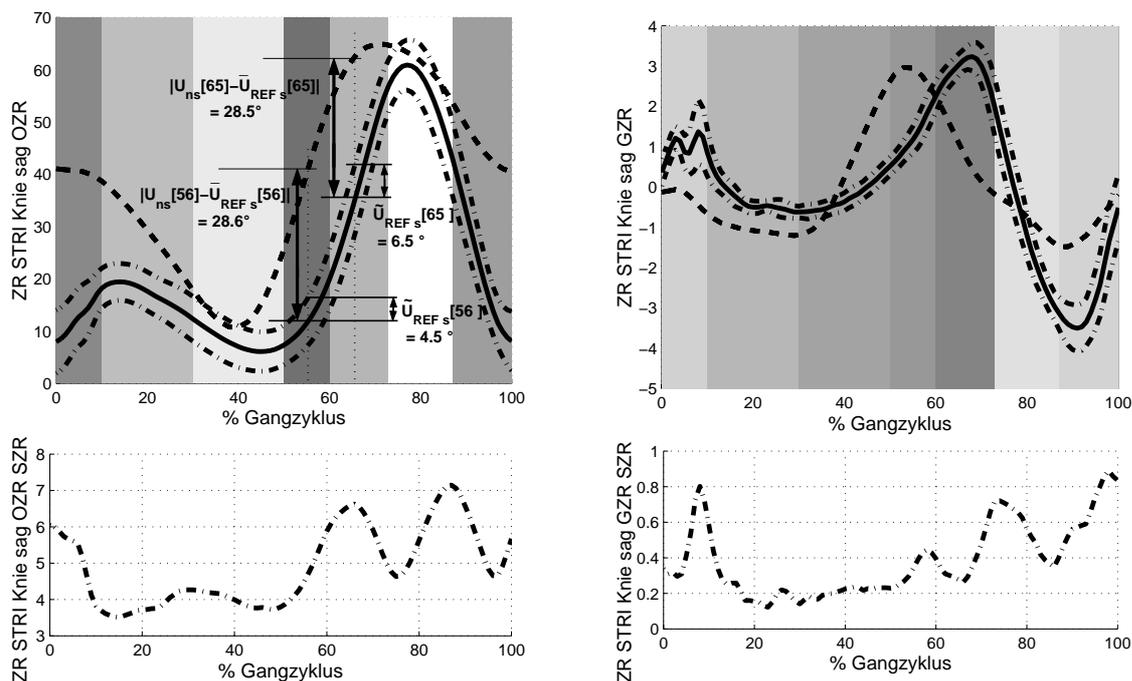


Abbildung 5.3: Erweiterte Darstellung der Kniezeitreihe (links, oben) und deren Geschwindigkeitszeitreihe (rechts, oben) entsprechend der Referenzabweichungen des Patienten (ID 50504) in den Gangphasen. Hohe Referenzabweichungen sind dunkler dargestellt. Die Referenzstreuungen  $\tilde{Z}_{REF\ s}[k]$  sind unten abgebildet.

Zusätzlich können die Zeitreihen bei der Visualisierung entsprechend der Referenzabweichung grau hinterlegt werden, um den Kliniker bei der subjektiven Analyse zu unterstützen, z.B. über alle sieben Gangphasen gemittelt, Abbildung 5.3. Hohe Abweichungen sind dabei dunkler dargestellt. Analog können auch die Geschwindigkeitszeitreihen mit deren Referenzabweichungen als grauer Hintergrund dargestellt werden, siehe Abbildung 5.3 rechts.

Subjektive Einschätzungen der wesentlichen pathologischen Gangstörungen eines gesamten Patientenkollektives sind nur bedingt und mit langjähriger Erfahrung bei bestimmten Patienten möglich [136, 152]. Durch Mittelung der Referenzabweichungszeitreihen über das gesamte Kollektiv lassen sich derartige Einschätzungen quantifizieren, siehe Tabelle 5.1. Die Patientencharts können zudem in Bezug zu den pathologischen Gangstörungen des gesamten Kollektives als graue Hinterlegung dargestellt werden, siehe Abbildung 5.4. Zur besseren Einschätzung dynamischer Effekte werden in dieser Arbeit zusätzlich Charts der Geschwindigkeitszeitreihen vorgeschlagen, die wiederum mit den pathologischen Ausmaßen des gesamten Patientenkollektives dargestellt werden können, siehe Abbildung E.1 im Anhang.

Gelenk/ Ebene	ICP, PRE (Patient ID 50504)			gesamt
	sagittal	frontal	transversal	
Becken OZR	$1.7 \pm 1.1$ (1.1)	$2.5 \pm 1.1$ (2.5)	$2.1 \pm 1.2$ (1.9)	$2.1 \pm 1.0$ (1.8)
Becken GZR	$2.7 \pm 1.0$ (2.1)	$2.3 \pm 0.7$ (2.8)	$1.6 \pm 0.7$ (0.9)	$2.2 \pm 0.7$ (1.9)
Hüfte OZR	$2.0 \pm 1.1$ (2.1)	$1.6 \pm 0.9$ (1.6)	$2.1 \pm 1.3$ (2.6)	$1.9 \pm 1.1$ (2.1)
Hüfte GZR	$2.5 \pm 0.9$ (2.3)	$2.0 \pm 0.7$ (1.1)	$1.5 \pm 0.3$ (1.2)	$2.0 \pm 0.5$ (1.5)
Knie OZR	$3.9 \pm 1.8$ (2.8)			$3.9 \pm 1.8$ (2.8)
Knie GZR	$3.6 \pm 0.9$ (2.4)			$3.6 \pm 0.9$ (2.4)
OSG OZR	$5.1 \pm 3.7$ (4.6)		$3.2 \pm 1.9$ (1.7)	$4.6 \pm 2.6$ (3.2)
OSG GZR	$2.7 \pm 0.8$ (2.5)		$2.4 \pm 0.9$ (1.0)	$2.6 \pm 0.8$ (1.8)
gesamt OZR	$3.1 \pm 1.2$ (2.6)	$2.0 \pm 0.9$ (2.0)	$2.4 \pm 0.9$ (2.3)	$2.5 \pm 0.8$ (2.3)
gesamt GZR	$2.9 \pm 0.6$ (2.3)	$2.2 \pm 0.9$ (2.0)	$1.9 \pm 0.3$ (1.1)	$2.3 \pm 0.5$ (1.8)

Tabelle 5.1: Gemittelte Referenzabweichungen der Kinematikzeitreihen (OZR) sowie deren Geschwindigkeitszeitreihen (GZR) des ICP-Kollektives und in Klammern eines Patienten ID 50504 jeweils zum PRE-therapeutischen Zustand.

Durch die Normierung der Abweichung bezüglich des Referenzverhaltens lassen sich sowohl verschiedene Bereiche einer Zeitreihe als auch unterschiedliche Zeitreihen miteinander vergleichen. Dadurch können auch Mittelwerte über mehrere Zeitreihen berechnet werden. So beträgt die gesamte Referenzabweichung der ICP-Patienten

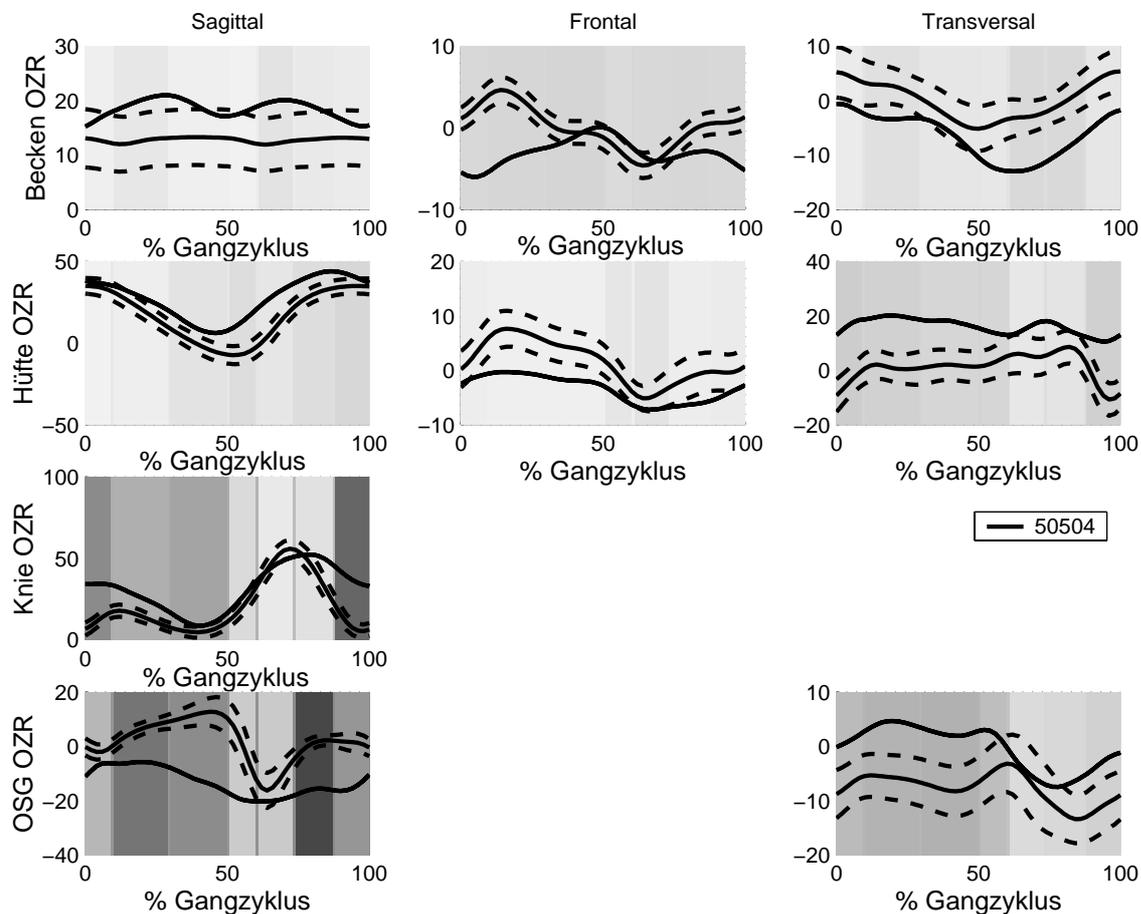


Abbildung 5.4: Neue Erweiterung eines Patientencharts (ID 50504) mit grauen Abstufungen entsprechend der pathologischen Gangabweichungen aller ICP-Patienten. Je dunkler die Hintergrundfarbe, desto größer ist die Gangstörung aller Patienten.

zum PRE-therapeutischen Zustand im Mittel  $2.5 \pm 0.8$ , wobei die sagittale Körperseite am stärksten mit  $3.1 \pm 1.2$  betroffen ist. Im Vergleich liegt beim Patient ID 50504 eine weniger stark ausgeprägte Pathologie vor, siehe Tabelle 5.1. Die wesentlichen Abweichungen betreffen das Knie und Sprunggelenk (OSG) beim gesamten Kollektiv wie auch bei diesem Patienten. Eine weitere detailliertere Übersicht der pathologischen Abweichungen ist ein neues Hierarchie-Konzept, das in dieser Arbeit entwickelt wurde, siehe Abbildung 5.5. Dadurch können die größten Abweichungen lokalisiert werden, wie z.B. große Abweichungen durch die Spastik im OSG, insbesondere in Mid Stance (MSt) oder beim Fußaufsetzen (Initial Contact, IC) in den

Geschwindigkeitszeitreihen des OSG. Der Grund ist die passive OSG Bewegung. Im Knie führen oftmals Fehlstellungen durch teilweise Kompensation (Terminal Swing, TSw) oder steifes Verhalten durch die Spastik insbesondere im Schwung (Mid Swing, MSw) zu großen Abweichungen. Derartige Aussagen decken sich mit den Expertenmeinungen, wobei sie in der vorliegenden Arbeit quantifiziert und systematisiert beschrieben sind, um auch versteckte Effekte zu finden, vgl. Kapitel 2.

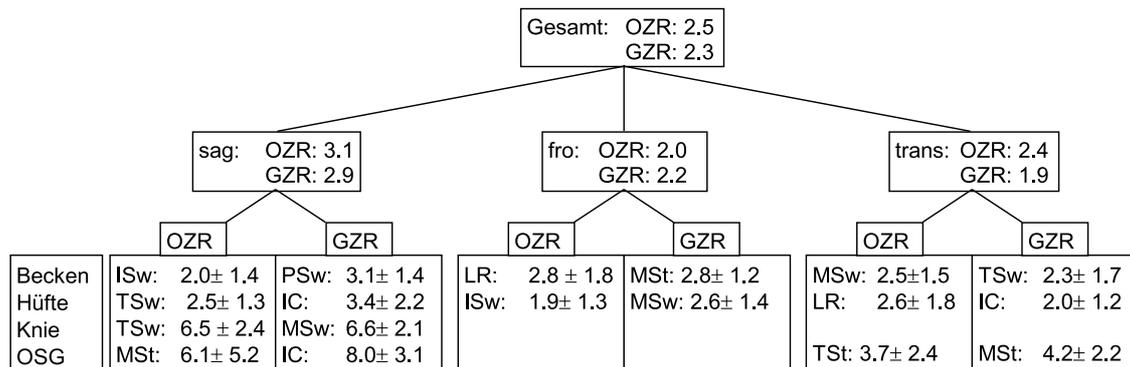


Abbildung 5.5: Hierarchie-Konzept mit dem pathologischen Ausmaß über das Gesamtkollektiv, vgl. graue Hinterlegung in Abbildungen 5.4 und E.1.

### Verallgemeinerte Charakterisierung des Krankheitsbildes

Eine genauere Betrachtung der Zeitreihenverläufe zur Beschreibung des Krankheitsbildes wird mit den überwachten Verfahren zur Relevanzbewertung und Klassifikation der extrahierten Einzelmerkmale erreicht. Das Ziel ist die objektiviertere Ermittlung wichtiger Merkmale, was in der Literatur oftmals beklagt wird: „Still the process of selecting the set of variables to use was subjective“ [136].

Extrahierte Einzelmerkmale aus Zeitreihen, die in der Literatur als etabliert verwendet werden, zeigt Tabelle 5.2. Die Extraktion dieser Merkmale ist durch langjährige Erfahrung mehrerer Kliniker empirisch gefunden. Mit diesen Merkmalen können im Folgenden die hier entwickelten Methoden verglichen und validiert werden. Aus weiterer Literatur [60, 115, 149, 162] existieren noch andere Einzelmerkmale, die pauschal aus Zeitreihen extrahiert (z.B. lediglich Mittelwert oder Extrema über die ganze Zeitreihe) und somit noch weniger geeignet sind, da der gezielte Zusammenhang zur Pathologie fehlt. Aus Sicht der Datenanalyse fallen bei vielen in der Literatur verwendeten Merkmalen zunächst drei kritische Punkte auf:

- Merkmale haben schlechte Relevanzen, z.B. L-15 oder L-16,

- Zwischen den Merkmalen existieren hohe Korrelationen, z.B. L-I bis L-IV,
- Merkmale beschreiben nicht die gewünschten funktionalen pathologischen Zusammenhänge, z.B. L-1 oder L-12.

Mit den hier entwickelten Methoden sind diese Punkte durch die rein automatisierte Extraktion von Einzelmerkmalen, die Verwendung weitgehend unabhängiger Merkmale (Rückstufung korrelierter Merkmale) und den Einbezug der Apriori-Relevanzen (zusätzliche Berücksichtigung nicht valider Merkmale) verbessert.

Nr.	Einzelmerkmal	$M_s$	$\rho_{\max}$
L-1	MAPO STRI Knie sag OZR	0.625	
L-2	SpW STRI Becken sag OZR	0.530	
L-3	MW IC Knie sag OZR	0.520	
L-4	Gehgeschwindigkeit	0.358	
L-5	MAX ST OSG sag OZR	0.254	0.90 zu L-6
L-6	MAX SW OSG sag OZR	0.239	0.90 zu L-5
L-7	MW STRI OSG tra OZR	0.210	
L-8	MW ST Hüfte tra OZR	0.170	
L-9	SpW STRI Knie sag OZR	0.156	0.72 zu L-13
L-10	Fußablösung (in % GZ, Standphase)	0.124	
L-11	MIN STRI Hüfte sag OZR	0.118	
L-12	MW STRI Becken sag OZR	0.106	
L-13	SpW STRI Hüfte sag OZR	0.071	0.72 zu L-9
L-14	Kadenz	0.061	
L-15	MIN SW Hüfte fro OZR	0.044	
L-16	MW STRI Becken tra OZR	0.000	
L-I	10% GA OSG sag OZR	0.338	0.89 zu L-IV
L-II	MAX ST OSG sag OZR	0.254	0.90 zu L-III
L-III	MAX SW OSG sag OZR	0.239	0.92 zu L-IV
L-IV	MW IC OSG sag OZR	0.146	0.92 zu L-III

Tabelle 5.2: Einzelmerkmale aus der Literatur mit Relevanzen  $M_s$  (informationstheoretische Maße, standardisierte Gangphasen) und Korrelationen untereinander mit  $\rho_{\max} > 0.7$ , oben aus [125, 136], unten aus [152].

Merkmale mit schlechten Relevanzen sind z.B. L-15: „MIN SW Hüfte fro OZR“ oder L-16: „MW STRI Becken tra OZR“. Mit der neuen Methode können rechnerbasiert derartige Merkmale als nicht geeignet erkannt werden [90, 94]. Dabei stellte sich zudem heraus, dass eine optimale Positionierung des Sakralmarkers (Marker am

Becken) unter Umständen schlecht gefunden werden kann. Das führt dann zu einem zusätzlichen Offset (konstante Abweichung) bei der Messung der Becken Zeitreihen. Dieser ist beim Mittelwert aus der Zeitreihen voll enthalten, so dass das Merkmal tendenziell nicht valide zur Bestimmung des Gehens wird.

Aus Sicht der Datenanalyse ist die Verwendung von abhängigen bzw. hoch korrelierten Merkmalen nicht erforderlich, da der Zugewinn von Informationen nicht gegeben ist. Zudem wird die klinische Diskussion bei einer Vielzahl von Merkmalen, die den einen gleichen Zusammenhang beschreiben, sehr mühsam, unübersichtlich und somit erschwert [175]. Aus diesem Grund werden Merkmale mit hohen Korrelationen in ihrer Relevanz zurückgestuft, vgl. Gl. (3.24) in Abschnitt 3.6.2.

Die Positionen von Extremwerten in den Zeitreihen sind unter Umständen nicht an funktionelle Gangphasen angepasst, wie z.B. das in der Literatur vorgeschlagene Einzelmerkmal L-1: „MAPO STRI Knie sag OZR“ über den gesamten Schritt. Das Merkmal soll die Position des stark ausgeprägten Maximums (für gesundes Gangverhalten) in der Schwungphase erfassen. Existieren allerdings bei Patienten Maxima in der Standphase, so wird der eigentliche funktionelle Zusammenhang mit diesem Merkmal falsch betrachtet, siehe Abbildung 5.6. Aus dem Grund sind derartige Merkmale hier mit der Apriori-Relevanz herabgestuft, da sie sehr kritisch zu prüfen sind, vgl. Gl. (3.23) in Abschnitt 3.6.2.

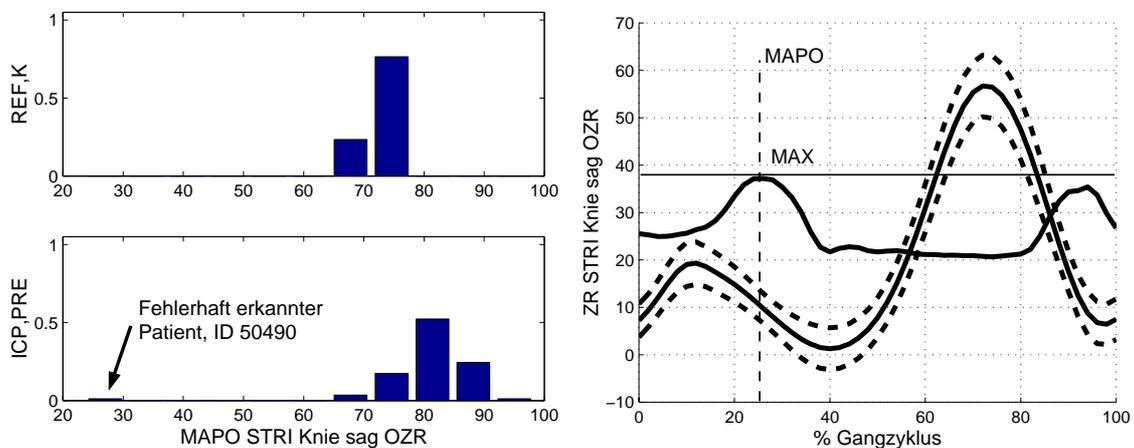


Abbildung 5.6: Links: Histogramm des Einzelmerkmals „MAPO STRI Knie sag OZR“, rechts: Fehlerhaftes Erkennen des funktionalen Zusammenhangs mit diesem Merkmal bei einem Patienten, ID 50490.

Aufgrund der Vielzahl von Einzelmerkmalen durch die systematische Berechnung sind auch sehr viele Einzelmerkmale geeignet, um die gegebenen Klassen voneinander zu trennen, z.B. die beiden Klassen ICP,PRE und REF,K. Allerdings sind diese

Einzelmerkmale oftmals hoch korreliert, unterschiedlich anfällig auf Messfehler und bei den Klinikern unterschiedlich bevorzugt. Daher kommt die Apriori-Relevanz und die Rückstufung korrelierter Einzelmerkmale zum Einsatz. Die dadurch erzielten Ergebnisse werden hier für die klinische Anwendung diskutiert und mit den bekannten Ergebnissen aus der Literatur verglichen. Die Diskussion basiert rein auf den durch die neue Methode ermittelten Einzelmerkmalen, klinisches Vorwissen wurde dabei nicht genutzt. Die Einzelmerkmale der unterschiedlichen Gangphasen können entweder durch standardisierte Phaseneinteilungen berechnet werden, oder teilweise durch individuelle Phasenerkennung, die oftmals mit aufwändiger Messdatenerfassung verbunden ist. Beide Varianten werden später miteinander verglichen. Weiterhin werden zur Bestimmung der Datenrelevanz die informationstheoretischen Maße mit der univariaten Varianzanalyse (ANOVA) verglichen. Beide Verfahren können mit der Apriori-Relevanz kombiniert werden.

Durch Verwendung der informationstheoretischen Maße, Einbezug der Apriori-Relevanzen und Rückstufung korrelierter Einzelmerkmale sind 16 relevante Einzelmerkmale ermittelt, die die Klassen ICP,PRE und REF,K trennen, siehe Tabelle 5.3. Die Merkmale enthalten zumindest teilweise unabhängige Informationen und sind in Kombination geeignet, um das gesamte Patientenverhalten zu beschreiben. Dadurch können auch einzelne Patienten, wie hier z.B. Patient ID 50504, anhand der gefundenen Einzelmerkmale mit der Referenz und dem Patientenkollektiv klinisch besser diskutiert und verglichen und zur Anwendung eingesetzt werden [175], vgl. auch Abbildungen 5.4 und E.1. Beispielsweise fällt auf, dass dieser Patient bei den meisten Merkmalen im Wertebereich des ICP-Kollektives liegt (d.h. typisches ICP-Verhalten aufweist) und bei manchen Merkmalen erheblich zum Schlechteren abweicht (relativ zur Referenz, z.B. einige Merkmale aus den Streuungszeitreihen wie „MW STRI OSG sag SZR“ oder „MIN STRI OSG sag GZR“). Bei keinem der charakteristischen Merkmale befindet sich der Patient im Referenzbereich.

Die Charakterisierung des gesamten Kollektives durch Einzelmerkmale steht in Bezug zum pathologischen Ausmaß. Die bereits wesentlich erkannten Gangstörungen spiegeln sich wieder, z.B. im OSG oder Knie. Bei Betrachtung der relativen Anzahl der Einzelmerkmale entsprechend ihrer Relevanz pro Kategorie lassen sich ähnliche qualitative Aussagen erhalten, siehe Abbildung 5.7. Hierbei ist zu erkennen, dass die Kategorie „sagittale Körperseite“ mehr relevante Einzelmerkmale hat als die anderen Kategorien (in Relation zur Anzahl von Einzelmerkmalen pro Kategorie): Bei informationstragenden Einzelmerkmalen (Relevanzen  $M_s > 0.1$ ) sind die schwarzen Balken (relative Anzahl Einzelmerkmale der sagittalen Körperseite) größer als bei den informationslosen Einzelmerkmalen (Relevanzen  $M_s$  zwischen 0.0 und 0.1). Die heuristisch ermittelten Werte der Apriori-Relevanzen stimmen daher gut mit den Ergebnissen überein (Herabstufung der frontalen und transversalen Ebene relativ

Einzelmerkmal ( $M_{s,ap}$ )	$M_{s,uk}$	$M_s$	ICP, PRE	Pat.	REF,K
Schrittlänge (1.0)	0.61	0.61 (0.61)	$0.3 \pm 0.1$	0.2	$0.6 \pm 0.1$
SpW STRI Becken sag OZR (1.0)	0.53	0.53 (0.53)	$8.0 \pm 3.3$	5.8	$2.9 \pm 0.8$
SpW MSw Knie Sag OZR (0.6)	0.42	0.70 (0.72)	$9.0 \pm 5.3$	10.0	$31.4 \pm 3.2$
MW STRI OSG sag SZR (0.6)	0.34	0.57 (0.58)	$6.1 \pm 3.6$	16.0	$1.8 \pm 0.7$
MW ST OSG sag OZR (0.8)	0.30	0.38 (0.41)	$-9.0 \pm 14.0$	-10.2	$5.5 \pm 2.5$
MW STRI Hüfte sag SZR (0.6)	0.29	0.48 (0.47)	$4.9 \pm 2.0$	8.6	$2.0 \pm 0.7$
MAX STRI Hüfte sag OZR (1.0)	0.28	0.28 (0.31)	$47.6 \pm 8.0$	44.1	$35.9 \pm 4.8$
MW STRI Becken tra SZR (0.48)	0.26	0.53 (0.52)	$6.7 \pm 2.8$	12.4	$2.1 \pm 0.8$
MAX STRI OSG tra OZR (0.8)	0.25	0.31 (0.31)	$11.7 \pm 13.6$	4.7	$-1.9 \pm 4.5$
MIN MSt OSG sag GZR (0.48)	0.23	0.48 (0.33)	$-0.6 \pm 0.5$	-0.4	$0.2 \pm 0.2$
MAX PSw Becken sag GZR (0.48)	0.22	0.46 (0.59)	$0.3 \pm 0.2$	0.2	$-0.0 \pm 0.1$
MIN STRI OSG sag GZR (0.8)	0.20	0.25 (0.28)	$-1.7 \pm 0.9$	-0.6	$-3.0 \pm 0.7$
MAX TSw OSG sag GZR (0.48)	0.19	0.40 (0.42)	$1.2 \pm 0.7$	1.1	$0.1 \pm 0.2$
SpW IC OSG sag OZR (0.6)	0.19	0.32 (0.28)	$1.2 \pm 0.7$	1.8	$0.6 \pm 0.2$
MW STRI Hüfte tra SZR (0.48)	0.19	0.39 (0.39)	$5.7 \pm 4.5$	11.4	$1.9 \pm 0.6$
MW STRI Becken fro OZR (0.8)	0.17	0.22 (0.20)	$0.1 \pm 3.5$	-3.0	$0.0 \pm 1.0$

Tabelle 5.3: Charakteristische Einzelmerkmale mit Wertebereiche des ICP,PRE-Kollektives (86 Datensätze) im Vergleich zur Referenz (REF,K 20 Datensätze) mit standardisierten Gangphasen, Apriori-Relevanz  $M_{s,ap}$ , Rückstufung korrelierter Einzelmerkmale  $M_{s,uk} = M_s \cdot M_{s,ap} \cdot M_{s,ko}$  und Berechnung  $M_s$  durch informationstheoretische Maße, in Klammern ist  $M_s$  mit individuellen Phaseneinteilungen angegeben. Die Werte des Patienten ID 50504 sind ebenfalls angegeben.

zur sagittalen Ebene). Beim Becken (Abbildung 5.7 rechts) existieren nur wenige charakteristische Einzelmerkmale, vgl. geringere pathologische Abweichungen in Abbildungen 5.4 und E.1 als helle Grautöne dargestellt.

Im Vergleich zur Literatur fällt auf, dass mit der neuen Methode mehr Merkmale gefunden werden, die eine größere Relevanz haben, vgl. Tabelle 5.2 mit 5.3. Das 16. Merkmal hat mit  $M_s = 0.22$  eine höhere Relevanz als das siebte Merkmal L-7 aus der Literatur. Im Folgenden werden die wichtigsten Merkmale im Einzelnen diskutiert und mit denen aus der Literatur verglichen.

Bei den Patienten ist die Schrittlänge mit  $0.3 \pm 0.1$  geringer als bei vergleichbaren Referenzpersonen mit  $0.6 \pm 0.1$ . Dieses Einzelmerkmal ist mit der Doppelschrittlänge hoch korreliert ( $\rho = 0.98$ ), die allerdings eine Datenrelevanz von  $M_s = 0.558$  hat und somit durch  $M_{s,ko} = 0$  herabgestuft ist.

Die Spannweite des Beckens („SpW STRI Becken sag OZR“) ist ein bereits in der Literatur übliches Merkmal, siehe Tabelle 5.2 und [125, 136, 147]. Bei den Patienten wird oftmals ein Kompensationsmuster „double bump“ verwendet, das durch

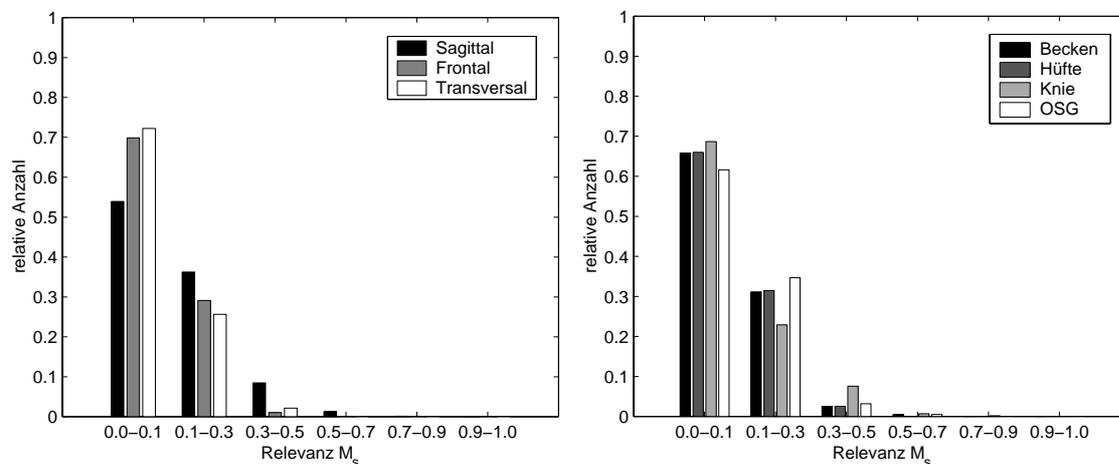


Abbildung 5.7: Bewertung von Kategorien: Relative Anzahl von Einzelmerkmalen entsprechend ihrer Relevanz und Kategorie „Körperebene“ (links) bzw. „Gelenk“ (rechts), siehe dazu auch in Abschnitt 5.3 hergeleitete Gangqualität.

je ein ausgeprägtes Maximum im Stand und Schwung charakterisiert und durch dieses Merkmal gut beschreibbar ist. Andere Merkmale erfassen selbstverständlich auch dieses Muster, wie z.B. „MAX STRI Becken sag GZR“ mit den Relevanzen  $M_{s,ap} = 0.8$  und  $M_s = 0.56$ . Aus Sicht der Datenanalyse eignet sich zwar das Merkmal geringfügig besser zur Klassentrennung ( $M_s = 0.53$  für „SpW STRI Becken sag OZR“) und beschreibt oftmals ähnliche Gangmechanismen (Ausnahmen: Patienten ohne ausgeprägtes „double bump“, aber mit kleinen, schnellen Auslenkungen des Oberkörpers, oder Patienten mit nur einem ausgeprägten Maximum im gesamten Schritt und folglich langsamen Auslenkungen des Oberkörpers, siehe Abbildung 5.8). Allerdings sind GZR für Kliniker weniger gut interpretierbar, in der Apriori-Relevanz herabgestuft und in diesem Fall mit „SpW STRI Becken sag OZR“ hoch korreliert ( $\rho = 0.81$ ), so dass es durch Rückstufung korrelierter Merkmale nicht in Tabelle 5.3 auftaucht. Die hier diskutierten Merkmale zeigen beispielhaft, dass nicht alle charakteristischen Besonderheiten aus den Referenzabweichungszeitreihen erkannt werden können. Beide Beckenmerkmale sind hoch relevant, obwohl die durchschnittliche Referenzabweichung eher unterdurchschnittlich ist.

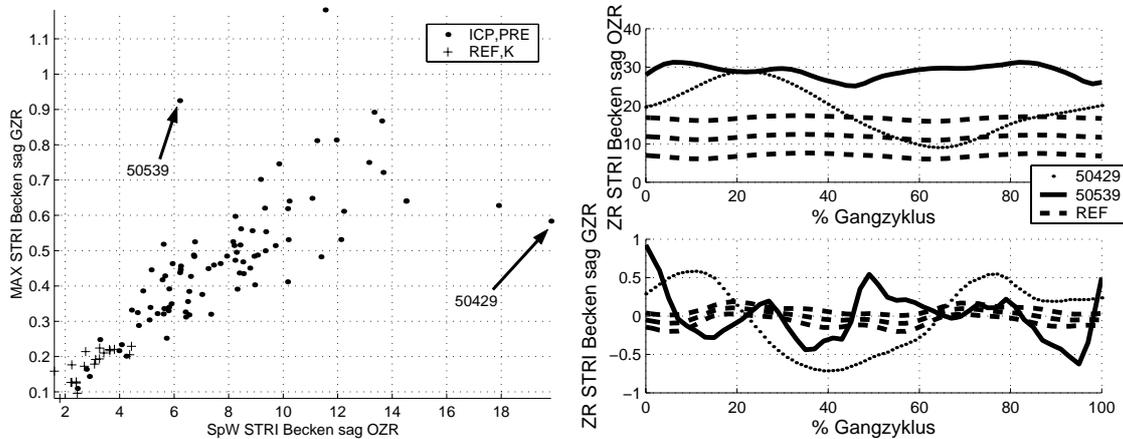


Abbildung 5.8: Diskussion von Einzelmerkmalen, links: „MAX STRI Becken sag GZR“ und „SpW STRI Becken sag OZR“, rechts: OZR und GZR des Beckens zweier Patienten.

Zwei der diskutierten Einzelmerkmale verwendet beispielsweise auch der Fuzzy-Klassifikator, siehe Abbildung 5.9. Die Fuzzy-Regel zeigt auch, dass beide Merkmale zur Unterscheidung notwendig sind. Patienten mit einer großen Schrittlänge weisen eine größere Spannweite im Becken auf, was auf einen Kompensationsmechanismus zur Erreichung größerer Schrittlängen hindeutet (Erhalten des Gleichgewichts). Hierbei ist leicht zu erkennen, dass eine fehlerfreie Klassifikation bereits mit wenigen Merkmalen zu erreichen ist, was in dieser Arbeit allerdings nicht im Vordergrund steht. Zu erkennen ist auch, dass die Verwendung von Merkmalskombinationen wichtig ist, um Patientenverhalten zu beschreiben. In der Literatur wurde das entweder durch Verwendung univariater Analysen vernachlässigt [3, 35] oder durch schwer interpretierbare Merkmalstransformation erreicht [14, 39]. In dieser Arbeit werden die Merkmale daher nicht weiter transformiert, aber in Kombination bewertet.

Die Patienten haben oftmals ein sehr steifes Knie, das sich insbesondere in der Schwungphase zeigt, da hier keine passive Bewegung vorkommt (durch die Methode mit „SpW MSw Knie Sag OZR“ erkannt). Allerdings gibt es beim Knieverlauf unterschiedliche Subgruppen, z.B. Recurvatum, milder und starker Kauergang, wie später bei den Subgruppen gezeigt. Dabei haben die Patienten teilweise große Bewegungsspannen in der Standphase (durch Überstreckung oder passive Bewegung), so dass die Verwendung in der Literatur [125, 136] von „SpW STRI Knie sag OZR“ über den gesamten Schritt eher ungünstig ist (zu sehen an der schlechteren Datenrelevanz  $M_s = 0.156$  in Tabelle 5.2).

Die Apriori-Relevanz fördert in der Praxis die Priorisierung von besser interpre-

Die Beispiele für Referenzpersonen (REF) sind dadurch charakterisiert, dass die Schrittlänge meistens größer als sonst ist: gelegentlich groß (zwischen 0.45 m und 0.6 m) und gelegentlich sehr groß (größer als 0.6 m). Weiterhin gilt für die Beispiele, dass die Spannweite der Beckenkipfung während des Schrittes (SpW STRI Becken sag OZR) meistens kleiner als sonst ist: gelegentlich sehr klein (kleiner als  $3^\circ$ ) und gelegentlich klein (zwischen  $3^\circ$  und  $5^\circ$ ). Aus den Aussagen lässt sich eine Regel aufbauen, die alle Fälle von Referenzpersonen (REF) beschreibt: WENN die Schrittlänge groß bis sehr groß (größer als 0.45 m) ist UND die Spannweite der Beckenkipfung während des Schrittes (SpW STRI Becken sag OZR) sehr klein bis klein (kleiner als  $5^\circ$ ) ist, DANN FOLGT DARAUS immer Referenzpersonen (REF).

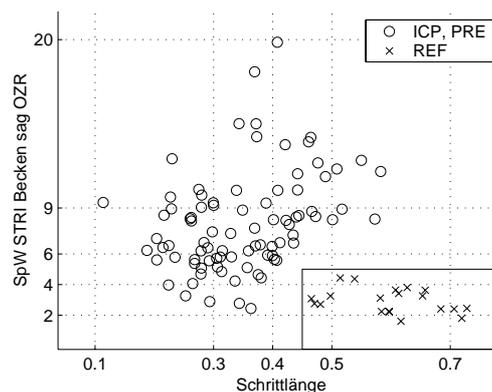


Abbildung 5.9: Links: Automatisiert generierter Erklärungstext der Klasse REF [89, 107]. Die Negation kann durch die de Morganschen Gesetze erreicht werden, um die Patienten zu beschreiben. Rechts: Visualisierung der Regel „WENN (Schrittlänge=PG oder PSG) UND (SpW STRI Becken sag OZR=PSK oder PK) DANN Klasse=REF“.

tierbaren oder messtechnisch valideren Merkmalen. Deren Festlegung beeinflusst das Ergebnis nur sehr gering hinsichtlich einer subjektiven Vorauswahl, das am Beispiel der Streuungszeitreihe (SZR) mit  $M_{s,ap} = 0.6$  zu sehen ist. Beispielsweise ist durch „MW STRI OSG sag SZR“ eine erhöhte Variabilität bei Patienten gegenüber der Referenz erkannt worden, trotz erheblicher Rückstufung durch die Apriori-Relevanz. Die erhöhte Variabilität erstreckt sich auch auf andere Gelenke, d.h. die Patienten haben einen sehr ungleichmäßigen, schlecht reproduzierbaren Gang. Durch die neue Methode der vorliegenden Arbeit werden damit auch weniger etablierte Merkmale vorgeschlagen, die als klinisch sehr wertvoll eingestuft worden sind [175]. Bemerkenswert ist auch, dass der Mittelwert („MW STRI OSG sag SZR“) eine größere Relevanz ( $M_s = 0.58$ ) gegenüber beispielsweise dem Maximum („MAX STRI OSG sag SZR“ mit  $M_s = 0.36$ ) aufweist. Der Grund ist, dass die Referenz im Schwung ebenfalls eine erhöhte Variabilität hat, vgl. Abbildung 5.3. Derartige Zusammenhänge können

mit der neuen Methode sehr gut erfasst und der klinischen Diskussion zur Verfügung gestellt werden.

Klinisch sehr wichtige Einzelmerkmale sind Mittelwerte der OSG-Zeitreihen, die mit der neuen Methode durch „MW ST OSG sag OZR“ ebenfalls erkannt worden sind. Das ist mit den Einzelmerkmalen über den ganzen Schritt oder nur Schwung hoch korreliert ( $\rho_{\max} = 0.904$ ). Der Grund, dass in Tabelle 5.3 das Merkmal über den Stand ermittelt wurde, liegt an geringfügig besseren Relevanzen im Bereich der Nachkommastellen des hier verwendeten Datensatzes. Mit einem anderen Referenzkollektiv ist beispielsweise das Merkmal über den ganzen Schritt relevanter. Aus Sicht der Datenanalyse ist die Verwendung aller drei Merkmale (siehe Tabelle 5.2) wegen hoher Korrelationen nicht erforderlich.

Im Vergleich zur Literatur werden weitere bekannte oder ähnliche aber bessere Einzelmerkmale durch die neue Methode automatisiert gefunden. Beispielsweise ist das durch die neue Methode gefundene „MAX STRI Hüfte sag OZR“ mit  $M_s = 0.279$  besser zur Beschreibung der Patienten geeignet als die aus der Literatur verwendeten „MIN STRI Hüfte sag OZR“ mit  $M_s = 0.118$  und „SpW STRI Hüfte sag OZR“ mit  $M_s = 0.071$ , die in Kombination die gleiche Information beinhalten.

Weiterhin findet die Methode auch weniger etablierte Merkmale, die in der Literatur und im klinischen Einsatz vernachlässigt wurden. Dazu zählen die erwähnten SZR oder auch die Geschwindigkeitszeitreihen (GZR). Dynamische Effekte im OSG sind in der Literatur weniger berücksichtigt, siehe z.B. „MIN STRI OSG sag GZR“ das infolge der Spastik ein steifes Verhalten ausdrückt und bei Patienten mit  $-1.7 \pm 0.9$  gegenüber der Referenz mit  $-3.0 \pm 0.7$  reduziert ist. Das Merkmal drückt das Abstoßverhalten („push off“) im Psw (negative Steigung der Referenz im OSG bei 50%-60% des Gangzyklus) aus, das bei Patienten nicht ausgeprägt ist, siehe Abbildungen E.1 und E.1 sowie später bei den Subgruppen.

In derartigem Detaillierungsgrad lassen sich nun prinzipiell die weiteren Einzelmerkmale interpretieren und diskutieren.

Die Leistung der Methode konnte dergestalt erfolgreich aufgezeigt werden [41, 90, 94, 127, 175], dass der Anwender besseren Zugang zur Analyse komplexer Daten hat. Allerdings sind die in Tabelle 5.3 angegebenen Einzelmerkmale nicht als endgültige Auswahl zu werten. Durch die Rückstufung korrelierter Merkmale werden nur geringfügig schlechtere Merkmale bezüglich des verwendeten Datensatzes herabgestuft, d.h. die Abhängigkeit vom verwendeten Datensatz ist groß. Somit empfiehlt es sich, auch die zurückgestuften Merkmale klinisch zu prüfen und zu diskutieren ggf. mit weiteren Datensätzen entsprechender Pathologie zu vergleichen. Außerdem kann die Festlegung der Apriori-Relevanz weitere klinische Faktoren mit einbeziehen und somit ggf. in ihren Werten leicht modifiziert werden. Eine endgültige Festlegung derartiger Werte ist aber nicht Gegenstand der Arbeit.

Ein methodischer Vergleich zwischen einer individuellen Phaseneinteilung und standardisierten Gangphasen zeigt, dass die meisten gefundenen Einzelmerkmale identisch sind, siehe Tabelle 5.3 und im Anhang Tabelle E.2. Sie sind auch unter klinischen Gesichtspunkten die wichtigsten, wie bereits diskutiert. Interessant sind die beiden zusätzlich gefundenen Einzelmerkmale „MIN SW Knie sag OZR“ und „MW LR Knie sag GZR“, die sogar Informationen enthalten, um ICP-Subgruppen zu unterscheiden, wie später noch gezeigt wird. Allerdings fallen diese Merkmale bei den standardisierten Gangphasen des verwendeten Datensatzes lediglich der Rückstufung korrelierter Merkmale zum Opfer<sup>1</sup>. Beide sind mit  $M_s = 0.45$  bzw.  $M_s = 0.73$  dennoch relevant. Weiterhin konnten Einzelmerkmale bei der individuellen Phaseneinteilung gefunden werden, die sich auf bestimmte Gangphasen in der OSG GZR beziehen. Deren Verwendung ist allerdings kritisch zu betrachten, da sie eine hohe Anfälligkeit auf Rauschen haben und klinisch kritisch zu prüfen sind (geringe Plausibilität). Somit wird hier die individuelle Phaseneinteilung nicht weiter verfolgt.

Ein anderer methodischer Vergleich ist die Berechnung der Datenrelevanz  $M_s$  zwischen informationstheoretischen Maßen und univariater Varianzanalyse (ANOVA), siehe Tabellen 5.3 und im Anhang Tabelle E.3. Hierbei finden sich ebenfalls die wichtigsten relevanten und bereits diskutierten Merkmale wieder, z.B. „SpW MSw Knie sag OZR“ oder „SpW STRI Becken sag OZR“. Bedingt durch den verwendeten Datensatz und die Rückstufung korrelierter Merkmale werden teilweise andere Merkmale gefunden, die aber hoch korreliert sind, wie z.B. „SpW LR OSG sag OZR“ und „SpW IC OSG sag OZR“ mit  $\rho = 0.81$ . Weitere Merkmale wie „MW ST Knie sag GZR“ sind bei den informationstheoretischen Maßen durch die Rückstufung korrelierter Merkmale zurückgestuft, aber dennoch relevant ( $M_s = 0.36$  mit informationstheoretischem Maß). Somit sind für die Daten beide Varianten der Relevanzbewertung einsetzbar und liefern nahezu identische Werte. Im Folgenden werden allerdings die informationstheoretischen Maße (mit standardisierten Gangphasen) verwendet.

### Verbessertes Finden von Subgruppen

Das Finden von Subgruppen bei den ICP-Daten ist sehr mühsam [12, 124, 174], aber nicht aussichtslos [92]. Ungeklärte Fragen sind hierbei:

- In welchen Zeitreihen existieren funktionelle Subgruppen?

---

<sup>1</sup>Das Einzelmerkmal „MW LR Knie sag GZR“ korreliert mit  $\rho = 0.75$  zu „MW MSw Knie sag GZR“, dieses wiederum mit  $\rho = 0.740$  zu „SpW MSw Knie sag OZR“, so dass die beiden ersten zurückgestuft werden.

- Wieviele Subgruppen existieren?
- Gibt es Zusammenhänge zwischen den Zeitreihen?

Effektive Lösungsansätze können mit den in Kapitel 3 entwickelten Verfahren zur Struktursuche ohne bekannte Klasseneinteilung erreicht werden. Allerdings können diese Fragen bei den ICP-Daten nicht völlig beantwortet werden, da interaktive oder heuristische Lösungsvarianten herbeigezogen werden müssen, die eine vollständige automatisierte Lösung verhindern.

Dazu werden nachfolgend verschiedene Varianten vorgestellt mit Verwendung der Kollektive ICP,PRE (86 Datensätze) und REF,K (20 Datensätze). Eine Lösung wurde bereits in Abschnitt 3.8 gezeigt, mit der Einteilung von vier Gruppen im Knie (eine Referenzgruppe und drei ICP-Subgruppen), siehe Abbildungen 3.11 und 3.12 und im Folgenden als SUB1 bezeichnet. Analog dazu können vom Anwender weitere Zeitreihen ausgewählt werden, wie z.B. „ZR STRI OSG sag OZR“, SUB2 siehe Abbildung 5.10. Die Validierungsmaße liefern plausible Hinweise auf die Cluster-Anzahl. Die Subgruppen können bei diesem Beispiel über die Zeitreihe mit allen  $K$  Abtastzeitpunkten gefunden werden, da das Problem relativ einfach ist (keine „versteckten“ Subgruppen). Die Ergebnisse stimmen mit den empirisch bekannten Gruppierungen überein, siehe Abschnitt 2.3 und [124, 151, 174]. Beispielsweise ist die zunehmende Dorsalflexion am Beginn des Gangzyklus aller Patientensubgruppen zu erkennen (Cluster 1 bis 3) sowie die erhöhte Abweichung zur Referenz (insbesondere Cluster 1 und 2). Diese Gelenkfehlstellungen werden auch bei den Subgruppen über Zeitreihenkombinationen gefunden, wie nachfolgend gezeigt wird.

Weiterhin können auch vielversprechend scheinende Kombinationen von Zeitreihen ausgewählt werden, wie z.B. „ZR STRI Knie sag OZR“ und „ZR STRI OSG sag OZR“, SUB3 siehe Abbildung 5.11. Aufgrund komplexer Zusammenhänge zwischen den Zeitreihen müssen die Cluster durch die Transformation mit der Hauptkomponentenanalyse berechnet werden (also durch erste und zweite „HK STRI Knie sag OZR“ und „HK STRI OSG sag OZR“). Die bereits berechneten Subgruppen im Knie (Abbildung 3.11) und OSG (Abbildung 5.10) können auch in der Kombination gefunden werden, allerdings muss die Cluster-Anzahl auf  $C = 5$  erhöht werden (vgl. nichtkompatible Cluster aus Abschnitt 3.8.2). Diese Anzahl ist auch durch  $S$  und  $u_{\text{REF}}$  empfohlen (Abbildung 5.11, links), bei einer anderen Anzahl werden bekannte Gruppen nicht gefunden oder funktionell ähnliche Gangbilder beschrieben. Das bedeutet, dass eine Cluster-Anzahl von  $C = 4$  (wie bei separaten Clustern über OSG und Knie) nicht ausreicht, um die Kombinationseffekte zu finden. Diese sind Recurvatum in Kombination mit starker Plantarflexion (Cluster 1). Weitere sind hier milder Kauergang mit starker Plantarflexion (Cluster 2) bzw. schwach ausgeprägter milder Kauergang mit geringer Referenzabweichung im OSG (Cluster 3) oder star-

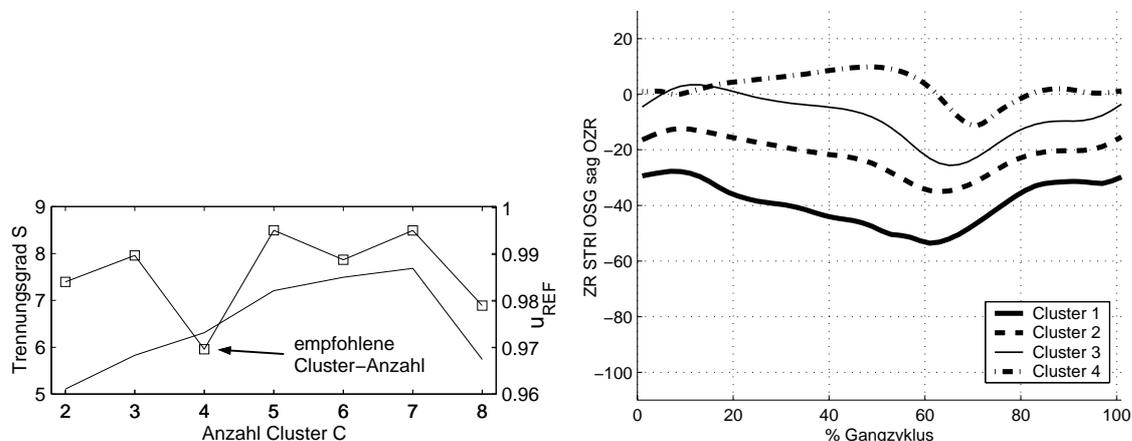


Abbildung 5.10: Cluster-Ergebnisse bei der „ZR STRI OSG sag OZR“ (SUB2), Trennungsgrad  $S$  ( $\square$ ) und Finden der Referenz  $u_{REF}$  (links), Cluster-Zentren mit den aus  $S$  und  $u_{REF}$  automatisiert empfohlenen Cluster-Anzahl von  $C = 4$  (rechts).

ker Kauergang mit kleiner Referenzabweichung im OSG (Cluster 5)<sup>2</sup>. Qualitative Zusammenhänge wurden in der Literatur lediglich empirisch vermutet [12, 174]. Der quantitative Nachweis erfolgt durch die vorliegende Arbeit.

Eine Vergrößerung des Suchraums bei automatisiertem Finden von Kombinationen von Zeitreihen ist in Tabelle 5.4 gezeigt. Hierbei wird bei festgelegter Cluster-Anzahl diejenige Zeitreihe ausgewählt, die den kleinsten Trennungsgrad  $S$  aufweist und die Voraussetzung der gefundenen Referenz mit  $u_{REF} > 0.9$  erfüllt. Für zwei Cluster-Zentren erfüllt „HK STRI Hüfte tra SZR“ (Merkmale: erste und zweite Hauptkomponenten der Streuungszeitreihe des transversalen Hüftgelenkwinkels) die beiden Bedingungen am besten. Durch zusätzliche Verwendung der „HK STRI Hüfte tra GZR“ wird die beste Zweier-Kombination anhand der beiden Bedingungen gefunden usw. Bei zwei Cluster-Zentren finden die Cluster die bereits bekannten Trennungen zwischen Referenz und Patienten, insbesondere die SZR (die bei der überwachten Relevanzbewertung große  $M_s$  zur Klassentrennung ICP,PRE und REF,K aufweisen). Bemerkenswert sind die gefundenen Kombinationen mit der transversalen Hüfte und OSG für alle Cluster-Anzahlen, die bereits empirisch vermutet wurden und teilweise auf Messbedingungen zurückzuführen sind.

Sehr interessante Ergebnisse sind bei  $C = 4$  bzw.  $C = 5$  Cluster-Zentren zu erhalten. Von klinischer Seite werden dabei eindeutig die Referenz als eine Gruppe

<sup>2</sup>Die Referenz ist durch das Cluster 4 eindeutig gefunden

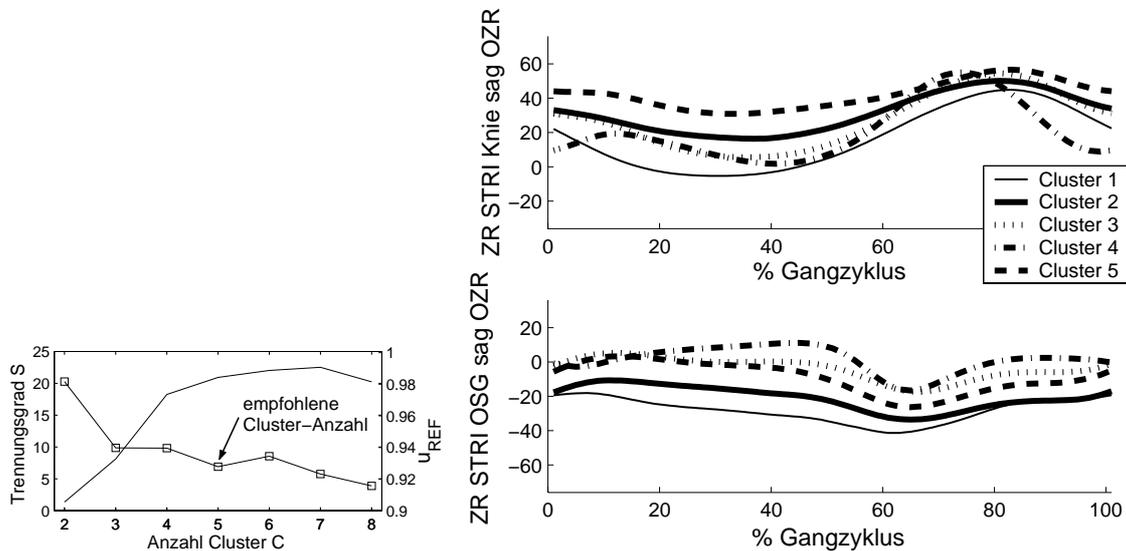


Abbildung 5.11: Cluster-Ergebnisse bei „HK STRI Knie sag OZR“ und „HK STRI OSG sag OZR“ (Kombination der Knie- und OSG-Zeitreihen, SUB3): Trennungsgrad  $S$  ( $\square$ ) und Finden der Referenz  $u_{REF}$  (links) sowie Cluster-Zentren mit der automatisch empfohlenen Cluster-Anzahl  $C = 5$  (rechts).

und mindestens zwei unterschiedliche Patienten-Subgruppen gefunden. Bei  $C = 4$  Cluster-Zentren wird die bereits dargestellte Kombination aus Knie und OSG gefunden, SUB4 siehe Abbildung 5.12 und fett gedruckte Kombination in Tabelle 5.4. Die anderen Zeitreihen beeinflussen dabei die Cluster-Anzahl mit  $C = 4$ . Dadurch werden allerdings bereits erkannte Effekte (insbesondere schwach ausgeprägte) vernachlässigt. Darüber hinaus wird der Zusammenhang zwischen OSG sag und Hüft flexion gefunden, der als biomechanische Kompensation vermutet wurde: Plantarflexion des OSG muss durch einen Beckenschiefstand kompensiert werden, der eine erhöhte Hüft-Adduktion hervorruft (z.B. Cluster 1 in Abbildung 5.12). Allerdings ist der Zusammenhang mit dem Knie sag gekoppelt, der die Plantarflexion durch das Recurvatum aufhebt, siehe Cluster 2. Cluster 4 zeigt einen milden Kauergang im Knie und eine geringe Referenzabweichung in der Hüft-Adduktion und dem OSG (eine geringe Plantarflexion muss nicht durch erhöhten Beckenschiefstand und dem Hüft-Adduktions-Ausgleich kompensiert werden). Die beim Clustern gefundenen GZR trennen im Wesentlichen die Referenz (Cluster 3) von allen Patienten. Dadurch wird der Trennungsgrad  $S$  verbessert, so dass die Auswahl der Zeitreihen beeinflusst wurde (insbesondere „ZR STRI Hüfte tra GZR“, „ZR STRI Knie sag GZR“

	Zwei Cluster-Zentren	$S(u, 2)$	Drei Cluster-Zentren	$S(u, 3)$
1 ZR	HK STRI Hüfte tra SZR	1.94	HK STRI Hüfte tra SZR	1.74
2 ZR	& HK STRI Hüfte tra GZR	2.37	& HK STRI Hüfte tra GZR	2.80
3 ZR	& HK STRI OSG tra GZR	3.19	& HK STRI Becken tra SZR	7.14
4 ZR	& HK STRI OSG sag GZR	4.26	& HK STRI OSG tra SZR	9.41
5 ZR	& HK STRI OSG tra SZR	5.67	& HK STRI OSG tra GZR	11.98
6 ZR	& HK STRI Hüfte sag GZR	7.28	& HK STRI Hüfte sag GZR	16.51
7 ZR	& HK STRI Becken sag GZR	9.91	& HK STRI Becken fro SZR	20.60
8 ZR	& HK STRI OSG sag SZR	12.90	& HK STRI Hüfte sag SZR	19.93
	Vier Cluster-Zentren	$S(u, 4)$	Fünf Cluster-Zentren	$S(u, 5)$
1 ZR	<b>HK STRI Knie sag OZR</b>	3.23	HK STRI OSG tra OZR	3.12
2 ZR	<b>&amp; HK STRI Hüfte tra GZR</b>	3.63	& HK STRI Hüfte tra OZR	3.88
3 ZR	<b>&amp; HK STRI Knie sag GZR</b>	6.11	& HK STRI Hüfte tra GZR	4.74
4 ZR	<b>&amp; HK STRI OSG sag OZR</b>	11.18	& HK STRI OSG tra GZR	5.26
5 ZR	<b>&amp; HK STRI Hüfte fro OZR</b>	13.15	& HK STRI OSG sag OZR	8.68
6 ZR	<b>&amp; HK STRI OSG sag GZR</b>	16.90	& HK STRI OSG sag GZR	9.41
7 ZR	& HK STRI OSG tra GZR	31.49	- keine Referenz gefunden -	-
8 ZR	& HK STRI Hüfte tra OZR	75.09	- keine Referenz gefunden -	-

Tabelle 5.4: Automatisiert gefundene Kombinationen von Zeitreihen zum Finden von Subgruppen bei einer Cluster-Anzahl von  $C = 2..5$ . Die Zeitreihen wurden jeweils durch einen kleinsten Trennungsgrad  $S$  und der Voraussetzung  $u_{\text{REF}} > 0.9$  gefunden. Fett gedruckt ist Kombination SUB4.

und „ZR STRI OSG sag GZR“).

Es kommt bei den realen Daten vor, dass die erste Zeitreihe lediglich durch geringfügig bessere Werte in  $S$  ausgewählt wird, d.h. eindeutige Präferenzen hinsichtlich der Subgruppen existieren demnach nicht. Die nachfolgend ausgewählten Zeitreihen hängen teilweise vom Startergebnis ab. Beispielsweise können für  $C = 5$  Cluster-Zentren unter Ausschluss von OSG tra (nicht valide messbar) klinisch relevante Ergebnisse erzielt werden, siehe Tabelle 5.5 und im Anhang Abbildung E.4. Der geringfügige Unterschied in  $S = 3.12$  bzw.  $S = 3.20$  hat Auswirkung auf das ganze Ergebnis. Hierbei lassen sich bereits bekannte Zusammenhänge erkennen (z.B. starke Plantarflexion des OSG mit tendenzieller Knieüberstreckung, die eine erhöhte Streuung im OSG zeigen). Allerdings überlagern sich die Effekte, so dass die Auswirkungen auf das Knie in dieser Kombination sehr schwach sind.

Weiterhin kann bei Vorgabe einer bestimmten Zeitreihe nach heuristisch vermuteten Zusammenhängen gesucht werden, z.B. Zusammenhänge mit dem „double

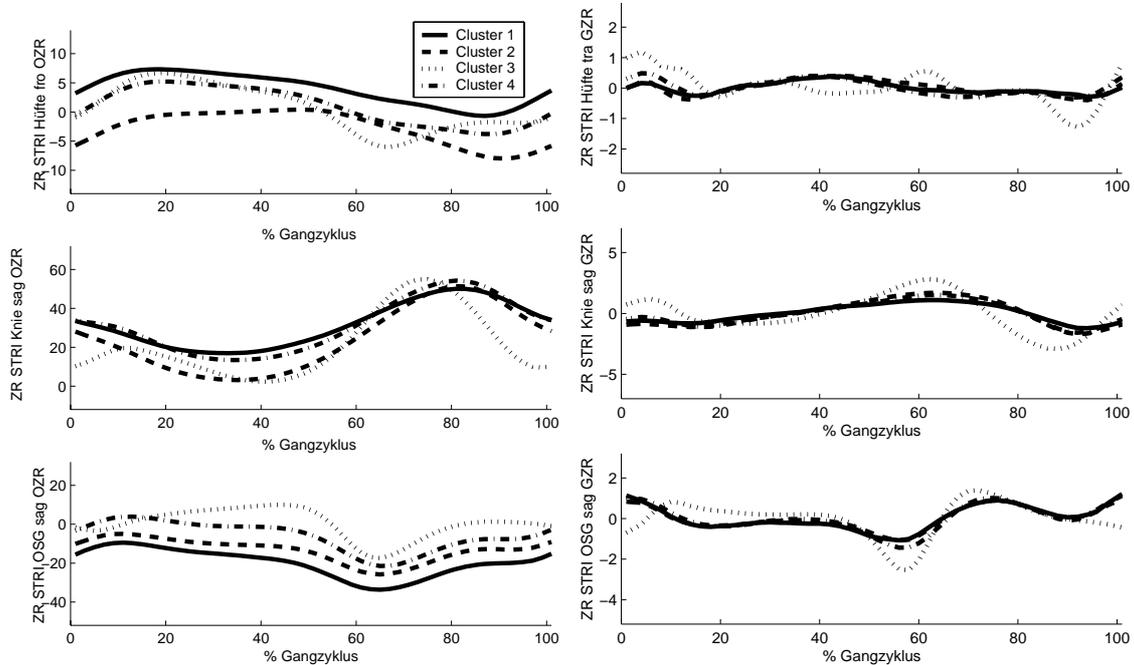


Abbildung 5.12: Visualisierung der vier Cluster-Zentren aus Tabelle 5.4 für die ersten sechs Zeitreihenkombinationen, SUB4 (bis einschließlich „HK STRI OSG sag GZR“).

bump“ bei der Becken sag OZR für  $C = 4$  Cluster-Zentren, siehe Tabelle 5.5 und im Anhang Abbildung E.3. Dadurch konnte gezeigt werden, dass das „double bump“ Muster mit einer permanent mittleren bis stark ausgeprägten anterioren (nach vorne gebeugten) Haltung in Kombination mit einem mittleren bis stark ausgeprägten Spitzfuß auftritt. Empirische Vermutungen konnten damit bestätigt werden, siehe Abschnitt 2.3 und [150, 174]. Bei detaillierterer Betrachtung kann allerdings auch erkannt werden, dass sich Cluster aufteilen. Im Becken existieren kaum unterscheidbare Muster, die sich aber in Hüfte und OSG unterschiedlich auswirken, siehe Abbildung E.3.

Das einheitlich automatisierte Finden aller hier beschriebenen Zusammenhänge konnte aus mehreren Gründen nicht erzielt werden. Es überlagern sich unterschiedliche Effekte im pathologischen Gang, die aus individueller Gangart und Aufteilung von Subgruppen (gleiches Muster in einer Zeitreihe, aber unterschiedliche Auswirkung in anderer Zeitreihe) bestehen. Hinzu sind einige Effekte nur sehr schwach ausgeprägt und kompliziert miteinander verknüpft. Zudem ist die Datenanzahl für eine derartige Lösungssuche zu gering. Weiterhin führen die Hauptkomponenten nur

	Fünf Cluster-Zentren	$S(u, 5)$	Vier Cluster-Zentren	$S(u, 4)$
1 ZR	HK STRI Knie sag OZR	3.20	HK STRI Becken sag OZR	2.36
2 ZR	& HK STRI Hüfte tra GZR	4.98	& HK STRI Hüfte tra GZR	3.48
3 ZR	& HK STRI OSG sag SZR	5.87	& HK STRI OSG sag OZR	5.48
4 ZR	& HK STRI OSG sag OZR	10.20	& HK STRI OSG sag GZR	6.74
5 ZR	& HK STRI OSG sag GZR	18.01	& HK STRI Hüfte sag GZR	8.16
6 ZR	& HK STRI Hüfte tra SZR	41.41	& HK STRI OSG tra GZR	10.49
7 ZR	& HK STRI Hüfte sag GZR	146.65	& HK STRI Hüfte sag OZR	14.99
8 ZR	& HK STRI Hüfte fro OZR	208.91	& HK STRI Becken sag GZR	22.22

Tabelle 5.5: Variationen beim automatisierten Finden von Subgruppen. Links: Fünf Cluster-Zentren unter Ausschluss aller OSG tra OZR (nicht valide messbar). Rechts: Vier Cluster unter Vorgabe der Becken sag OZR als Startsuche und lediglich Berücksichtigung des Trennungsgrades  $S$  (die Referenz kann hierbei in keiner Kombination gefunden werden, auch nicht bei fünf Cluster-Zentren).

bedingt zu Lösungen beim Unterscheiden der Subgruppen. Die Validierungsmaße ( $S$  und  $u_{\text{REF}}$ ) sind effektiv, aber für eine vollständige Automatisierung zu ergänzen (z.B. durch Bevorzugung valider Messergebnisse entsprechend der Apriori-Relevanzen). Dennoch konnte mit der neuen Methode erfolgreich die Existenz von Subgruppen mit deren unterschiedlichen Auswirkungen auf das gesamte Gangbild gezeigt werden. Empirisch bekannte Ansätze konnten bestätigt und an deren Grenzen weiterführende Erkenntnisse (z.B. Kombinationseffekte mit  $C = 5$  Cluster zwischen Knie und OSG oder Kompensationen zwischen Hüfte, Knie und OSG) erzielt werden. Es kann davon ausgegangen werden, dass die hier dargestellten Ergebnisse nicht zufällig entstanden sind, z.B. durch Datenrauschen. Gründe sind dafür die Übereinstimmung mit den in der Literatur dargestellten empirischen Ansätzen, die hier diskutierten biomechanischen Zusammenhänge und datenanalytische Hinweise<sup>3</sup>. Eine Bestätigung der Cluster-Ergebnisse wird zudem in den nächsten Abschnitten durch überwachte Verfahren gezeigt. Eine eindeutige, alle Zeitreihen umfassende Einteilung in

<sup>3</sup>Beispielsweise stark ansteigende  $S$  außerhalb der hier vorgestellten Zeitreihenkombinationen. Wie bereits in Kapitel 3 beschrieben, bedeutet nach heuristischen Überprüfungen ein  $S < 20$  gute Cluster-Ergebnisse. Zum Vergleich beträgt  $S = 86.20$  für  $C = 4$  Cluster-Zentren aus Tabelle 5.4, wenn bereits bei der vierten Kombination „HK STRI Becken fro OZR“ (anstatt „HK STRI OSG sag OZR“ mit  $S = 11.18$ ) verwendet wird (starke „Höhenunterschiede“ im Knie werden systematisch durch eine entgegenwirkende Oberkörperhaltung ausgeglichen, das die Patienten allerdings in diesem Zusammenhang nicht nutzen, wobei das Becken, frontal große pathologische Ausmaße aufweist, siehe Abbildung 5.5).

Subgruppen kann bei den ICP-Daten (im Gegensatz zu den SCI-Daten) mit diesen methodischen Werkzeugen nicht gefunden werden.

Nachfolgend werden verschiedene Subgruppen (86 ICP,PRE und 20 REF,K Datensätze) verwendet:

- SUB1: Vier Cluster-Zentren über „ZR STRI Knie sag OZR“ (Abbildung 3.11).
- SUB2: Vier Cluster-Zentren über „ZR STRI OSG sag OZR“ (Abbildung 5.10).
- SUB3: Fünf Cluster-Zentren über „HK STRI Knie sag OZR“ und „HK STRI OSG sag OZR“, siehe Abbildung 5.11.
- SUB4: Vier Cluster-Zentren aus sechs Kombinationen von Zeitreihen, siehe fett gedruckte Kombination in Tabelle 5.4 (bis einschließlich „HK STRI OSG sag GZR“) und Abbildung 5.12.

### Verallgemeinerte Charakterisierung der Subgruppen

Die beschriebenen Werkzeuge zur Diagnose lassen sich nun auf die ermittelten Subgruppen als weitere Klasseneinteilungen anwenden, die im Folgenden beispielhaft dargestellt sind. Die Subgruppen haben insgesamt ähnliche pathologische Ausmaße wie das gesamte Patientenkollektiv, aber mit teilweise unterschiedlichen Schwerpunkten in einzelnen Gangphasen, siehe Abbildung 5.13 und vergleiche Tabelle 5.1 bzw. Abbildungen 5.4 und 5.5. Bei näherer Untersuchung fällt auf, dass ähnlich große Abweichungen im Becken, sag (MSt und ISw durch „double bump“), im Becken fro (insbesondere LR und MSt) und im Knie sag (TSw) auftreten. Im Sprunggelenk sind hingegen die wesentlichen Abweichungen verschoben.

Die gefundenen Cluster von SUB1 beschreiben sehr gut bekannte empirische Subgruppen. Tabelle 5.6 zeigt für die Subgruppen SUB1 die charakteristischen Merkmale. Hierbei fällt auf, dass zunächst wichtige Einzelmerkmale von der Klassentrennung ICP,PRE bzw. REF,K (d.h. alle Patienten einheitlich betrachtet, vgl. Tabelle 5.3) bereits bekannt sind (z.B. „SpW STRI Becken sag OZR“ oder „MW STRI OSG sag SZR“) oder aufgrund hoher Korrelationen bereits diskutiert wurden. Darüber hinaus tauchen allerdings auch Einzelmerkmale auf wie „MIN STRI Knie sag OZR“ (Unterscheidung funktionaler Subgruppen) oder „MIN LR Knie sag GZR“ (Beschreibung pathologischer Stoßdämpfung beim Fußaufsetzen), die sehr viel detailliertere Informationen beitragen. Daher kann durchaus Tabelle 5.3 mit derartigen Einzelmerkmalen ergänzt werden, da sie die Subgruppen der Patienten beschreiben. Das 2-Klassenproblem zur Trennung von ICP,PRE und REF,K reicht daher zum Finden von Merkmalen, die Subgruppen unterscheiden, nicht immer aus.

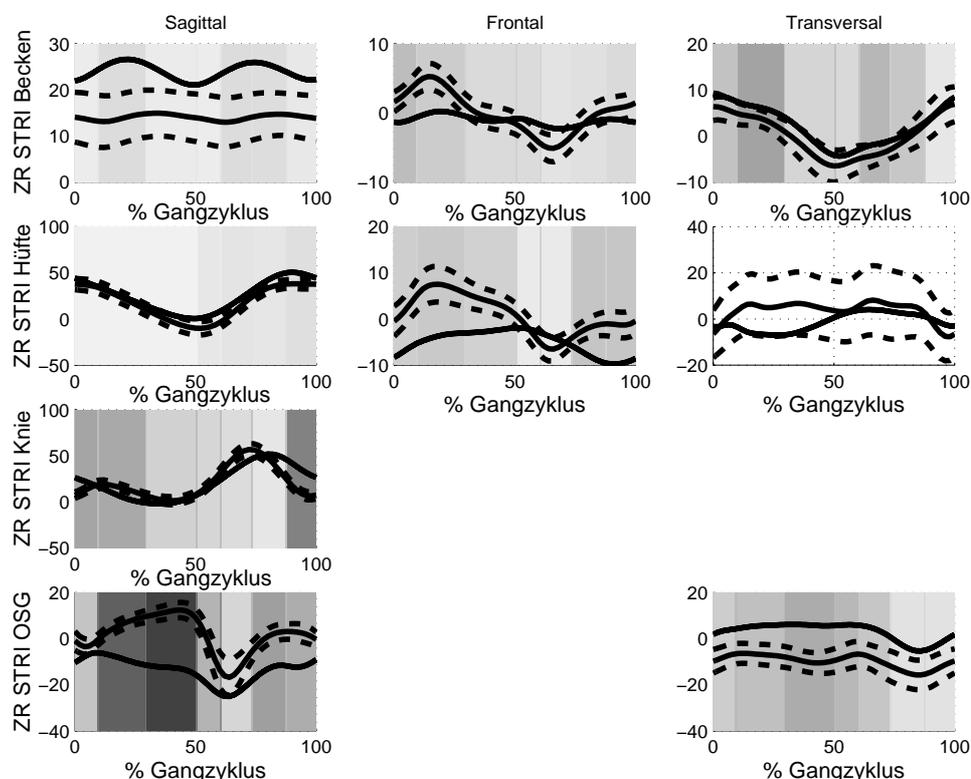


Abbildung 5.13: Pathologische Gangabweichungen als graue Hinterlegungen einer Subgruppe (Cluster 2) aus SUB4.

Weiterhin fällt auf, dass einige Einzelmerkmale aus anderen Zeitreihen auftreten, die mit den Knie-Subgruppen zusammen hängen, wie z.B. „MW TSt OSG sag OZR“, „MW STRI OSG sag SZR“ oder „HK Knie sag GZR“, „HK Hüfte tra GZR“. Das zeigt die gleichen Zusammenhänge wie bereits im vorherigen Abschnitt beim automatisierten Clustern über mehrere Zeitreihen. Allerdings wurden die Ergebnisse mit anderen mathematischen Methoden ermittelt, das zusätzlich auf valide Ergebnisse hinweist. Allerdings sind die Effekte teilweise über bestimmte Phasen im Gangzyklus vorhanden und meistens schwach ausgeprägt, zu sehen an den geringen Relevanzen  $M_s$ . Die „1. HK Knie sag OZR“ und „2. HK Knie sag OZR“ tragen zwar viel zur Unterscheidung der Subgruppen bei, können sie allerdings einzeln nicht vollständig klären. Bei den weiteren Hauptkomponenten fällt auf, dass meistens die Relevanzen der zweiten Hauptkomponente in der Regel nur noch die Hälfte der Subgruppen-Informationen beinhaltet, wie z.B.  $M_s = 0.05$  der „2. HK OSG sag OZR“. Daher können u.U. die Cluster-Ergebnisse verbessert werden, indem iterativ die Anzahl

der Hauptkomponenten festgelegt wird.

Einzelmerkmal	$M_{s,ap}$	$M_s$	$M_{s,uk}$	Hauptkomponente	$M_s$
MIN STRI Knie sag OZR	1.00	0.37	0.37	1. HK Knie sag OZR	0.402
MIN LR Knie sag GZR	0.48	0.33	0.16	2. HK Knie sag OZR	0.376
SpW STRI Becken sag OZR	1.00	0.14	0.14	1. HK Knie sag GZR	0.270
MW STRI OSG tra OZR	0.80	0.16	0.13	1. HK Becken sag GZR	0.204
MIN ISw Knie sag GZR	0.48	0.23	0.11	1. HK Hüfte tra GZR	0.189
Gehgeschwindigkeit	1.00	0.10	0.10	1. HK OSG sag GZR	0.157
MW TSt OSG sag OZR	0.60	0.13	0.08	1. HK Hüfte fro GZR	0.134
MW TSw OSG sag GZR	0.48	0.17	0.07	1. HK Becken fro SZR	0.122
SpW PSw OSG sag OZR	0.60	0.12	0.07	1. HK OSG tra OZR	0.119
SpW LR Knie sag OZR	0.60	0.12	0.07	1. HK OSG sag OZR	0.116
Fußablösung	1.00	0.07	0.07	1. HK OSG tra SZR	0.114
MAX MSt OSG sag GZR	0.48	0.15	0.07	1. HK OSG sag SZR	0.112
MW STRI OSG sag SZR	0.60	0.12	0.07	2. HK Knie sag GZR	0.102
MAX TSw Knie sag GZR	0.48	0.15	0.07	1. HK Knie sag SZR	0.100
MAX STRI Becken sag OZR	1.00	0.06	0.06	1. HK Hüfte sag GZR	0.087
SpW PSw Hüfte fro OZR	0.48	0.13	0.06	1. HK Hüfte sag SZR	0.085

Tabelle 5.6: Charakteristische Einzelmerkmale der Subgruppen SUB1 (Abbildung 3.12, 106 Datensätze, 4-Klassenproblem) mit Verwendung standardisierter Gangphasen und informationstheoretischen Maßen. Links: Mit Apriori-Relevanz  $M_{s,ap}$  und Rückstufung korrelierter Einzelmerkmale  $M_{s,uk} = M_s \cdot M_{s,ap} \cdot M_{s,ko}$ . Rechts: Relevanzen der Hauptkomponenten.

Analog zu den Knie-Subgruppen (SUB1) lassen sich nun die ebenfalls empirisch etablierten Subgruppen aus SUB2 charakterisieren, siehe Tabelle 5.7. Hierin finden sich einige aus Tabelle 5.6 bekannte Einzelmerkmale wie „SpW STRI Becken sag OZR“ oder „MW STRI OSG sag SZR“ wieder, die sogar das gesamte ICP,PRE-Kollektiv beschreiben. Ferner fallen qualitativ die Zusammenhänge zwischen Knie und OSG sag auf. Dennoch tauchen auch eine Reihe nicht übereinstimmender Kombinationen auf (z.B. „SpW SW Hüfte tra OZR“). Diese Unstimmigkeiten zeigen die unterschiedlichen und sehr komplexen Subgruppen, so dass aufgrund der reinen Empirie derartige Zusammenhänge kaum zu finden sind.

Obwohl auch Zusammenhänge zum Becken sag entdeckt wurden, ist dessen Zeitreihe bei der automatisierten Suche nach Clustern (Tabelle 5.4) nicht enthalten. Weitere Gründe (zu den bereits diskutierten) bestehen darin, dass die Hauptkomponenten nicht für Subgruppen ausgelegt sind (sondern lediglich maximale Streuung

aller Daten liefern) und der Zusammenhang sehr schwach ausgeprägt ist.

Weiterhin ist auffällig, dass die „2. HK Knie sag OZR“ mit  $M_s = 0.10$  eine relativ hohe Relevanz hat und weit vor der ersten Hauptkomponente liegt. Der Grund ist, dass der Zusammenhang zum OSG eher mit der zweiten Hauptkomponente des Knies erklärt wird. Diese Hauptkomponente trägt zu bestimmten Knie-Subgruppen viel Information bei, wie z.B. zu dem Recurvatum.

Einzelmerkmal	$M_{s,ap}$	$M_s$	$M_{s,uk}$	Hauptkomponente	$M_s$
MW STRI OSG sag OZR	1.00	0.44	0.44	1. HK OSG sag OZR	0.47
SpW STRI Becken sag OZR	1.00	0.11	0.11	1. HK Knie sag GZR	0.13
Schrittlänge	1.00	0.08	0.08	1. HK Hüfte tra GZR	0.11
SpW SW Hüfte tra OZR	0.64	0.11	0.07	2. HK Knie sag OZR	0.10
SpW ISw Hüfte sag OZR	0.60	0.11	0.07	1. HK OSG sag GZR	0.10
MW SW Hüfte sag GZR	0.64	0.10	0.06	1. HK Hüfte fro GZR	0.09
SpW SW Knie sag OZR	0.80	0.08	0.06	1. HK Hüfte sag GZR	0.09
MIN SW Hüfte sag GZR	0.64	0.10	0.06	1. HK OSG sag SZR	0.08
MAX MSt OSG sag GZR	0.48	0.12	0.06	2. HK Hüfte sag OZR	0.07
MAX TSw Knie sag OZR	0.60	0.10	0.06	1. HK Becken sag GZR	0.07
MAX LR Hüfte tra GZR	0.38	0.15	0.06	2. HK Hüfte tra OZR	0.06
MIN MSt OSG sag GZR	0.48	0.12	0.06	2. HK OSG sag GZR	0.05
MW STRI OSG sag SZR	0.60	0.08	0.05	1. HK OSG tra SZR	0.05
MW TSw OSG sag GZR	0.48	0.10	0.05	1. HK Hüfte fro SZR	0.05
MW ST Becken sag GZR	0.64	0.07	0.04	1. HK Hüfte sag OZR	0.05
MW MSw Hüfte fro GZR	0.38	0.10	0.04	1. HK Becken tra SZR	0.04

Tabelle 5.7: Charakteristische Einzelmerkmale und Hauptkomponenten der Subgruppen SUB2 (Abbildung 5.10, 106 Datensätze, 4-Klassenproblem) mit Verwendung standardisierter Gangphasen und informationstheoretischen Maßen.

Abschließend sind charakteristische Einzelmerkmale von SUB4 gezeigt, siehe Tabelle 5.8. Insbesondere die ersten sechs aufgeführten Einzelmerkmale decken sich gut mit den bekannten Ergebnissen bzw. erweitern diese (z.B. „MW STRI Hüfte fro OZR“). Die weiteren Einzelmerkmale sind prädestiniert zur künftigen Analyse von Subgruppen, da sie sich lediglich auf bestimmte Phasen beziehen und somit empirisch schwer zu finden sind.

Sehr bemerkenswert sind die gefundenen Merkmalskombinationen mit dem Fuzzy-Klassifikator, siehe Abbildung 5.14. Hierbei sind genau die vermuteten und bereits diskutierten Zusammenhänge zwischen OSG sag und Hüfte fro automatisiert beschrieben. Eine starke Plantarflexion (im OSG) tritt entweder mit Adduktion der

Einzelmerkmal	$M_{s,ap}$	$M_s$	$M_{s,uk}$	Hauptkomponente	$M_s$
MW STRI OSG sag OZR	1.00	0.27	0.27	2. HK Knie sag OZR	0.29
MW STRI Hüfte fro OZR	0.80	0.24	0.19	1. HK Knie sag GZR	0.25
MIN STRI Knie sag OZR	1.00	0.17	0.17	1. HK OSG sag OZR	0.22
MIN LR Knie sag GZR	0.48	0.27	0.13	1. HK Hüfte fro OZR	0.20
Gehgeschwindigkeit	1.00	0.12	0.12	1. HK Hüfte sag GZR	0.18
SpW STRI Becken sag OZR	1.00	0.10	0.10	1. HK Hüfte tra GZR	0.18
MIN ISw Knie sag GZR	0.48	0.17	0.08	1. HK OSG sag GZR	0.17
MAX STRI OSG tra OZR	0.80	0.09	0.07	1. HK Becken sag GZR	0.16
SpW PSw OSG sag OZR	0.60	0.12	0.07	1. HK Hüfte fro GZR	0.15
MAX STRI Becken sag OZR	1.00	0.07	0.07	1. HK OSG sag SZR	0.12
MIN MSt OSG sag GZR	0.48	0.15	0.07	1. HK Becken fro GZR	0.11
SpW TSt Hüfte sag OZR	0.60	0.10	0.06	1. HK OSG tra SZR	0.11
MAX MSt OSG sag GZR	0.48	0.13	0.06	1. HK Becken fro SZR	0.10
MW TSw OSG sag GZR	0.48	0.13	0.06	1. HK Knie sag OZR	0.10
MW STRI OSG sag SZR	0.60	0.10	0.06	1. HK Becken tra SZR	0.07
SpW SW Hüfte tra OZR	0.64	0.09	0.06	2. HK Becken fro OZR	0.07

Tabelle 5.8: Charakteristische Einzelmerkmale und Hauptkomponenten der Subgruppen SUB4 bei 106 Datensätzen (Abbildung 5.12, standardisierte Gangphasen, informationstheoretische Maße).

Hüfte (Cluster 1, linke Regel, positiver „MW STRI Hüfte fro OZR“, empirisch aus Biomechanik bekannt) oder sogar mit Abduktion der Hüfte (Cluster 2) auf. Zur biomechanischen Erklärung des Verhaltens von Cluster 2 gibt möglicherweise der Knieverlauf Hinweise (Abbildung 5.12) oder es existieren Kompensationen zwischen der linken und rechten Körperseite. Die rechte Regel beschreibt klinisch bekannte Zusammenhänge beim milden Kauergang (Cluster 4), der durch geringe Abweichungen im OSG zur Referenz (hier Cluster 3), aber schlechte Stoßdämpfung im Knie („shock absorbtion“, kleines „Min LR Knie sag GZR“) charakterisiert ist [150]. Weiterhin ist zu erkennen, dass im Gegensatz zur Referenz die Steigung des Knieverlaufs beim Fußaufsetzen („Min LR Knie sag GZR“) bei ICP generell negativ ist.

Die Komplexität der Zusammenhänge wird z.B. mit den besten Merkmalen des Knies ersichtlich, siehe Abbildung 5.15 und vgl. Abbildung 5.12. Die Hauptkomponenten trennen zwar formal die Subgruppen besser auf (größeres  $M_s$ ), hingegen sind „MIN STRI Knie sag OZR“ und „MIN LR Knie sag GZR“ besser interpretierbar (z.B. Recurvatum durch sehr kleines Minimum über Knie sag OZR und negativen Aufsetzwinkel in LR). Dadurch wird ersichtlich, dass der milde und starke Kauergang nicht eindeutig zu trennen sind. Gründe sind zum einen die überlagerten Ef-

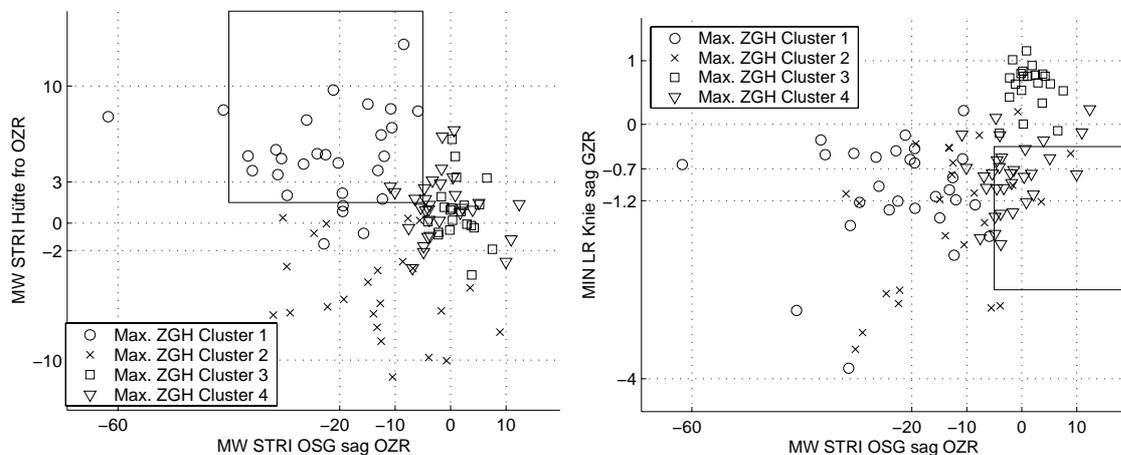


Abbildung 5.14: Zwei Regeln zur Beschreibung der Subgruppen aus SUB4.

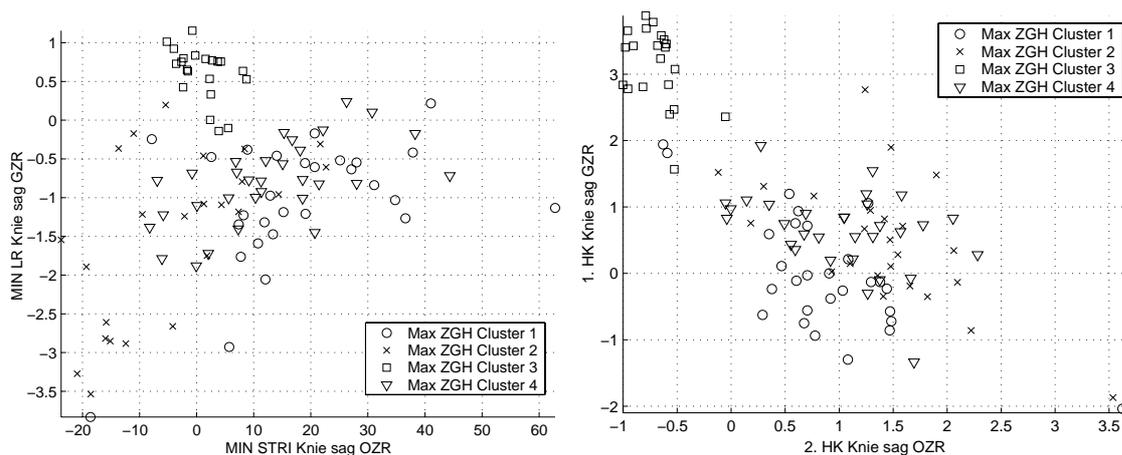


Abbildung 5.15: Darstellung der Subgruppen SUB4 aus Abbildung 5.12 durch charakteristische Einzelmerkmale aus Tabelle 5.8 (Cluster 1 und 4 = milder und starker Kauergang, Cluster 2 = Recurvatum, Cluster 3 = Referenz), links: Interpretierbare Einzelmerkmale. Rechts: Hauptkomponenten.

fekte mit anderen Zeitreihen und zum anderen sind die Hauptkomponenten lediglich Hilfsgrößen beim Finden von Subgruppen. Hingegen sind die meisten interpretierbaren Einzelmerkmale nicht zum Clustern geeignet, z.B. sind GZR sehr anfällig auf Ausreißer, was die Cluster-Ergebnisse maßgeblich beeinträchtigt [13]. Ein möglicher Ansatz ist wiederholtes Clustern über die so gefundenen Hauptkomponenten oder über die interpretierbaren Einzelmerkmale. Darauf wird in dieser Arbeit nicht wei-

ter eingegangen. Hierzu ist fundierteres klinisches Wissen nötig, da in der Literatur die Subgruppen nur ansatzweise bekannt und lediglich durch qualitative Verläufe in Zeitreihen beschrieben sind [114, 174]. Deren Charakterisierung über bestimmte Merkmale erfolgte wegen mangelnder Quantifizierung mit geeigneten Analyseverfahren noch nicht.

## 5.2.2 Neues Auswerteverfahren für die Therapie

### Verallgemeinerte Quantifizierung des pathologischen Ausmaßes

Um einen generellen Überblick der Therapie-Effekte zu erhalten, kann das pathologische Ausmaß basierend auf der Referenzabweichungszeitreihe aus Gl. (3.8) eingesetzt werden, siehe Abbildung 5.9. Die Therapie erzielt den gewünschten klinischen Effekt einer Verbesserung des OSG sag (Normalisierung bezüglich der Referenz).

Gelenk/ Ebene	ICP, PRE → ICP,POST (MW ± STD)		
	sagittal	frontal	transversal
Becken OZR	1.7 ± 1.1 → 1.8 ± 1.2	2.5 ± 1.1 → 2.5 ± 1.5	2.1 ± 1.2 → 1.9 ± 1.3
Becken GZR	2.7 ± 1.0 → 2.6 ± 1.0	2.3 ± 0.7 → 2.3 ± 0.8	1.6 ± 0.7 → 1.5 ± 0.9
Hüfte OZR	2.0 ± 1.1 → 2.0 ± 1.1	1.6 ± 0.9 → 1.5 ± 0.9	2.1 ± 1.3 → 2.3 ± 1.5
Hüfte GZR	2.5 ± 0.9 → 2.5 ± 0.9	2.0 ± 0.7 → 1.9 ± 0.7	1.5 ± 0.3 → 1.5 ± 0.5
Knie OZR	3.9 ± 1.8 → 3.7 ± 1.7		
Knie GZR	3.6 ± 0.9 → 3.5 ± 0.9*		
OSG OZR	5.1 ± 3.7 → 3.1 ± 2.1*		3.2 ± 1.9 → 3.1 ± 1.9*
OSG GZR	2.7 ± 0.8 → 2.4 ± 0.6*		2.4 ± 0.9 → 2.3 ± 0.8
gesamt OZR	3.1 ± 1.2 → 2.6 ± 1.0*	2.0 ± 0.9 → 2.0 ± 1.1	2.4 ± 0.9 → 2.4 ± 1.1
gesamt GZR	2.9 ± 0.6 → 2.7 ± 0.6*	2.2 ± 0.9 → 2.1 ± 0.7	1.9 ± 0.3 → 1.8 ± 0.5
gesamt OZR		2.5 ± 0.8 → 2.3 ± 0.7	
gesamt GZR		2.3 ± 0.5 → 2.2 ± 0.5	

Tabelle 5.9: Gemittelte Referenzabweichungen der Kinematikzeitreihen (OZR) sowie deren Geschwindigkeitszeitreihen (GZR) des ICP-Kollektives zum PRE- und POST-therapeutischen Zustand. Signifikante Verbesserungen sind mit  $*(p < 0.05)$  symbolisiert.

Insbesondere bei der Änderung der Referenzabweichung „MW STRI OSG sag RZR“ konnten wichtige Zusammenhänge entdeckt werden, siehe Abbildung 5.16, links und [91]. Hierbei ist die Änderung von PRE nach POST („ $\Delta_{\text{PRE,POST}}$  MW STRI OSG sag RZR“) über den Ausgangswerten PRE aufgetragen. Dabei fällt eine nahezu lineare Verbesserung der meisten Patienten auf (Gruppe A), allerdings auch einige

Ausnahmen (Gruppe B) und wenige Verschlechterungen (Gruppe C). In der Gruppe C sind viele Patienten, die relativ zur Referenz eine geringfügige Plantarflexion PRE-therapeutisch und durch die Therapie eine Dorsalflexion („Über-Korrektur“) aufweisen.

Naheliegende Vermutungen zur Erklärung dieser Zusammenhänge mit der Botulinum-Toxin-Dosierung konnten nicht festgestellt werden<sup>4</sup>, siehe Abbildung 5.16, rechts. Sowohl in Gruppe A, B und C sind vergleichbare Dosierungen injiziert worden.

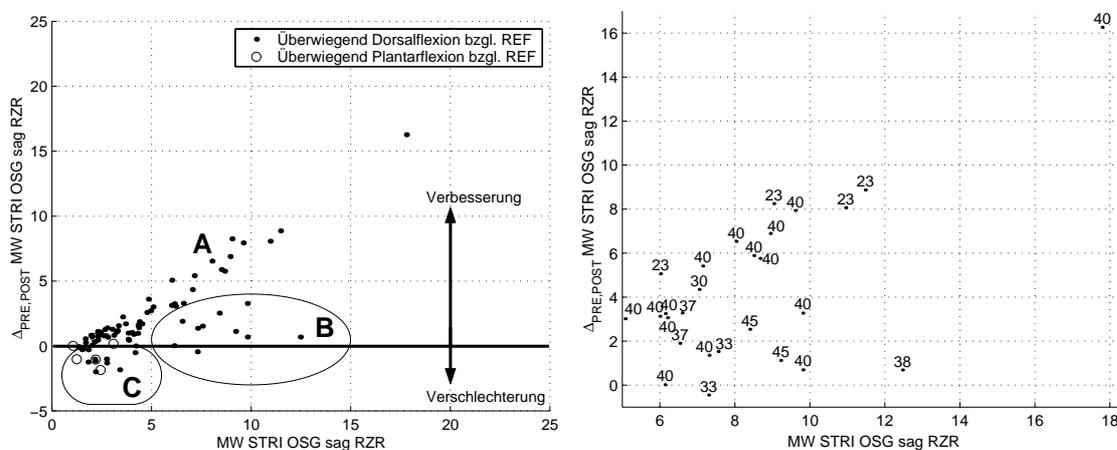


Abbildung 5.16: Links: PRE-POST-Differenz über den PRE-Werten von „MW STRI OSG sag RZR“. Rechts: Exemplarischer Ausschnitt des linken Diagramms mit körpergewichtsbezogenen Botulinum-Toxin-Gesamtdosierungen.

Auffallend hingegen sind unterschiedliche Entwicklungen der Subgruppen in den drei Gruppen A, B und C, siehe Abbildung 5.17. Die Subgruppen mit der Knieüberstreckung (Recurvatum, Cluster 2 im linken bzw. Cluster 1 im rechten Bild) erklären die meisten Datensätze der Gruppe B. Bis auf wenige Ausnahmen sind sogar alle Patienten mit einem stark ausgeprägten Recurvatum betroffen (Gruppe D).

Ausnahmen (Patienten mit Recurvatum bzw. aus Cluster 1 von SUB1 die nicht in Gruppe B enthalten sind) betreffen nur sechs Datensätze, siehe Abbildung 5.18, links. Erstaunlicherweise sind hierbei beide Beine dieser Patienten betroffen, d.h. nur drei Patienten.

<sup>4</sup>Eingesetzt wurden überwachte Klassifikatoren zum Beschreiben der drei Gruppen A, B, C bzw. Korrelationsanalysen zum Erklären der Botulinum-Toxin-Dosierungen, siehe Abbildungen E.5 und E.6 sowie Tabellen E.5 und E.4 im Anhang.

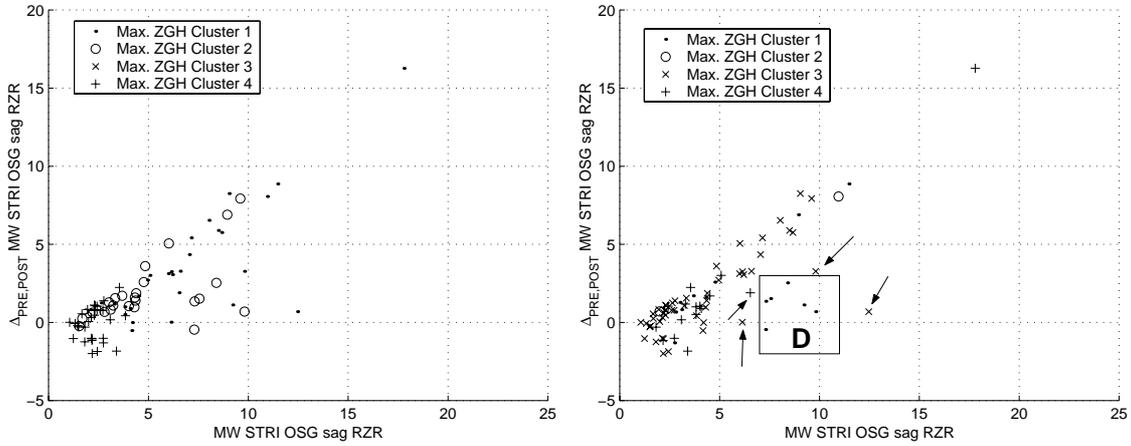


Abbildung 5.17: PRE-POST-Änderungen aus Abbildung 5.16 mit Einteilungen in Subgruppen, links: SUB4, rechts: SUB1.

Die Ausnahmen aus der Gruppe B ohne ausgeprägtes Recurvatum (mit Pfeilen in Abbildung 5.17 markiert) sind in Abbildung 5.18, rechts gezeigt (alle sechs Datensätze sind von unterschiedlichen Patienten). Eine Diskussion möglicher Ursachen erfolgt in dieser Arbeit aufgrund der sehr kleinen Anzahl von Ausnahmen nicht.

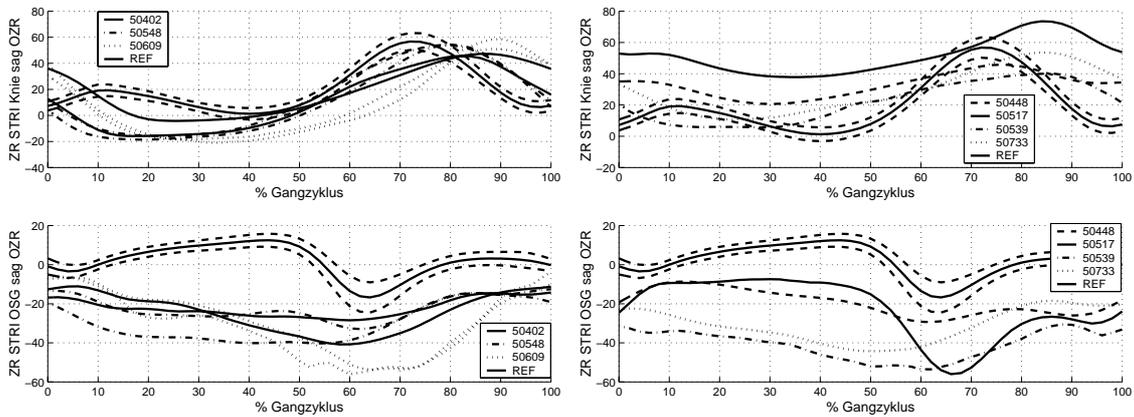


Abbildung 5.18: Ausnahmen der PRE-POST-Änderungen, links: Die Datensätze der drei Patienten mit Recurvatum die nicht in Gruppe B enthalten sind (betreffen linke und rechte Körperseite), rechts: Die vier Patienten aus Gruppe B ohne Recurvatum.

### Verallgemeinerte Charakterisierung der Therapiewirkung

Die überwachten Verfahren können auch für die Klasseneinteilung ICP,PRE und ICP,POST eingesetzt werden, um gezielt nach Therapieeffekten zu suchen, siehe Tabelle 5.10. Demnach ändern sich nur sehr wenige Merkmale durch die Therapie. Das beste dieser Merkmale ist „MW ST OSG sag OZR“, wenn auch mit sehr kleinen Relevanzen (d.h. nur geringfügige Änderungen sind vorhanden), siehe Abbildung 5.19. Dabei fällt auf, dass sich die PRE-Werte zum POST-Zeitpunkt in Richtung REF verschieben, d.h. es tritt eine geringfügige Verbesserung auf. Selbstverständlich ist dieses Merkmal zu anderen Merkmalen des OSG sag hoch korreliert, wie zu „MW STRI OSG sag OZR“ mit  $\rho = 0.98$  oder „MW SW OSG sag OZR“ mit  $\rho = 0.86$ . Noch kleinere Änderungen durch die Therapie (kleine Relevanzen) treten beim dynamischen OSG sag Verhalten in bestimmten Phasen auf, z.B. „MAX MSw OSG sag GZR“ mit  $M_s = 0.04$ . Alle weiteren Einzelmerkmale aus anderen Gelenken bzw. Körperebenen haben nahezu verschwindend kleine Relevanzen bezüglich einer Therapiewirkung. Bereits durch das pathologische Ausmaß wurden derartige Wirkungen der Therapie erkannt. Die weiteren Einzelmerkmale, die das gesamte ICP-Gangverhalten charakterisieren, werden allerdings nicht durch die Therapie verändert, siehe Tabelle 5.3 und E.6 im Anhang. Aus Sicht der Datenanalyse bleibt das charakteristische ICP-Verhalten überwiegend unverändert.

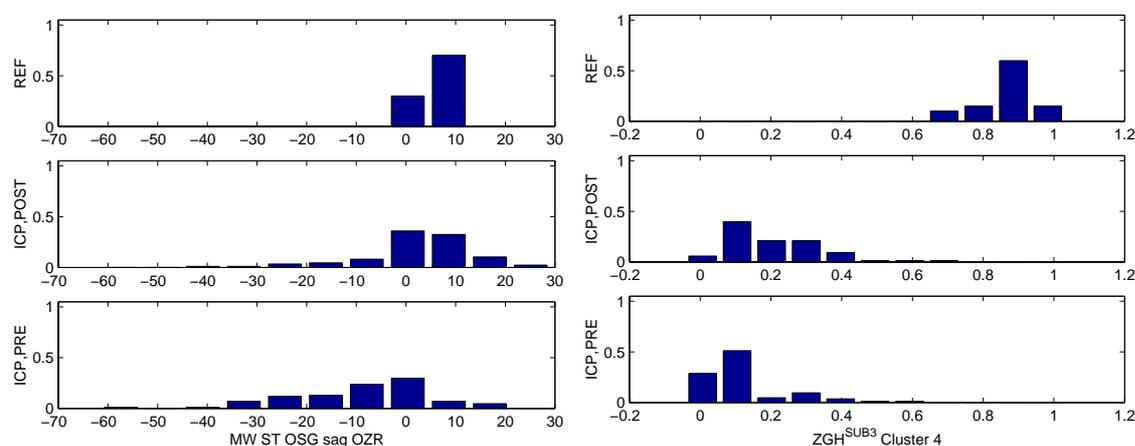


Abbildung 5.19: Histogramme der drei Klassen ICP,PRE und ICP,POST sowie REF.

Bei Betrachtung der Subgruppen lassen sich die Aussagen noch detaillierter auswerten. Beachtlich sind die Veränderungen von ICP,PRE nach ICP,POST bei den ZGH zu den verschiedenen Clustern. Die zu klärende klinische Fragestellung ist:

Einzelmerkmal	$M_{s,ap}$	$M_s$	$M_{s,uk}$	ICP,PRE	ICP,POST	REF,K
MW ST OSG sag OZR	0.80	0.14	0.11	$-9.0 \pm 14.0$	$2.0 \pm 11.5$	$5.5 \pm 2.5$
ZGH <sup>SUB3</sup> Cluster 4 (REF)	1.00	0.10	0.10	$0.1 \pm 0.1$	$0.2 \pm 0.1$	$0.9 \pm 0.1$
ZGH <sup>SUB3</sup> Cluster 3	1.00	0.07	0.07	$0.3 \pm 0.2$	$0.4 \pm 0.2$	$0.1 \pm 0.0$
ZGH <sup>SUB3</sup> Cluster 2	1.00	0.04	0.04	$0.2 \pm 0.2$	$0.1 \pm 0.1$	$0.0 \pm 0.0$
ZGH <sup>SUB2</sup> Cluster 2	1.00	0.03	0.03	$0.3 \pm 0.2$	$0.2 \pm 0.2$	$0.0 \pm 0.0$
MAX MSw OSG sag GZR	0.48	0.04	0.02	$1.2 \pm 0.7$	$0.8 \pm 0.5$	$1.2 \pm 0.4$
SpW ST OSG sag OZR	0.80	0.03	0.02	$25.6 \pm 11.7$	$21.2 \pm 9.9$	$25.8 \pm 5.9$
MAX STRI Becken tra GZR	0.64	0.03	0.02	$0.7 \pm 0.3$	$0.7 \pm 0.4$	$0.5 \pm 0.1$
MIN STRI Hüfte sag SZR	0.60	0.03	0.02	$2.2 \pm 1.5$	$2.3 \pm 1.4$	$0.8 \pm 0.3$
MAX MSw Hüfte tra GZR	0.38	0.05	0.02	$0.1 \pm 0.4$	$0.1 \pm 0.5$	$0.6 \pm 0.3$
ZGH <sup>SUB4</sup> Cluster 4	1.00	0.01	0.01	$0.3 \pm 0.1$	$0.4 \pm 0.1$	$0.1 \pm 0.0$
MAX IC OSG sag GZR	0.48	0.02	0.01	$1.0 \pm 1.0$	$1.1 \pm 0.7$	$-0.6 \pm 0.2$
MIN LR OSG sag SZR	0.36	0.03	0.01	$3.8 \pm 2.5$	$3.9 \pm 2.9$	$1.0 \pm 0.4$
SpW LR OSG tra OZR	0.48	0.02	0.01	$3.4 \pm 2.0$	$2.4 \pm 1.7$	$3.3 \pm 1.5$
MAX ISw Hüfte tra GZR	0.38	0.03	0.01	$0.2 \pm 0.4$	$0.2 \pm 0.5$	$0.5 \pm 0.3$
Gehgeschwindigkeit	1.00	0.01	0.01	$0.8 \pm 0.3$	$0.8 \pm 0.3$	$1.2 \pm 0.1$
MW TSt OSG sag GZR	0.48	0.02	0.01	$-0.3 \pm 0.4$	$-0.2 \pm 0.3$	$0.0 \pm 0.3$
ZGH <sup>SUB2</sup> Cluster 4 (REF)	1.00	0.10	0.10	$0.2 \pm 0.2$	$0.4 \pm 0.3$	$0.8 \pm 0.2$
ZGH <sup>SUB4</sup> Cluster 3 (REF)	1.00	0.05	0.05	$0.1 \pm 0.1$	$0.2 \pm 0.1$	$0.8 \pm 0.1$

Tabelle 5.10: Oben: Charakteristische Einzelmerkmale und Wertebereiche von ICP,PRE (86 Datensätze) im Vergleich zu ICP,POST (86 Datensätze) mit standardisierten Gangphasen, Apriori-Relevanzen  $M_{s,ap}$ , Rückstufung korrelierter Einzelmerkmale und Berechnung  $M_s$  mit informationstheoretischen Maßen. Die ZGH zu den Cluster-Zentren beziehen sich auf die verschiedenen Subgruppen, z.B. ZGH<sup>SUB1</sup> für SUB1. Unten: Relevanzen von „Referenz-Cluster“.

Gehören die Patienten nach der Therapie einer anderen Subgruppe an? Z.B. Gibt es Patienten, die im PRE-Zustand der Recurvatum-Subgruppe angehören und durch die Therapie diese Knieüberstreckung sich normalisiert, so dass die Patienten im POST-Zustand der Referenzgruppe angehören?

Die größten Relevanzen weisen die ZGH der fünf Cluster-Zentren von SUB3 auf (die von Fall zu Fall mit den ZGH der OSG-Subgruppen hoch korrelieren), siehe Tabelle 5.10. Auffällig sind die hohen Relevanzen zu den Cluster-Zentren, die das Referenzkollektiv beschreiben, hier z.B. „ZGH<sup>SUB3</sup> Cluster 4 (REF)“ (ZGH zum

„Referenz-Cluster 4“ in SUB3, siehe Abbildung 5.19. Die ZGH zu den verschiedenen „Referenz-Clustern“ (aus SUB2 oder SUB4) sind bei den Daten von ICP,PRE und ICP,POST hoch korreliert, so dass sie in der Relevanz herab gestuft sind (Tabelle 5.10 unten). Die hohen Relevanzen drücken eine Normalisierung des Gangbildes aus, das allerdings sehr stark durch das OSG sag dominiert wird, siehe „ZGH<sup>SUB2</sup> Cluster 2“ oder „ZGH<sup>SUB2</sup> Cluster 4 (REF)“. Auffallend ist auch, dass alle ZGH der Knie-Subgruppen (SUB1) eine Relevanz  $M_s = 0.00$  haben. Die Patienten gehören also im Knie ihrer ursprünglichen Subgruppen an (PRE-Zustand Gruppierung), d.h. im Knie findet kein Wechsel der Subgruppen statt.

### Neue Visualisierungen der Subgruppen

Mit der maximalen ZGH zu den einzelnen Clustern lassen sich diskrete Klasseneinteilungen für die einzelnen Patienten erzeugen. Durch Beibehalten dieser Klasseneinteilung, aber Verwendung der Datensätze zum POST-Zustand lassen sich Mittelwertzeitreihen visualisieren, die tendenzielle Änderungen durch die Therapie beschreiben, siehe Abbildungen 5.20 und 5.21.

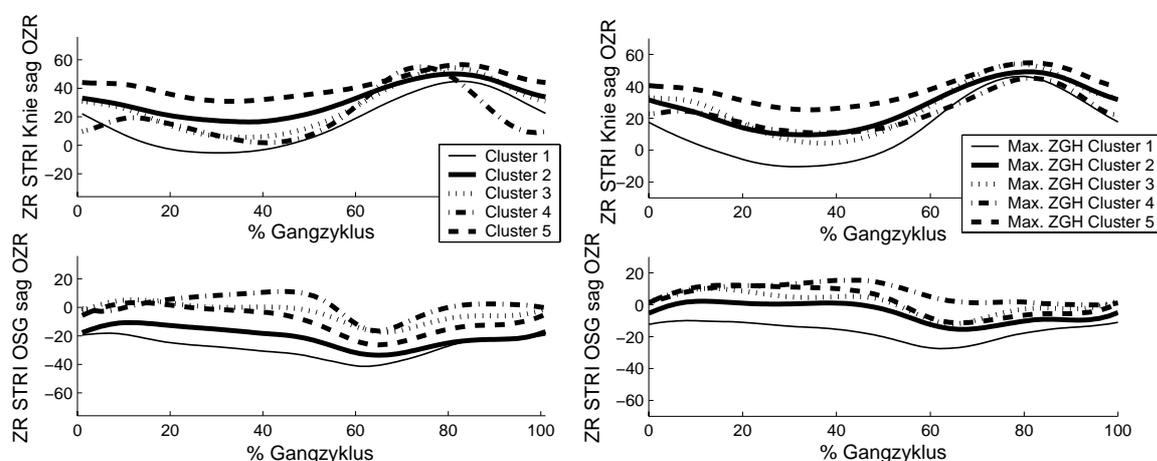


Abbildung 5.20: Subgruppen aus SUB3, links: PRE-therapeutische Cluster. Rechts: Mittelwertzeitreihen der diskretisierten PRE-therapeutischen Cluster-ZGH zum POST-Zustand.

Hierbei sind die bereits diskutierten Effekte dargestellt, z.B. die Über-Korrektur von Patienten mit einer geringen PRE-therapeutischen OSG sag Referenzabweichung, Cluster 4 in Abbildung 5.21. Die unbefriedigenden Verbesserungen der Patienten mit Recurvatum sind gut durch Cluster 1 in Abbildung 5.20 zu sehen.

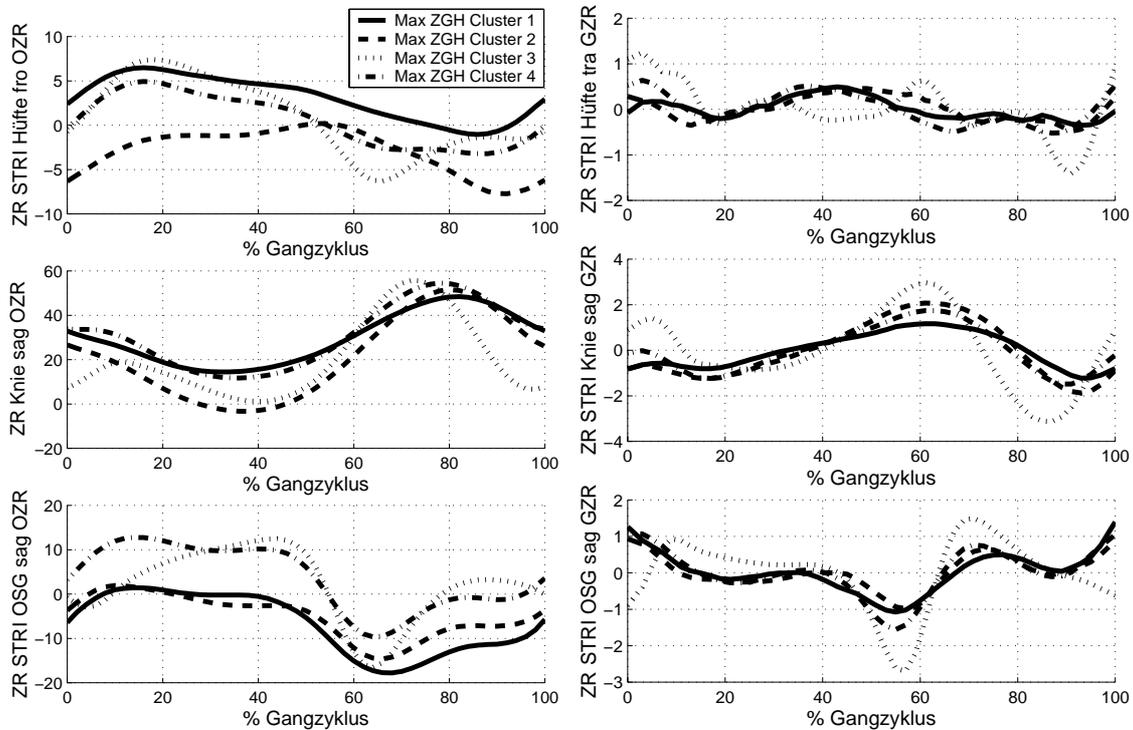


Abbildung 5.21: Visualisierung der Subgruppen SUB4 zum POST-Zustand, vgl. Abbildung 5.12.

### 5.2.3 Zusammenfassung und Wertung

Es existieren viele langjährige Forschungsarbeiten über ICP-Patienten [125, 136, 150, 159, 174] mit deren Hilfe die in der vorliegenden Arbeit modifizierten Methoden validiert wurden. Allerdings werden in den bereits bestehenden Arbeiten aufgrund der ICP-Komplexität viele offene Fragen beklagt [30, 53, 146]. Dazu konnten in dieser Arbeit wesentliche Beiträge zur Lösung geleistet werden [89, 90, 91, 92, 94, 96]:

- Plausible, interpretierbare Einschätzungen des pathologischen Ausmaßes wurden durch Referenzabweichungen realisiert. Die Aussagen sind im Vergleich zur Literatur [18, 159, 182] besser interpretierbar, da sie das Verhältnis zum Referenzkorridor bewerten und das subjektive Analyseverfahren abbilden [41].
- Charakteristische, interpretierbare Einzelmerkmale, die aus der Literatur bekannt sind, wurden mit den hier verwendeten Methoden ebenfalls gefunden, einige Merkmale eignen sich sogar noch besser. Weiterhin wurden auch bisher vernachlässigte Merkmale erkannt, die klinisch sehr nützlich sind [175].

- Relevante Subgruppen existieren und wurden in dieser Arbeit quantitativ nachgewiesen. Durch Einbezug des gesamten Datenraumes und eine automatisierte Analyse konnten sogar Zusammenhänge zwischen bestimmten Gelenken aufgedeckt werden. Hinweise zur Existenz von Subgruppen werden in der Literatur [12, 151, 174] nur ansatzweise empirisch vermutet. Erste quantitative Analysen beziehen sich nur auf einzelne Gelenke oder klinische Parameter, Zusammenhänge können damit nicht gefunden werden [110, 118, 145].
- Ansätze für eine Therapieprognose wurden in der vorliegenden Arbeit gefunden, Beiträge dazu liefern die gefundenen Subgruppen zwischen den Gelenken. Prognostische Aussagen bei ICP mit Botulinum-Toxin-Behandlung gibt es derzeit in der Literatur kaum [152].

### 5.3 Inkomplette Querschnittlähmung (SCI)

Die SCI-Patienten (Inkomplette Querschnittlähmung, Spinal Cord Injury) sind zwar alle durch eine teilweise Schädigung des Rückenmarks gekennzeichnet, aber die Ursachen (Blutung, Tumor, Unfall, ...) und Lähmungshöhe der Wirbelsäule sind stark unterschiedlich, d.h. das Kollektiv ist neurologisch stark heterogen, siehe Kapitel 2. Die Anwendung der hier vorgestellten Werkzeuge ist analog zu den ICP-Daten (vgl. auch Abbildung 5.1), so dass die Ergebnisse teilweise kompakt dargestellt werden und auf weiterführende Literatur verwiesen wird [4, 41, 88, 93, 95]. Darüber hinaus sind bei den SCI-Patienten klinische Fragestellungen und Schwerpunkte unterschiedlich, beispielsweise ist die quantitative Einschätzung der Gangqualität einzelner Patienten von großem Interesse. Dazu stehen hier visuelle Experteneinschätzungen zur Verfügung, an denen sich die Auswahl von Qualitätsparametern orientieren kann.

Mit diesen Einschätzungen lässt sich der Verlauf der Therapie dokumentieren. Im Gegensatz zu den ICP-Patienten existieren allerdings keine differenzierten Therapievarianten (z.B. Dosierung und Injektionsbereich von Medikamenten, unterschiedliche Operationen, ...). Dafür ist die Überprüfung der Laufbandtherapie von großem Interesse, insbesondere zur effektive Nutzung immer knapper werdender Ressourcen [4, 127]. Die Motivation der Patienten kann zudem durch die Rückführung einer quantitativen Gangqualität während dem Gehen gesteigert werden (analog eines Fahrradtachos bei Sportlern zur intensiveren Trainingsausnutzung).

### 5.3.1 Neues Auswerteverfahren für die Diagnose

#### Verallgemeinerte Quantifizierung des pathologischen Ausmaßes

Aufgrund sehr individueller Schädigungen des Rückenmarks kommt der einzelnen Betrachtung der Patienten eine klinisch sehr große Bedeutung zu. Dabei ist neben den pathologischen Ausmaßen für das gesamte Kollektiv auch die objektive, standardisierte Einschätzung einzelner Patienten wichtig. Derartige Einschätzungen existieren in der klinischen Praxis nur wenige. Viele sind durch subjektive Meinungen geprägt. Zu dem Datensatz existieren hier formalisierte, visuelle Einschätzungen von drei unabhängigen Experten (VAS A, VAS B, VAS C und deren Mittelwert VAS M, VAS = Visuelle Analog Skala), die auf einer Punkteskala von Null (Patient kann sehr schlecht gehen) bis Zehn (Patient läuft gut) ausgelegt sind. Allerdings variieren auch die drei Meinungen oder sind stark an klinisch erhobene Parameter angelehnt, ohne das eigentliche Kinematik-Gangbild zu bewerten, siehe Tabelle 5.11 und im Anhang Abbildung E.7.

VAS	Parameter	$\rho$
VAS A	Gehgeschwindigkeit	0.56
	& Entlastung % KG	0.70
	& „MW STRI OSG sag RZR“	0.77
VAS B	Gehgeschwindigkeit	0.52
	& Lähmungshöhe	0.68
	& „MW STRI Hüfte sag RZR“	0.73
VAS C	Gehgeschwindigkeit	0.77
	& Lähmungshöhe	0.81
	& „MW STRI OSG sag RZR“	0.84
VAS M	Gehgeschwindigkeit	0.70
	& Lähmungshöhe	0.76
	& „MW STRI Hüfte fro sag RZR“	0.80

Tabelle 5.11: Lineare Regression mit erreichter Korrelation  $\rho$  zur Erklärung der VAS mit den klinischen Parametern: prozentuale Gewichtsentslastung bezogen auf das Körpergewicht (Entlastung % KG), erreichte Gehdauer, Gehgeschwindigkeit, Halten am Barren links bzw. rechts, Lähmungshöhe, Gehstrecke, Variabilität, Körpergewicht, Hilfsmittel rechter bzw. linker Fuß und Kinematik-Einzelmerkmale aus Tabelle 5.12.

Allein durch Verwendung der erhobenen klinischen Parameter kann die VAS durch die Gehgeschwindigkeit und die prozentuale Gewichtsentlastung gut nachgebildet werden. Allerdings muss beachtet werden, dass diese die beiden Parameter bereits durch die subjektive Einschätzung des Gehvermögens von erfahrenen Klinikern während der Therapie optimiert wurden (selbst die Gehgeschwindigkeit wird durch physiologische Bewertung während der Laufbandtherapie eingestellt). Weiterhin fällt auf, dass die Merkmale aus der eigentlichen Gang-Kinematik sehr eingeschränkt einbezogen werden, Tabelle 5.11 rechts.

Aufgrund der unterschiedlichen Expertenmeinungen und des fehlenden Bezuges zur Kinematik bei der Bestimmung einer Gangqualität wird im Folgenden das quantitative pathologische Ausmaß basierend auf den Referenzabweichungszeitreihen aus Gl. (3.8) angewendet.

Das pathologische Ausmaß für das gesamte SCI,PRE-Kollektiv (46 Datensätze) zeigt Tabelle 5.12. Dabei wurde das REF,M Kollektiv (Referenz mit mittlerer Gehgeschwindigkeit, 20 Datensätze) verwendet. Das Ziel einer therapeutischen Verbesserung der Patienten ist das Angleichen an das physiologische Gangbild (Referenzgangbild) bei mittlerer Gehgeschwindigkeit. Im Vergleich zu den ICP-Patienten zeigen die SCI-Patienten weniger stark ausgeprägte Abweichungen.

Gelenk/ Ebene	sagittal	SCI,PRE → SCI,POST	
		frontal	transversal
Becken OZR	$2.3 \pm 1.5 \rightarrow 1.8 \pm 1.4$	$1.8 \pm 1.0 \rightarrow 1.3 \pm 0.6$	$1.1 \pm 0.6 \rightarrow 1.0 \pm 0.5$
Becken GZR	$0.8 \pm 0.3 \rightarrow 0.7 \pm 0.3^*$	$0.9 \pm 0.2 \rightarrow 0.8 \pm 0.2$	$0.8 \pm 0.3 \rightarrow 0.9 \pm 0.2$
Hüfte OZR	$2.1 \pm 1.2 \rightarrow 1.7 \pm 1.0$	$1.6 \pm 0.9 \rightarrow 1.3 \pm 0.7$	$1.2 \pm 0.8 \rightarrow 1.1 \pm 0.6$
Hüfte GZR	$1.7 \pm 0.4 \rightarrow 1.3 \pm 0.5^*$	$1.0 \pm 0.2 \rightarrow 0.9 \pm 0.3$	$0.8 \pm 0.3 \rightarrow 0.9 \pm 0.3^*$
Knie OZR	$2.3 \pm 0.8 \rightarrow 1.9 \pm 1.2^*$		
Knie GZR	$2.0 \pm 0.6 \rightarrow 1.6 \pm 0.7^*$		
OSG OZR	$2.1 \pm 0.8 \rightarrow 1.9 \pm 0.9^*$		$1.2 \pm 1.0 \rightarrow 1.1 \pm 0.5$
OSG GZR	$1.3 \pm 0.3 \rightarrow 0.9 \pm 0.3^*$		$0.8 \pm 0.2 \rightarrow 0.7 \pm 0.3$
gesamt OZR	$1.8 \pm 1.6 \rightarrow 1.5 \pm 0.4^*$	$1.4 \pm 0.9 \rightarrow 1.3 \pm 0.7$	$1.1 \pm 0.7 \rightarrow 1.1 \pm 0.5$
gesamt GZR	$1.1 \pm 0.7 \rightarrow 1.0 \pm 0.3^*$	$0.8 \pm 0.3 \rightarrow 0.8 \pm 0.3$	$0.7 \pm 0.3 \rightarrow 0.8 \pm 0.3$
gesamt OZR		$1.5 \pm 1.0 \rightarrow 1.4 \pm 0.9^*$	
gesamt GZR		$0.9 \pm 0.5 \rightarrow 0.8 \pm 0.4^*$	

Tabelle 5.12: Gemittelte Referenzabweichungen der Kinematikzeitreihen (OZR) sowie deren Geschwindigkeitszeitreihen (GZR) des SCI,PRE-Kollektives (46 Datensätze). Die SCI,POST-Werte dienen hier nur dem späteren Verweis für die Datenauswertung bezüglich Therapie, signifikante Verbesserungen sind mit \* markiert.

Um ein objektives Qualitätsmaß zu ermitteln, das die Gang-Kinematik einschätzt, werden im Folgenden die Merkmale aus Tabelle 5.12 für die einzelnen Patienten verwendet. Sie werden mit Hilfe der Regression zur Nachbildung der VAS bewertet<sup>5</sup>, siehe Tabelle 5.13. Die zusätzliche Verwendung von mehr als drei Merkmalen verbessert die erreichte Korrelation  $\rho$  kaum (maximal erreichte Korrelation ist  $\rho = 0.69$ ). Weiterhin fällt auf, dass sich die drei Experten noch am meisten an den sagittalen Merkmalen der Hüfte, des Knie und des OSG orientieren. Insbesondere bei VAS M ist dabei der Einbezug des sagittalen Beckenwinkels eher unwichtig (das Merkmal erscheint bei der Regressionsanalyse an letzter Stelle mit einer erreichten Korrelation von  $|\rho| = 0.69$ ). Das Qualitätsmaß soll unabhängig von der Pathologie (Patientenkollektiv) standardisiert und objektiv die Gangqualität einschätzen. Zum Vergleich sind bei der automatisierten Charakterisierung der ICP-Patienten die Beckenwinkel weniger wichtig, vgl. Abbildung 5.7 (die Gangqualität soll unabhängig vom Patientenkollektiv entwickelt werden). Zudem ist die Beckenbewegung zur Bewertung des Gehens der SCI-Patienten verfälscht, da sie durch die Gewichtsentlastung oder das Halten am Barren beeinflusst wird. Weiterhin ist wie bereits beschrieben die Messung des Winkels nicht valide, da eine optimale Positionierung des Sakralmarkers schwierig ist, insbesondere beim Anlegen des Gewichtsentlastungssystems. Die Merkmale aus den anderen Körperebenen sind bei der Erklärung der VAS eher unwichtig. Daher wird im Folgenden der Mittelwert der Referenzabweichung über die sagittalen Hüft-, Knie- und OSG-Winkel „MW sag RZR“ betrachtet (Mittelwert aus „MW STRI Hüfte sag RZR“, „MW STRI Knie sag RZR“ und „MW STRI OSG sag RZR“). Zum Vergleich korreliert der Mittelwert der Referenzabweichung über alle neun Gelenke mit nur  $\rho = 0.61$  zur VAS M und bildet somit die Gangqualität schlechter ab. Der Grund ist, dass die frontale und transversale Ebene im Gegensatz zur sagittalen Ebene geringere Referenzabweichungen aufweisen (sowohl bei ICP als auch bei SCI) und daher eine Gesamteinschätzung trotz Pathologie zum Besseren tendiert.

Die Gewichtungsfaktoren  $\alpha_i$  aus Gl. (3.26) können als unterschiedliche Korridorbreite der Referenz interpretiert werden, vgl. Gl. (3.8) mit  $\gamma = 1/\alpha_i$ . Allerdings ist die Festlegung aufgrund der unterschiedlichen Gewichtung der einzelnen Experten schwierig. Zudem erklärt bereits „MW sag RZR“ die VAS zufriedenstellend.

Weitere Merkmale zur Bestimmung einer Kinematik-Gangqualität, wie z.B. die Referenzabweichung über die GZR oder Korrelationskoeffizienten zur Einschätzung

---

<sup>5</sup>Basierend auf den Referenzabweichungszeitreihen können natürlich weitere Einzelmerkmale verwendet werden, die sogar die VAS M noch besser erklären, wie z.B. Maximum der Referenzabweichung, Mittelwerte der Referenzabweichung über Standphasen oder Kombinationen aus beiden. Diese sind allerdings anfällig für Messfehler oder bewerten nicht das gesamte Gangbild, so dass sie nicht weiter betrachtet werden.

VAS	Einzelmerkmale	$\alpha_i$	Korrelation $ \rho $	
			mit $\alpha_i$	„MW sag RZR“
VAS A	MW STRI Knie sag RZR	-1.40	0.58	0.62
	& MW STRI OSG sag RZR	-0.74	0.65	
	& MW STRI Hüfte sag RZR	-0.43	0.67	
VAS B	MW STRI OSG sag RZR	-0.62	0.41	0.55
	& MW STRI Hüfte sag RZR	-0.70	0.49	
	& MW STRI Knie sag RZR	-0.70	0.55	
VAS C	MW STRI Knie sag RZR	-1.83	0.50	0.64
	& MW STRI Hüfte sag RZR	-1.47	0.63	
	& MW STRI Becken sag RZR	+0.65	0.66	
VAS M	MW STRI Knie sag RZR	-1.14	0.51	0.64
	& MW STRI Hüfte sag RZR	-0.75	0.63	
	& MW STRI OSG sag RZR	-0.59	0.66	

Tabelle 5.13: Multiple Regressionsanalyse mit erreichter (betragsmäßiger) Korrelation  $\rho$  zur Erklärung der VAS mit den Einzelmerkmalen über OZR der einzelnen neun Gelenkwinkel aus Tabelle 5.12. Als Vergleich dient der Mittelwert „MW sag RZR“ über die Einzelmerkmale der sagittalen Hüft-, Knie- und OSG-Winkel.

von Kurvenähnlichkeiten aus Gl. (3.10), sind in ihrer klinischen Akzeptanz tendenziell gering.

Daher wird hier zur Einschätzung der Kinematik-Gangqualität der „MW sag RZR“ neu vorgeschlagen, der aus klinischer Sicht akzeptiert wird [4, 41, 127]. Damit sind die wichtigsten Gelenke und Körperebenen beim Gehen erfasst. Er stellt einen guten Kompromiss aus Interpretierbarkeit (mittlere Abweichung in Bezug auf die halbe Referenzkorridorbreite) und einer guten Korrelation mit  $\rho = 0.64$  zur VAS M dar. Weiterhin fiel auf, dass eine größere Korrelation mit  $|\rho| = 0.78$  zwischen VAS M und „MW sag RZR“ für Patienten ohne Gewichtsentlastung erreicht wird, siehe im Anhang Abbildung E.7.

### Verallgemeinerte Charakterisierung des Krankheitsbildes

In den letzten Jahren wurden SCI-Patienten aufgrund zunehmender erfolgsversprechender Therapieaussichten in Ganganalyselabors verstärkt untersucht. Allerdings besteht aufgrund der mangelnden Forschungsarbeiten zur Auswertung der SCI-Gang-Kinematik ein großer Nachholbedarf.

Die relevanten Einzelmerkmale des gesamten SCI-Kollektives zeigt Tabelle 5.14.

Da die neurologischen Ursachen bei den SCI-Patienten unterschiedlich sind, ist die klinische Bedeutung derartiger Merkmale über das gesamte Kollektiv zunächst eher gering. Anders aus Sicht der Datenanalyse, da hierbei ein wichtiger Beitrag zur Reduzierung einer großen Anzahl von Daten auf wenige informationstragende Merkmale geleistet wird. Dabei fällt auf, dass einige Merkmale sich auf bestimmte Gangphasen des Schwungs beziehen (wobei durch  $M_{s,ap}$  der gesamte Schritt bevorzugt wurde).

Nr.	Einzelmerkmal	$\rho_m$	$M_{s,uk}$	SCI, PRE	REF,M	REF,L
S1	MW ISw OSG sag OZR	✓	0.417	$9.1 \pm 6.2$	$-8.0 \pm 3.4$	$6.2 \pm 3.1$
S2	SpW ST Hüfte sag OZR	✓	0.412	$28.8 \pm 6.4$	$40.0 \pm 2.6$	$29.7 \pm 4.0$
S3	MAX ISw Knie sag OZR	✓	0.383	$29.5 \pm 12.8$	$57.0 \pm 5.0$	$28.8 \pm 8.4$
S4	MIN STRI Hüfte sag OZR	✓	0.329	$7.9 \pm 10.9$	$-7.0 \pm 5.9$	$-3.0 \pm 6.0$
S5	SpW STRI Hüfte fro OZR	✓	0.287	$6.3 \pm 2.5$	$12.0 \pm 3.5$	$10.0 \pm 2.9$
S6	MIN SW Hüfte sag GZR	✓	0.268	$-0.7 \pm 0.4$	$-0.1 \pm 0.1$	$-0.3 \pm 0.2$
S7	SpW STRI Becken sag OZR	✓	0.227	$4.7 \pm 2.1$	$2.6 \pm 0.7$	$2.8 \pm 1.0$
S8	SpW TSw Hüfte sag OZR		0.210	$5.8 \pm 2.9$	$2.1 \pm 1.0$	$5.2 \pm 2.7$
S9	MW STRI Hüfte sag SZR	✓	0.203	$2.1 \pm 0.7$	$1.3 \pm 0.3$	$1.9 \pm 0.5$
S10	SpW ST Knie sag OZR		0.185	$14.3 \pm 7.7$	$16.5 \pm 3.2$	$8.8 \pm 3.3$
S11	MW PSw OSG tra GZR		0.150	$-0.1 \pm 0.1$	$0.1 \pm 0.1$	$-0.1 \pm 0.1$
S12	MIN ST OSG sag GZR		0.148	$-1.1 \pm 0.7$	$-1.9 \pm 0.6$	$-0.9 \pm 0.5$
S13	MW STRI Becken sag SZR	✓	0.148	$1.4 \pm 0.4$	$0.9 \pm 0.2$	$1.1 \pm 0.3$
S14	MIN ISw OSG tra GZR		0.147	$-0.3 \pm 0.4$	$-1.5 \pm 0.6$	$-0.3 \pm 0.3$
S15	MW ST OSG sag GZR		0.141	$0.2 \pm 0.1$	$0.1 \pm 0.1$	$0.1 \pm 0.1$
S16	MAX SW OSG sag GZR		0.135	$1.3 \pm 0.9$	$1.9 \pm 0.6$	$2.0 \pm 1.1$

Tabelle 5.14: Charakteristische Einzelmerkmale des SCI,PRE-Kollektives (46 Datensätze) im Vergleich zur Referenz (REF,M 20 Datensätze) mit standardisierten Gangphasen, Apriori-Relevanz  $M_{s,ap}$ , Berechnung von  $M_s$  durch informationstheoretische Maße und Rückstufung korrelierter Einzelmerkmale  $M_{s,uk}$ . Die Wertebereiche von REF,L (Referenz mit langsamer Gehgeschwindigkeit) dienen nur dem Vergleich.  $\rho_m$  gibt Korrelationen  $\rho > 0.7$  zu den Einzelmerkmalen aus Tabelle 5.15 an.

Abbildung 5.22 zeigt beispielhaft zwei Fuzzy-Regeln zur Charakterisierung des SCI-Krankheitsbildes. Hierbei fällt wieder die Wichtigkeit der Merkmalskombination auf, die oft nichtlinear zusammen hängen. Die eindeutige Trennung der beiden Klassen ist wiederum mit bereits wenigen Merkmalen zu erreichen. Ein automatisiert generierter Erklärungstext [89, 107] der links visualisierten Regel lautet (die Negation kann mit den de Morganschen Gesetzen erfolgen, vgl. Abbildung 5.9):

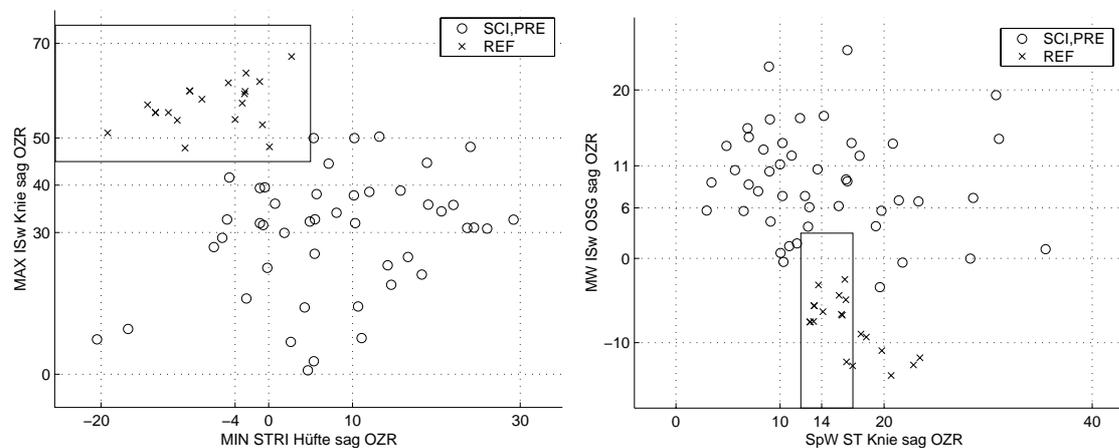


Abbildung 5.22: Visualisierung zweier automatisch generierter Fuzzy-Regeln zur Unterscheidung SCI,PRE und REF.

Die Beispiele für Referenzpersonen (REF) sind dadurch charakterisiert, dass das Minimum der Hüftflexion während des Schrittes (MIN STRI Hüfte sag OZR) häufig kleiner als sonst ist: häufig leicht negativ (zwischen  $-12^\circ$  und  $-2^\circ$ ); gelegentlich stark negativ (kleiner als  $-12^\circ$ ) und gelegentlich ungefähr Null (zwischen  $-2^\circ$  und  $5^\circ$ ). Weiterhin gilt für die Beispiele, dass das Maximum der Knieflexion während Initial Swing (MAX ISw Knie sag OZR) meistens größer als sonst ist: meistens groß (zwischen  $45^\circ$  und  $60^\circ$ ) und gelegentlich sehr groß (größer als  $60^\circ$ ). Aus den Aussagen lässt sich eine Regel aufbauen, die alle Fälle von Referenzpersonen (REF) beschreibt: WENN das Minimum der Hüftflexion während des Schrittes (MIN STRI Hüfte sag OZR) stark negativ bis ungefähr Null (kleiner als  $5^\circ$ ) ist UND das Maximum der Knieflexion während Initial Swing (MAX ISw Knie sag OZR) groß bis sehr groß (größer als  $45^\circ$ ) ist, DANN FOLGT DARAUS immer Referenzpersonen (REF).

Trotz der klinischen Skepsis, konnten mit den gezeigten Merkmalen über das gesamte Kollektiv einige Gemeinsamkeiten der SCI-Pathologie erkannt werden. Bei detaillierterer Diskussion der Merkmale konnten Zusammenhänge gefunden werden, die aufgrund der wenigen SCI-Forschungsergebnisse weitgehend ungeklärt waren, wie nachfolgend gezeigt wird. Viele SCI-Patienten können aufgrund geschwächter Streckmuskeln (im Wesentlichen Gluteus Maximus Muskel) ihre Hüfte während des Gehens nicht vollständig strecken. Die automatisierte Charakterisierung fand die Gangstörung bei den Patienten durch die beiden Merkmale „MIN STRI Hüfte sag OZR“ (bei Patienten im Vergleich zur Referenz erhöht) und „SpW ST Hüfte sag OZR“ (bei Patienten reduziert). Die Fähigkeit, die Hüfte vollständig zu strecken,

ist ein wichtiger Indikator einer therapeutischen Entwicklung und wird gezielt bei der Laufbandtherapie trainiert [7]. Ein weiteres charakteristisches Merkmal der SCI-Patienten ist der erhöhte Mittelwert „MW ISw OSG sag OZR“. Die Patienten laufen oftmals ängstlich und versuchen, ein Stolpern zu vermeiden. Daher bemühen sie sich, die Bodenfreiheit zu erhöhen, um im Schwung nicht in Bodenkontakt zu geraten. Das wird durch das Beibehalten des OSG in Dorsalflexion (oder zumindest kleine Plantarflexion) während des Schwunges erreicht. Des Weiteren ist das Verhalten eine Kompensation für eine reduzierte Knieflexion (kleines „MAX ISw Knie sag OSG“). Das SCI-Gangbild zeigt weiterhin eine reduzierte Spannweite (phasenweise) in Hüfte, Knie und OSG, siehe „SpW SW Hüfte sag OZR“ und „SpW STRI Hüfte fro OZR“. Das hängt auch mit dem eher vorsichtigen Gangverhalten und der kleinen Schrittlänge (liegt hier nicht als Messung vor) zusammen. Die Patienten haben eine sehr schwache Rumpfmuskulatur, so dass sie Schwierigkeiten haben, die Hüfte anzuheben (Hüft-Ab-Adduktion, frontaler Hüftwinkel). Weiterhin kann das Merkmal auch mit dem Gewichtsentlastungssystem zusammen hängen. Die „SpW STRI Becken sag OZR“ ist bei den Patienten erhöht, obwohl sich alle Patienten zur PRE-Untersuchung am Barren halten. Das zeigt eine schlechte Kontrolle des Oberkörpers der Patienten. Beim Becken ist die Betrachtung der Spannweite (SpW) im Gegensatz zum Mittelwert zulässig, da die Probleme der Messdatenerfassung (konstanter Offset) darin nicht enthalten sind.

Manche der gefundenen Merkmale hängen allerdings auch mit dem langsamen Gehen und verschobenen Gangphasen zusammen, vermutlich z.B. „SpW ST Knie sag OZR“. Tabelle 5.15 zeigt dafür charakteristische Merkmale für das 2-Klassenproblem zur Trennung von SCI,PRE und REF,L zusammen mit REF,M (ODER-Verknüpfung bei der Datenauswahl von REF,L und REF,M und Vereinheitlichung als eine Klasse). Hierbei fällt auf, dass die meisten Merkmale identisch bzw. hoch korreliert zu den bereits diskutierten Merkmalen sind. Daher führt die alleinige Betrachtung von REF,M zu validen Ergebnissen, die zudem die klinische Zielstellung der Therapie erfüllt (Annäherung des SCI-Gangbildes an mittlere Gehgeschwindigkeit). Ein weiterer Vergleich zu einer individuellen Phaseneinteilung erfolgt hier nicht mehr.

Eine hohe Relevanz  $M_s$  gibt zudem Hinweise auf eine zuverlässige Anwendung der Merkmale. Im Vergleich zu den ICP-Patienten weisen die Relevanzen der SCI-Patienten geringere Werte auf. Ein Grund ist, dass manche Patienten sich kaum vom Gangbild der Referenz unterscheiden. Zudem werden trotz niedriger Priorisierung durch die Apriori-Relevanz  $M_{s,ap}$  einige phasenbezogene Merkmale gefunden. Das deutet im Vergleich zum ICP-Gangbild auf weniger stark ausgeprägte globale Gangstörungen hin.

Nr.	Einzelmerkmal	$\rho_m$	$M_{s,uk}$	SCI, PRE	REF,L	REF,M
C1	MAX STRI Becken sag GZR	✓	0.32	$0.4 \pm 0.2$	$0.2 \pm 0.1$	$0.2 \pm 0.0$
C2	MIN STRI Hüfte sag OZR	✓	0.29	$7.9 \pm 10.9$	$-3.0 \pm 6.0$	$-7.0 \pm 5.9$
C3	SpW STRI Becken fro OZR	✓	0.24	$3.7 \pm 2.3$	$5.7 \pm 1.2$	$7.9 \pm 2.8$
C4	MIN PSw Hüfte fro GZR	✓	0.19	$-0.2 \pm 0.1$	$-0.4 \pm 0.2$	$-0.6 \pm 0.2$
C5	MIN SW Hüfte sag GZR	✓	0.18	$-0.7 \pm 0.4$	$-0.3 \pm 0.2$	$-0.1 \pm 0.1$
C6	MAX MSt Hüfte sag GZR		0.17	$-0.1 \pm 0.3$	$-0.5 \pm 0.1$	$-0.5 \pm 0.2$
C7	MAX STRI Hüfte sag GZR		0.16	$1.8 \pm 0.5$	$1.9 \pm 0.3$	$2.1 \pm 0.2$
C8	MIN SW OSG sag OZR		0.15	$-4.7 \pm 8.3$	$-7.5 \pm 6.4$	$-15.4 \pm 3.6$
C9	MW STRI Becken sag SZR	✓	0.15	$1.4 \pm 0.4$	$1.1 \pm 0.3$	$0.9 \pm 0.2$
C10	MW ISw OSG sag OZR	✓	0.15	$9.1 \pm 6.2$	$6.2 \pm 3.1$	$-8.0 \pm 3.4$
C11	SpW ISw Hüfte sag OZR	✓	0.14	$6.9 \pm 4.2$	$5.5 \pm 4.1$	$18.8 \pm 2.2$
C12	MW TSw OSG tra GZR		0.14	$-0.1 \pm 0.5$	$0.6 \pm 0.3$	$0.7 \pm 0.3$
C13	MAX SW Becken sag GZR		0.13	$0.2 \pm 0.1$	$0.1 \pm 0.1$	$0.2 \pm 0.0$
C14	SpW SW Knie sag OZR		0.13	$41.9 \pm 11.6$	$44.2 \pm 4.8$	$53.6 \pm 2.9$
C15	MAX MSw Hüfte fro GZR		0.12	$0.2 \pm 0.2$	$0.4 \pm 0.1$	$0.4 \pm 0.1$
C16	MW STRI Hüfte sag SZR	✓	0.11	$2.1 \pm 0.7$	$1.9 \pm 0.5$	$1.3 \pm 0.3$

Tabelle 5.15: Charakteristische Einzelmerkmale für 2-Klassenproblem SCI,PRE gegen REF,L UND REF,M zusammen (mit informationstheoretischen Maßen, standardisierten Gangphasen, Rückstufung korrelierter Merkmale).  $\rho_m$  gibt Korrelationen  $\rho > 0.7$  zu den Einzelmerkmalen aus Tabelle 5.14 an.

### Verbessertes Finden von Subgruppen

Aufgrund der individuellen Schädigungen der Wirbelsäule sind unterschiedliche Auswirkungen in Form von Subgruppen im Gangverhalten von der klinischen Seite her zu erwarten. Das Finden von Subgruppen und somit die Bestätigung dieser Annahmen wird im Folgenden gezeigt.

Exemplarisch zeigt Abbildung 5.23 Subgruppen über eine heuristisch gefundene Kombination aus drei Zeitreihen, die als SUB1,SCI bezeichnet wird. Die Auswahl der Zeitreihen basiert auf den Ergebnissen bei der Ermittlung der Gangqualität, da die klinischen Experten verstärkt auf die drei Zeitreihen achten und ihre Einschätzung zum größten Teil daraus ableiten. Die Zeitreihen sind auf ein  $[-1, +1]$  Intervall normiert und alle Abtastzeitpunkte sind als Merkmale beim Clustern verwendet. Aus Sicht der Datenanalyse lassen sich Subgruppen bei den SCI-Patienten leichter finden als bei den ICP-Patienten. Die Separation ist sogar bei den drei Zeitreihenkombinationen mit  $S = 11.92$  sehr gering. Die Gründe liegen darin, dass die Laufmuster nicht so stark individuell ausgeprägt sind und somit keine überlagerten Effekte existieren. Alle SCI-Patienten konnten vor ihrer Erkrankung ohne jegli-

che orthopädische Einschränkung gehen. Aus klinischer Sicht kann daher vermutet werden, dass ein allgemeines Grundlaufmuster bei den Patienten erhalten ist und somit die stark individuellen Überlagerungseffekte nicht auftreten (zum Vergleich: Die ICP-Patienten mussten von Geburt an ein individuelles Optimum zum Gehen finden, das dementsprechend stark unterschiedlich zwischen den Patienten ist). Erst durch die Erkrankung sind die Muskeln nicht mehr willkürlich ansteuerbar, so dass Subgruppen entsprechend dem Grad der Schädigung auftreten.

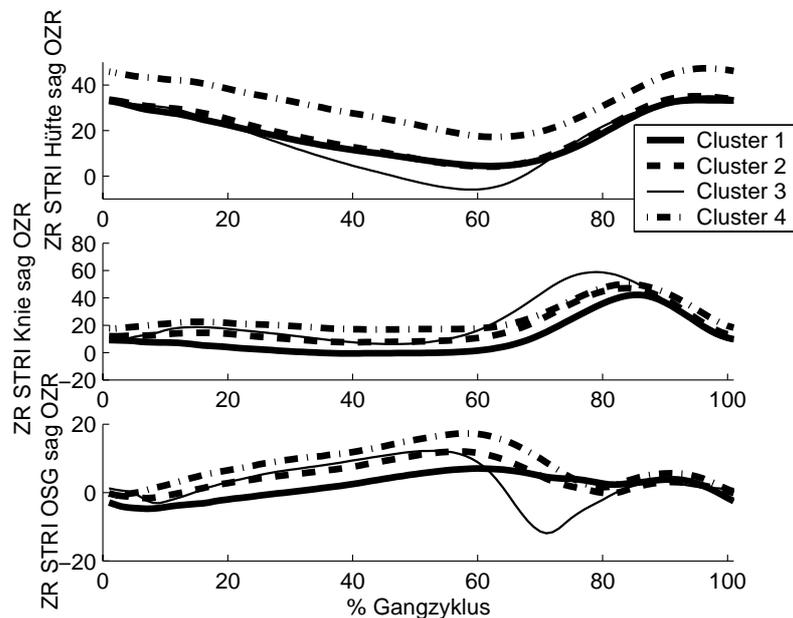


Abbildung 5.23: Subgruppen SUB1,SCI mit „ZR STRI Hüfte sag OZR“, „ZR STRI Knie sag OZR“ und „ZR STRI OSG sag OZR“.

Durch das Clustern konnten sowohl die Referenzdaten sehr gut erkannt (Cluster 3 in Abbildung 5.23) als auch weitere Patienten-Subgruppen gefunden werden. Bemerkenswert ist hierbei, dass sich nur drei voneinander deutlich unterscheidbare Muster innerhalb der Querschnittspatienten ergeben. Das deutet darauf hin, dass in der (neurologisch) sehr inhomogenen Patientengruppe klar unterscheidbare funktionelle Gangmuster existieren, die in gewisser Weise miteinander vergleichbar sind: Eine Subgruppe hat ein gestrecktes Knie insbesondere während der Standphase mit einer nur tendenziell leicht erhöhten Hüft- und Plantarflexion (Cluster 1). Eine weitere Subgruppe (Cluster 4) geht mit einem permanent gebeugten Knie während der Standphase in Kombination mit einer stark erhöhten Hüftflexion und leicht erhöhten Dorsalflexion. Cluster 2 beschreibt ein Gangbild, das funktionelle Bewegungen beider Patientensubgruppen beinhaltet. Alle gefundenen Subgruppen können mit bio-

mechanischen Modellen bestätigt werden (z.B. hat ein gebeugtes Knie eine erhöhte Hüftflexion zur Folge oder bei einem gestreckten Knie muss die Vorwärtsbewegung durch eine erhöhte Hüftflexion erreicht werden).

Eine Automatisierung zum Finden geeigneter Zeitreihenkombinationen<sup>6</sup> zeigt Tabelle 5.16. Dabei wurden für alle Zeitreihen die ersten zwei Hauptkomponenten als Merkmale verwendet. Bei  $C = 4$  Clustern dominiert die Kniebeugung, die zwischen drei Patientensubklassen und der Referenz trennt (Abbildung 5.24). Nachfolgend wird iterativ unter Beibehaltung der bisher ausgewählten Zeitreihen

	Zwei Cluster-Zentren	$S(u, 2)$	Drei Cluster-Zentren	$S(u, 3)$
1 ZR	OSG tra SZR	5.24	Hüfte sag GZR	2.33
2 ZR	& Knie sag SZR	9.98	& Knie sag GZR	3.48
3 ZR	& OSG sag SZR	15.15	& OSG sag GZR	7.26
4 ZR	& Hüfte fro SZR	22.29	& Hüfte sag OZR	10.55
5 ZR	& Hüfte sag SZR	28.74	& Knie sag OZR	18.72
6 ZR	& Knie sag GZR	34.49	& OSG sag OZR	26.30
7 ZR	& Hüfte sag GZR	32.91	& Knie sag SZR	102.94
8 ZR	& Knie sag OZR	30.59	& OSG tra GZR	105.60
	Vier Cluster-Zentren	$S(u, 4)$	Fünf Cluster-Zentren	$S(u, 5)$
1 ZR	<b>Knie sag OZR</b>	1.99	Knie sag OZR	1.82
2 ZR	<b>&amp; OSG sag GZR</b>	3.26	& Hüfte sag GZR	2.64
3 ZR	<b>&amp; OSG sag OZR</b>	4.52	& OSG sag SZR	3.43
4 ZR	<b>&amp; OSG sag SZR</b>	5.72	& Knie sag GZR	5.95
5 ZR	<b>&amp; OSG tra SZR</b>	9.19	& OSG sag GZR	20.41
6 ZR	<b>&amp; OSG tra GZR</b>	23.13	& Hüfte sag OZR	149.17
7 ZR	& Hüfte sag OZR	77.52	& OSG sag OZR	665.79
8 ZR	& OSG tra OZR	373.03	& Knie sag SZR	860.16

Tabelle 5.16: Beste Trennungsgrade und Reihenfolge der Zeitreihen (Zeilen) bei der Cluster-Findung für zwei bis fünf Cluster-Zentren (Spalten) für 23 Patienten vor der Therapie und 10 Referenzpersonen.

diejenige Zeitreihe mit minimalem Trennungsgrad ergänzt (2.-8. Zeile von Tabelle 5.16). Dabei fällt auf, dass der Trennungsgrad ab einer bestimmten Anzahl von

<sup>6</sup>Die Automatisierung erfolgt durch festgelegte Cluster-Anzahl  $C$  und iteratives Ergänzen von Zeitreihen zu Kombinationen. Dabei ist der kleinste Trennungsgrad  $S$  zu erfüllen sowie das Finden der Referenz mit  $u_{\text{REF}} > 0.9$ . Die Cluster-Anzahl wird dann sukzessiv erhöht. Dieses Vorgehen wurde bereits beim ICP-Datensatz erfolgreich angewendet und die modifizierte Methode in Abschnitt 3.8.3 erläutert.

Zeitreihen steil ansteigt und somit ein unbefriedigendes Cluster-Ergebnis anzeigt. Das Ergebnis deutet auf weniger prägnante Subklassen bei Betrachtung mehrerer Zeitreihen hin. Daher wird im Folgenden die Subgruppe SUB2,SCI mit vier Cluster-Zentren der ersten sechs Zeitreihenkombinationen betrachtet (bis einschließlich „OSG tra GZR“, fett in Tabelle 5.16 aufgrund des auffällig kleinen Trennungsgrad für gute Cluster-Einteilungen gemäß Kapitel 3). Selbstverständlich kann zukünftig das Finden von Zeitreihenkombinationen über den Merkmalsraum mit allen Abtastzeitpunkten ebenfalls in diesem Stil automatisiert werden, da die SCI-Patienten keine ausgeprägt „versteckten“ Subgruppen haben.

Die in Abbildung 5.24 visualisierten Subgruppen zeigen die bereits diskutierten Zusammenhänge zwischen Knie und OSG. Durch das automatisierte Vorgehen sind darüber hinaus weitere geeignete Kombinationen von Zeitreihen gefunden. Beispielsweise zeigt die Patientensubgruppe mit dem gestreckten Knie in der Standphase eine erhöhte Streuung im Sprunggelenk (ZR STRI OSG sag SZR), möglicherweise aufgrund eines weniger gut kontrollierbaren Fußaufsetzverhalten. Ein fehlerhaftes Aufsetzverhalten ist zudem in allen Subgruppen bei der OSG Geschwindigkeitszeitreihe insbesondere der Loading Response (LR, 0..10% des Gangzyklus) zu erkennen (siehe ZR STRI OSG sag GZR). Auf diese Weise lassen sich nun weitere Ausprägungen der verschiedenen Subgruppen klinisch interpretieren.

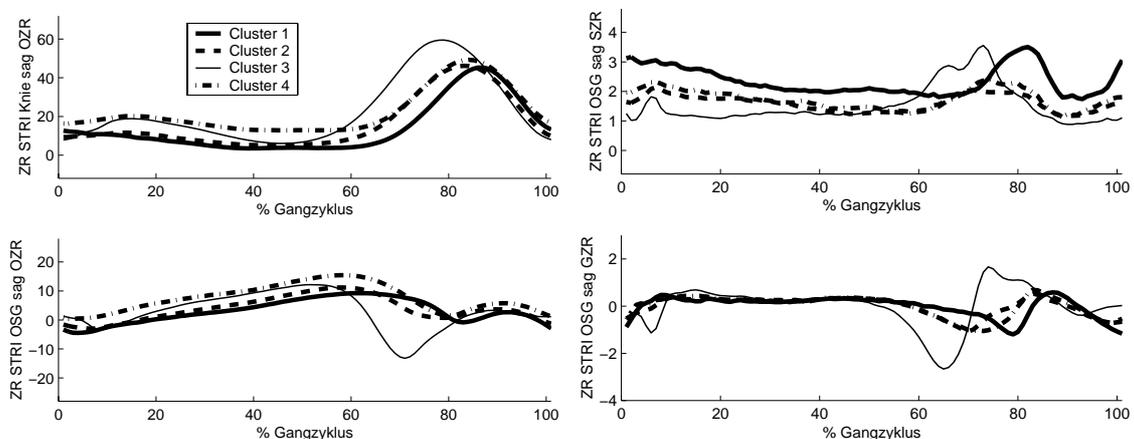


Abbildung 5.24: Visualisierung der Subgruppen SUB2,SCI mit vier Cluster-Zentren der ersten sechs Zeitreihenkombinationen aus Tabelle 5.16.

### Verallgemeinerte Charakterisierung der Subgruppen

Aufgrund der neurologischen Heterogenität der Patienten kommt prinzipiell der Charakterisierung von Subgruppen klinisch eine größere Bedeutung zu als der Charakterisierung des gesamten Kollektives, siehe Tabelle 5.17. Auffällig sind allerdings die großen Übereinstimmungen<sup>7</sup> der Merkmale zwischen SUB1,SCI und SUB2,SCI und mit denen zur Charakterisierung des gesamten Kollektives aus den Tabellen 5.14 und 5.15. Somit wirken sich die neurologisch stark heterogenen Patienten nicht so stark auf individuelle Unterschiede im Gangbild aus.

Einzelmerkmal	$M_{s,uk}$	ü	Einzelmerkmal	$M_{s,uk}$	ü
MW STRI Knie sag OZR	0.317	✓	MW STRI Knie sag OZR	0.226	✓
MIN STRI Hüfte sag OZR	0.248	✓	MAX ISw Knie sag OZR	0.209	
MIN STRI OSG sag OZR	0.190	✓	MIN STRI OSG sag OZR	0.201	✓
MW ISw OSG sag OZR	0.165	✓	MW ISw OSG sag OZR	0.180	✓
SpW ST Hüfte sag OZR	0.146		SpW TSw Hüfte sag OZR	0.147	✓
MAX ISw OSG sag GZR	0.139		SpW STRI Hüfte sag OZR	0.132	
SpW STRI Becken fro OZR	0.126	✓	MW STRI Hüfte sag SZR	0.131	✓
SpW TSw Hüfte sag OZR	0.097	✓	SpW STRI Becken fro OZR	0.128	✓
SpW STRI Becken sag OZR	0.094	✓	MIN STRI Hüfte sag OZR	0.121	✓
MW TSw Knie sag OZR	0.083	✓	MW TSw Knie sag OZR	0.117	✓
MIN SW Hüfte sag GZR	0.080	✓	SpW STRI Becken sag OZR	0.112	✓
MW STRI Hüfte sag SZR	0.062	✓	MW STRI OSG sag SZR	0.109	
MIN STRI Becken fro OZR	0.062		MIN SW Hüfte sag GZR	0.090	✓
MAX STRI Becken fro OZR	0.061		SpW ST Knie sag OZR	0.083	
SpW TSw OSG sag OZR	0.060		MIN ST OSG sag GZR	0.079	
MIN TSt Becken sag GZR	0.049		MIN TSw OSG tra GZR	0.079	

Tabelle 5.17: Charakteristische Einzelmerkmale zur Unterscheidung von Subgruppen (46 SCI,PRE-Datensätze und 20 REF,M Datensätze). Charakterisierung von SUB1,SCI (Links) bzw. von SUB2,SCI (rechts) und übereinstimmend (ü) gefundene Merkmale.

Bei der qualitativen Analyse der Abbildung 5.24 fallen bestimmte Abweichungen des Clusters 3 (Referenz) zu den anderen drei Clustern (SCI) auf, z.B. die maximale Kniebeugung im MSw (73%-87% des Gangzyklus). Allerdings taucht das Merkmal nicht in den Tabellen 5.14, 5.15 und 5.17 auf. Ein wesentlicher Grund ist, dass das langsame Referenzverhalten in MSw im Wertebereich der SCI-Patienten liegt. Im

<sup>7</sup>Was klinisch zu erwarten war, da die Kombinationen der Zeitreihen ähnlich sind. Allerdings ist die Berechnung unterschiedlich, hier mit bzw. ohne Hauptkomponenten Transformation

ISw (60%-73%) hingegen unterscheiden sich die SCI-Patienten eher zu REF,L UND REF,M. Das wurde durch das Merkmal „MAX ISw Knie sag OZR“ bei allen Varianten gefunden, siehe auch im Anhang Tabelle E.8. Das „MIN ST OSG sag OZR“ beschreibt ebenfalls tendenziell das SCI-Verhalten, wobei sehr starke Ähnlichkeiten zum langsamen Gehen existieren, siehe C8 in Tabelle 5.15. Auffällig hingegen ist die OSG SZR, die einen wesentlichen Beitrag zur Charakterisierung von SCI-Patienten liefert, was auch ansatzweise in der Literatur bekannt ist [6]. In den Tabellen 5.14 und 5.15 ist die OSG SZR durch hohe Korrelationen zur Hüfte sag SZR zurückgestuft.

### 5.3.2 Neues Auswerteverfahren für die Therapie

Mit den neuen Analysemethoden lassen sich ebenfalls die Effekte der Therapie für SCI-Patienten quantitativ dokumentieren. Im Folgenden werden analog zu den vorherigen Abschnitten die drei methodischen Schwerpunkte angewendet, siehe Abbildung 5.1.

#### Verallgemeinerte Quantifizierung des pathologischen Ausmaßes

In Bezug auf Tabelle 5.12 lassen sich bereits einige signifikante Verbesserungen im Gangbild der SCI-Patienten feststellen, die sich auf mehrere Gelenke beziehen. Die einzigen geringen Verschlechterungen betreffen die transversale Becken GZR und Hüfte GZR, d.h. das dynamische Verhalten in diesen Gelenkebenen. Eine mögliche Erklärung ist, dass die Patienten im Laufe der Therapie (vgl. Kapitel 2) keine oder immer weniger Hilfsmittel benötigen, die zum Teil die natürlichen Bewegungen und u.U. auch pathologische Gangabweichungen einschränken (z.B. Gewichtsentlastung, Halten am Barren, hochgebundener Fuß, Peroneus-Schiene, ...). Insbesondere die Becken- und Hüftbewegungen werden bei der Gewichtsentlastung oder beim Halten am Barren eingeschränkt. Aus therapeutischer Sicht werden die Patienten so wenig wie nötig durch Hilfsmittel unterstützt, damit sie so eigenständig wie möglich gehen. Eine weitere Erklärung ist, dass die Gangkinematik beim Fortlassen der Hilfsmittel sich leicht verschlechtert, da nun das gesamte Körpergewicht durch die immer noch geschwächten Muskeln zu tragen ist, obwohl sich der Patient zunehmend regeneriert. Der Effekt mit der sich leicht verschlechternden Gangkinematik ist bei einem der im Folgenden diskutierten Patienten ebenfalls zu erkennen (Patient ID 10123).

Auf Basis des Gangqualitätsmaßes kann der Verlauf der Therapie bei einzelnen Patienten quantitativ dokumentiert werden, siehe Abbildung 5.25 links. Zu erkennen ist eine stetige Angleichung an das Referenzverhalten bei Patient ID 10108 (durch kleiner werdende Referenzabweichung). Ab dem 7. Zeitpunkt während der Therapie

kann der Patient bereits ohne Gewichtsentlastung gehen, wobei das Gangbild sich nicht wesentlich verbessert, da die Muskeln nun das gesamte Körpergewicht tragen müssen. Zwar sind die Muskeln durch die Therapie stärker gewordenen, haben sich aber noch nicht vollständig rehabilitiert. Bei Patient 10123 ist zwar die Referenzabweichung nicht allzu groß, aber eine stetige Verbesserung ist kaum zu erkennen.

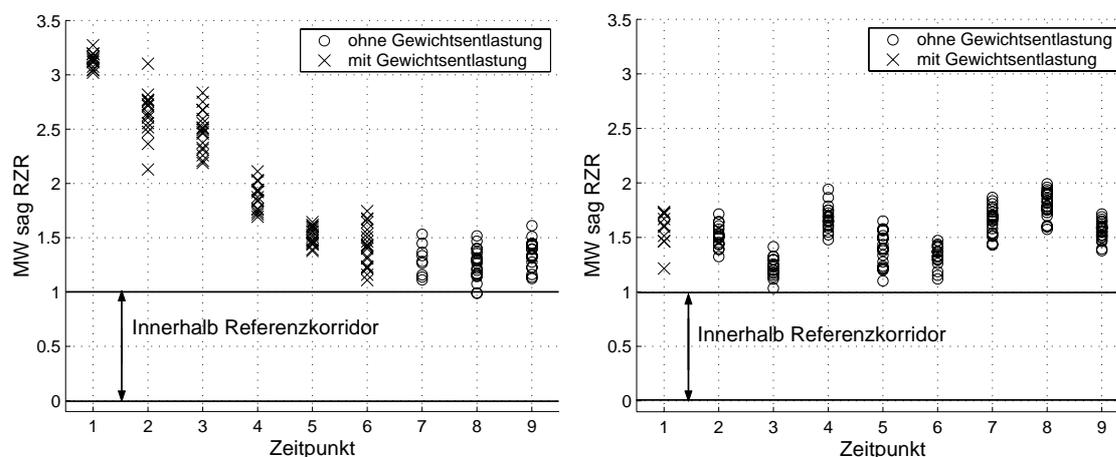


Abbildung 5.25: Dokumentation der Therapie anhand des Gangqualitätsmaß „MW sag RZR“ über einzelne Schritte, links: Patienten ID 10108 mit neun Untersuchungszeitpunkten, rechts: Patient ID 10123.

### Verallgemeinerte Charakterisierung der Therapiewirkung

Die Untersuchung charakteristischer Merkmale, die sich während der Therapie ändern, wird nur für die 15 Patienten durchgeführt, bei denen auch Daten nach der Therapie existieren. Die relevanten Einzelmerkmale für die Problemstellung zeigt Tabelle 5.18, wobei die Zugehörigkeit für Cluster 3 aus SUB2,SCI (Referenz) das beste Einzelmerkmal ist (Histogramm in Abbildung 5.27 links). Da das Cluster 3 die Ähnlichkeit zum Referenzkollektiv bewertet, deutet das auf eine zunehmende graduelle Verbesserung der Patienten durch die Therapie hin. Andere relevante Merkmale sind Spannweiten im Hüftgelenk.

Zudem fällt bei den relevanten Änderungsmerkmalen auf, dass einige von ihnen identisch oder hoch korreliert zu den Merkmalen aus den Tabellen 5.14, 5.15 und 5.17 sind. Das zeigt, dass sich viele charakteristische SCI-Merkmale durch die Therapie

Einzelmerkmal	$M_{s,uk}$	SCI,PRE	SCI,POST	REF,LM
ZGH Cluster 3 SUB2,SCI	0.332	$0.1 \pm 0.1$	$0.3 \pm 0.3$	$0.8 \pm 0.2$
SpW STRI Hüfte fro OZR	0.195	$6.0 \pm 2.2$	$9.2 \pm 2.6$	$12.0 \pm 3.5$
SpW STRI Hüfte sag OZR	0.183	$31.9 \pm 7.4$	$40.6 \pm 6.9$	$40.4 \pm 2.5$
MAX ST Knie sag GZR	0.169	$0.9 \pm 0.5$	$1.9 \pm 0.8$	$2.3 \pm 0.3$
MW STRI Knie sag SZR	0.161	$3.6 \pm 1.2$	$2.2 \pm 0.6$	$2.1 \pm 0.4$
MW SW Knie sag OZR	0.158	$28.1 \pm 6.9$	$35.2 \pm 8.7$	$39.2 \pm 4.7$
SpW STRI Becken fro OZR	0.150	$3.4 \pm 1.8$	$5.3 \pm 2.5$	$7.9 \pm 2.8$
ZGH Cluster 1 SUB2,SCI	0.128	$0.3 \pm 0.3$	$0.1 \pm 0.2$	$0.0 \pm 0.0$
MW PSw Hüfte fro GZR	0.092	$-0.1 \pm 0.1$	$-0.2 \pm 0.2$	$-0.4 \pm 0.2$
MIN MSw OSG sag GZR	0.088	$-1.7 \pm 1.4$	$-0.9 \pm 1.3$	$0.1 \pm 0.2$

Tabelle 5.18: Charakteristische Merkmale für die Änderung während der Therapie (2-Klassenproblem SCI,PRE gegen SCI,POST für jeweils 30 Datensätze).

normalisieren, siehe Abbildung 5.26. Hierbei fällt auf, dass die PRE-POST Änderung (links) sich dem Referenzverhalten mit mittlerer Gehgeschwindigkeit annähert (Pfeil im rechten Bild). Die beiden Merkmale beschreiben sowohl eine gesteigerte Rumpfstabilität (die Hüfte kann besser angehoben werden), als auch eine verbesserte Stoßdämpfung durch das Knie (Zunehmende Kniebeugung am Anfang des Gangzyklus). Das therapeutische Ziel des Angleichens an ein Gangbild mit mittlerer Gehgeschwindigkeit konnte durch die vorliegende Arbeit somit quantitativ nachgewiesen werden.

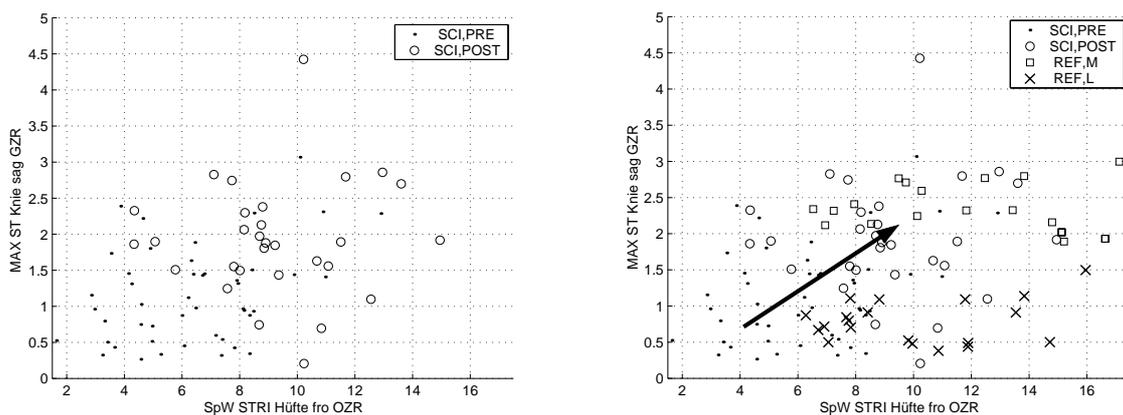


Abbildung 5.26: Charakteristische Einzelmerkmale aus Tabelle 5.18.

### Neue Visualisierungen der Subgruppen

Ebenso aufschlussreich ist die Darstellung der Mittelwertzeitreihen nach der Therapie mit vor der Therapie berechneten Cluster-Zugehörigkeiten der Patienten (Abbildungen 5.27 und 5.28). Die visualisierten Zeitreihen ermöglichen zumindest tendenzielle Aussagen über subklassenspezifische Änderungen durch die Therapie. So fällt auf, dass insbesondere die Patienten aus Cluster 1 stark profitieren: In der „ZR STRI OSG sag SZR“ sind die individuellen Streuungen deutlich verringert. Allerdings besteht immer noch das gestreckte Knieverhalten in Kombination mit der erhöhten Plantarflexion. Bei den beiden Clustern 2 und 4 ist qualitativ erkennbar, dass sie sich aneinander und dem Referenzverhalten annähern. Das Annähern an das Referenzverhalten ist anhand der ZGH zu Cluster 3 durch das Histogramm in Abbildung 5.27 gezeigt. Cluster 3 ist bei der Darstellung nicht enthalten, da die Referenz nicht abgebildet ist und keine Patienten dem Cluster 3 zum PRE-Zeitpunkt angehören, siehe Abbildung 5.27 links.

Weiterhin lassen sich die Merkmale aus Tabelle 5.18 auch in den Zeitreihen finden. Beispielsweise haben die Subgruppen nach der Therapie einen steileren Anstieg des Knies im Schwung („MAX ST Knie sag GZR“) oder eine erhöhte Hüftbewegung („SpW STRI Hüfte sag OZR“ insbesondere bei Cluster 4 in Abbildung 5.27). Die Reduzierung der individuellen Streuungen des OSG sag (z.B. als Merkmal „MW STRI OSG sag SZR“ mit  $M_s = 0.23$ ) ist zwar sehr relevant, aber mit „MW STRI Knie sag SZR“ mit  $\rho = 0.83$  hoch korreliert und somit in Tabelle 5.18 herabgestuft.

Die hier gezeigten Ergebnisse und exemplarische klinische Diskussionen lassen sich nun weiter fortführen. Insbesondere die klinische Interpretation und somit Rückführung der Erkenntnisse (z.B. Quantifizierung der Gangqualität, unterschiedliche Änderungseffekte der Subgruppen durch die Therapie) muss für die praxisnahe Anwendung weiter erfolgen, siehe Übergang von der computergestützten zur klinischen Analyse (Visualisierung  $\rightarrow$  klinische Interpretation) in Abbildung 3.1. Der klinische Nutzen aus den gezeigten Erkenntnissen liegt in der Optimierung von Therapien, der quantitativen Beschreibung von Patientenverhalten oder einem verbesserten Grundlagenverständnis über die Patienten.

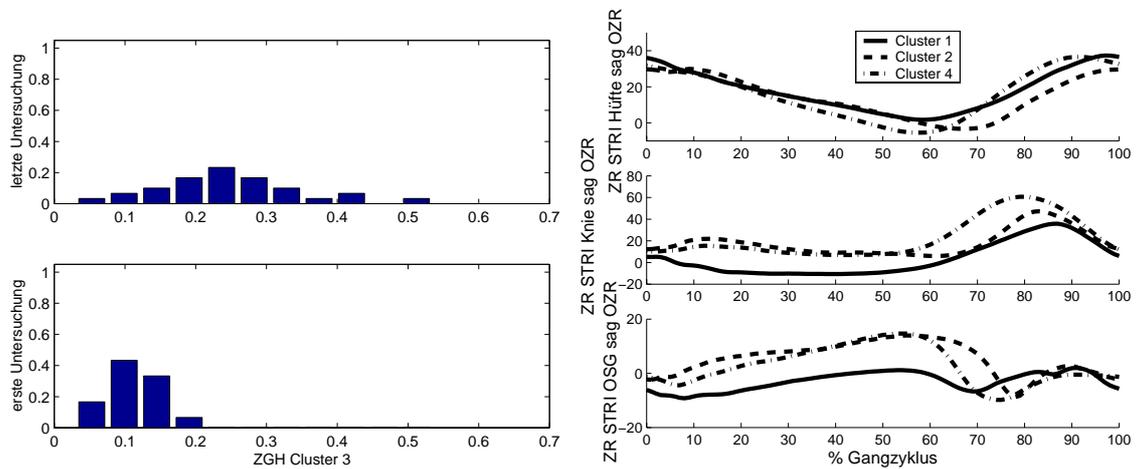


Abbildung 5.27: ZGH Cluster 3 von SUB2,SCI (links). Mittelwertzeitreihen der drei Patienten-Cluster von SUB1,SCI für 30 SCI,POST-Datensätze (rechts).

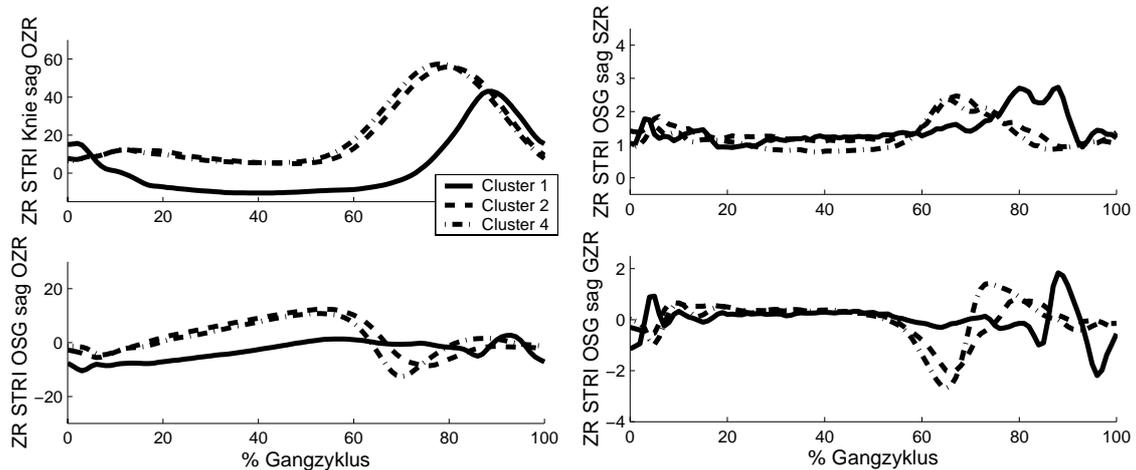


Abbildung 5.28: Darstellung der Mittelwertzeitreihen der drei Patienten-Cluster von SUB2,SCI für 30 SCI,POST-Datensätze.

### 5.3.3 Zusammenfassung und Wertung

Mit den in Kapitel 3 beschriebenen modifizierten Verfahren konnten wesentliche Beiträge zur Analyse der Gang-Kinematik von SCI-Patienten erzielt werden [88, 90, 93, 95]. Im Einzelnen sind das:

- Ein verallgemeinertes, quantitatives Maß für die Gangqualität wurde in Anlehnung an Experteneinschätzungen entwickelt und bereits erfolgreich in der klinischen Praxis umgesetzt [4, 41, 127]. Die wesentlichen Vorteile gegenüber herkömmlichem Vorgehen (subjektive, visuelle Einschätzungen, neurologische Maße) bestehen in der Berücksichtigung der funktionellen Gang-Kinematik und in der Quantifizierung. Damit sind sie von einer subjektiven Variabilität unabhängig.
- Die Charakterisierung der SCI-Kinematik konnte gezeigt werden, z.B. wesentliche Merkmale in sagittaler Ebene von Hüfte, Knie und OSG. Sie wurden klinisch auf Plausibilität geprüft und decken sich stark mit den aus der Gangqualität gewonnenen Erkenntnissen.
- Große klinische Akzeptanz konnte mit den Ergebnissen beim Finden von Subgruppen erzielt werden. Dabei ergaben sich nur wenige voneinander deutlich unterscheidbare funktionelle Mechanismen trotz der neurologisch stark heterogenen SCI-Patienten.
- Die Methodik wurde ebenfalls zur Dokumentation der Therapieerfolge in der Gang-Kinematik eingesetzt. Bei den meisten Patienten konnte eine Normalisierung der wesentlichen, charakteristischen SCI-Merkmale gezeigt werden. Es wurden auch Patienten erkannt, die keine Verbesserung der Gangqualität zeigten. Dadurch kann eine rechtzeitige Optimierung der Therapie eingeleitet werden.

## 6 Zusammenfassung und Ausblick

Die vorliegende Arbeit schlägt ein Konzept für eine modellgestützte Diagnostik mittels Data Mining am Beispiel der Bewegungsanalyse vor. Dabei handelt es sich um eine neue Strategie, die empirische Vorgehensweisen bei der Analyse von Zeitreihen (Kapitel 2) formalisiert und in eine datenbasierte Auswertung integriert. Hierzu wurden interpretierbare Merkmale extrahiert und verschiedene überwachte und unüberwachte Lernverfahren eingesetzt (Kapitel 3). Das gesamte Konzept der Arbeit ist in einem erweiterten Programmsystem realisiert (Kapitel 4). Die Ergebnisse wurden beispielhaft in der klinischen Bewegungsanalyse anhand der Messdaten von Patienten mit infantiler Cerebralparese und inkompletter Querschnittlähmung sowie Probanden ohne orthopädische Einschränkungen als Referenz demonstriert (Kapitel 5).

Die zentrale Idee und der Innovationswert der Arbeit besteht in der Aufbereitung der Messdaten zu einem einheitlichen, auf Expertenbefragungen basierenden Merkmalsatz, so dass dieser auf beliebige Datensätze und klinische Problemformulierungen angewendet werden kann. Da somit das empirische Analyseverfahren in die rechnerbasierte Analyse einbezogen wurde, entsteht ein hoher Grad an interpretierbaren Ergebnissen. Sie sind bereits in der klinischen Praxis umgesetzt [4, 41, 127, 175].

Die wichtigsten Ergebnisse der Arbeit sind:

1. Eine neue universelle Methodik mit modularen Elementen wurde entwickelt. Dadurch lassen sich im Gegensatz zu bisherigen bekannten Analysen von Bewegungsdaten verschiedene Patientengruppen untersuchen und auf unterschiedliche Problemstellungen hin auswerten.
2. Eine erweiterte, systematische Vorverarbeitung wurde entwickelt, die die Vorgehensweise klinischer Experten formalisiert abbildet.
3. Die systematische Vorverarbeitung ist in ein neues methodisches Konzept integriert, das die Anwendung verschiedener Data Mining Methoden für die Auswertung klinischer Bewegungsdaten ermöglicht.

4. Die verwendeten Data Mining Methoden (z.B. Relevanzbewertungen durch informationstheoretische Maße, überwachte Fuzzy-Klassifikatoren, unüberwachte Fuzzy-Cluster-Verfahren) wurden mit bereits bestehenden Methoden zur klinischen Datenanalyse (z.B. empirische Analysen) verglichen und deren Vorteile aufgezeigt.
5. Modifikationen bei der Anwendung von Data Mining Methoden wurden geleistet, um bessere Analyseergebnisse zu erhalten. Hierzu zählen beispielsweise der formalisierte Einbezug von Apriori-Wissen oder die Validierung von Ergebnissen mit Hilfe bekannter Gruppen bei der Struktursuche von unbekanntem Subgruppen.
6. Der Aufbau und die Erprobung einer neuen Softwaretoolbox zur automatisierten Datenvor- und -weiterverarbeitung wurde realisiert, die das hier erarbeitete neue methodische Konzept beinhaltet.
7. Durch die formalisierte Abbildung der klinischen Vorgehensweise und den Einsatz ausgewählter Data Mining Methoden mit den entsprechenden Modifikationen konnte die klinische Interpretation von computerbasierten Ergebnissen erreicht werden.
8. Durch die hierarchische Quantifizierung und Lokalisierung von Gangabweichungen und der Kombination von Experteneinschätzungen ist die Berechnung einer quantitativen Gangqualität entwickelt worden, die der besseren und detaillierteren Patienteneinschätzung dient.
9. Bei der Auswertung der Bewegungsdaten mit dem neuen Konzept konnten charakteristische Merkmale gefunden werden, die Patientenkollektive besser beschreiben als bereits bekannte Merkmale aus der Literatur.
10. Bisher nur qualitativ bekannte bzw. unbekannte Beziehungen zwischen den Gelenken konnten durch die Struktursuche nach unbekanntem Subgruppen aufgezeigt und quantitativ beschrieben werden. Derartige Beziehungen können auch für prognostische Aussagen bei der Therapie herangezogen werden, wie z.B. geringe bzw. keine Verbesserung von ICP-Recurvatum Patienten durch Botulinum-Toxin.

Die mit der neuen Methodik erzielten Ergebnisse wurden zunächst mit existierenden klinischen Ergebnissen aus der Literatur [125, 136, 150, 159, 174] erfolgreich validiert. Wesentliche Beiträge zur Lösung offener Fragen aus der Literatur, wie z.B. stark subjektiv geprägte Merkmalsextraktion, empirische Vermutungen, fehlende

Transparenz oder Betrachtung eines eingeschränkten Analysebereichs, konnten durch die rein rechnergestützte Vorgehensweise erreicht werden [89, 90, 91, 92, 94, 96]. Vorteile gegenüber existierenden Verfahren [30] sind

- die Universalität (Bearbeitung unterschiedlicher klinischer Fragestellungen) durch die Modularität der Methodik,
- die Unabhängigkeit von der Pathologie (anwendbar auf beliebige Patientengruppen) durch die reine computerbasierte Auswertung mit formalisiert einbezogener subjektiver Vorgehensweise,
- die Objektivität durch den Einsatz von Rechnern auf diesem Gebiet,
- die Vollständigkeit und Systematisierung durch die Betrachtung des gesamten Datenraumes sowie
- die Interpretierbarkeit durch Nachbildung des subjektiven Analysevorgehens.

Die Data Mining Methoden sind somit in der Lage, neue Hypothesen über Zusammenhänge zu erkennen sowie klinische Aussagen zu belegen. Alle so aufgestellten neuen Hypothesen müssen anschließend mit klinischen und biomechanischen Experten eingehend analysiert werden, um die zugrundeliegenden Ursache-Wirkungs-Mechanismen zu verstehen.

Das vorgeschlagene Konzept ist offen für zukünftige Erweiterungen:

Das Finden von Subgruppen kann in präziseren Merkmalsräumen erfolgen, beispielsweise mit interpretierbaren Einzelmerkmalen.

Mit dem Einbezug biomechanischer Modelle in die neue Methodik können bislang noch nicht manifestierte grundlegende pathologische Zusammenhänge erforscht werden. Insbesondere bei chirurgischen Eingriffen in den Bewegungsapparat ist das Wissen über derartige oftmals unbekannte Zusammenhänge wichtig.

Die systematische Auswertung der Gangdaten erforderte neue kategorische Bezeichner. Für die klinische Anwendung kann die Interpretierbarkeit der hier verwendeten Abkürzungen durch Rückumwandlung in orthopädische Bezeichnungen gesteigert werden. Erste Ansätze sind durch die automatisierten Erklärungstexte gezeigt worden. Weiterhin können nun die mit dem neuen Konzept zur Verfügung stehenden Ergebnisse in eine verbesserte praxisnahe Verwendung überführt werden. Die dazu notwendige klinische Interpretation konnte in der vorliegenden Arbeit nur exemplarisch erfolgen und ist weiter auszubauen. Deren gezeigte Potentiale bieten konkretisierte und systematisch dokumentierte Entscheidungsfindungen für klinische Experten.

# A Begriffe

**ASIA:** Neurologische Bewertung von Schmerz- bzw. Druckempfindlichkeit (für 28 Körperbereiche wie Brust, Oberarm, Oberschenkel, ... Punkteverteilung von Null (abwesend) bis zwei (normal bei leichter Berührung und Nadelstichempfinden)) und motorischen Fähigkeiten der Extremitäten (für zehn Muskelgruppen wie Ellenbogenbeuger, Hüftbeuger, Kniestrecker, ... Punkteverteilung von Null (komplette Lähmung) bis fünf (aktive Bewegung über volles Bewegungsausmaß gegen vollen Widerstand)), siehe [33].

**Botulinum-Toxin, Botulinum-A-Toxin:** Eines der stärksten Nervengifte, die Wirkung zielt auf die Nervenenden ab. Anwendung im medizinischen Bereich, in kleinsten Dosen: Im Muskel eingespritzt (injiziert) wirkt es vorübergehend lähmend (ca. 3 Monate, vollständiger Abbau bis ca. 1.5 Jahre), Anwendungen vorwiegend bei Spastik [81, 152].

**diplegisch:** Beide Beine (oder Arme) von Lähmungserscheinungen betroffen.

**distal:** Vom Körpermittelpunkt nach unten entferntes Segment, s. Abbildung A.3.

**Doppelstand:** Phase, in der beide Füße gleichzeitig Bodenkontakt haben (double-support). Sie umfasst beim normalen Gehen (bei mittlerer Geschwindigkeit) ca. 10% des gesamten Gangzyklus und befindet sich zwischen dem Fersen- und Fußsohlenkontakt des einen Beines (Abbildung A.1) sowie Fersen- und Zehenablösung des anderen Beines. Die Zeit des Doppelstands ist antiproportional zur Gehgeschwindigkeit [17]. Beim Laufen kommt der Doppelstand gar nicht vor.

**Gang- oder Schrittzyklus:** Intervall, in dem die Gang-Aktivitäten zwischen zwei Bodenaufsetzpunkten eines Fußes (Initial Contact, IC) beschrieben werden. Bei Menschen ohne orthopädische Einschränkungen setzt die Ferse zuerst auf (Heel Strike). Die verschiedenen Aktivitäten während eines Gangzyklus werden in % des vollständigen Gangzyklus angegeben, wobei sie in unterschiedliche Schritphasen unterteilt werden können (s. unten und [17, 120]).

Ein Gangzyklus umfasst eine Standphase (ca. 60% bei mittlerer Gehgeschwindigkeit) und eine Schwungphase (ca. 40%, Abbildungen A.1 und A.2). In der Literatur werden weiterhin drei Hauptaufgaben unterschieden. Diese sind Gewichtsübernahme auf das betrachtete Bein (weight acceptance, Loading Response), Tragen des Körpergewichts auf diesem Bein (single limb support, Mid Stance und Terminal Stance) und das Vorbringen des anderen Beines (limb advancement, Schwung) [63, 120].

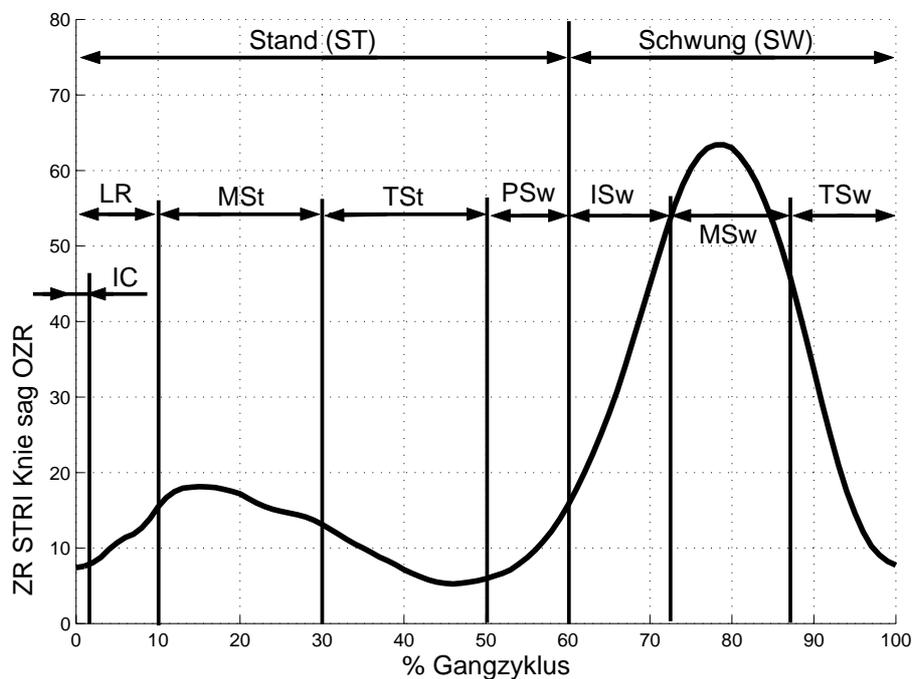


Abbildung A.1: Einteilungen eines Gangzyklus, hier am Beispiel eines Kniegelenkwinkelverlaufs eines Probanden.

**hemiplegisch:** Lähmungserscheinungen in einem Arm und einem Bein auf der selben Körperseite, d.h. eine neuromuskuläre Funktionsstörung einer Körperseite aus frontaler Sicht, die andere Körperseite ist nahezu intakt [174].

**Kadenz:** Schrittrate pro Minute.

**Klasse (Ausgangsklasse):** Nach [22] umfasst eine Klasse diejenigen Objekte, die eine Einheitlichkeit, gemäß definierter Kriterien, aufweisen. Hierbei wird in semantische (inhaltliche Ähnlichkeit, oft empirisch zweckbestimmt) und

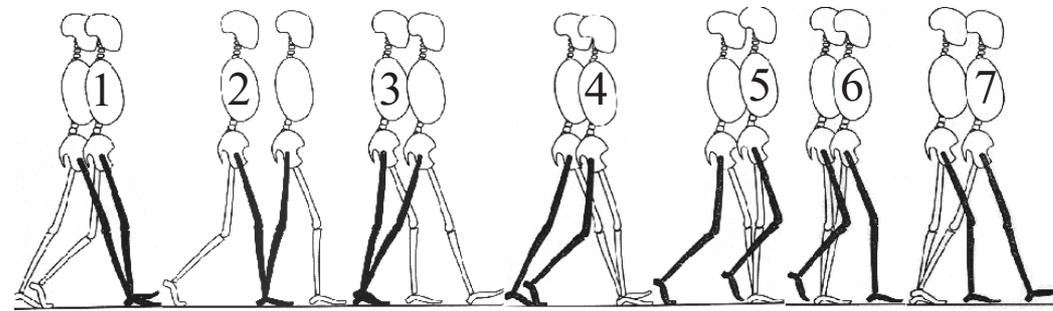


Abbildung A.2: Einteilung in Gangphasen [108].

natürliche (formale Ähnlichkeit, z.B. durch Abstände definiert) Klassen unterschieden. Klasseneinteilungen sind z.B. „Patienten-Referenz“, „Untersuchungszeitpunkte“, wie PRE-POST-therapeutische Untersuchung oder „pathologische Subgruppen“. Während Objekte elementare Informationen tragen, liefern Klassen mit ihrer Gesamtheit an Objekten globale Informationen.

**Körperbewegungen:** In der Orthopädie werden gelenkspezifische Bewegungen verwendet, siehe Tabelle A.1.

**Körperebenen:** In der Medizin / Orthopädie werden drei fiktive Ebenen durch den menschlichen Körper unterschieden, diese sind frontal (d.h. senkrecht zur Betrachtungsrichtung von vorne), sagittal (von der Seite) und transversal (von oben), siehe Abbildung A.4.

**Körperrichtungen:** In der Medizin werden für die verschiedenen Glieder entsprechende Richtungsbezeichnungen verwendet (Abbildung A.3), z.B. bedeutet Abduktion vom Körper weg und Adduktion zum Körper hin, distal vom Körperzentrum (proximal) weg.

**Merkmal:** Merkmale sind charakteristische Eigenschaften von Objekten und dienen zu deren Beschreibung [22]. Merkmale werden hier als Oberbegriff für **Einzelmerkmale** (z.B. Raum-Zeit-Parameter, oder berechnete Merkmale aus den Zeitreihen, wie Maxima) und **Zeitreihen** (Zeitreihenmerkmale z.B. Knieflexions-Zeitreihe) verwendet.

**monoplegisch:** Lähmungserscheinung in nur einer Extremität.

**Objekt:** Objekte sind allgemeine diskrete Abbildungen (Modelle) von Systemen. Sie werden durch einen Satz von Informationen über das System erklärt [22].

Gelenk/ Segment	Sagittale Körperebene	Frontale Körperebene	Transversale Körperebene
Becken	Anterior (nach vorne) $> 0^\circ$ ( $0^\circ \cong$ senkrecht gestreckt), Posterior (nach hinten) $< 0^\circ$	Kranial (nach rechts), $> 0^\circ$ Kaudal (nach links), $< 0^\circ$	Innenrotation, $> 0^\circ$ Außenrotation, $< 0^\circ$
Hüfte	Flexion (zum Bauch hin gebeugt) $> 0^\circ$ , ( $0^\circ \cong$ senkrecht gestreckt), Extension $< 0^\circ$	Adduktion (zur Körpermitte), $> 0^\circ$ Abduktion (vom Körper weg, nach außen), $< 0^\circ$	Innenrotation, $> 0^\circ$ Außenrotation, $< 0^\circ$
Knie	Flexion (nach hinten gebeugt) $> 0^\circ$ ( $0^\circ \cong$ senkrecht gestreckt), Extension $< 0^\circ$	Adduktion (zur Körpermitte), $> 0^\circ$ Abduktion (vom Körper weg, nach außen), $< 0^\circ$	Innenrotation, $> 0^\circ$ Außenrotation, $< 0^\circ$
Oberes Sprunggelenk (OSG)	Dorsalflexion (nach oben gebeugt), $> 0^\circ \cong$ waagerechte Stellung, Plantarflexion $< 0^\circ$	Adduktion (zur Körpermitte), $> 0^\circ$ Abduktion (vom Körper weg, nach außen), $< 0^\circ$	Innenrotation, $> 0^\circ$ Außenrotation, $< 0^\circ$

Tabelle A.1: Orthopädische Gelenkbezeichnungen (bzw. Becken-Segment) und Winkelangaben der in dieser Arbeit verwendeten Zeitreihen und Kategorisierung.

Somit werden alle Gangdaten einer Person zu einem Objekt (dieser Person) zusammengefasst.

**Orthopädie:** Wissenschaft von der Erkennung und Behandlung angeborener oder erworbener Fehler des menschlichen Bewegungsapparats, sowie Fehlbildungen und Erkrankungen der Bewegungsorgane.

**pathologisch:** Krankhaft, von der „Norm“ abweichend.

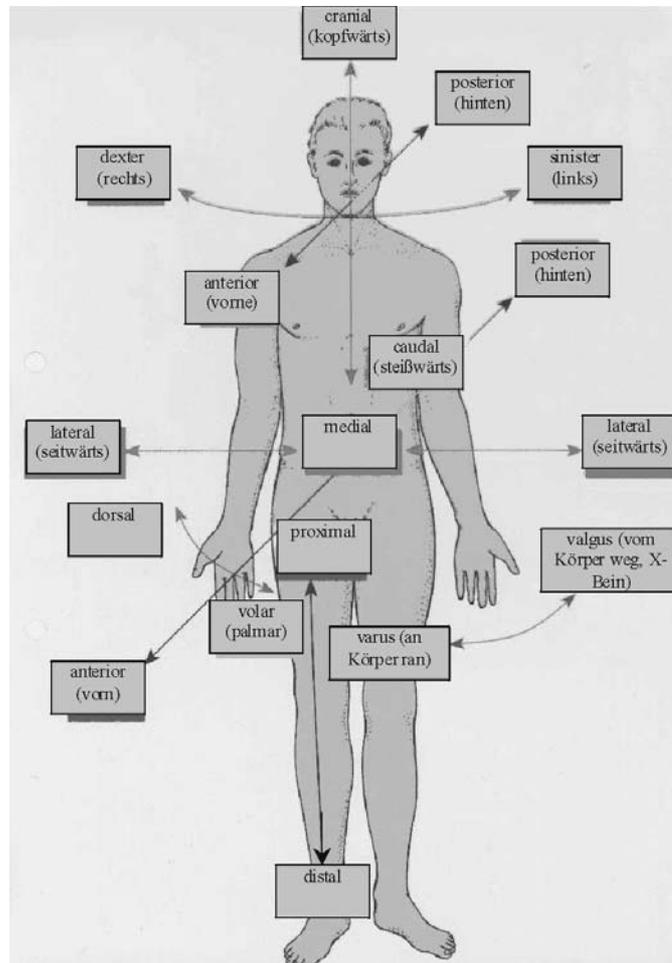


Abbildung A.3: Körperrichtungen bei verschiedenen Gliedern, nach [2].

**Personenbasisdaten:** In dieser Arbeit als Oberbegriff für patientenspezifische Daten, die aus der Voruntersuchung hervorgehen, wie z.B. Größen (gesamter Körper, Beine, Füße, ...), Gewicht, Alter, Geschlecht, maximale Bewegungsfähigkeit der Gelenke, Begleiterkrankungen.

**Physiologie:** Wissenschaftsgebiet zur Untersuchung „normaler“ biophysikalischer Lebensvorgänge.

**proximal:** Körpersegment näher am Körpermittelpunkt gelegen, s. Abbildung A.3.

**quatroplegisch:** Lähmungen in allen vier Extremitäten

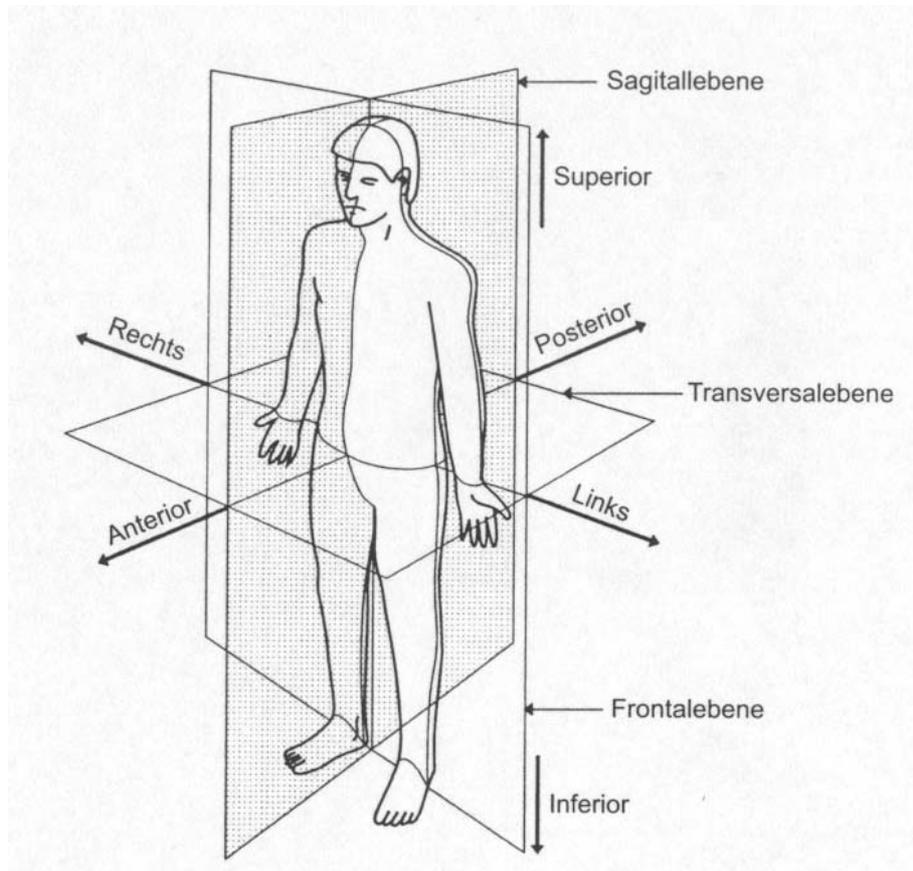


Abbildung A.4: Körperebenen und Richtungen, nach [2].

**Raum-Zeit-Parameter (Time-Distance-Parameters):** Einzelmerkmale, die während der Ganganalyse ebenfalls erhoben werden, wie z.B. Schrittlänge, oder Kadenz (Schritte/Minute), (absolute) Gehgeschwindigkeit, Zeitdauer des Schrittes, prozentuale Aufteilung der einzelnen Schrittphasen.

**Schritt:** Ein Schritt wird in dieser Arbeit verwendet, um den Prozess zwischen zwei Fußaufsetzpunkten (IC) des linken und rechten Fußes zu beschreiben (step). Ein Gangzyklus besteht somit aus zwei hintereinander folgenden Schritten (stride, hier als Doppelschritt bezeichnet).

**Schrittphasen:** Der komplette Schrittzyklus wird üblicherweise in sieben Schrittphasen eingeteilt, siehe Abbildungen A.1 und A.2 sowie [17, 120]. Der Initial Contact (IC) ist hierbei ein Ereignis und wird oftmals zwischen 0% und 2% des Gangzyklus angegeben. Die Schrittphasen umfassen im Einzelnen:

**Loading Response (LR, 0%-10%):** Die Phase beginnt mit dem Fußaufsetzpunkt (IC, 0%-2%) und endet, wenn der andere Fuß abgehoben ist. Dabei wird das nach unten verlaufende Körpergewicht abgebremst, es findet eine Stoßdämpfung statt (Shock Absorbtion).

**Mid Stance (MSt, 10%-30%):** Diese Phase beginnt, wenn der andere Fuß abgehoben ist und endet, wenn das Körpergewicht über dem betrachteten Fuß lastet. Sie ist die erste Phase, bei der nur ein Fuß Bodenkontakt hat. Dabei lastet ein Großteil des Körpergewichts auf diesem Fuß. Bei ca. 15% ist die Fußsohle im vollständigen Kontakt zum Boden (foot flat).

**Terminal Stance (TSt, 30%-50%):** Die Phase schließt sich wiederum an die vorherige an (MSt) und endet mit dem IC des anderen Fußes. Sie beinhaltet die Fersenablösung des einen Fußes. Der Körper bewegt sich vor diesen Fuß. Bei ca. 45% ist dabei die Ferse vollständig vom Boden abgelöst.

**Pre-Swing (PSw, 50%-60%):** Die Phase beginnt mit dem IC des anderen Fußes und endet mit der Zehenablösung des betrachteten Fußes (Toe-Off), wobei eine Abstoßphase (Push-Off) vorkommt.

**Initial Swing (ISw, 60%-73%):** Sie ist die erste Schwungphase des betrachteten Beines und endet, wenn sich dieses Bein gegenüber dem anderen (jetzt Stand-) Bein befindet. Hierbei wird das Schwungbein beschleunigt.

**Mid Swing (MSw, 73%-87%):** Die Phase endet, wenn das Schwungbein vorn ist und das Schienbein des anderen (Stand-) Beines vertikal gerichtet ist.

**Terminal Swing (TSw, 87%-100%):** Letzte Schwungphase, sie endet mit dem Aufsetzen des Fußes (IC) und beinhaltet auch ein Abbremsen des Beines während dem Schwung.

**Spastik:** Unfähigkeit, einen Muskel zu entspannen.

**WISCI:** Funktionale Bewertung des Gehens mit einer Punkteverteilung von Null (gar nicht gehfähig) bis 20 (gehfähig über eine Strecke von mindestens 20 Metern ohne Gehhilfen), siehe [43, 44].

**Zerebralparese, Cerebralparese (Cerebral Palsy, CP):** CP-Patienten leiden an einer Störung der Gehirnzentren, die die Haltung und Bewegung kontrollieren. Dies führt zu einer Überaktivität bestimmter Muskeln oder einer Unfähigkeit, die Muskeln gezielt zu kontrollieren. Handelt es sich um die

Abk.	Standardisierte Gangphasen	Individuelle Phaseneinteilung	Bedeutung
STRI	0%..100%	0.. $K$	Stride, kompletter Gangzyklus
ST	0%..60%	0.. $k_{ST}$	Stance, Standphase
SW	60%..100%	$k_{ST}$ .. $K$	Swing, Schwungphase
IC	0%..2%	0.. $\frac{1}{50} \cdot K$	Initial Contact
LR	0%..10%	0.. $k_{LR}$	Loading Response
MSt	10%..30%	$k_{LR}$ .. $k_{MSt}$ , $k_{MSt} = k_{LR} + \frac{1}{2} \cdot (k_{TSt} - k_{LR})$	Mid Stance
TSt	30%..50%	$k_{MSt}$ .. $k_{TSt}$ , $k_{TSt} = k_{MSt} + \frac{1}{2} \cdot (k_{TSt} - k_{LR})$	Terminal Stance
PSw	50%..60%	$k_{TSt}$ .. $k_{ST}$	Pre Swing
ISw	60%..73%	$k_{ST}$ .. $k_{ISw}$ , $k_{ISw} = k_{ST} + \frac{1}{3} \cdot (K - k_{ST})$	Initial Swing
MSw	73%..87%	$k_{ISw}$ .. $k_{MSw}$ , $k_{MSw} = k_{ISw} + \frac{1}{3} \cdot (K - k_{ST})$	Mid Swing
TSw	87%..100%	$k_{MSw}$ .. $K$	Terminal Swing

Tabelle A.2: Abkürzungen der einzelnen Schrittphasen. Bei der Berechnung individueller Phaseneinteilungen werden  $k_{LR}$  (Einzelunterstützungsphase des betrachteten Beins bzw. Fußablösung des gegenüberliegenden Beins),  $k_{TSt}$  (Fußaufsetzen des gegenüberliegenden Beins),  $k_{ST}$  (Fußablösung des betrachteten Beins) und  $K$  (Fußaufsetzen des betrachteten Beins, auch als IC bezeichnet) gemessen.

Wadenmuskulatur, kommt es zu einer Spitzfuß-Stellung (Pes Equinus), wobei die Überaktivität häufig gerade bei schnellen Bewegungen (z.B. beim Gehen) auftaucht. Bei heranwachsenden Kindern (infantile CP, ICP) kann durch die ständigen Fehlhaltungen eine Missbildung von Muskeln und Gelenken resultieren, z.B. Muskelverkürzungen, Fußschädigungen. Mit der ICP treten auch manchmal Anfallsleiden (Epilepsie), Sehstörungen oder andere Verhaltensauffälligkeiten auf [2]. Je nach Ausmaß der ICP sind gute Therapieerfolge im frühen Säuglingsalter durch die Vojta- oder Bobath-Therapie möglich, wobei eine Diagnose durch pathologische, frühkindliche Reflexe oder durch Computertomographie erfolgen kann. Eine Heilung wegen der Gehirnschädigung im fortgeschrittenen (Kindes-) Alter ist fast nicht möglich, wohl aber eine Besserung. Die Häufigkeit der Zerebralparese von Geburt an beträgt ca. 2,0-2,5‰ [26].

## **B Tabellarischer Literaturüberblick**

Quelle	Patienten, Personengruppen	Merkmalsart	Größe Merkmalsauswahl	klinisches Ziel	Interpretierbarkeit
[3]	ICP (35)	1,2,9	klein, subjektiv	Validierung zweier Therapievarianten	ja
[6]	ICP (31) - Ref (8)	4	klein, subjektiv	Gangvariabilität	ja
[12]	ICP (34) - Ref	7	klein, subjektiv	Grundlagen, Zusammenhänge Knie und OSG für chirurgische Eingriffe	ja
[14, 15, 16]	Probanden	8	groß, automatisiert	Diagnose	nein
[18]	Plattfuß-Patienten	8	groß, automatisiert	Therapievalidierung	nein
[18]	Plattfuß (28) - Ref (28)	8	groß, automatisiert	Diagnose	bedingt
[24, 97, 98, 99]	Ref	9	groß, automatisiert	Diagnose	ja
[35]	ICP	7	klein, subjektiv	Grundlagen	ja
[36]	ICP (40), Ref (18)	1,2	klein, subjektive Vorauswahl	Therapiedokumentation	ja
[39, 40]	Knie Osteoarthritis (13), Ref (30)	8	groß, automatisiert über alle Abtastzeitpunkte	Diagnose	nein
[43, 44]	SCI (40)	9	klein, subjektiv	Gangqualität	ja
[50]	ICP (6), Ref (6)	9	- (Modellbildung)	Grundlagen	bedingt
[60]	ICP (40), Ref (73)	1,2,3	klein, subjektiv	Diagnose, Therapievalidierung	ja
[64]	Ref (94), untersch. Patienten (131)	8	groß, automatisiert	Patientenerkennung	nein
[76]	ICP (55), Ref (5)	9	klein, subjektiv	Gangqualität	ja
[84]	Knie Osteoarthritis (144), Ref (144)	9	klein, subjektiv auf einen Parameter beschränkt	Symmetrisches Laufverhalten	bedingt
[85]	Ref (10)	8	klein, subjektiv auf einen Parameter beschränkt	Phasenverschiebung linke/rechte Körperseite	ja
Fortsetzung auf der nächsten Seite					

Quelle	Patienten, Personengruppen	Merkmalsart	Größe Suchraum, Merkmalsauswahl	klinisches Ziel	Interpretierbarkeit
[87]	Ref (28)	8	groß, automatisiert	Beschreibung Referenz	nein
[88, 89, 90, 93, 94, 95]	ICP (43), SCI (30), REF (20)	1-9	groß, automatisiert	Diagnose, Charakterisierung Patienten, Subgruppen, Therapiedokumentation	ja
[110]	Hirnschlag Patienten (47)	1,2	klein, subjektiv	Subgruppen	ja
[114]	ICP (146)	1,2	klein, subjektiv	Subgruppen	ja
[116]	Hirnschlag-Patienten	7	klein, subjektiv	Grundlagen und Charakterisierung Patienten	ja
[115]	Hirnschlag-Patienten (31)	8	groß, automatisiert	Diagnose, Datenreduktion	bedingt
[118]	ICP (88), Ref (68)	9	klein, subjektiv	Diagnose, Erkennen von Subgruppen	ja
[135]	Probanden mit unterschiedlichen Schuhen	1,2	klein, subjektive Vorauswahl	Erkennung von Personen (individuelle Unterschiede)	nein
[134]	Knie Osteoarthritis (10), Ref (26)	8	groß, automatisiert	Diagnose	bedingt
[145]	OSG-Arthrose (10), Ref (10)	9	klein, nur eine Kinematikzeitreihe	Subgruppen	ja
[152]	ICP (20)	1,2	klein, subjektiv	Therapievalidierung	ja
[136]	ICP (66), Ref (24)	8	klein, subjektiv	Gangqualität	bedingt
[159]	ICP (2), Ref (174)	8	groß, automatisiert	Gangqualität	nein
[161]	ICP	1,2,7	subjektiv, klein	Therapievalidierung	ja
[174]	ICP	7	subjektiv, subjektiv	Subgruppen	ja
[77, 167]	ICP	9	subjektiv, empirischer Entscheidungsbaum	Diagnose, Therapieauswahl	ja

Fortsetzung auf der nächsten Seite

Quelle	Patienten, Personengruppen	Merkmalsart	Größe Merkmalsauswahl	Suchraum, Merkmalsauswahl	klimisches Ziel	Interpretierbarkeit
[176]	ICP (128)	8	klein, Messdaten	wenig	Subgruppen	nein
[182]	Ref (20)	8	klein, subjektiv		Gangqualität	nein

Tabelle B.1: Überblick wichtiger Arbeiten zur Analyse von Gangdaten mit Personen- bzw. Patientenarten und deren Anzahl. Siehe dazu die sieben Merkmalsarten aus Abschnitt 2.3.1, weitere sind 8: Transformierte Merkmale aus Zeitreihen, 9: Sonstige (z.B. Raum-Zeit-Parameter). Bei der Größe des Suchraums bedeutet „groß“ den Einbezug aller und „klein“ lediglich die Beschränkung auf einen Teil der zur Verfügung stehenden Daten.

# C Methoden und Theoriegrundlagen

## C.1 Hauptkomponentenanalyse über Zeitreihen

Die Hauptkomponenten über Zeitreihen ( $K = 100$  Abtastzeitpunkte entspricht einem  $K$ -dimensionalen Merkmalsraum) berechnen sich mit Gl. (3.41). Die  $\phi_i$  Eigenvektoren dienen als affine („Linearität“ ohne Berücksichtigung des translatorischen Anteils) Transformationsvorschrift für die einzelnen Abtastzeitpunkte der Zeitreihen, links und Mitte in Abbildung C.1. Dadurch entsteht ein virtueller, dimensionsreduzierter Merkmalsraum, rechts in Abbildung C.1. Die Klasseneinteilung (hier ICP,PRE und REF) geht in die Berechnung nicht mit ein. Daher kann die Hauptkomponentenanalyse nur bedingt zur Klassentrennung eingesetzt werden (im Gegensatz zur Diskriminanzanalyse mit ähnlicher Mathematik). In Abbildung C.1 rechts ist diese Klasseneinteilung lediglich zur Orientierung mit angegeben. Die klinische Interpretation ist in diesem virtuellen Raum sehr schwierig.

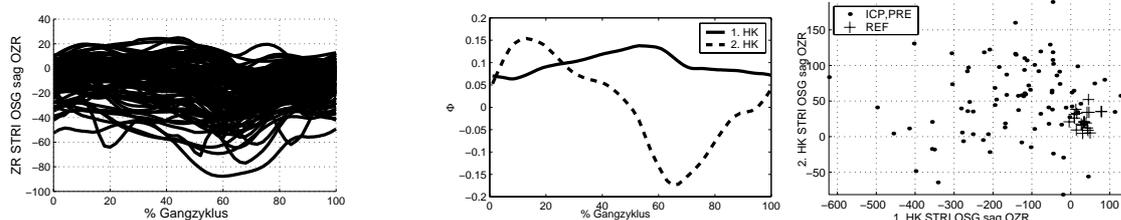


Abbildung C.1: Links: Zeitreihen von 106 Datensätzen (86 ICP,PRE Patienten, 20 REF, K Personen), Mitte: Transformationsvorschrift der Hauptkomponentenanalyse (Eigenvektoren  $\phi_1$ ,  $\phi_2$ ), rechts: Transformierte Merkmale im zweidimensionalen Raum.

## C.2 Proximitätsmaße

Der Begriff Proximitätsmaße dient als Oberbegriff für Distanz- und Ähnlichkeitsmaße [11].

Zwei Winkelverläufe (Zeitreihen, siehe z.B. Abbildung C.2)  $Z_i[k]$  und  $Z_j[k]$ ,  $k = 1..K$  können unterschieden werden, indem für jeden Abtastzeitpunkt ein Abstandsmaß eingeführt wird und diese aufsummiert werden. Ein Abstandsmaß zweier Vektoren (Minkowski-Metrik [11], hier am Beispiel zweier Zeitreihen) ist

$$\delta_{i,j} = \left[ \sum_{k=1}^K |Z_i[k] - Z_j[k]|^r \right]^{\frac{1}{r}}, \quad (\text{C.1})$$

wobei dieses für  $r = 2$  die Euklidische Norm ist. Da dieses Maß mit zunehmender Anzahl  $K$  steigt, wird im Folgenden ein auf die Anzahl  $K$  gemitteltes Abstandsmaß

$$\bar{\delta}_{i,j} = \left[ \frac{1}{K} \cdot \sum_{k=1}^K |Z_i[k] - Z_j[k]|^r \right]^{\frac{1}{r}}, \quad (\text{C.2})$$

mit  $r = 2$  verwendet. In Matrixschreibweise ist ein quadratisches Abstandsmaß

$$\delta^2(\mathbf{z}_j, \mathbf{z}_i) = (\mathbf{z}_j - \mathbf{z}_i)^T \cdot \mathbf{M} \cdot (\mathbf{z}_j - \mathbf{z}_i), \quad (\text{C.3})$$

wobei  $\mathbf{M}$  eine Gewichtungsmatrix ist. Wenn  $\mathbf{M} = \mathbf{I}$  die Einheitsmatrix ist, wird die quadratische Euklidische Distanz (vgl. (C.1)) erhalten. Ist  $\mathbf{M}$  die inverse Kovarianzmatrix (über alle Datensätze, oder nur eine bestimmte Auswahl) wird der Abstand entsprechend der Datenstreuung gewichtet (z.B. Mahalanobis- oder Tatsuoaka-Distanz, [155]).

Eine weitere Möglichkeit, zwei Zeitreihen zu vergleichen, besteht in der Betrachtung der Korrelation. Eine Korrelation kann als Maß für den Zusammenhang zwischen zwei Variablen angesehen werden. Bei Zeitreihen kann sie somit als Maß für den Zusammenhang zwischen zwei Verläufen (unabhängig von ihrer Distanz) dienen. Die Korrelation berechnet sich durch

$$\begin{aligned} \rho_{i,j} &= \frac{\sum_{k=1}^N (Z_i[k] - \text{MW}(Z_i[k])) \cdot (Z_j[k] - \text{MW}(Z_j[k]))}{\sqrt{\sum_{k=1}^N (Z_i[k] - \text{MW}(Z_i[k]))^2 \cdot \sum_{k=1}^N (Z_j[k] - \text{MW}(Z_j[k]))^2}} \\ &= \frac{\frac{1}{N} \cdot \sum_{k=1}^N (Z_i[k] - \text{MW}(Z_i[k])) \cdot (Z_j[k] - \text{MW}(Z_j[k]))}{\sqrt{\sigma_i^2 \cdot \sigma_j^2}}, \end{aligned} \quad (\text{C.4})$$

wobei  $\text{MW}(Z_i[k])$  bzw.  $\text{MW}(Z_j[k])$  der Mittelwert der i-ten bzw. j-ten Zeitreihe ist. Sie kann als normierte Kovarianz zweier Merkmale (hier Zeitreihen) betrachtet

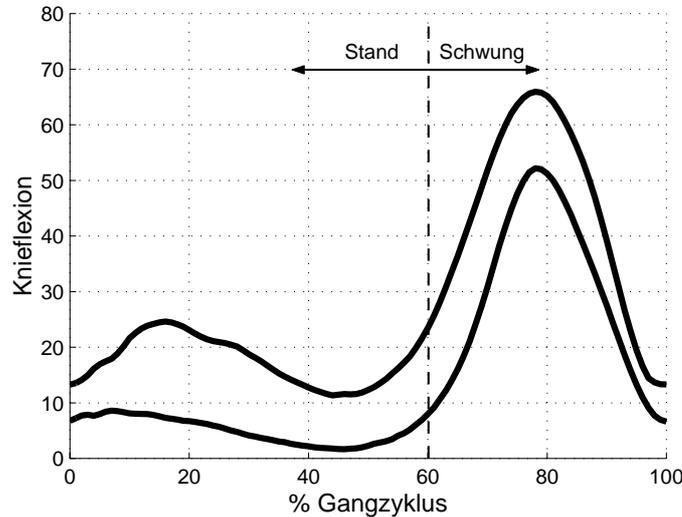


Abbildung C.2: Zwei Zeitreihen mit dem Abstandsmaß aus Gl. (C.2) für die Standphase  $\bar{\delta}_{i,j} = 12.79^\circ$  und die Schwungphase  $\bar{\delta}_{i,j} = 15.30^\circ$ .

werden, wobei sie bezüglich beider Standardabweichungen normiert ist. Das Korrelationsmaß kann somit Werte zwischen -1 und +1 annehmen. Ein Wert von +1 bedeutet eine positive Korrelation. Hierbei sind die Kurvenverläufe identisch, allerdings unabhängig von ihrer Distanz (Mittelwert) bzw. eines (konstanten und positiven) Verstärkungsfaktors. Ein Wert von -1 bedeutet eine negative Korrelation, der Verstärkungsfaktor ist negativ (die Verläufe sind um ihre jeweilige Mittelwertsachse gespiegelt). Eine Korrelation von 0 (unkorreliert) bedeutet, dass der Kurvenverlauf der einen Kurve nicht aus dem der anderen erschlossen werden kann [144]. So haben zwei gleiche Sinuskurven, die sich nur um einen Phasenwinkel von  $\frac{\pi}{2}$  unterscheiden, eine Korrelation von 0, d.h. unter Vorgabe eines Funktionswertes der einen Sinuskurve kann der entsprechende Wert der anderen Kurve nicht eindeutig bestimmt werden (ohne zusätzliche Information, z.B. Zeit, Abbildung C.3). In der Ganganalyse können durch Messfehler oder durch individuelle Unterschiede die Kurvenverläufe zeitverzögert sein, so muss dies in der Korrelationsbetrachtung berücksichtigt werden. Die zu vergleichenden Kurven sind somit auch mit einer bestimmten Zeitverzögerung zu untersuchen. Die Autokorrelation betrachtet um  $K$  Abtastwerte verschobene Abhängigkeiten einer Zeitreihe. Sie wird durch formales Ersetzen der Zeitreihe  $Z_j[k]$  in Gleichung (C.4) durch die zeitverschobene Zeitreihe  $Z_i[k + \Delta k]$  berechnet. Die Kreuzkorrelation betrachtet hingegen zwei verschiedene, zeitverschobene Zeitreihen. Als Zusammenfassung liefert Tabelle C.1 einen Überblick.

Die Auto- bzw. Kreuzkorrelationsfunktion (AKF, KKF) zeigt die entsprechen-

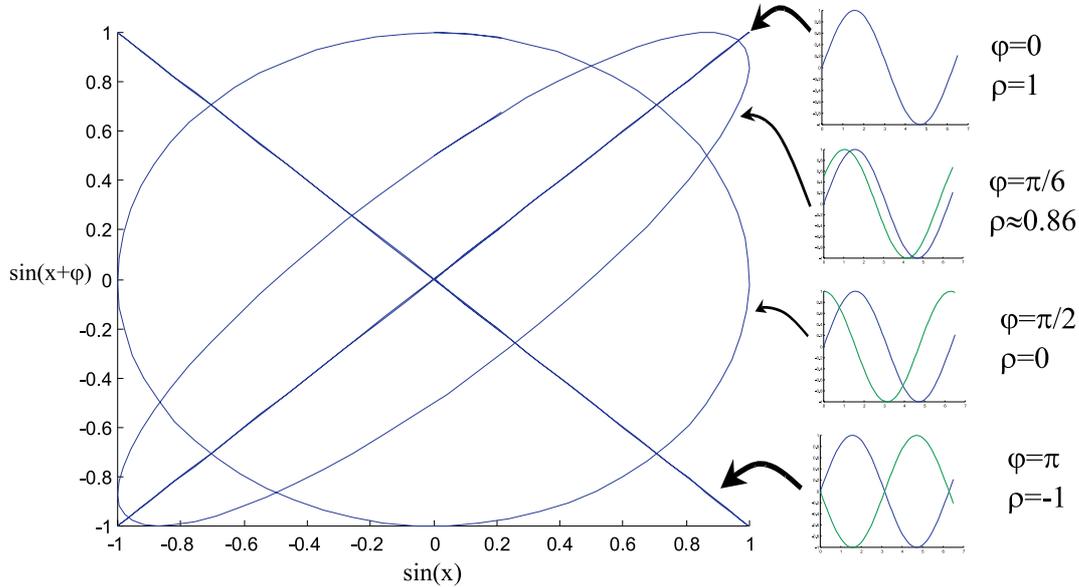


Abbildung C.3: Beispiele für Korrelationskoeffizienten  $\rho$  bei mit dem Winkel  $\varphi$  phasenverschobenen Sinuskurven, links: Darstellung der beiden Verläufe ( $\sin(x)$  und  $\sin(x+\varphi)$ ) gegeneinander, rechts: Darstellung beider Verläufe gegenüber x-Koordinate.

Bezeichnung	Berechnung
Korrelation	$\rho_{i,j} = \frac{\frac{1}{N} \cdot \sum_{k=1}^N (Z_i[k] - \text{MW}(Z_i[k])) \cdot (Z_j[k] - \text{MW}(Z_j[k]))}{\sqrt{\sigma_i^2 \cdot \sigma_j^2}}$
Autokorrelation	$\rho_{i,K} = \frac{\frac{1}{N-K} \cdot \sum_{k=1}^{N-K} (Z_i[k] - \text{MW}(Z_i[k])) \cdot (Z_i[k+K] - \text{MW}(Z_i[k]^*))}{\sigma_i^2}$ <p>mit <math>\text{MW}(Z_i[k]) = \frac{1}{N-K} \cdot \sum_{k=1}^{N-K} Z_i[k]</math>  und <math>\text{MW}(Z_i[k]^*) = \frac{1}{N-K} \cdot \sum_{k=K}^N Z_i[k]</math></p>
Kreuzkorrelation	$\rho_{i,j,K} = \frac{\frac{1}{N-K} \cdot \sum_{k=1}^{N-K} (Z_i[k] - \text{MW}(Z_i[k])) \cdot (Z_j[k+K] - \text{MW}(Z_j[k]))}{\sqrt{\sigma_i^2 \cdot \sigma_j^2}}$

Tabelle C.1: Überblick verschiedener Korrelationen.

den Korrelationskoeffizienten gegenüber einer Verschiebung  $K$  auf (Abbildung C.4). Dadurch können beispielsweise charakteristische Zeitverzögerungen beim Vergleich von Gangkurven aufgedeckt werden.

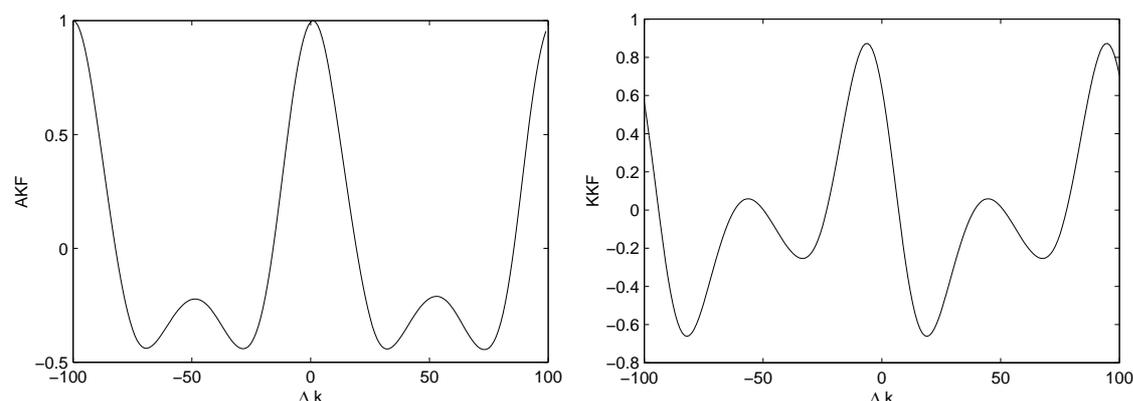


Abbildung C.4: Links: Autokorrelationsfunktion der oberen Zeitreihe aus Abbildung C.2, sie sind immer symmetrisch und rechts: Kreuzkorrelationsfunktion der Zeitreihen aus Abbildung C.2.

Ein weiteres Maß ist die nicht-parametrische Rang-Korrelation. Es betrachtet lediglich die Rangfolge zweier Messgrößen, die zudem keiner bestimmten Verteilung unterliegen müssen. Es ist robuster gegen Ausreißer, ähnlich dem Zentralwert oder Median. Am Beispiel der beiden Zeitreihen  $Z_i[k]$  und  $Z_j[k]$  sei  $R_i[k]$  und  $R_j[k]$  die Rangreihenfolge der Zeiteihenelemente, woraus sich der Spearman-Rang-Korrelationskoeffizient durch

$$r_{s_{i,j}} = \frac{\sum_{k=1}^N (R_i[k] - \text{MW}(R_i)) \cdot (R_j[k] - \text{MW}(R_j))}{\sqrt{\sum_{k=1}^N (R_i[k] - \text{MW}(R_i))^2 \cdot \sum_{k=1}^N (R_j[k] - \text{MW}(R_j))^2}} \quad (\text{C.5})$$

berechnet.

Derartige Proximitätsmaße sind allerdings klinisch wenig akzeptiert, so dass sie in dieser Arbeit nicht zur direkten Interpretation von Zeitreihen verwendet werden.

### C.3 Cluster-Verfahren

In der Literatur werden unterschiedliche Prinzipien von Cluster-Verfahren unterschieden, z.B. hierarchische oder partitionierende Verfahren [11, 45]. Bei den hierarchischen Verfahren werden entweder Cluster sukzessiv vereint (agglomerativ, beginnend mit jedem Datensatz als ein Cluster) oder getrennt (divisiv, beginnend mit einem Cluster über alle Datensätze). Das Vereinen oder Trennen von Clustern kann unterschiedlich erfolgen [20, 22, 70], z.B. single linkage (kleinste Distanz zwischen Datensätzen zweier Cluster), complete linkage (größte Distanz der Datensätze zweier Cluster) oder centroid linkage (mittlere Distanz aller Datensätze zweier Cluster). Die partitionierenden Verfahren gehen von einer bestimmten Cluster-Anzahl aus und optimieren die Zugehörigkeit der Datensätze zu den Clustern, ein allgemeines Vorgehen zeigt Abbildung C.5. Daher können die Fuzzy-Cluster-Verfahren, die eine Optimierungsfunktion minimieren, zu den partitionierenden Verfahren gezählt werden [66]. Ein Beispiel einer Optimierungsfunktion zeigt Gl. (3.27a), die große Cluster-Zugehörigkeiten  $u$  und kleine Distanzen  $d_c$  (bzw. umgekehrt) favorisiert.

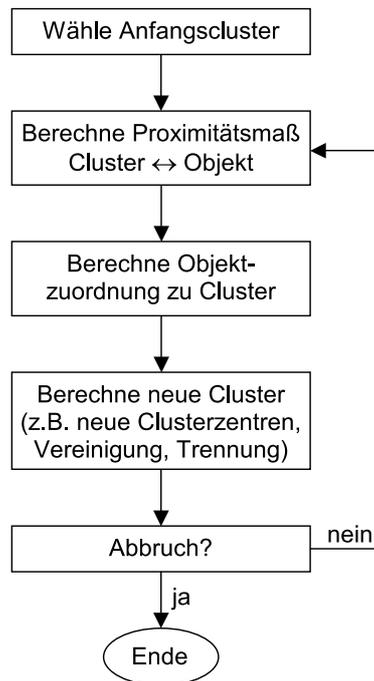


Abbildung C.5: Prinzip zur iterativen Cluster-Berechnung.

Nachfolgend werden die Leistungen unterschiedlicher Fuzzy-Verfahren anhand eines Testdatensatzes (Abbildung C.6 links) demonstriert. Die Fuzzy-Verfahren

sind der Fuzzy-C-Means mit Euklidischer Distanz (EU), der Fuzzy-C-Means mit Mahalanobis-Distanz (MA), der Gustafson-Kessel (GK) und der Gath-Geva (GG), siehe Abschnitt 3.8.2. Der Testdatensatz besteht aus fünf intuitiv einteilbaren Klassen A bis E. Diese Klassen unterscheiden sich in ihrer Ausrichtung und Position, so dass charakteristische Eigenschaften der verschiedenen Cluster-Algorithmen verdeutlicht werden können. In der Ganganalyse kommen allerdings derart offensichtlich zu trennende Klassen selten vor, meistens überlappen sich die Klassen, insbesondere die Patientensubgruppen.

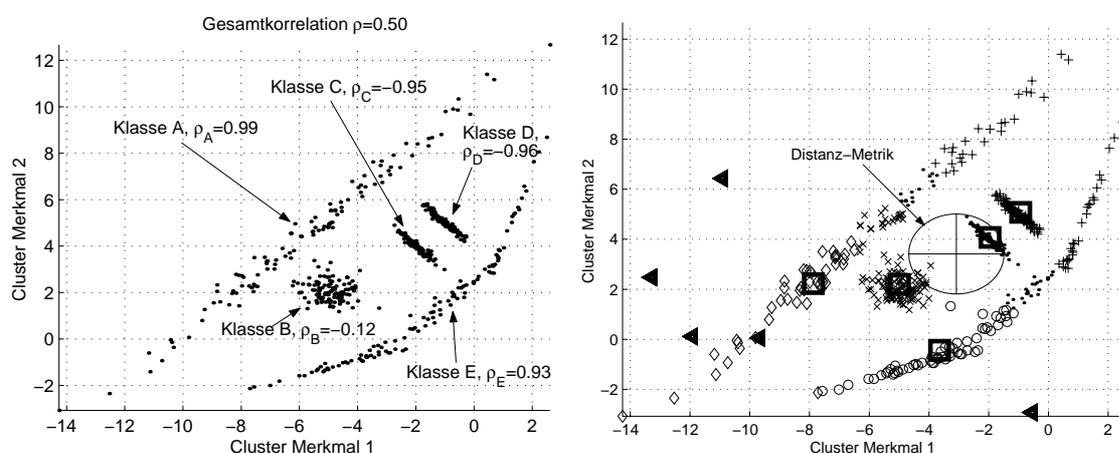


Abbildung C.6: Links: Künstlicher Testdatensatz mit zwei Merkmalen und fünf intuitiv einteilbaren Klassen mit deren Korrelationsangaben  $\rho_{A..E}$ , rechts: Cluster Ergebnis durch den EU mit fünf Cluster-Zentren □, zufälligen Start-Clustern ▷ und Euklidischer Distanz. Die maximale Zugehörigkeit zu den jeweiligen Cluster-Zentren ist symbolisch durch  $\cdot$ ,  $\circ$ ,  $\times$ ,  $+$ ,  $\diamond$  dargestellt.

Durch den EU werden wegen der Euklidischen Distanz kugelförmige Punkthäufungen erkannt, z.B. Klasse B (siehe Ausrichtung der „Distanz-Metrik“, hier als  $\oplus$  symbolisiert, wobei die leichte ovale Form lediglich durch die unterschiedlichen Achsenskalierungen verursacht ist). Die Klassen C und D können ebenfalls gut erkannt werden, da sie ausreichenden Abstand zueinander haben. Allerdings werden dadurch auch Datensätze der Klassen A und E mit in diese beiden Cluster einbezogen. Daher werden auch die Cluster-Zentren von  $\circ$  und  $\diamond$  „weggedrückt“.

Beim MA ist die „Distanz-Metrik“ entsprechend der Kovarianz aller Datensätze ausgerichtet, siehe Abbildung C.7 links. In Richtung der Hauptdiagonalen (von links unten nach rechts oben) sind die Distanzen reduziert. Eine Auswirkung dabei ist, dass die Klassen C und D in einem Cluster enthalten sind und damit auch einige

Datensätze aus Klasse E. Die Klasse A wird in zwei Cluster aufgeteilt, da die Distanz senkrecht zur Hauptdiagonalen vergrößert wird.

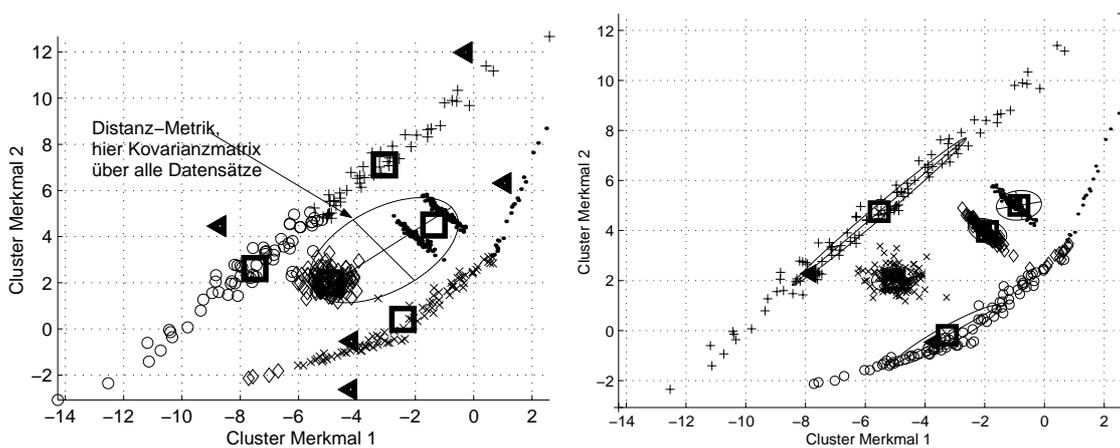


Abbildung C.7: Links: FCM Ergebnis mit Mahalanobis-Distanz, rechts: Gustafson-Kessel-Algorithmus mit Start-Clustern vom FCM, Euklidischer Distanz.

Der GK berücksichtigt clusterspezifische Datenausrichtungen. Daher können die Klassen A bis C gut erkannt werden (siehe Symbolisierungen der Distanz-Metriken). Die Klasse D wird durch Datensätze aus der Klasse E beeinflusst, d.h. die Distanz-Metrik bezieht sich nicht nur auf die Klasse D. Dadurch kommt ein fehlerhaftes Anlernen zustande. Der GK ist für dieses Anwendungsbeispiel stark von den Start-Clustern abhängig (viele lokale Minima in der Optimierungsfunktion), so dass die Start-Cluster aus EU übernommen wurden.

Die Ergebnisse können beim GG nicht verbessert werden. Dieser ist ebenfalls von den Start-Clustern abhängig. Das beste Ergebnis ist ähnlich dem des GK.

# D Funktionen von Gait-CAD

m-File	Beschreibung	Zeilen
Bein.m	Erzeugt Körperseiten unabhängiges Projekt (KUP), siehe Abschnitt 4.2	74
CLUSTER.M	Implementierung aller Cluster-Algorithmen und Validierungen sowie Visualisierungen, siehe Abschnitt 3.8	1266
EM_AUT.M	Zeigt Einzelmerkmale in Tabelle an, siehe Abschnitt 3.10	99
EM_TRANS.M	Transformiert Einzelmerkmal in Klasse, siehe Abschnitt 3.3	16
GAITCAD.M	Verwaltung aller einzelnen Funktionen, Hauptaufruf, siehe Kapitel 4	240
KAT_BER.M	Erstellt Kategorien, siehe Abschnitte 3.3 und 3.6.2	138
KAT_BEW.M	Bewertet Kategorien, siehe Abschnitt 3.6.1	167
KAT_LIST.M	Stellt alle Kategorien in Tabelle dar	40
LDPRJ_G.M	Laden von Projekten	265
LOADNORM.M	Laden von Referenzdaten	94
MW2NORM.M	Transformiert Mittelwerte zu Referenzdaten	13
NORMMASZ.M	Berechnet Referenzabweichung, siehe Abschnitte 3.4 und 3.5	31
Normier_ZR.m	Normiert Zeitreihen auf [0,1] Intervall, siehe Abschnitt 3.8.2	31
SAVENORM.M	Speichert Referenzdaten	14
Test_Daten_erstellen.m	Erstellt künstliche Testdaten, siehe Anhang C.3	24
aktparawin.m	Aktualisiert Hauptfenster	186
append_prj.m	Fügt Projekt an bestehendes an, siehe Abschnitt 4.2	86
ausgang_kombi.m	Kombiniert Klassen, siehe Abschnitt 3.3	18
ausgang_kombi_text.m	Erzeugt Menüaufruf	22
ausgangloeschen_text.m	Löscht Klasse, siehe Abschnitt 3.3	25
ausgkl_einz_text.m	Erzeugt Menüaufruf	23

Fortsetzung auf der nächsten Seite

m-File	Beschreibung	Zeilen
ausgkl_zusfuegen.m	Kombiniert Klassen, siehe Abschnitt 3.3	24
aut_em_loesch.m	Datenvorverarbeitung zum Ersetzen von „Null- elementen“, siehe Abschnitt 3.3	25
aut_zr_loesch.m	Datenvorverarbeitung zum Ersetzen von „Null- zeitreihen“, siehe Abschnitt 3.3	147
auto_9-Gangplot.m	Visualisierung Zeitreihen als Chart, siehe Ab- schnitt 3.10	14
berechne_abstand.m	Berechnung von Distanzen für Cluster, siehe Ab- schnitt 3.8	69
cluster_auto.m	Automatisierung Cluster über mehrere Merkma- le, siehe Abschnitt 3.8	57
cluster_auto_komp.m	Automatisierung Cluster über mehrere Merkma- le, siehe Abschnitt 3.8	67
cluster_hka_visu.m	Visualisierung von Cluster über HKA, siehe Ab- schnitt 3.8	21
cluster_okay.m	Für Menüaufruf	126
cluster_text.m	Für Menüaufruf	83
color_style.m	Farbwahl	36
datenauswahl_text.m	Für Menüaufruf	42
ds_loesch.m	Datensätze löschen	47
ds_loesch_text.m	Für Menüaufruf	31
eml_untersuchung.m	Vorverarbeitung für Patienten mit unterschiedli- chen Untersuchungszeitpunkten	33
find_code_alle.m	Unterschiedliche Klassen suchen	43
gleichsetzen_normdaten.m	Linke und rechte Körperseite gleichsetzen	40
interpret_einzelmerk.m	Apriori-Relevanzen erzeugen, siehe Ab- schnitt 3.6.2	134
kafka_export.m	Exportschnittstelle zu KAFKA (überwachte Fuzzy-Klassifikation), siehe Abschnitt 3.7	58
kat_auswahl.m	Merkmale durch Kategorien auswählen	17
kat_auswahl_text.m	Menüaufruf	44
kat_aut_losch.m	Automatisch Kategorien löschen	27
Lauf_Sim2_g.m	Zweidimensionale Visualisierung der Kinematik- daten durch schematisiertes Personenmodell	178
merk_gene_em.m	Einzelmerkmale aus Einzelmerkmalen generieren	134
merk_gene_em_text.m	Für Menüaufruf	32
merkmalsgenerierung.m	Generierung neuer Merkmale (Zeitreihen, Einzel- merkmale), siehe Abschnitte 3.4 und 3.5	393
merkmalsgenerierung_text.m	Für Menüaufruf	32
merkmalsloesch_text.m	Für Menüaufruf	42
mittel_em.m	Erzeugt Mittelwerte	59

Fortsetzung auf der nächsten Seite

m-File	Beschreibung	Zeilen
phasen_resample.m	Interpolation von Zeitreihen entsprechend individueller Phaseinteilung	46
readpar1_g.m	Initialisierung	131
resample_g.m	Normiert Zeitreihen, siehe Abschnitt 3.3	8
saveprj_g.m	Speichert Projekt	22
visu_einzel_ausf.m	Visualisiert Einzelmerkmale, siehe Abschnitt 3.10	69
visu_einzel_text.m	Für Menüaufruf	41
visu_zeitreihe.m	Visualisierung Zeitreihen, siehe Abschnitt 3.10	198
visu_zr_signi.m	Visualisierung Zeitreihen mit Referenzabweichung, siehe Abschnitt 3.10	193

Tabelle D.1: MATLAB m-Files (mit Kurzbeschreibung und Anzahl der Zeilen) die in der vorliegenden Arbeit zur Softwareimplementierung „Gait-CAD“ realisiert wurden.

Daneben werden „KAFKA“-Funktionen verwendet, die nicht im Rahmen dieser Arbeit entwickelt wurden (Kapitel 3, [108]).

Nachfolgend ist ein exemplarischer Auszug der Funktion „normmasz“ gezeigt:

```
function [masz_betr,masz_riecht,masz_betr0,masz_riecht0,masz_zr,vorz,vorz0]
    =normmasz(d_orgs_auswahl,my,mstd,n)
% [masz_betr,masz_riecht,masz_betr0,masz_riecht0,masz_zr,vorz,vorz0]=
    normmasz(d_orgs_auswahl,my,mstd,n)
% Berechnet Maß für Abstand von Zeitreihen in d_orgs zur Referenz
% (beschrieben durch Strukt ref, mit ref.my=Mittelwertzeitreihe,
    ref.mstd= Standardabweichungszeitreihe)
%
% masz_betr    =    summiert Betrag aller Abstandsmaße über Abtastzeitpunkte
    (der Zeitreihe) auf
% masz_riecht =    summiert alle Abstandsmaße über Abtastzeitpunkte
    (der Zeitreihe) auf
%
% Bewertung nur der Werte der Zeitreihe d_orgs, die aus dem Referenzkorridor
    (der Strand.abw.) hinausgehen:
% masz_betr0   =    Summe aller Beträge
% mas_riecht0 =    Summe über Werte
% vorz        =    Berechnet Patienten-Zeitreihen ober/unterhalb
    von ReferenzMITTELWERT
% vorz0       =    Berechnet Patienten-Zeitreihe ober/unterhalb
    von ReferenzKORRIDOR, im Korridor=0

if (nargin>4) mstd=n*mstd;end;

if size(my,1)~=1 my=my';end;    %my muss in einer (1,anz_samples) vorliegen
if size(mstd,1)~=1 mstd=mstd';end;
```

```
%Mittelwerte berechnen und durch n*Standardabweichungen teilen
masz=( d_orgs_auswahl-ones(size(d_orgs_auswahl,1),1)*my ) ./
      ( ones(size(d_orgs_auswahl,1),1)* mstd);
indnan=find(isnan(masz));
masz(indnan)=zeros(size(indnan));
masz_zr=masz;

masz_riecht=sum(masz')/size(d_orgs_auswahl,2);
masz_betr=sum(abs(masz)')/size(d_orgs_auswahl,2);
vorz=sum(sign(masz)')/size(d_orgs_auswahl,2);

%für Bewertung nur der Werte der Zeitreihe d_orgs, die aus dem Referenzkorridor
      (der Strand.abw.) hinausgehen
ind=find(abs(masz)<1);masz(ind)=zeros(size(ind));
ind=find(masz>=1);   masz(ind)=masz(ind)-1;
ind=find(masz<=-1); masz(ind)=masz(ind)+1;
masz_riecht0=sum(masz')/size(d_orgs_auswahl,2);
masz_betr0=sum(abs(masz)')/size(d_orgs_auswahl,2);
vorz0=sum(sign(masz)')/size(d_orgs_auswahl,2);
```

# E Ergänzungen zu den Datensätzen

## E.1 Bezeichnungen

Tabelle E.1 zeigt Textbausteine, mit denen die unterschiedlichen Kinematikzeitreihen von den Labors bezeichnet werden. Hierbei treten auch synonyme oder gelenkwinkelspezifische Bezeichnungen auf.

(synonyme) Abkürzungen	Bedeutung
L-, [Left	Linke Körperseite
R-, [Right	Rechte Körperseite
ANK, Ankle	OSG, Oberes Sprunggelenk
KNEE	Knie
HIP	Hüfte
Pelvis, Pelvic	Becken
ELBOW	Ellenbogengelenk
Shl	Schultergelenk
Trunk	oberer Rumpf (Wirbelsäule als 'Gelenk')
Head	Position zwischen Kopf und Körper (Hals als 'Gelenk')
Flex, FlexExt, DorsiPlanFlex	Flexion (Winkelbezeichner in Sagittalebene)
Rot, Rotation	Rotation (Winkelbezeichner in Transversalebene)
Abd, ValgVar, AbAdduct	Abduktion (Winkelbezeichner in Frontalebene)
Tilt	Kippen, Neigung
Lat, Obliquity	lateral (seitwärts), für Winkel in Frontalebene
Fwd, Tilt	forward (vorwärts), für Winkel in Sagittalebene

Tabelle E.1: Textbausteine aus den Labors zur Bezeichnung der Kinematikzeitreihen.

## E.2 ICP-Daten

Abbildung E.1 zeigt die erweiterte Kinematik-Visualisierung eines Patientencharts (ID 50504) mit Geschwindigkeitszeitreihen (GZR) und die graue Hinterlegung wesentlicher pathologischer Ausmaße des gesamten Kollektives.

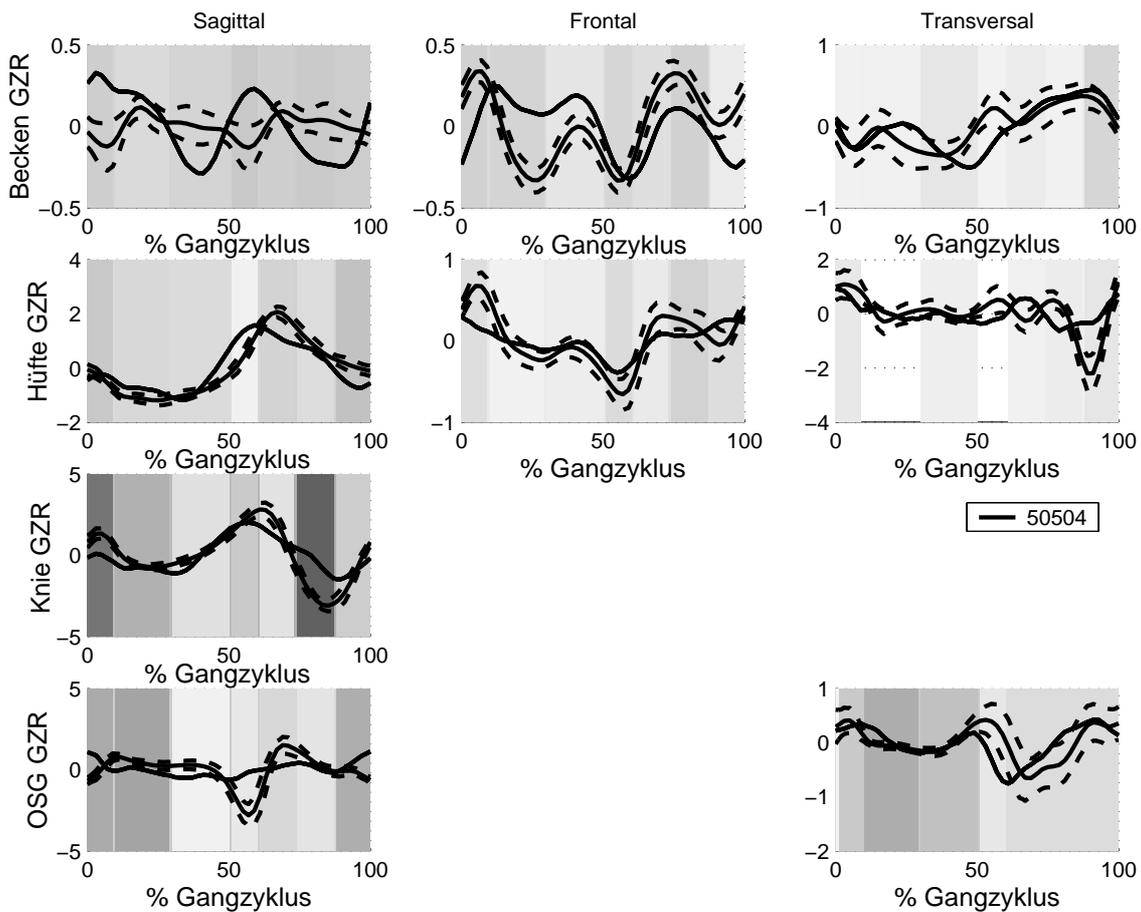


Abbildung E.1: Erweiterte Darstellung der Charts als Geschwindigkeitszeitreihen und Visualisierung der pathologischen Gangabweichung des Patientenkollektives als unterschiedliche graue Abstufungen.

Tabelle E.2 zeigt charakteristische Einzelmerkmale, die mit einer individuellen Phaseneinteilung gefunden sind. Beim Vergleich mit den standardisierten Phasen existieren beispielsweise erhebliche Unterschiede in der Relevanz bei „MIN ISw OSG sag GZR“, siehe auch Abbildung E.2. Hierbei gibt es infolge der individuellen Phaseneinteilung lediglich geringfügige Verschiebungen der Zeitreihen insbesondere im

ISw (60%-73% des Gangzyklus), was im Wesentlichen in der GZR zum Ausdruck kommt. Ob dieses nun ein klinisch plausibles Merkmal ist, ist eher zweifelhaft. Im Gegensatz dazu ist das Einzelmerkmal „MIN STRI OSG sag GZR“ ein offensichtlicher ICP-Effekt (durch beide Varianten erkannt), welcher das Abstoßverhalten beschreibt. Somit existieren keine Merkmale für diesen Datensatz, die durch die individuelle Phasenerkennung wesentlich besser erkannt worden sind.

Einzelmerkmal	$M_{s,ap}$	$M_{s,uk}$	$M_s$	Identisch mit Tabelle 5.3
Schrittlänge	1.00	0.61	0.61 (0.61)	✓
SpW STRI Becken sag OZR	1.00	0.53	0.53 (0.53)	✓
MIN SW Knie sag OZR	0.80	0.43	0.54 (0.45)	$\rho_{\max} = 0.70$
MW LR Knie sag GZR	0.48	0.40	0.83 (0.73)	$\rho_{\max} = 0.59$
MW STRI OSG sag SZR	0.60	0.35	0.58 (0.57)	✓
MW ST OSG sag OZR	0.80	0.33	0.41 (0.38)	✓
MAX STRI Hüfte sag OZR	1.00	0.31	0.31 (0.28)	✓
MW STRI Hüfte sag SZR	0.60	0.28	0.47 (0.48)	✓
MAX STRI OSG tra OZR	0.80	0.25	0.31 (0.31)	✓
MW STRI Becken tra SZR	0.48	0.25	0.52 (0.53)	✓
MAX MSt OSG sag GZR	0.48	0.23	0.48 (0.37)	$\rho_{\max} = 0.62$
MIN STRI OSG sag GZR	0.80	0.22	0.28 (0.25)	✓
MAX TSw OSG sag GZR	0.48	0.20	0.42 (0.40)	✓
MIN ISw OSG sag GZR	0.48	0.20	0.42 (0.11)	$\rho_{\max} = 0.61$
SpW STRI OSG tra OZR	0.80	0.19	0.24 (0.23)	$\rho_{\max} = 0.52$
SpW MSt Hüfte sag OZR	0.60	0.19	0.32 (0.18)	$\rho_{\max} = 0.59$

Tabelle E.2: Charakteristische Einzelmerkmale des ICP,PRE-Kollektives (86 Datensätze) im Vergleich zur Referenz (REF,K 20 Datensätze) mit individueller Phaseneinteilung, Apriori-Relevanz  $M_{s,ap}$ , Rückstufung korrelierter Einzelmerkmale  $M_{s,uk} = M_s \cdot M_{s,ap} \cdot M_{s,ko}$  und Berechnung  $M_s$  durch informationstheoretische Maße. Zum Vergleich stehen die Einzelmerkmale mit standardisierten Gangphasen bei den Relevanzen in Klammern sowie die identisch gefundenen bzw. die dazu maximalen Korrelationen  $\rho_{\max}$ . Unterschiedliche Relevanzen  $M_s$  bei identischen Merkmalen über einen kompletten Doppelschritt begründen sich durch die interpolierten Zeitreihen bei individueller Phaseneinteilung.

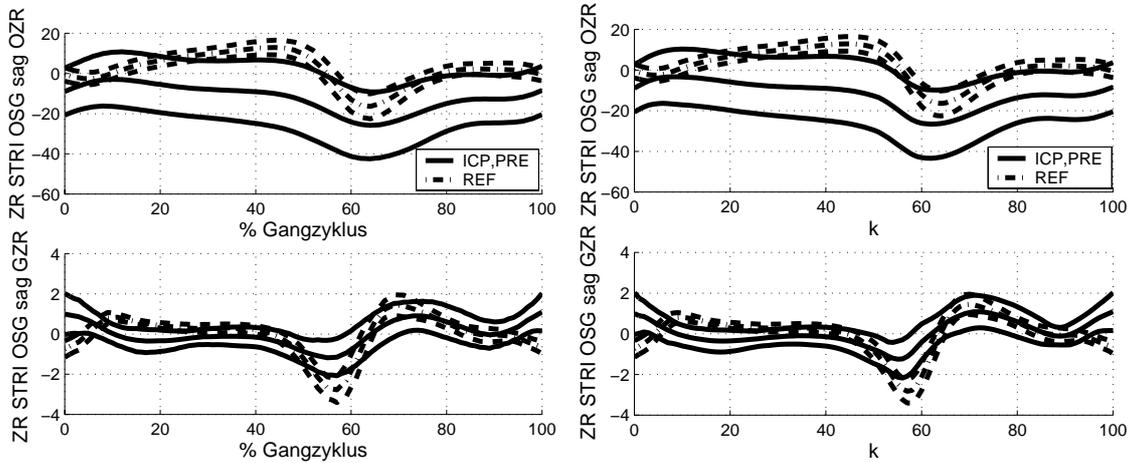


Abbildung E.2: Zeitreihen ( $\bar{Z}_{ns}[k] \pm \tilde{Z}_{ns}[k]$ ) des OSG (OZR bzw. GZR) für das gesamte ICP,PRE- bzw. REF-Kollektiv. Links: Mit standardisierten Gangphasen. Rechts: Mit individuelle Phaseneinteilung und entsprechender Interpolation der Zeitreihen.

Tabelle E.3 zeigt charakteristische Einzelmerkmale, die mit der univariaten Varianzanalyse (ANOVA) gefunden wurden. Dieses Verfahren ist eine gute Alternative zu den informationstheoretischen Maßen und überdies rechentechnisch einfacher zu implementieren. Bei diesen Datensätzen existieren ausschließlich kompakte Klassen, so dass auch die univariate Varianzanalyse (ANOVA) eingesetzt werden kann.

Abbildung E.3 zeigt valide Cluster-Ergebnisse von Kombinationen aus Zeitreihen, die halbautomatisiert mit heuristischem Vorgehen gefunden wurde. Es lässt sich erkennen, dass sich bestimmte Muster im Becken kaum unterscheiden (Cluster 1 und 3), allerdings mit unterschiedlichen Auswirkungen auf Hüfte und OSG (Cluster 2 und 3 in Abbildung E.3).

Abbildung E.4 zeigt halbautomatisiert gefundene Cluster-Ergebnisse unter Ausschluss aller Merkmale von OSG tra.

Einzelmerkmal	$M_{s,ap}$	$M_{uk}$	$M_s$	Identisch mit Tabelle 5.3
Doppelschrittlänge	1.00	0.54	0.54	$\rho_{\max} = 0.98$
SpW MSw Knie sag OZR	0.60	0.46	0.76	✓
MW ST Knie sag GZR	0.64	0.34	0.54	$\rho_{\max} = 0.62$
SpW STRI Becken sag OZR	1.00	0.32	0.32	✓
MAX STRI Hüfte sag OZR	1.00	0.28	0.28	✓
MIN STRI OSG sag GZR	0.80	0.21	0.27	✓
MW LR Becken sag GZR	0.48	0.19	0.40	$\rho_{\max} = 0.66$
MAX PSw Becken sag GZR	0.48	0.19	0.39	✓
MW STRI OSG sag OZR	1.00	0.18	0.18	$\rho_{\max} = 0.98$
MW STRI Hüfte sag SZR	0.60	0.18	0.30	✓
MW STRI Becken tra SZR	0.48	0.16	0.34	✓
SpW PSw Hüfte fro OZR	0.48	0.16	0.34	$\rho_{\max} = 0.65$
MW IC OSG sag GZR	0.48	0.16	0.34	$\rho_{\max} = 0.78$
SpW LR OSG sag OZR	0.60	0.14	0.23	$\rho_{\max} = 0.81$
MIN TSt Becken sag GZR	0.48	0.14	0.28	$\rho_{\max} = 0.66$
SpW STRI OSG tra OZR	0.80	0.13	0.16	$\rho_{\max} = 0.52$
Schrittlänge	1.0	0.53	0.53	✓ ( $\rho_{\max}^* = 0.98$ )
MW STRI OSG sag SZR	0.6	0.13	0.22	✓ ( $\rho_{\max}^* = 0.61$ )
MW ST OSG sag OZR	0.8	0.14	0.18	✓ ( $\rho_{\max}^* = 0.98$ )
MAX STRI OSG tra OZR	0.8	0.13	0.16	✓ ( $\rho_{\max}^* = 0.43$ )
MIN MSt OSG sag GZR	0.48	0.15	0.31	✓ ( $\rho_{\max}^* = 0.54$ )
MAX TSw OSG sag GZR	0.48	0.16	0.33	✓ ( $\rho_{\max}^* = 0.78$ )
SpW IC OSG sag OZR	0.6	0.08	0.13	✓ ( $\rho_{\max}^* = 0.81$ )
MW STRI Hüfte tra SZR	0.48	0.06	0.13	✓ ( $\rho_{\max}^* = 0.54$ )
MW STRI Becken fro OZR	0.8	0.00	0.00	✓ ( $\rho_{\max}^* = 0.10$ )

Tabelle E.3: Oben: 16 charakteristische Einzelmerkmale des ICP,PRE-Kollektives (86 Datensätze) im Vergleich zur Referenz (REF,K 20 Datensätze) mit standardisierten Gangphasen, Apriori-Relevanz  $M_{s,ap}$ , Rückstufung korrelierter Einzelmerkmale  $M_{s,uk} = M_s \cdot M_{s,ap} \cdot M_{s,ko}$  und Berechnung  $M_s$  durch univariate Varianzanalyse (ANOVA).  $\rho_{\max}$  gibt die maximale Korrelation zu den gefundenen Merkmalen aus Tabelle 5.3 an. Unten: Neun zusätzlich gefundene Einzelmerkmale aus Tabelle 5.3, das hier angegebene  $M_s$  ist zum Vergleich mit der univariaten Varianzanalyse (ANOVA) berechnet.  $\rho_{\max}^*$  bezieht sich auf die 16 Merkmale von oben.

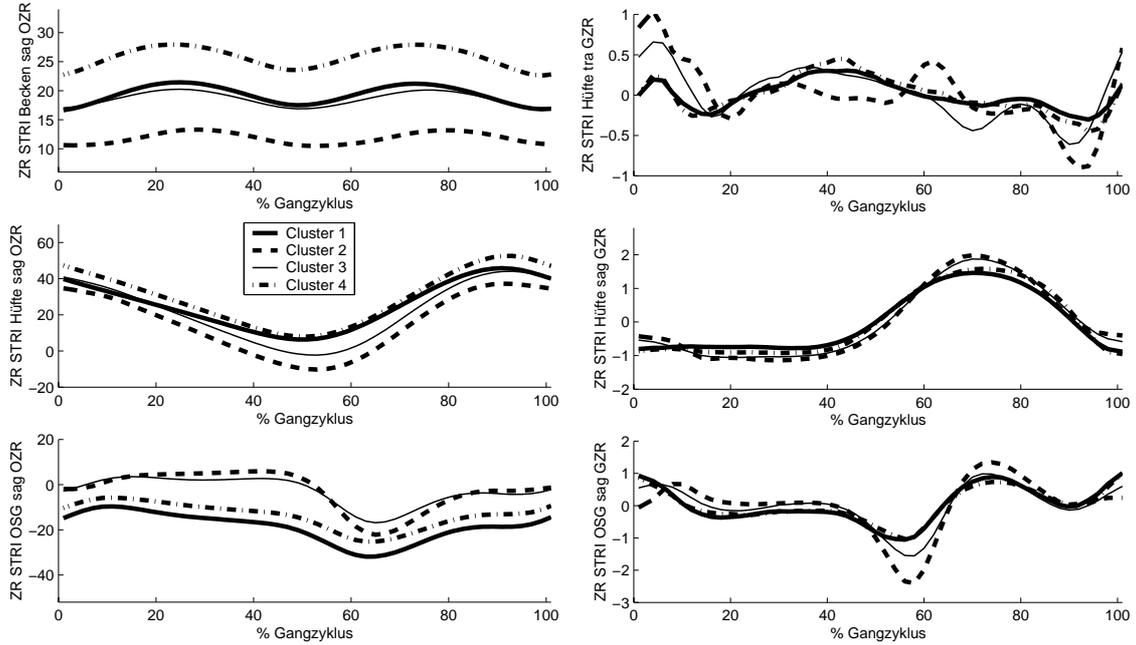


Abbildung E.3: Visualisierung der vier Cluster-Zentren aus Tabelle 5.5 (rechts) für die ersten sieben Zeitreihenkombinationen (bis einschließlich „HK STRI Hüfte sag OZR“).

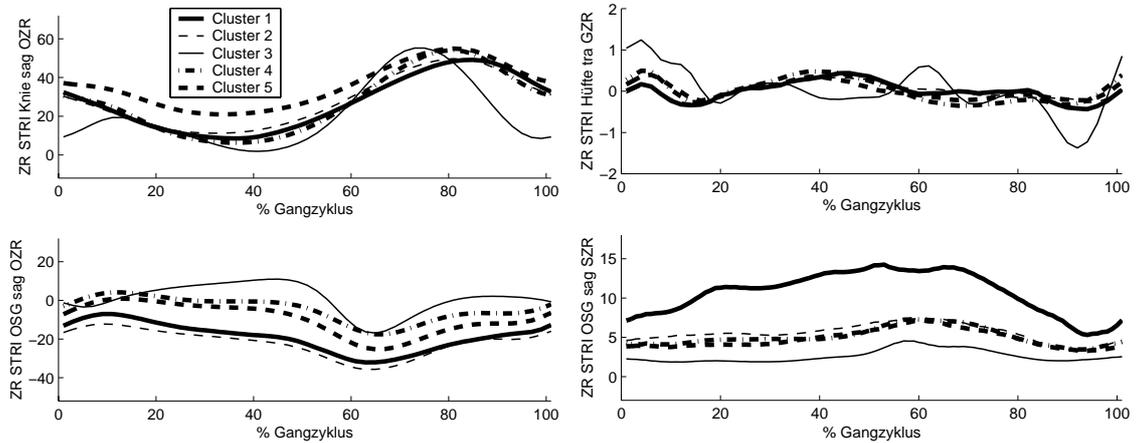


Abbildung E.4: Visualisierung der fünf Cluster-Zentren aus Tabelle 5.5 (links) für die ersten fünf Zeitreihenkombinationen (bis einschließlich „HK STRI OSG sag GZR“).

Tabellen E.4 und E.5 zeigen die Korrelationskoeffizienten zwischen Botulinum-Toxin-Dosierung und Einzelmerkmalen. Als Einzelmerkmale wurden klinische Parameter (z.B. Gewicht, Alter), interpretierbare Einzelmerkmale aus den Zeitreihen zum PRE-Untersuchungszeitpunkt (über STRI, ST und SW, siehe Abschnitt 3.5) und deren Differenzen zu den POST-Untersuchungen (DIFF-PRE-POST). Auffällig ist die Gesamtdosierung in Bezug zum Körpergewicht. Weiterhin stehen (wenn überhaupt) die Streuungszeitreihen in Bezug zur Dosierung (leichte Verbesserung durch die Therapie, vermutlich bessere Gangstabilität).

Position	Merkmal	$\rho$
1	Injektion Ischios Med	0.621
2	Dosierung Insges (Units)	0.610
3	MAX SW Knie sag li SZR	-0.598
4	SpW SW Knie sag li SZR	-0.580
5	MAX ST Knie sag li GZR	-0.571
6	DIFF-PRE-POST: MIN STRI Hüfte fro li SZR	-0.568
7	MW SW Knie sag li RZR	-0.555
8	MW SW Knie sag li SZR	-0.538
9	MW SW Becken fro li RZR SZR	-0.521
10	MW SW Becken fro li SZR	-0.516
11	DIFF-PRE-POST: MW Hüfte fro li SZR	-0.505
12	MW STRI Hüfte tra re GZR	-0.500

Tabelle E.4: Korrelationskoeffizienten  $\rho$  von Botulinum-Toxin Dosierung (umgerechnet Units/kg)

Position	Merkmal	$\rho$
1	Umgerechnet(Units/kg KG)	0.610
2	Gewicht (kg)	0.566
3	DIFF-PRE-POST: MW STRI Knie fro li SZR	0.529
4	DIFF-PRE-POST: MW ST OSG tra li SZR	0.504
5	MAX STRI Knie sag SZR	-0.501
6	DIFF-PRE-POST: MAX STRI Knie sag SZR	0.497
7	DIFF-PRE-POST: MW STRI Knie sag SZR	0.497
8	DIFF-PRE-POST: MW ST OSG tra li SZR	0.494
9	R Ischios Med	0.493
10	DIFF-PRE-POST: SpW ST Becken tra re GZR	-0.492
11	Geburtsdatum	-0.487
12	MW STRI Knie sag re RZR SZR	-0.485

Tabelle E.5: Korrelationskoeffizienten  $\rho$  von Botulinum-Toxin-Dosierung (Dosierung Insges (Units))

Anhand des 3-Klassenproblems zur Trennung der Gruppen A, B, C aus Abbildung 5.16 konnten keine Fuzzy-Regeln gefunden werden, die die Botulinum-Toxin-Dosierung verwenden. Regeln, die andere Merkmale verwenden zeigt Abbildung E.5.

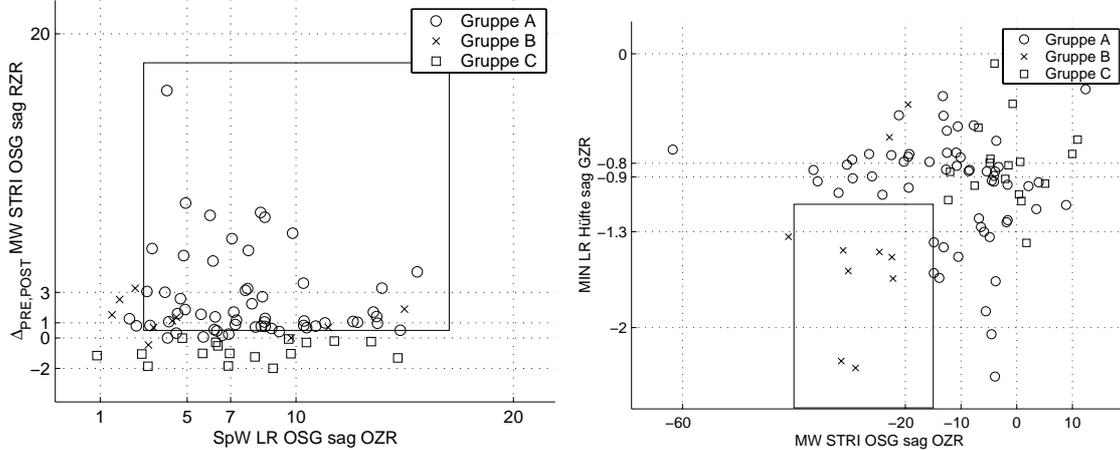


Abbildung E.5: Regeln zum Erklären der Gruppen A, B und C.

Fuzzy-Regeln zum Erklären der Botulinum-Toxin-Dosierungen (3-Klassenproblem zur Unterscheidung der Dosierungen „kleiner 30“, „zwischen 30 und 40“ und „größer 40“) zeigt Abbildung E.6, die allerdings sehr fragwürdig erscheinen. Bessere Regeln konnten nicht gefunden werden.

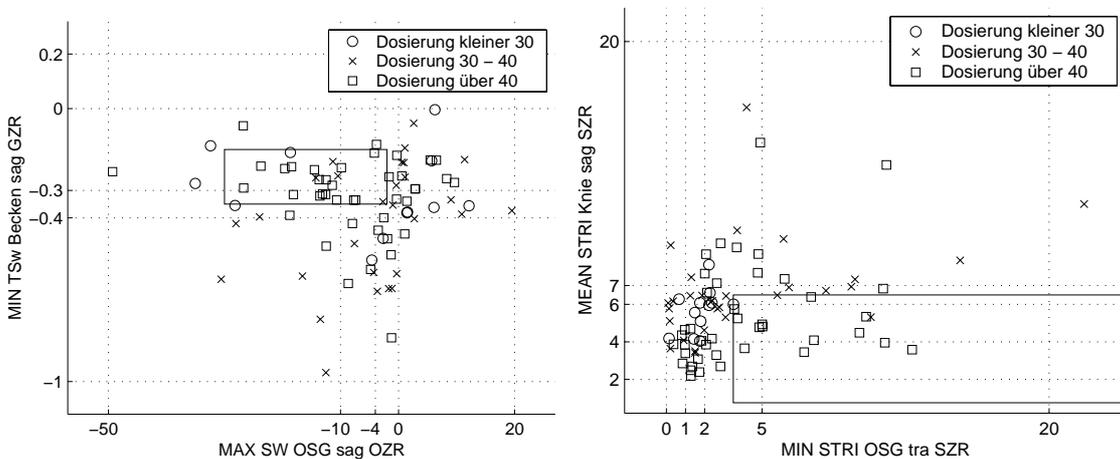


Abbildung E.6: Regeln zum Erklären der Botulinum-Toxin-Dosierungen.

Tabelle E.6 zeigt Merkmalsrelevanzen für das 2-Klassenproblem zur Trennung von ICP,PRE und ICP,POST. Hierzu wurden die Einzelmerkmale aus Tabelle 5.3 verwendet. Dabei fällt auf, dass lediglich – wenn auch geringe – Änderungen im Sprunggelenk („MW ST OSG sag OZR“) erzielt werden. Alle weiteren charakteri-

stischen ICP-Merkmale ändern sich durch die Therapie kaum.

Einzelmerkmal	$M_s$	ICP, PRE	ICP,POST	REF,K
Schrittlänge	0.00	$0.3 \pm 0.1$	$0.3 \pm 0.1$	$0.6 \pm 0.1$
SpW STRI Becken sag OZR	0.00	$8.0 \pm 3.3$	$7.7 \pm 3.3$	$2.9 \pm 0.8$
SpW MSw Knie Sag OZR	0.00	$9.0 \pm 5.3$	$10.0 \pm 6.2$	$31.4 \pm 3.2$
MW STRI OSG sag SZR	0.00	$6.1 \pm 3.6$	$5.9 \pm 3.6$	$1.8 \pm 0.7$
MW ST OSG sag OZR	0.14	$-9.0 \pm 14.0$	$2.0 \pm 11.5$	$5.5 \pm 2.5$
MW STRI Hüfte sag SZR	0.00	$4.9 \pm 2.0$	$5.0 \pm 1.9$	$2.0 \pm 0.7$
MAX STRI Hüfte sag OZR	0.00	$47.6 \pm 8.0$	$47.8 \pm 7.7$	$35.9 \pm 4.8$
MW STRI Becken tra SZR	0.00	$6.7 \pm 2.8$	$7.0 \pm 3.0$	$2.1 \pm 0.8$
MAX STRI OSG tra OZR	0.01	$11.7 \pm 13.6$	$6.6 \pm 15.2$	$-1.9 \pm 4.5$
MIN MSt OSG sag GZR	0.02	$-0.6 \pm 0.5$	$-0.4 \pm 0.4$	$0.2 \pm 0.2$
MAX PSw Becken sag GZR	0.00	$0.3 \pm 0.2$	$0.3 \pm 0.2$	$-0.0 \pm 0.1$
MIN STRI OSG sag GZR	0.001	$-1.7 \pm 0.9$	$-1.6 \pm 0.7$	$-3.0 \pm 0.7$
MAX TSw OSG sag GZR	0.00	$1.2 \pm 0.7$	$1.2 \pm 0.7$	$0.1 \pm 0.2$
SpW IC OSG sag OZR	0.00	$1.2 \pm 0.7$	$1.1 \pm 0.5$	$0.6 \pm 0.2$
MW STRI Hüfte tra SZR	0.00	$5.7 \pm 4.5$	$6.2 \pm 4.9$	$1.9 \pm 0.6$
MW STRI Becken fro OZR	0.00	$0.1 \pm 3.5$	$-0.0 \pm 3.7$	$0.0 \pm 1.0$

Tabelle E.6: Charakteristische Einzelmerkmale aus Tabelle 5.3 mit Relevanzen  $M_s$  (informationstheoretische Maße) für das Klassifikationsproblem zur Trennung von ICP,PRE und ICP,POST.

Tabelle E.7 zeigt Botulinum-Toxin-Dosierungen sowie die Anzahl vollständiger Schritte aller ICP-Datensätze.

Nr	ID	AI	Gw	PRE	Anzahl Schritte	Dos	reDo	rG	lG	rILa	lILa	rIM	rRe	lRe	rS	lS	rT	lT	rA	lA
					U1	U2														
1	50244	9	18	2	3	1	720	40	80	80	0	160	80	80	80	0	0	0	0	0
2	50313	9	25	2	4	12	500	20	160	160	0	0	0	0	90	90	0	0	0	0
3	50324	5	22	1	-	-	500	22.7	80	80	40	40	0	0	90	90	0	0	0	0
4	50377	6	20	1	-	-	700	35	88	88	0	88	88	90	80	90	0	0	0	0
5	50402	7	22	5	2	6	720	32.7	80	80	0	80	80	80	80	40	40	0	0	0
6	50411	5	15	2	5	5	450	30	75	75	0	75	0	0	75	75	0	0	0	0
7	50414	5	14	-	5	1	500	33.3	62.5	62.5	0	70	50	60	62.5	62.5	0	0	0	0
8	50416	6	26	-	2	-	640	35	80	80	0	80	80	80	80	0	0	0	0	0
9	50429	5	12	1	5	4	400	33.3	64	80	0	32	32	32	64	64	0	0	0	0
10	50438	7	20	1	5	-	800	40	80	65	0	165	100	80	80	65	0	0	0	0
11	50448	6	20	5	4	6	800	40	100	100	0	100	100	100	100	100	0	0	0	0
12	50450	5	15	2	3	5	600	40	75	75	0	75	75	75	75	75	0	0	0	0
13	50459	10	24	-	2	1	1000	41.6	120	160	0	120	80	80	120	160	0	0	0	0
14	50475	4	15	2	3	2	450	30	60	80	0	60	0	50	60	80	0	0	0	0
15	50476	10	22	8	7	2	500	22.7	125	125	0	0	0	0	125	125	0	0	0	0
16	50489	8	19	-	1	-	800	42	120	120	0	80	80	80	120	120	0	0	0	0
17	50490	10	33	5	2	2	1000	30	160	160	0	0	0	0	160	160	0	0	160	160
18	50497	3	13	1	3	2	500	38.5	80	80	0	80	0	0	80	80	0	0	0	0
19	50498	6	15	8	5	2	600	40	100	100	0	60	40	40	100	100	0	0	0	0
20	50504	4	18	7	3	5	660	35	100	100	0	100	60	60	60	60	0	0	0	0
21	50517	5	16	3	4	3	600	37	160	200	0	80	40	40	0	0	0	0	0	0
22	50539	6	21	2	5	3	800	38	160	160	0	160	80	80	0	0	0	0	0	0
23	50542	5	20	6	5	1	800	40	160	160	0	160	80	80	0	0	0	0	0	0
24	50548	4	16	6	7	5	640	40	160	160	0	100	0	0	60	60	0	0	0	0
25	50561	6	17	1	-	1	400	23.5	160	0	0	0	80	80	0	0	0	0	0	0
26	50589	5	16	1	4	3	640	40	160	80	0	160	0	0	80	80	0	0	0	0
27	50609	4	16	1	1	3	720	45	120	120	0	80	60	60	100	100	0	0	0	0
28	50637	6	17	2	3	6	770	45	100	125	0	80	80	80	100	125	0	0	0	0
29	50703	6	20	2	4	4	800	40	150	250	0	200	0	0	0	0	0	0	0	0
30	50714	10	20	6	6	5	800	40	200	200	0	100	0	0	100	100	0	0	0	0
31	50718	4	17	2	4	7	400	23	200	200	0	0	0	0	0	0	0	0	0	0
32	50726	6	20	5	5	7	800	40	150	250	0	100	0	0	100	100	0	0	0	0
33	50730	5	16	5	4	6	640	40	200	100	0	150	0	0	100	100	0	0	0	0
34	50733	7	20	5	3	3	800	40	150	300	0	0	100	100	0	0	0	0	0	0
35	50743	6	17	5	5	5	680	40	300	180	0	0	0	0	100	100	0	0	0	0
36	50761	6	16	6	5	1	640	40	100	150	0	90	0	0	100	100	0	0	0	0
37	50766	3	14	4	10	4	450	32	150	120	0	0	0	0	100	80	0	0	0	0
38	50785	3	14	6	5	6	560	40	260	100	0	100	0	0	0	0	0	0	0	0
39	50812	7	19	1	1	1	600	30	300	300	0	0	0	0	0	0	0	0	0	0
40	50815	5	19	1	3	5	500	26	250	250	0	0	0	0	0	0	0	0	0	0
41	50825	7	19	1	-	5	500	25	300	200	0	0	0	0	0	0	0	0	0	0
42	50837	5	17	3	5	2	550	32	200	150	0	0	0	0	100	100	0	0	0	0
43	50898	7	14	5	10	5	560	40	260	200	0	0	0	0	100	0	0	0	0	0
MW		6	18																	

Tabelle E.7: Personenbasisdaten, Anzahl vollständiger Schritte, bei denen die beiden zugehörigen Körperseiten vorhanden sind sowie Botulinum-Toxin-Dosierung. Abkürzungen: Gw=Gewicht (kg), Al=Alter (Jahren), Dos=Dosierung insgesamt (Units), reDo=relative Dosierung (Units/kg Körpergewicht), r=rechts, l=Links, G=Gastroc, S=Soleus, I=Ischios, Re=Rectus, A=Adductor, La=Lateralis, M=Medialis T=Tib Post, z.B.: rILa=rechte Seite, Ischios Lateralis

## E.3 SCI-Daten

Die Variabilität der Experteneinschätzung zeigt Abbildung E.7 links. Hierbei sind für 23 SCI,PRE Patienten die formalisierten Einschätzungen von drei Experten VAS A, VAS B, VAS C und der daraus berechnete Mittelwert VAS M (Visuelle Analogskala, Wertebereich von Null bis Zehn) aufgetragen.

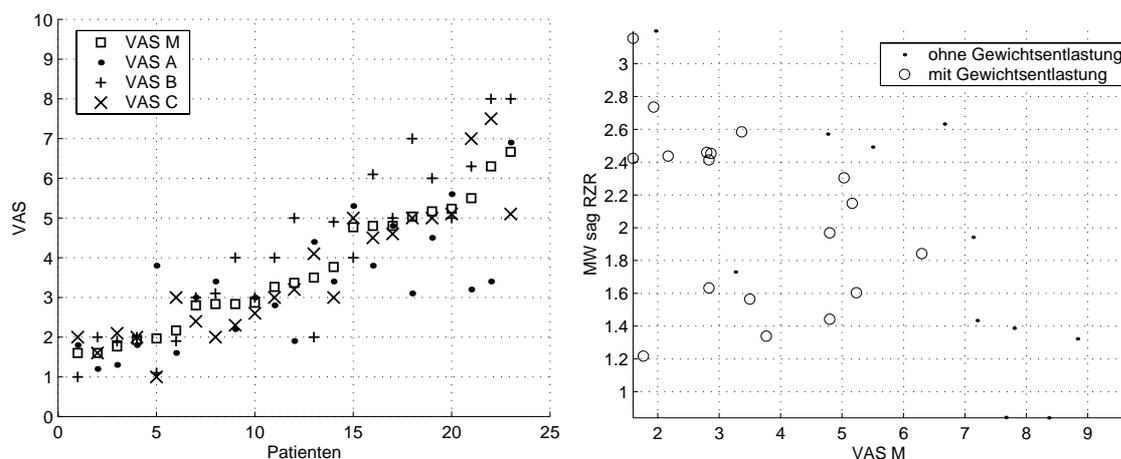


Abbildung E.7: VAS Einschätzungen (sortiert nach aufsteigendem VAS M) der Experten ( $\cdot$ ,  $+$ ,  $\times$ ) und Mittelwert ( $\square$ ) über den 23 Patienten zum PRE-Zustand (links). Gangqualität „MW sag RZR“ über gemittelte Experteneinschätzung VAS M (rechts).

Abbildung E.7 rechts zeigt die quantitative Gangqualität „MW sag RZR“ über der gemittelten Experteneinschätzung VAS M. Hierbei fällt auf, dass eine sehr hohe Korrelation  $|\rho| = 0.78$  zwischen den beiden Merkmalen bei Patienten ohne Gewichtsentlastung besteht. Bei den Patienten mit Gewichtsentlastung beträgt die Korrelation nur  $|\rho| = 0.40$ .

Tabelle E.8 zeigt ergänzende Angaben mit Korrelationen  $\rho > 0.7$  zwischen den Einzelmerkmalen aus den Tabellen 5.14 und 5.15.

Nr.	Einzelmerkmal	$\rho$
C1	MAX STRI Becken sag GZR	0.87 zu S7
C3	SpW STRI Becken fro OZR	0.72 zu S5
C4	MIN PSw Hüfte fro GZR	0.77 zu S5
C11	SpW ISw Hüfte sag OZR	0.88 zu S3
S2	SpW ST Hüfte sag OZR	0.71 zu C11
S3	MAX ISw Knie sag OZR	0.88 zu C11
S5	SpW STRI Hüfte fro OZR	0.77 zu C4
S7	SpW STRI Becken sag OZR	0.87 zu C1

Tabelle E.8: Korrelation zwischen Einzelmerkmalen.

# Literaturverzeichnis

- [1] *Otho Track 4.1 - Gait Analysis Software - Reference Manual*. MotionAnalysis, 1999.
- [2] *Pschyrembel Klinisches Wörterbuch*. de Gruyter, 2001.
- [3] ABEL, M., G. JUHL, C. VAUGHAN und D. DAMIANO: *Gait Assessment of Fixed Ankle-Foot Orthoses in Children with Spastic Diplegia*. Archives of Physical Medicine and Rehabilitation, 79:126–133, 1998.
- [4] ABEL, R., J. DIETERLE, A. ONASCH, T. LOOSE, M. SCHABLOWSKI, J. SCHWEIDLER, R. MIKUT und R. RUPP: *Quantifying Rehabilitation of Locomotor Skills in Incomplete Spinal Cord Injury*. Gait and Posture, 18, Suppl. 2:88–89, 2003.
- [5] ABEL, R., R. RUPP, A. SIEBEL, L. DÖDERLEIN, H.J. GERNER, R. MIKUT, N. PETER und G. BRETTHAUER: *Classification of Gait Analysis Data Using Fuzzy Logic Based Rule Generation and Multivariate Statistical Analysis*. Gait and Posture, 12(1):58 (Abstract ESMAC'2000, Lund), 2000.
- [6] ABEL, R., R. RUPP und D. SUTHERLAND: *Quantifying the Variability of a Complex Motor Task Specifically Studying the Gait of Dyskinetic CP Children*. Gait & Posture, 17:50–58, 2003.
- [7] ABEL, R., M. SCHABLOWSKI, R. RUPP und H.J. GERNER: *Gait Analysis on the Treadmill - Monitoring Exercise in the Treatment of Paraplegia*. Spinal Cord, 40:17–22, 2002.
- [8] ADLASSNIG, K.-P.: *Fuzzy Set Theory and Fuzzy Logic in Medicine*. In: *Proc. 7th Europ. Congr. on Intelligent Techniques and Soft Computing EUFIT'99, Sep. 13-16, 1999, Aachen*, 1999.
- [9] ANDRIACCHI, T. und D. HURWITZ: *Gait Biomechanics and the Evolution of Total Joint Replacement*. Gait and Posture, 5:256–264, 1997.

- 
- [10] BACHER, J.: *Clusteranalyse*. Oldenbourg Verlag, München, 1996.
- [11] BACKHAUS, K., B. ERICHSON, W. PLINKE und R. WEIBER: *Multivariate Analysemethoden: eine anwendungsorientierte Einführung*. Springer-Verlag, Berlin u.a., 2000.
- [12] BADDAR, A., K. GRANATA, D. DAMIANO, D. CARMINES, J. BLANCO und M. ABEL: *Ankle and Knee Coupling in Patients with Spastic Diplegia: Effects of Gastrocnemius-Soleus Lengthening*. *Journal of Bone Joint Surgery*, 84:736–744, 2002.
- [13] BARTEL, D.: *Analyse ausgewählter Einzelmerkmale in der Instrumentellen Ganganalyse, Praktikumsbericht*. Technischer Bericht, Institut für Angewandte Informatik, Forschungszentrum Karlsruhe, 2004.
- [14] BARTON, G.: *Interpretation of Gait Data Using Kohonen Neural Networks*. *Gait and Posture*, 10:85–86, 1999.
- [15] BARTON, G. und A. LEES: *An Application of Neural Networks for Distinguishing Gait Patterns on the Basis of Hip-Knee Joint Angle Diagrams*. *Gait and Posture*, 5:28–33, 1997.
- [16] BARTON, G., P. LISBOA und A. LEES: *Topological Clustering of Patients Using a Self Organising Neural Map*. *Gait and Posture*, 12:57, 2000.
- [17] BECKERS, D. und J. DECKERS: *Ganganalyse und Gangschulung*. Springer-Verlag, Berlin, Heidelberg, 1997.
- [18] BERTANI, A., A. CAPPELLO, M. G. BENEDETTI, L. SIMONCINI und F. CATTANI: *Flat Foot Functional Evaluation Using Pattern Recognition of Ground Reaction Data*. *Clinical Biomechanics*, 14:484–493, 1999.
- [19] BEZDEK, C.: *Fuzzy Models for Pattern Recognition : Methods That Search for Structures in Data*. IEEE Press, 1992.
- [20] BEZDEK, J.: *Pattern Recognition with Fuzzy Objective Function Algorithms*. Planum Press, New York and London, 1981.
- [21] BOCK, H. H.: *Automatische Klassifikation*. Vandenhoeck & Ruprecht, Göttingen, 1974.
- [22] BOCKLISCH, S.: *Prozeßanalyse mit unscharfen Verfahren*. VEB Verlag Technik, Berlin, 1987.

- [23] BONISSONE, P. und K. DECKER: *Selecting Uncertainty Calculi and Granularity: An Experiment in Trading-Off Precision and Complexity*. In: KANAL, L. N. und J. F. LEMMER (Herausgeber): *Uncertainty in Artificial Intelligence*, Seiten 217–247. North-Holland, Amsterdam, 1986.
- [24] BOUILLAND, S. und P. LOSLEVER: *Multiple Correspondence Analysis of Biomechanical Signals Characterized Through Fuzzy Histograms*. *Journal of Biomechanics*, 31:663–666, 1998.
- [25] BOWEN, T., N. LENNON, P. CASTAGNO, F. MILLER und J. RICHARDS: *Variability of Energy-Consumption Measures in Children with Cerebral Palsy*. *Journal of Pediatric Orthopaedics*, 18:738–742, 1998.
- [26] BOYD, R. und R. HAYS: *Current Evidence for the Use of Botulinum Toxin Type A in the Management of Children with Cerebral Palsy: A Systematic Review*. *European Journal of Neurology*, 8, Suppl. 5:1–20, 2001.
- [27] CAPI, G., Y. NASU, L. BAROLLI und K. MITOBE: *Real Time Gait Generation for Autonomous Humanoid Robots: A Case Study for Walking*. *Robotics and Autonomous Systems*, 42:107–116, 2003.
- [28] CHATFIELD, C.: *Analyse von Zeitreihen*. Hanser-Verlag, 1982.
- [29] CHATTERJEE, S. und B. PRICE: *Praxis der Regressionsanalyse*. Oldenbourg, München, Wien, 1995.
- [30] CHAU, T.: *A Review of Analytical Techniques for Gait Data*. *Gait and Posture*, 13:49–66 (Part 1); 102–120 (Part 2), 2001.
- [31] CIOS, K. (Herausgeber): *Medical Data Mining and Knowledge Discovery*, Band 60 der Reihe *Studies in Fuzziness and Soft Computing*. Physica-Verlag, 2001.
- [32] CROMMERT, H. VAN DE, T. MULDER und J. DUYSSENS: *Neural Control of Locomotion; Part 2: Sensory Control of the Central Pattern Generator and its Relation to Treadmill Training*. *Gait and Posture*, 7:251–263, 1998.
- [33] CURT, A., M. KECK und V. DIETZ: *Functional Outcome Following Spinal Cord Injury: Significance of Motor-Evoked Potentials and ASIA Scores*. *Archives of Physical Medicine and Rehabilitation*, 79:81–86, 1998.

- [34] DAMIANO, D., T. MARTELOTTA, D. SULLIVAN, K. GRANATA und M. ABEL: *Muscle Force Production and Functional Performance in Spastic Cerebral Palsy: Relationship of Cocontraction*. Archives of Physical Medicine and Rehabilitation, 81:895–900, 2000.
- [35] DAVIDS, J., A. BAGLEY und M. BRYAN: *Kinematic and Kinetic Analysis of Running in Children with Cerebral Palsy*. Developmental Medicine and Child Neurology, 40:528–535, 1998.
- [36] DAVIDS, J., T. FOTI, J. DABELSTEIN, D. BLACKHURST und A. BAGLEY: *Objective Assessment of Dyskinesia in Children with Cerebral Palsy*. Journal of Pediatric Orthopaedics, 19:211–214, 1999.
- [37] DAVIS, R.: *Clinical Gait Analysis*. Proc IEEE Eng Med Bio, 7(3):35–40, 1988.
- [38] DAVIS, R., S OUNPUU, D. TYBURSKI und J. GAGE: *A Gait Analysis Data Collection And Reduction Technique*. Human Movement Science, 10(5):575–587, 1991.
- [39] DELUZIO, K., U. WYSS, P. COSTIGAN, C. SORBIE und B. ZEE: *Gait Assessment in Unicompartmental Knee Arthroplasty Patients: Principal Component Modelling of Gait Waveforms and Clinical Status*. Human Movement Science, 18:701–711, 1999.
- [40] DELUZIO, K., U. WYSS, B. ZEE, P. COSTIGAN und C. SORBIE: *Principal Component Models of Knee Kinematics and Kinetics: Normal Vs. Pathological Gait Patterns*. Human Movement Science, 16:201–218, 1997.
- [41] DIETERLE, J., T. LOOSE, M. SCHABLOWSKI, R. MIKUT, R. RUPP und R. ABEL: *A New Measure for Assessing Gait Quality in SCI Patients with 3-D Gait Analysis*. Gait and Posture, 16, Supplement 1:138, 2002.
- [42] DIETZ, V. und J. DUYSSENS: *Significance of Load Receptor Input During Locomotion: A Review*. Gait and Posture, 111:102–110, 2000.
- [43] DITUNNO, J., P. DITUNNO, V. GRAZIANI, G. SCIVOLETTO, M. BERNARDI, V. CASTELLANO, M. MARCHETTI, H. BARBEAU, H. FRANKEL, J. D'ANDREA GREVE, H. KO, R. MARSHALL und P. NANCE: *Walking Index for Spinal Cord Injury (WISCI): An International Multicenter Validity and Reliability Study*. Spinal Cord, 38:234–243, 2000.
- [44] DITUNNO, P. und J. DITUNNO: *Walking Index for Spinal Cord Injury (WISCI II): Scale Revision*. Spinal Cord, 39 (12):654–656, 2001.

- [45] DUDA, R. und P. HART: *Pattern Classification and Scene Analysis*. Wiley-Interscience, 1973.
- [46] DUDA, R., P. HART und D. STORK: *Pattern Classification*. John Wiley & Sons, New York, 2001.
- [47] DUYSSENS, J. und H. VAN DE CROMMERT: *Neural Control of Locomotion; Part 1: The Central Pattern Generator from Cats to Humans*. Gait and Posture, 7:131–141, 1998.
- [48] EVERITT, B.: *Cluster Analysis*. John Wiley & Sons, 1974.
- [49] FELDKAMP, M.: *Ganganalyse bei Kindern mit zerebraler Bewegungsstörung*. Richard Pflaum Verlag KG München, 1979.
- [50] FONSECA, S., K. HOLT, E. SALTZMAN und L. FETTERS: *A Dynamical Model of Locomotion in Spastic Hemiplegic Cerebral Palsy: Influence of Walking Speed*. Clinical Biomechanics, 16:793–805, 2001.
- [51] GAGE, J.: *Gait Analysis in Cerebral Palsy*. London: Mac Keith Press; Oxford: Blackwell Scientific Publishers; New York: Cambridge University Press, 1991.
- [52] GAGE, J.: *Gait Analysis. An Essential Tool in Treatment of Cerebral Palsy*. Clinical Orthopaedics and Related Research, 288:126–134, 1993.
- [53] GAGE, J.: *Editorial: The Role of Gait Analysis in the Treatment of Cerebral Palsy*. Journal of Pediatric Orthopaedics, 14:701–702, 1994.
- [54] GAGE, J., P. DELUCA und T. RENSHAW: *Gait Analysis: Principles and Applications - Emphasis on its Use in Cerebral Palsy*. Journal of Bone and Joint Surgery, 77:1607–1623, 1995.
- [55] GAGE, J., P. DELUCA und T. RENSHAW: *Gait Analysis: Principles and Applications - Emphasis on its Use in Cerebral Palsy*. Instructional Course Lectures of the American Academy of Orthopaedic Surgeons, 45:491–508, 1996.
- [56] GERNER, H.J.: *Die Querschnittlähmung. Erstversorgung. Behandlungsstrategie. Rehabilitation*. Blackwell Wissenschafts-Verlag, 1992.
- [57] GERNER, H.J. und R. ABEL: *Rehabilitation nach Erkrankungen, Verletzungen und Operationen der Wirbelsäule*. In: Die Wirbelsäule, Thieme, 392–415, 2000.

- [58] GOODWIN, G. und K. SIN: *Adaptive Filtering, Prediction and Control*. Prentice Hall, Englewood Cliffs, NJ, 1984.
- [59] GRAHAM, H., K. AOKI, I. AUTTI-RÄMÖ, R. BOYD, M. DELGADO, D. GAEBLER-SPIRA, M. GORMLEYJR, B. GUYER, F. HEINEN, A. HOLTON, D. MATTHEWS, G. MOLENAERS, F. MOTTA, P. RUIZ und J. WISSEL: *Recommendations for the Use of Botulinum Toxin Type A in the Management of Cerebral Palsy*. *Gait and Posture*, 11:67–79, 2000.
- [60] GRANATA, K., M. ABEL und D. DAMIANO: *Joint Angular Velocity in Spastic Gait and the Influence of Muscle-Tendon Lengthening*. *Journal of Bone and Joint Surgery - A - American Volumes*, 82:174–186, 2000.
- [61] GÜNTHER, M.: *Computersimulationen zur Synthetisierung des muskulär erzeugten menschlichen Gehens unter Verwendung eines biomechanischen Mehrkörpermodells*. Doktorarbeit, Fakultät Physik der Eberhard-Karls-Universität zu Tübingen, 1997.
- [62] HARRIS, G. und P. SMITH: *Human Motion Analysis - Current Applications and Future Directions*. Design and Applications. IEEE Press, 445 Hoes Lane, P.O. Box 1331, Piscataway, NJ 08855-1331, 1996.
- [63] HARRIS, G. und J. WERTSCH: *Procedures for Gait Analysis*. *Archives of Physical Medicine and Rehabilitation*, 75:216–225, 1994.
- [64] HOLZREITER, S. und M. KOHLE: *Assessment of Gait Patterns Using Neural Networks*. *Journal of Biomechanics*, 26(6):645–651, Jun 1993.
- [65] HÖPPNER, F., F. KLAWONN und R. KRUSE: *Fuzzy-Clusteranalyse*. Vieweg, 1997.
- [66] HÖPPNER, F., F. KLAWONN, R. KRUSE und T. RUNKLER: *Fuzzy Cluster Analysis - Methods for Classification, Data Analysis and Image Recognition*. John Wiley & Sons, 1999.
- [67] HORAK, F.: *Clinical Assessment of Balance Disorders*. *Gait and Posture*, 6:76–84, 1997.
- [68] HUANG, P., C. HARRIS und M. NIXON: *Recognising humans by gait via parametric canonical space*. *Artificial Intelligence in Engineering*, 13:359–366, 1999.

- [69] ISMAIL, A. und S. ASFOUR: *Discrete Wavelet Transform: A Tool in Smoothing Kinematic Data*. Journal of Biomechanics, 32:317–321, 1999.
- [70] JAIN, A. und R. DUBES: *Algorithms for Clustering Data*. Prentice Hall, 1988.
- [71] JOHNSON, D., D. DAMIANO und M. ABEL: *The Evolution of Gait in Childhood and Adolescent Cerebral Palsy*. Journal of Pediatric Orthopaedics, 17:392–396, 1997.
- [72] KADABA, M., H. RAMAKRISHNAN und M. WOOTTEN: *Measurement of Lower Extremity Kinematics During Walking*. Journal of Orthopaedic Research, 8:383–392, 1990.
- [73] KADABA, M., H. RAMAKRISHNAN, M. WOOTTEN, J. GAINEY, G. GORTON und G. COCHRAN: *Repeatability of Kinematic, Kinetic, and Electromyographic Data in Normal Adult Gait*. Journal of Orthopaedic Research, Seiten 849–860, 1989.
- [74] KARLSSON, D. und R. TRANBERG: *On Skin Movement Artefact-Resonant Frequencies of Skin Markers Attached to the Leg*. Human Movement Science, 18:627–635, 1999.
- [75] KAUFMAN, K., H. CHAMBERS und D. SUTHERLAND: *Variability of Temporal Distance Measurements in Pathological Gait Studies*. Gait and Posture, 4:169, 1996.
- [76] KELLY, I., M. O'REGAN, A. JENKINSON und T. O'BRIAN: *The Quality Assessment of Walking in Cerebral Palsy*. Gait and Posture, 5:70–74, 1997.
- [77] KIRTLEY, C.: *Automated Diagnosis of Gait Abnormalities*. In: *Biomechanics of the Lower Limb in Health, Disease and Rehabilitation*, Seiten 152–154. University of Salford, UK, ISBN 0 902896 512, 2003.
- [78] KLAWONN, F.: *Visualisierung von Fuzzy-Clusteranalyse-Ergebnissen*. In: *Proc. 12. Workshop Fuzzy Systeme, Dortmund*, Seiten 1–12. Forschungszentrum Karlsruhe, FZKA 6767, 2002.
- [79] KLAWONN, F. und F. HÖPPNER: *An Alternative Approach to the Fuzzifier in Fuzzy Clustering to Obtain Better Clustering Results*. In: *3rd Eusflat. EUS-FLAT*, Seiten 730–734. Hochschule Zittau, 2003.

- [80] KLEISSEN, R., J. BUURKE, J. HARLAAR und G. ZILVOLD: *Electromyography in the Biomechanical Analysis of Human Movement and its Clinical Application*. Gait and Posture, 8:143 – 158, 1998.
- [81] KOMAN, L., A. BRASHEAR, S. ROSENFELD, H. CHAMBERS, B. RUSSMAN, M. RANG, L. ROOT, E. FERRARI, J. GARCIA DE YEBENES PROUS, B. SMITH, C. TURKEL, J. WALCOTT und P. MOLLOY: *Botulinum Toxin Type A Neuromuscular Blockade in the Treatment of Equinus Foot Deformity in Cerebral Palsy: A Multicenter, Open-Label Clinical Trial*. Pediatrics - English Edition, 108(5):1062–1071, 2001.
- [82] KONONENKO, I.: *Machine Learning for Medical Diagnosis: History, State of the Art and Perspective*. Artificial Intelligence in Medicine, 23:89–109, 2001.
- [83] KRONMÜLLER, H.: *Digitale Signalverarbeitung*. Springer-Verlag, 1991.
- [84] LAFUENTE, R., J. BELDA, J. SANCHEZ-LACUESTA, C. SOLER, R. POVEDA und J. PRAT: *Quantitative Assessment of Gait Deviation: Contribution to the Objective Measurement of Disability*. Gait and Posture, 11:191–198, 2000.
- [85] LAMOTH, C., P. BEEK und O. MEIJER: *Pelvis-Thorax Coordination in the Transverse Plane During Gait*. Gait and Posture, 16:101–114, 2002.
- [86] LEE, E., J. GOH und K. BOSE: *Value of Gait Analysis in the Assessment of Surgery in Cerebral Palsy*. Arch Phys Med Rehabil (United States), 73:642–646, 1992.
- [87] LENHOFF, M., T. SANTNER, J. OTIS, M. PETERSON, B. WILLIAMS und S. BACKUS: *Bootstrap Prediction and Confidence Bands: A Superior Statistical Method for Analysis of Gait Data*. Gait and Posture, 9:10–17, 1999.
- [88] LOOSE, T., J. DIETERLE, R. MIKUT, R. RUPP, R. ABEL, M. SCHABLOWSKI, G. BRETTHAUER und H.J. GERNER: *Automatisierte Interpretation von Zeitreihen am Beispiel von klinischen Bewegungsanalysen*. Automatisierungstechnik (at), 8:359–369, 2004.
- [89] LOOSE, T., J. JÄKEL und R. MIKUT: *Datenbasierte Generierung natürlicher Erklärungs-texte am Beispiel der Instrumentellen Ganganalyse*. In: *Proc. 12. Workshop Fuzzy Systeme, Dortmund*, Seiten 43–57. Forschungszentrum Karlsruhe, FZKA 6767, 2002.

- [90] LOOSE, T., H. MALBERG, R. MIKUT, J. DIETERLE, M. SCHABLOWSKI, S. WOLF, R. ABEL, L. DÖDERLEIN und R. RUPP: *Ein modulares Verfahren zur automatisierten Auswertung von Ganganalysedaten*. Biomedizinische Technik, 47, Ergänzungsband 1:700–703, 2002.
- [91] LOOSE, T., H. MALBERG, R. MIKUT, R. RUPP, J. SIMON, S. WOLF und L. DÖDERLEIN: *Quantitative Evaluation of CP Gait After Botulinum Toxin Therapy on the Basis of a Normalcy Measure*. Gait and Posture, 16, Suppl. 1:176–177, 2002.
- [92] LOOSE, T., R. MIKUT und G. BRETTHAUER: *Fuzzy-Clustering über simultan aufgezeichnete Ganganalyse-Zeitreihen*. In: *Proc. 13. Workshop Fuzzy Systeme, Dortmund*, Seiten 5–22. Forschungszentrum Karlsruhe, FZKA 6900, 2003.
- [93] LOOSE, T., R. MIKUT, J. DIETERLE, R. RUPP, R. ABEL, SCHABLOWSKI, M., H.J. GERNER und G. BRETTHAUER: *Automatisierte Bewegungscharakterisierung für Patienten mit inkompletter Querschnittlähmung*. In: *AUTOMED 2003, 4. Workshop*, Seiten 20–21. Forschungszentrum Karlsruhe, FZKA 6875, <http://bibliothek.fzk.de/zb/berichte/FZKA6875.pdf>, 2003.
- [94] LOOSE, T., R. MIKUT, H. MALBERG, J. SIMON, M. SCHABLOWSKI, R. RUPP und L. DÖDERLEIN: *A Computer Based Method to Assess Gait Data*. In: HUTTEN, H. und P. KRÖSL (Herausgeber): *IFMBE Proceedings, 2nd European Medical and Biological Engineering Conference, EMBEC'02 (ISSN 1680-0737, ISBN 3-901351-62-0)*, Seiten 798–799. International Federation for Medical and Biological Engineering, 2002.
- [95] LOOSE, T., R. MIKUT und R. RUPP: *Unsupervised and Supervised Learning of Fuzzy Algorithms to Analyse Kinematic Data*. In: *Biomechanics of the Lower Limb in Health, Disease and Rehabilitation*, Seiten 72–73. University of Salford, UK, ISBN 0 902896 512, 2003.
- [96] LOOSE, T., R. MIKUT, R. RUPP und M. SCHABLOWSKI: *GAIT-CAD - A Matlab Toolbox for Application of Data Mining Methods in Gait Analysis*. Gait and Posture, 18, Suppl. 2:114–115, 2003.
- [97] LOSLEVER, P. und F. BARBIER: *Multivariate Graphical Presentation for Gait Rehabilitation Study*. Gait and Posture, 7:39–44, 1998.
- [98] LOSLEVER, P. und S. BOUILLAND: *Marriage of Fuzzy Sets and Multiple Correspondence Analysis: Examples with Subjective Interval Data and Biomedical Signals*. Fuzzy Sets and Systems, 107:255–275, 1999.

- [99] LOSLEVER, P., E. LAASSEK und J.-C. ANGUE: *Combined Statistical Study of Joint Angles and Ground Reaction Forces Using Component and Multiple Correspondence Analysis*. IEEE Transactions on Biomedical Engineering, 41:1160–1167, 1994.
- [100] MACKINNON, C. und D. WINTER: *Control of Whole Body Balance in the Frontal Plane During Human Walking*. Journal of Biomechanics, 26:633–644, 1993. vorhanden.
- [101] MALL, V., F. HEINEN, J. KIRSCHNER, M. LINDER, S. STEIN, U. MICHAELIS, P. BERNIUS, M. LANE und R. KORINTHENBERG: *Evaluation of Botulinum Toxin A Therapy in Children with Adductor Spasm by Gross Motor Function Measure*. Journal of Child Neurology, 15:214–217, 2000.
- [102] MARGHITU, D. und P. NALLURI: *An Analysis of Greyhound Gait Using Wavelets*. Journal of Electromyography and Kinesiology, 7:203–212, 1997.
- [103] MAYAGOITIA, R., A. NENE und P. VELTINK: *Accelerometer and Rate Gyroscope Measurement of Kinematics: An Inexpensive Alternative to Optical Motion Analysis Systems*. Journal of Biomechanics, 35:537–542, 2002.
- [104] MCLACHLAN, G.: *Cluster Analysis and Related Techniques in Medical Research*. Statistical methods in Medical Research, 1:27–48, 1992.
- [105] MIKUT, R., J. JÄKEL und L. GRÖLL: *Automatic Design of Interpretable Membership Functions*. In: *Proc. 8th Zittau Fuzzy Colloquium*, Seiten 103–111. Hochschule Zittau/Görlitz, 2000.
- [106] MIKUT, R., J. JÄKEL, H. MALBERG und G. BRETTHAUER: *Datenbasierter Entwurf von Fuzzy-Systemen für medizinische Diagnoseaufgaben*. Automatisierungstechnik, 48(7):317–326, 2000.
- [107] MIKUT, R., T. LOOSE und J. JÄKEL: *Rule-Oriented Information Acquisition from Biological Time Series in Clinical Decision Making*. In: *Proc. 10th Zittau Fuzzy Colloquium*, Seiten 300–307. Hochschule Zittau/Görlitz, 2002.
- [108] MIKUT, R., H. MALBERG, N. PETER, J. JÄKEL, L. GRÖLL, G. BRETTHAUER, R. ABEL, L. DÖDERLEIN, R. RUPP, M. SCHABLOWSKI, A. SIEBEL und H.J. GERNER: *Diagnoseunterstützung für die Instrumentelle Ganganalyse (Projekt GANDI)*. Forschungszentrum Karlsruhe, FZKA 6613, <http://bibliothek.fzk.de/zb/berichte/FZKA6613.pdf>, 2001.

- [109] MORRIS, M., J. MCGINLEY, F. HUXHAN, J. COLLIER und I. IANSEK: *Constraints on the Kinetic, Kinematic and Spatiotemporal Parameters of Gait in Parkinson's Disease*. Human Movement Science, 18:461–483, 1999.
- [110] MULROY, S., J. GRONLEY, W. WEISS, C. NEWSAM und J. PERRY: *Use of Cluster Analysis for Gait Pattern Classification of Patients in the Early and Late Recovery Phases Following Stroke*. Gait and Posture, 18:114–125, 2003.
- [111] NOONAN, K., S. HALLIDAY, R. BROWNE, S. O'BRIEN, K. KAYES und J. FEINBERG: *Interobserver Variability of Gait Analysis in Patients with Cerebral Palsy*. Journal of Pediatric Orthopaedics, 23:279–287, 2003.
- [112] NOVACHEK, T.: *The Biomechanics of Running*. Gait and Posture, 7:77–95, 1998.
- [113] OBUSEK, J., K. HOLT und R. ROSENSTEIN: *The Hybrid Mass-Spring Pendulum Model of Human Leg Swinging: Stiffness in the Control of Cycle Period*. Biological Cybernetics, 73:139–147, 1995.
- [114] O'BYRNE, J., A. JENKINSON und T. O'BRIEN: *Quantitative Analysis and Classification of Gait Patterns in Cerebral Palsy Using a Three-Dimensional Motion Analyzer*. Journal of Child Neurology, 13:101–108, 1998.
- [115] OLNEY, S., M. GRIFFIN und I. MCBRIDE: *Multivariate Examination of Data From Gait Analysis of Persons With Stroke*. Physical Therapy, 78:814–828, 1998.
- [116] OLNEY, S. und C. RICHARDS: *Hemiparetic Gait Following Stroke*. Gait and Posture, 4:136–148 (Part 1), 149–162 (Part 2), 1996.
- [117] O'MALLEY, M.: *Normalization of Temporal-Distance Parameters in Pediatric Gait*. Journal of Biomechanics, Vol. 25, No. 5:619–625, 1996.
- [118] O'MALLEY, M., M. ABEL, D. DAMIANO und C. VAUGHAN: *Fuzzy Clustering of Children with Cerebral Palsy Based on Temporal-Distance Gait Parameters*. IEEE Transactions on Rehabilitation Engineering, Vol. 5, No. 4:300–309, 1997.
- [119] OUNPUU, S., R. DAVIS und P. DELUCA: *Joint Kinetics: Methods, Interpretation and Treatment Decision-Making in Children with Cerebral Palsy and Myelomeningocele*. Gait and Posture, 4:62–78, 1996.
- [120] PERRY, J.: *Gait Analysis. Normal and Pathological Function*. Slack Inc, Thorofare, 1992.

- [121] QUATRANO, L. und S. STANHOPE (Herausgeber): *Gait Analysis in Rehabilitation Medicine*, Arlington, Virginia, 26-28 September 1996. National Institute of Child Health and Human Development, NIH.
- [122] RENOUIJ, S. und C. WITTEMAN: *Talking Probabilities: Communicating Probabilistic Information with Words and Numbers*. *International Journal of Approximate Reasoning*, 22:169–194, 1999.
- [123] RICHARDS, G., V. RAYWARD-SMITH, P. SÖNKSEN, S. CAREY und C. WENG: *Data Mining for Indicators of Early Mortality in a Database of Clinical Records*. *Artificial Intelligence in Medicine*, 22:215–231, 2001.
- [124] RODDA, J., R. BAKER, M. GALEA und H. GRAHAM: *A New Biomechanical Classification of Sagittal Gait Patterns in Spastic Diplegia*. *Gait and Posture*, 16, Suppl. 1:S7–S8, 2002.
- [125] ROMEI, M., M. GALLI, F. MOTTA, M. SCHWARTZ und M. CRIVELLINI: *Use of the Normalcy Index for the Evaluation of Gait Pathology*. *Gait and Posture*, 19:85–90, 2004.
- [126] ROMKES, J. und R. BRUNNER: *Comparison of a Dynamic and a Hinged Ankle-foot Orthosis by Gait Analysis in Patients with Hemiplegic Cerebral Palsy*. *Gait and Posture*, 15:18–24, 2002.
- [127] RUPP, R., T. LOOSE, R. MIKUT, M. SCHABLOWSKI, J. DIETERLE, H.J. GERNER und G. BRETTHAUER: *Quantitative Bewertung von Gangqualität*. *Biomedizinische Technik - Biomedical Engineering*, 48, Ergänzungsband 1:294–295, 2003.
- [128] RUSSELL, D., L. AVERY, P. ROSENBAUM, P. RAINA, S. WALTER und R. PALISANO: *Improved Scaling of the Gross Motor Function Measure for Children with Cerebral Palsy: Evidence of Reliability and Validity*. *Physical Therapy*, 80:873–885, 2000.
- [129] SADEGHI, H., P. ALLARD, F. PRINCE und H. LABELLE: *Symmetry and Limb Dominance in Able-Bodied Gait: A Review*. *Gait and Posture*, 12:34–45, 2000.
- [130] SCHABLOWSKI, M., J. SCHWEIDLER und R. RUPP: *HeiDATAProVIT-Heidelberg Data Archiving, Tag Assembling, Processing and Visualization Tool*. *Computer Methods and Programs in Biomedicine*, 73:61–70, 2004.
- [131] SCHIEBL, F.: *Fuzzy-Bewegungsanalyse - die Analyse sportlicher Bewegungen auf der Basis unscharfer Mengen*. Verlag Karl Hofmann, Schorndorf, 2000.

- [132] SCHLITZGEN, R. und B. STREITBERG: *Zeitreihenanalyse, 9. Auflage*. Oldenbourg, München, Wien, 2001.
- [133] SCHMALZ, T., S. BLUMENTRITT und R. JARASCH: *Energy Expenditure and Biomechanical Characteristics of Lower Limb Amputee Gait: The Influence of Prosthetic Alignment and Different Prosthetic Components*. *Gait and Posture*, 16:255–263, 2002.
- [134] SCHNEIDER, E. und E. CHAO: *Fourier Analysis of Ground Reaction Forces in Normals and Patients with Knee Joint Disease*. *Journal of Biomechanics*, 16:591–601, 1983.
- [135] SCHÖLLHORN, W., B. NIGG, D. STEFANYSHYN und W. LIU: *Identification of Individual Walking Patterns Using Time Discrete and Time Continuous Data Sets*. *Gait and Posture*, 15:180–186, 2002.
- [136] SCHUTTE, L., U. NARAYANAN, J. STOUT, P. SELBER, J. GAGE und M. SCHATZ: *An Index for Quantifying Deviations from Normal Gait*. *Gait and Posture*, 11:25–31, 2000.
- [137] SEISING, R.: *Eine kleine Geschichte der Fuzzy-Systeme in der Medizin*. In: *Proc. 12. Workshop Fuzzy Systeme, Dortmund*, Seiten 27–42. Forschungszentrum Karlsruhe, FZKA 6767, 2002.
- [138] SELLES, R., J. BUSSMANN, R. WAGENAAR und H. STAM: *Comparing Predictive Validity of Four Ballistic Swing Phase Models of Human Walking*. *Journal of Biomechanics*, 34:1171–1177, 2001.
- [139] SHANNON, C.: *A Mathematical Theory of Communication*. *The Bell System Technical Journal*, 27:379–423, 1948.
- [140] SIMON, J., S. WOLF und L. DÖDERLEIN: *Gait Analysis of the Growing Foot*. *Gait and Posture*, 16, Suppl. 1:110, 2002.
- [141] SKAGGS, D., S. RETHLEFSEN, R. KAY, S. DENNIS, R. REYNOLDS und TOLO V.: *Variability in Gait Analysis Interpretation*. *Journal of Pediatric Orthopaedics*, 20:759–764, 2000.
- [142] SÖDERSTRÖM, T. und P. STOICA: *System Identification*. Prentice Hall, 1989.
- [143] STEINER, R.: *Attraktorregelung für die Fortbewegung einer simulierten zweibeinigen Laufmaschine in drei Dimensionen*. Doktorarbeit, Universität Düsseldorf, 1999.

- [144] STONE, J.: *Independent Component Analysis: An Introduction*. Trends in Cognitive Sciences, 6:59–64, 2002.
- [145] SU, F., W. WU, Y. CHENG und Y. CHOU: *Fuzzy Clustering of Gait Patterns of Patients After Ankle Arthrodesis Based on Kinematic Parameters*. Medical Engineering and Physics, 23:83–90, 2001.
- [146] SUTHERLAND, D.: *The Evolution of Clinical Gait Analysis*. Gait and Posture, Seiten 14: 61–70 (Part 1), 2001, 16: 159–179 (Part 2), 2002.
- [147] SUTHERLAND, D.: *Gait Disorders in Childhood and Adolescence*. Williams & Wilkins, 1984.
- [148] SUTHERLAND, D.: *The Development of Mature Gait*. Gait and Posture, 6:163–170, 1997.
- [149] SUTHERLAND, D.: *The Evolution of Clinical Gait Analysis: Part II Kinematics*. Gait and Posture, 16:159–179, 2002.
- [150] SUTHERLAND, D. und L. COOPER: *The Pathomechanics of Progressive Crouch Gait in Spastic Diplegia*. Orthopaedic Clinics of North America, 9:143–154, 1978.
- [151] SUTHERLAND, D. und J. DAVIDS: *Common Gait Abnormalities of the Knee in Cerebral Palsy*. Clinical Orthopaedics, 288:139–147, 1993.
- [152] SUTHERLAND, D., K. KAUFMAN, M. WYATT, H. CHAMBERS und S. MUBARAK: *Double-Blind Study of Botulinum A Toxin Injections Into the Gastrocnemius Muscle in Patients with Cerebral Palsy*. Gait and Posture, 10:1–9, 1999.
- [153] TAGAWA, Y., N. SHIBA, S. MATSUO und T. YAMASHITA: *Analysis of Human Abnormal Walking Using a Multi-Body Model: Joint Models for Abnormal Walking and Walking Aids to Reduce Compensatory Action*. Journal of Biomechanics, 33:1405–1414, 2000.
- [154] TAN, T., L. GUAN und J. BURNE: *A Real-Time Image Analysis System for Computer-Assisted Diagnosis of Neurological Disorders*. Real-Time Imaging, Vol. 5:253–269, 1999.
- [155] TATSUOKA, M. M.: *Multivariate Analysis*. Macmillan, New York, 1988.

- [156] THE MATHWORKS INC., Natick, Mass.: *MATLAB – The Language of Technical Computing. Using MATLAB*, 1999.
- [157] THOMAS, S., C. MOORE, C. KELP-LENANE und C. NORRIS: *Simulated Gait Patterns: The Resulting Effects on Gait Parameters, Dynamic Electromyography, Joint Moments, and Physiological Cost Index*. *Gait and Posture*, 4:100–107, 1996.
- [158] THOMPSON, N, R. BAKER, A. COSGROVE, I. CORRY und H. GRAHAM: *Musculoskeletal Modelling in Determining the Effect of Botulinum Toxin on the Hamstrings of Patients with Crouch Gait*. *Developmental Medicine and Child Neurology*, 40:622–625, 1998.
- [159] TINGLEY, M., C. WILSON, E. BIDEN und W. KNIGHT: *An Index to Quantify Normality of Gait in Young Children*. *Gait and Posture*, 16:149–158, 2002.
- [160] VAUGHAN, C.: *Theories of Bipedal Walking: An Odyssey*. *Journal of Biomechanics*, 36:513–523, 2003.
- [161] VAUGHAN, C., N. SUBRAMANIAN und M. BUSSE: *Selective Dorsal Rhizotomy as a Treatment Option for Children with Spastic Cerebral Palsy*. *Gait and Posture*, 8:43–59, 1998.
- [162] WALBRÖL, S.: *Überprüfung der Wertigkeit funktionsverbessernder Eingriffe beim erwachsenen Patienten mit Infantiler Zerebralparese unter Einsatz der Instrumentellen Ganganalyse*. Doktorarbeit, Orthopädische Universitätsklinik Heidelberg, 2000.
- [163] WATELAIN, E., F. BARBIER, P. ALLARD, A. THEVENON und J. ANGUE: *Gait Pattern Classification of Healthy Elderly Men Based on Biomechanical Data*. *Arch Phys Med Rehabil*, 81:579–586, 2000.
- [164] WATELAIN, E., J. FROGER, F. BARBIER, G. LENSEL, M. ROUSSEAU, F. LEPOUTRE und A. THEVENON: *Comparison of Clinical Gait Analysis Strategies by French Neurologists, Psychiatrists and Physiotherapists*. *Journal of Rehabilitation Medicine*, 35:8–14, 2003.
- [165] WATERS, R. und S. MULROY: *The Energy Expenditure of Normal and Pathologic Gait*. *Gait and Posture*, 9:207–231, 1999.
- [166] WEAVER, W. und C. E. SHANNON: *The Mathematical Theory of Communication*. Technischer Bericht, University of Illinois Press, 1949.

- [167] WEINTRAUB, M., T. BYLANDER und S. SIMON: *QUAWDS: A Composite Diagnostic System for Gait Analysis*. Computer Methods and Programs in Biomedicine, 32:91–106, 1990.
- [168] WERNER, M.: *Signale und Systeme. Lehr- und Arbeitsbuch*. Vieweg, Braunschweig, 2000.
- [169] WERNSTEDT, J.: *Experimentelle Prozeßanalyse*. Verlag Technik, Berlin, 1989.
- [170] WINDHAM, M.: *Cluster Validity for Fuzzy Clustering Algorithms*. Fuzzy Sets and Systems, 3:1–9, 1980.
- [171] WINTER, D.: *Biomechanics and Motor Control of Human Movements*. Wiley-Interscience, 1990.
- [172] WINTER, D.: *Human Balance and Posture Control During Standing and Walking*. Gait and Posture, 3:193–214, 1995.
- [173] WINTER, D. und P. ENG: *Kinetics: Our Window Into the Goals and Strategies of the Central Nervous System*. Behavioural Brain Research, 67(2):111–120, Mar 1995. Review.
- [174] WINTERS, T., J. GAGE und R. HICKS: *Gait Patterns in Spastic Hemiplegia in Children and Young Adults*. Journal of Bone and Joint Surgery, 69:437–441, 1987.
- [175] WOLF, S., R. RUPP, M. SCHABLOWSKI, L. DÖDERLEIN, T. LOOSE und R. MIKUT: *Automated Classification and Rule Extraction from the Gait Pattern of CP-Gait*. Gait and Posture, 18, Suppl. 2:118, 2003.
- [176] WONG, M., S. SIMON und R. OLSHEN: *Statistical Analysis of Gait Patterns of Persons with Cerebral Palsy*. Statistics in Medicine, 2:345–354, 1983.
- [177] WOODRUFF, S., C. BOTHWELL-MYERS, M. TINGLEY und W. ALBERT: *Gait Pattern Classification of Children with Developmental Coordination Disorder*. Adapted Physical Activity Quarterly, 19:378–391, 2002.
- [178] XIE, X. und G. BENI: *A Validity Measure for Fuzzy Clustering*. IEEE Trans. on Pattern Analysis and Machine Intelligence, 13:841–847, 1991.
- [179] YANG, T., R. CHAN, T. CHUANG, T. LIU und J. CHIU: *Treatment of Cerebral Palsy with Botulinum Toxin: Evaluation with Gross Motor Function Measure*. Journal of Formos Medical Association, 98:832–836, 1999.

- [180] ZADEH, L.: *Fuzzy Sets*. Information and Control, 8:338–353, 1965.
- [181] ZADEH, L. und J. KACPRZYK (Herausgeber): *Computing with Words in Information/Intelligent Systems, Vol. 1: Foundations, Vol. 2: Applications*. Physica-Verlag, Heidelberg, 2000.
- [182] ZANCHI, V., V. PAPIĆ und M. CECIC: *Quantitative Human Gait Analysis*. Simulation Practice and Theory, 8:127–140, 2000.