

Bewegungsintentionsschätzung auf Basis von Gelenkkoordination

Motion Intention Estimation Based on Interjoint Coordination

Heike Vallery und Martin Buss

Für die Gangrestitution halbseitig gelähmter Patienten durch motorisierte Orthesen, genauso wie für intelligente Prothesen, stellt die Koordinierung gesunder und robotisch unterstützter Gliedmaßen eine regelungstechnische Herausforderung dar. Der hier vorgeschlagene Ansatz verwendet die Methode der Hauptkomponentenanalyse, um die Kopplungen der Freiheitsgrade im gesunden menschlichen Gang zu analysieren. Auf Grundlage dieser statistischen Zusammenhänge werden in Echtzeit aus den Bewegungen des gesunden Beins passende Bewegungen für das kranke Bein geschätzt. So kann die Intention eines teilweise gelähmten oder beinamputierten Patienten aus seiner übrigen Körperbewegung abgeleitet werden, um die beeinträchtigten Glieder zu aktuierten oder zu überwachen. Um diesen Ansatz zu evaluieren, werden Simulationen mit aufgezeichneten Gangtrajektorien gesunder Probanden durchgeführt. Die Resultate dieser theoretischen Untersuchungen zeigen ein vielversprechendes Potential.

For the restitution of walking of a hemiplegic patient by means of a motorized orthosis, as well as in intelligent prosthetics, a major challenge is the coordination of healthy and robotically assisted limbs. The approach suggested here employs the method of Principal Components Analysis to first analyze the coupling of human joint motion in healthy subjects. Based on this knowledge, adequate motion for inoperable limbs in impaired patients is estimated on-line from sound limb motion. Thus, the intention of a partially paralyzed person or an amputee can be deduced from residual body motion, in order to coordinately actuate or supervise the impaired limbs. To evaluate the approach, simulations with recorded gait trajectories of healthy subjects are performed. The results of these theoretical investigations show a promising potential.

Schlagwörter: Intentionserkennung, Hauptkomponentenanalyse, Gangrehabilitation

Keywords: Intention detection, principal component analysis, gait rehabilitation

1 Einleitung

Zur Unterstützung und Wiederherstellung des menschlichen Gangs bei Lähmung oder nach Beinamputationen gibt es vielfältige robotische Hilfsmittel, wie z.B. die Gangrehabilitationsroboter Lokomat (Hokoma AG, Zürich) und LOPES [1], die mobile aktuierte Orthese HAL [2], oder die adaptiv gedämpfte Beinprothese C-Leg (Otto Bock AG, Duderstadt). Die regelungstechnische Herausforderung solcher Systeme besteht in der erforderlichen Kooperativität mit dem Patienten, dem idealerweise durch das technische Hilfsmittel lediglich assistiert wird bei der Ausführung der von ihm gewünschten Bewegung.

Teilweise ist es möglich, die Intention des Patienten aus eventuell vorhandener, allerdings unzureichender Muskelaktivität durch Beobachtung der erzeugten Bewegungen zu erkennen und zu verstärken, wie in [3] oder in [4] beschrieben. Dabei kann die Verstärkung von Willküraktivität mit zusätzlichen Informationen über ein normales Gangbild kombiniert werden. So schlägt z.B. [5] eine impedanzbasierte Trajektorienadaptation vor, die dem Patienten erlaubt, innerhalb variabler Grenzen von einer gegebenen physiologisch korrekten Referenztrajektorie abzuweichen. Dabei wird die Referenz allmählich an das individuelle Gangmuster des Patienten angepasst. Ein ähnlicher Ansatz besteht darin, die vom Gehirn an die Muskeln gesendeten Signale

mittels EMG zu messen, um die Bewegung dementsprechend zu unterstützen, wie z. B. in [27] realisiert.

Eine Alternative, falls die Erkennung der Bewegungsintention an den beeinträchtigten Gliedmaßen selbst nicht möglich ist, besteht in der Beobachtung der gesunden Körperteile, welche die Bewegungsintention des Patienten verraten können. So schlägt z. B. [6] vor, den Wunsch eines paraplegischen Patienten, aus sitzender Position aufzustehen, aus der Beschleunigung des Thorax abzuleiten.

In diesem Beitrag wird ein allgemeiner Ansatz vorgeschlagen, der Kopplungen zwischen Gliedmaßen im gesunden Gangbild automatisiert analysiert und daraus die beabsichtigte Bewegung ausgefallener Körperteile berechnet. Auch wenn sich die hier beschriebene Anwendung auf den menschlichen Gang konzentriert, kann dieser Grundgedanke auch auf andere synergetische Bewegungsmuster übertragen werden.

Ausgangspunkt der Methode sind Regelungsstrategien, die das menschliche Gehirn zur Bewältigung komplexer, erlernter Bewegungsmuster einsetzt [7–9]: Bei funktionellen Bewegungen wie Greifen oder Laufen sind die einzelnen Freiheitsgrade untereinander stark gekoppelt; diese linearen Abhängigkeiten werden auch als „Synergien“ bezeichnet. Diese Beobachtung legt die Vermutung einer reduzierten Anzahl von Stellgrößen nahe. Offenbar hat das menschliche Gehirn solch ausgefeilte Methoden zur Behandlung der Redundanz oder „Abundanz“ [10] des Bewegungsapparats (zuerst beschrieben von [11] als „*Motor Equivalence*“) entwickelt. Ein Mittel zur Analyse der Kopplungen bietet die statistische Methode der Hauptkomponentenanalyse [12; 13]: Die Bewegungsvariablen werden dadurch in einen niedriger dimensionalen Raum dominanter Linearkombinationen komprimiert, welche hypothetisch als Rekonstruktion der Stellgrößen interpretiert werden können.

Die tatsächlich zugrunde liegenden Stellgrößen und die Art und Weise, wie sie im zentralen Nervensystem generiert werden, bleiben jedoch höchst spekulativ. Einige sind überzeugt von der Existenz eines zentralen Mustergenerators (*Central Pattern Generator*, CPG) im menschlichen Rückenmark [14], wie er in Tieren gefunden werden kann [15]. Die Mechanismen menschlicher Bewegungssynergien scheinen jedoch nicht unveränderlich zu sein, sondern sind adaptiv, wie von [10] gezeigt: Patienten mit teilweise gelähmten Armen zeigen noch immer synergetisches Greifen, jedoch mit veränderten Synergiemustern. Dies bedeutet, dass noch immer Kopplungen aktiv sind, dass diese jedoch neu erlernt worden sind, angepasst an die neuen, krankheitsbedingten Einschränkungen.

Die Erkenntnisse über menschliche Bewegungskoordination motivierten die Idee, die Kopplungen zur Generierung menschenähnlicher Bewegungsmuster zu verwenden [16], und resultierten in mehreren Ansätzen automatisierter Gangmustergenerierung mithilfe einer reduzierten Menge von Regelvariablen, sei es für Animationszwecke [17; 18], zur Bewegungsanalyse [19] oder für Laufro-

boter [20; 21]. In [22] wird beispielsweise ein Laufroboter mit CPG vorgestellt.

Die in diesem Beitrag vorgestellte Methode nutzt die Forschungsergebnisse über Gelenkkopplungen zur Bewegungsintentionsschätzung, z. B. für Anwendungen in der Gangrehabilitation oder Prothetik. Basierend auf der beschriebenen Hypothese gemeinsamer Stellgrößen wird durch die Analyse gesunder Gangmuster eine Abbildungsmatrix bestimmt, die instantan den Zuständen eines Beins (Winkel und Winkelgeschwindigkeiten) passende Zustände des kontralateralen Beins zuordnet. Mit Hilfe einer solchen Abbildungsmatrix kann dann bei einem halbseitig gelähmten (hemiplegischen) oder amputierten Patienten die gewünschte Bewegung des beeinträchtigten Beins durch Beobachtung des anderen geschätzt werden. Voraussetzung für dieses Vorgehen ist die Ähnlichkeit der Kopplungen der Referenzperson und des Patienten. Da die Winkelverläufe der einzelnen Gelenke für die gleiche auf die Hüfthöhe normierte Geschwindigkeit z. B. für alle Männer sehr ähnlich sind, wie in [23] dargestellt, wird auch eine starke interpersonelle Ähnlichkeit der Synergien vermutet.

Zunächst wird das Konzept der Bewegungsintentionsschätzung vorgestellt, welche auf Hauptkomponentenanalyse in Verbindung mit einem Kalman-Filter basiert. Dann wird diese Methode anhand der Beispielanwendung der Gangrehabilitation simulativ evaluiert. In den Simulationen wird der Vorteil einer Berücksichtigung von Zeitableitungen, d. h. Winkelgeschwindigkeiten, gegenüber der sonst üblichen Kopplungsanalyse nur auf Basis von Winkeln oder Positionen analysiert. Zudem wird untersucht, inwiefern eine zusätzliche Segmentierung des Gangzyklus' in Stand und Schwung mit separater Betrachtung der Kopplungen eine weitere Verbesserung der Schätzung bewirkt. Zuletzt wird der Fragestellung nach interpersoneller Übertragbarkeit nachgegangen, d. h. wie gut die Intentionsschätzung auf Basis eines fremden Gangmusters funktioniert.

2 Bewegungsintentionsschätzung

Als Grundlage werden dominante Kopplungen der Bewegungsvariablen, d. h. von Winkeln, Geschwindigkeiten und Beschleunigungen beider Beine, aus den Gangmustern gesunder Probanden extrahiert. Aus diesen Kopplungen wird eine Funktion abgeleitet, die den Bewegungen eines Teils der Gliedmaßen die geschätzte Bewegung der übrigen Gliedmaßen (z. B. eines gelähmten Beins) zuordnet. Die Information in den geschätzten Werten von Winkeln und zeitlichen Ableitungen wird danach mit Hilfe eines Kalman-Filters stochastisch optimal kombiniert.

2.1 Extraktion von Gelenkkopplungen

Die Hauptkomponentenanalyse (*Principal Components Analysis*, PCA) [12; 13] ist eine allgemeine Methode zur Datenreduktion unter Ausnutzung statistischer (linearer) Verwandtschaften. Wenn n Messwerte des d -Tupels $\mathbf{x}^T = (x_1 \dots x_d)$ gegeben sind, und lineare Korrelationen

zwischen den Komponenten x_i vorliegen, kann durch eine geeignete Transformation in einen Raum der niedrigeren Dimension $p < d$ eine optimale Datenkompression durchgeführt werden.

Gesucht ist hierfür diejenige Abbildungsmatrix $\Gamma \in \mathbb{R}^{d \times p}$, die den Informationsverlust durch die Kompression in die neuen Koordinaten y und somit den quadratischen Fehler

$$\|x - \Gamma y\|^2 \tag{1}$$

minimiert. Die Lösung dieses Optimierungsproblems, d. h. die optimale Matrix Γ , besteht aus den $d - p$ ersten Eigenvektoren der Kovarianzmatrix M . Üblicherweise werden als erste Eigenvektoren die mit den höchsten zugehörigen Eigenwerten bezeichnet. Die Einträge der symmetrischen Kovarianzmatrix berechnen sich aus den Daten x zu:

$$M_{ij} = \frac{\sum_{k=1}^n (x_{i,k} x_{j,k})}{n - 1} . \tag{2}$$

Es handelt sich hierbei um eine orthogonale Transformation unter Vernachlässigung der Richtungen mit geringster Datenvarianz.

Für die Anwendung von PCA müssen die Daten x_i mittelwertfrei sein, was eventuell eine vorherige Subtraktion des Mittelwerts erfordert. Zudem ist es ratsam, die Daten zu normieren (im vorliegenden Fall auf eine Standardabweichung von 1), da PCA sehr sensitiv auf relative Skalierung reagiert.

Die Anzahl der Eigenvektoren in Γ kann auf Basis des kumulativen Anteils ihrer Eigenwerte an der Summe aller Eigenwerte gewählt werden. Dieser Prozentsatz liefert einen Schätzwert dafür, wieviel Information während der Reduktion beibehalten wird.

Mit Kenntnis der dominanten Kopplungen können inkomplette Messdaten vervollständigt werden: Das überbestimmte Gleichungssystem

$$x = \Gamma y \tag{3}$$

(mit Γ bekannt aus früheren Messungen) kann zur Berechnung einer Anzahl q fehlender Messwerte in x verwendet werden, falls die Anzahl $d - q$ bekannter Komponenten mindestens gleich der Dimension p von y ist. Mit bekannten Komponenten $x_1 \in \mathbb{R}^{(d-q)}$ von x und unbekanntem Komponenten $x_2 \in \mathbb{R}^q$ spaltet sich (3) auf in

$$\begin{aligned} x_1 &= \Gamma_1 y \\ x_2 &= \Gamma_2 y , \end{aligned} \tag{4}$$

mit $\Gamma_1 \in \mathbb{R}^{(d-q) \times p}$ und $\Gamma_2 \in \mathbb{R}^{q \times p}$ als korrespondierenden Untermatrizen von Γ . Durch Minimierung des quadratischen Fehlers

$$\|x_1 - \Gamma_1 y\|^2 \tag{5}$$

wird x_2 aus x_1 rekonstruiert durch

$$x_2 = \Gamma_2 \Gamma_1^\square x_1 , \tag{6}$$

mit Γ_1^\square als linker Pseudoinverser von Γ_1 :

$$\Gamma_1^\square = (\Gamma_1^T \Gamma_1)^{-1} \Gamma_1^T . \tag{7}$$

Für die Bewegungsintentionsschätzung bei teilweise gelähmten Patienten oder Amputierten sind die „bekannten“ Dateneinträge x_1 die Bewegungen gesunder Glieder, während die „fehlenden“ Einträge x_2 die Bewegungen der beeinträchtigten oder fehlenden Glieder darstellen.

Der Vektor x enthält dann die aktuellen Gelenkwinkel und (optional) deren erste und zweite Ableitungen:

$$x^T = ((\varphi^T)_n, (\dot{\varphi}^T)_n, (\ddot{\varphi}^T)_n) . \tag{8}$$

Der Index n verweist auf die Normierung aller Variablen auf Standardabweichung 1 und Bereinigung der Winkel von ihrem Mittelwert (Die Ableitungen sind naturgemäß mittelwertfrei). Für eine erste einfache Anwendung auf den menschlichen Gang wird zunächst die sagittale Ebene betrachtet, und hierin die Flexions-/Extensionsbewegung von Hüfte und Knie beider Beine. Die verwendeten Winkelkonventionen zeigt das Bild 1.




Bild 1: Winkelkonventionen.

Der Vorteil der Einbeziehung von Zeitableitungen (Geschwindigkeiten und Beschleunigungen) liegt in der Erweiterung der ansonsten rein statischen PCA um eine dynamische Dimension. Es können somit mehr Informationen über das Systemverhalten integriert werden, weshalb eine bessere Datenrekonstruktion zu erwarten ist.

Zunächst werden die Gelenksynergien aus aufgezeichneten Trajektorien gesunder Probanden extrahiert. Diese Analyse liefert die Kopplungsmatrix Γ .

Mit bekanntem Γ generiert die Bewegungsintentionsschätzung Sollbewegungen für ausgefallene Gliedmaßen eines Patienten. Als Eingangswerte dienen die aktuellen Bewegungen der gesunden Gliedmaßen: Zu jedem Abtastzeitpunkt wird x_2 aus x_1 mit Hilfe von Gl. (6) geschätzt. Diese Werte werden wieder um Mittelwert und Standardabweichung erweitert und ergeben so für jedes Gelenk die geschätzten Werte Winkel φ_g , Geschwindigkeit $\dot{\varphi}_g$ und Beschleunigung $\ddot{\varphi}_g$.

Wie zuvor erläutert, darf die Matrix Γ bei q unbekanntem Koordinaten des Vektors x maximal $d - q$ Eigenvektoren enthalten. Diese Bedingung ist allerdings vermutlich erfüllt, da beim menschlichen Gang in der Regel über 90% der Bewegungsinformation in den ersten Eigenvektoren enthalten ist [8; 19].

Anmerkung: Im Gegensatz zur statistischen Regression mit Hilfe des standardmäßig verwendeten besten linearen erwartungstreuen Schätzers (BLES) wird hier nicht direkt

von einem Bein auf das andere geschlossen, sondern der „Umweg“ über einen niedriger dimensional Raum gewählt. Dieses Vorgehen basiert auf der Hypothese, dass synergetischen Bewegungen ein reduzierter Satz Steuervariablen y zugrunde liegt, welche die Intention des Patienten beinhalten, sowie dem Ziel, diese Intention zu vervollständigen.

2.2 Kombination dynamischer Information durch Kalman-Filterung

Werden für die Rekonstruktion auch Zeitableitungen berücksichtigt, so sind die berechneten Variablen theoretisch redundant: Beschleunigungen, Geschwindigkeiten und Winkel werden geschätzt. Da die Schätzung jedoch mit Unsicherheiten behaftet ist und zudem keine Zusammenhänge zwischen den Ableitungen einer Variablen berücksichtigt, sind diese untereinander nicht notwendigerweise kohärent. Durch Verwendung eines Kalman-Filters kann die Redundanz dazu verwendet werden, die Informationen der einzelnen Ableitungen zu kombinieren und durch stochastische Optimierung die Qualität der Schätzung zu verbessern. Darüber hinaus werden die geschätzten Trajektorien geglättet.

Für jedes Gelenk wird ein separates Filter entworfen, welches auf einem einfachen Doppelintegrator-Modell basiert. Durch die Filterung werden alle Werte so korrigiert, dass sie dem Modell entsprechen und somit kohärent werden. Unter der Annahme, dass die Fehler in den PCA-geschätzten Variablen φ_g , $\dot{\varphi}_g$ und $\ddot{\varphi}_g$ als unkorreliertes Rauschen modelliert werden können, werden verbesserte, stochastisch optimale Schätzwerte $\hat{\varphi}$, $\hat{\dot{\varphi}}$ und $\hat{\ddot{\varphi}}$ generiert. Der Entwurf ist in Bild 2 dargestellt. Um die Unsicherheiten in den einzelnen Zeitableitungen, d. h. $E(w^2)$ (Beschleunigung), $E(v_2^2)$ (Geschwindigkeit) und $E(v_1^2)$ (Winkel) zu bestimmen, werden die jeweiligen Abweichungen rekonstruierter Trajektorien von den Originaldaten analysiert. Das Filter kann auch verwendet werden, falls keine Beschleunigungen berücksichtigt werden. In diesem Fall wird der Beschleunigungseingang zu Null gesetzt und die Unsicherheit gleich der Standardabweichung der Beschleunigung gewählt.

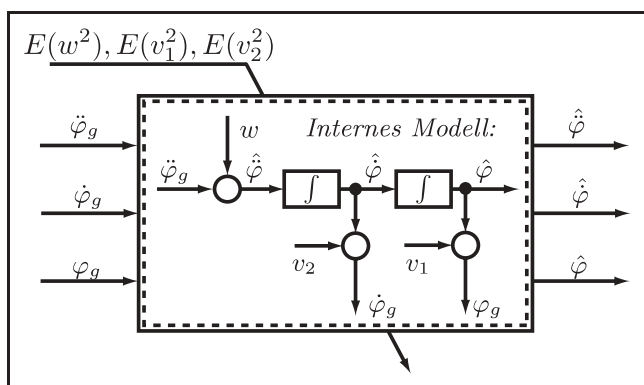


Bild 2: Entwurf des Kalman-Filters. Auf Basis eines internen Modells korrigiert das Filter die unsicherheitsbehafteten und nicht kohärenten Werte φ_g , $\dot{\varphi}_g$, $\ddot{\varphi}_g$, die aus der PCA-Schätzung resultieren, und liefert stochastisch optimale, verbesserte Werte $\hat{\varphi}$, $\hat{\dot{\varphi}}$, und $\hat{\ddot{\varphi}}$.

3 Anwendung: Gangrehabilitation bei Halbseitenlähmung

Anhand des Beispiels der Gangrehabilitation halbseitig gelähmter Patienten wird die Anwendung des beschriebenen Algorithmus illustriert und drei verschiedene Gesichtspunkte genauer untersucht: Die Verbesserung durch die vorgeschlagene Einbeziehung von Zeitableitungen kombiniert mit Kalman-Filterung, eine Variation des Algorithmus durch Splittung in Schwung- und Standphase, sowie die Übertragbarkeit von Gangmustern zwischen verschiedenen Personen.

3.1 Vorgehensweise

Für eine simulative Evaluierung werden aufgezeichnete Gangtrajektorien gesunder Probanden verwendet. Zunächst werden die Gelenkkopplungen im Gang analysiert. Anschließend wird eine halbseitige Lähmung simuliert, indem die Bewegungsdaten eines Beins aus den Daten entfernt werden. Diese Bewegung wird dann – mithilfe der Kopplungen – ausgehend vom „gesunden“ Bein rekonstruiert und zur Evaluierung wieder mit dem ursprünglichen originalen Bewegungsmuster verglichen.

Die Trajektorien, die in allen Simulationen verwendet wurden, entstammen der Carnegie Mellon Database¹. Für diese Analyse werden 10 gesunde männliche Probanden berücksichtigt (Datenbanknummern 2, 6, 7, 8, 16, 35, 38, 39, 43 und 55). Diese Probanden unterscheiden sich stark in Alter, Körperbau und -größe und gehen auch mit unterschiedlichen auf die Hüfthöhe normierten Geschwindigkeiten (zwischen 1,5 bis 2,1 /s). Für eine weibliche Vergleichsgruppe fehlen ausreichend viele Datensätze. Geschwindigkeiten und Beschleunigungen müssen aus den Winkeln durch Differentiation in Kombination mit phasenloser Filterung bestimmt werden. Aus den Gangmustern aller Probanden werden dann die statistischen Eigenschaften (Standardabweichungen und Mittelwerte) und die Eigenvektoren extrahiert.

3.2 Verwendung von Zeitableitungen

Um eine Rekonstruktion fehlender Daten zu ermöglichen, müssen, wie in Abschnitt 2.1 dargestellt, Eigenvektoren weggelassen werden. Um den Informationsgehalt der verbleibenden ersten Eigenvektoren abzuschätzen, wird für jeden Probanden der kumulative Anteil der Eigenwerte an der Gesamtsumme der Eigenwerte berechnet. Dieser entspricht dem Anteil an erklärter Varianz in den Daten. Diese Anteile werden über alle zehn Probanden gemittelt. Werden ausschließlich Winkel verwendet, so werden 3 der 4 Eigenvektoren benötigt, um einen Anteil von mindestens 95% der Varianz zu erklären. Damit ist das Gleichungssystem aus Gl. (3) jedoch einfach unterbestimmt. Es können daher höchstens zwei Eigenvektoren verwendet werden, die zusammen lediglich einen Anteil von 78,4% erklären. Werden auch Geschwindigkeiten einbezogen, so können die

¹ (<http://mocap.cs.cmu.edu>)

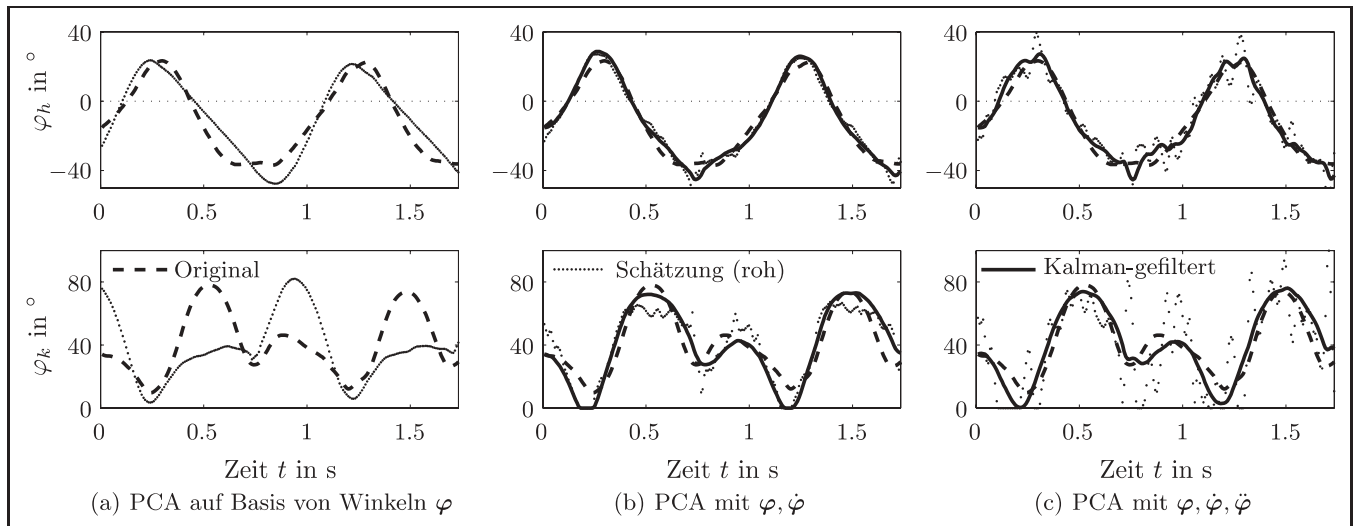


Bild 3: Rekonstruierte Werte für Hüft- und Kniewinkel φ_h bzw. φ_k in der sagittalen Ebene mit und ohne Einbeziehung von Zeitableitungen im Vergleich zu den originalen Trajektorien. Dargestellt sind die Rekonstruktionen basierend auf Winkeln (a), Winkeln und Winkelgeschwindigkeiten (b), Winkeln, Geschwindigkeiten und Beschleunigungen (c). Dabei sind die Anzahlen der jeweils verwendeten Eigenvektoren (von links nach rechts): 2, 4 und 6. Wenn Zeitableitungen einbezogen werden, resultieren auch (hier nicht dargestellt) Schätzwerte für Geschwindigkeiten und Beschleunigungen. Die Informationsgehalte der geschätzten Winkel und der Ableitungen werden durch ein Kalman-Filter stochastisch optimal kombiniert.

ersten 4 der 8 Eigenvektoren über 95% der Varianz erklären. Das Gleichungssystem für die Bestimmung der Winkel und der Geschwindigkeiten des kranken Beins ist mit diesen 4 Eigenvektoren eindeutig bestimmt. Bei Einbeziehung der Beschleunigungen reichen 6 der 12 Vektoren für 95% Informationsgehalt aus, das resultierende Gleichungssystem ist damit ebenfalls bestimmt.

Diese Ergebnisse zum Informationsgehalt der Eigenvektoren legen, zusätzlich zu den in Abschnitt 2.2 aufgeführten Argumenten, die Erwartung nahe, dass die Schätzung sich durch Berücksichtigung von Zeitableitungen verbessert. In Bild 3 ist der geschätzte Hüft- und Kniewinkelverlauf eines Probanden dargestellt, wie er sich mit Winkelinformationen allein bzw. in Kombination mit Ableitungen bestimmen lässt. Wie erwartet führt die Berücksichtigung von Geschwindigkeiten zu einem deutlich verbesserten Rekonstruktionserfolg. Allerdings muss dafür verstärktes Rauschen der rekonstruierten Trajektorie in Kauf genommen werden. Die Einbeziehung von Beschleunigungen erzielt, wie in Bild 3c) erkennbar ist, nur noch geringfügige weitere Verbesserung, demgegenüber steht weiter verstärktes Rauschen. Dies ist vermutlich verursacht durch die zweifache Differentiation; im Folgenden werden daher nur Winkel und Geschwindigkeiten verwendet. Darüber hinaus ist in Bild 3b) und c) auch die deutliche qualitative Verbesserung der Schätzung durch das Kalman-Filter zu erkennen, sowie die durch das Filter erzielte Glättung. Dieses vereint wie beschrieben die Informationen aus Winkeln, Geschwindigkeiten und eventuell Beschleunigungen und liefert so plausiblere Ergebnisse.

3.3 Segmentierung in Stand und Schwung

Bisher wurde das gesamte Gangbild als eine Einheit analysiert und zur Schätzung verwendet. Während des Gehens

ergeben sich jedoch völlig andere dynamische Konfigurationen, je nachdem, welches Bein sich in Kontakt mit dem Boden befindet. Ausgehend von der Vermutung, dass auch die Regelungsstrategien des Gehirns den unterschiedlichen Gegebenheiten angepasst sind, wird nun eine getrennte Kopplungsanalyse für Stand- und Schwungphase vorgestellt (Die Phasenbezeichnung bezieht sich hier auf das kranke Bein). In Bild 4 ist die Verbesserung der Rekonstruktion gegenüber der nicht unterteilten Analyse in der Simulation zu erkennen.

Dennoch ist diese Verbesserung kritisch zu betrachten: Sie verlangt eine Umschaltung während des Übergangs von einer Gangphase zur anderen. Damit ist der Algorithmus von einer exakten Detektion der jeweiligen Übergänge abhängig. Zudem könnte das Schalten unter Umständen zu




Bild 4: Schätzwerte für Hüft- und Kniewinkel mit einer separaten Analyse und Schätzung für Stand- und Schwungphase. Die Trajektorien werden deutlich besser rekonstruiert als ohne Aufteilung. Optimal resultieren 3 Eigenvektoren für den Stand und 4 für die Schwungphase.

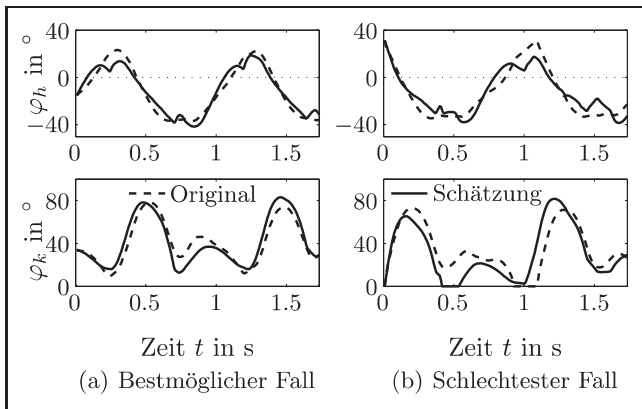


Bild 5: Untersuchung zur Übertragbarkeit von Kopplungen. Dargestellt sind Schätzwerte für Hüft- und Kniewinkel φ_h bzw. φ_k jeweils eines Probanden auf der Basis der gemittelten Kopplungsinformationen der 9 anderen Probanden. Die gewählte Anzahl der Eigenvektoren ist 2 für die Stand- und 3 für die Schwungphase. Dargestellt ist der beste und der schlechteste Fall, d.h. die Probanden mit der höchsten bzw. niedrigsten Ähnlichkeit mit der Referenzgruppe, aus der die Kopplungen stammen.

unerwünschten Grenzyklen oder gar zur Instabilität des geregelten Systems führen. Der Verbesserung steht somit eine sinkende Robustheit gegenüber. Allerdings wird zumindest ein hartes Umschalten durch das Kalman-Filter verhindert, da dies durch das Doppelintegratorverhalten keine Sprünge in der Referenztrajektorie zulässt.

3.4 Interpersonelle Übertragbarkeit

Theoretisch ideal wäre es, die maximal mögliche Anzahl Eigenvektoren in Γ beizubehalten. Dies bestätigt sich auch in Versuchen, bei denen die Bewegung eines Beins auf Basis des individuellen Gangmusters des Probanden rekonstruiert wird. Allerdings sinkt die Ähnlichkeit der Eigenvektoren zwischen den Probanden mit wachsendem Eigenwert. Als Maß für die Ähnlichkeit der Kopplungen zweier Probanden wird dabei der Korrelationskoeffizient des jeweiligen Eigenvektors verwendet. Der durchschnittliche Koeffizient aller möglichen Probandenpaare ergibt für den ersten Eigenvektor einen Wert von 0,82. Dieser Wert fällt mit dem zugehörigen Eigenwert ab, für den vierten Eigenvektor beträgt die mittlere Korrelation nur noch 0,68. Dieses Resultat deckt sich mit Beobachtungen aus [19], in dem ebenfalls ein Abfallen der interpersonel-

len Eigenvektor-Korrelation mit dem Eigenwert beobachtet wurde. Die dominanten linearen Gelenkkopplungen variieren anscheinend zwischen verschiedenen Personen wenig, während sich bei den weniger ausgeprägten Gelenkkopplungen individuelle Unterschiede bemerkbar machen.

Basierend auf diesen Überlegungen liegt die Erwartung nahe, dass die Übertragung von Kopplungsinformationen zwischen Personen robuster wird, wenn weniger Eigenvektoren berücksichtigt werden. Damit werden individuelle Unterschiede weniger stark abgebildet. Diese Vermutung bestätigt sich in simulativen Untersuchungen: In Bild 5 ist die Rekonstruktion zweier Probanden auf Basis des gemittelten Gangbilds der jeweiligen 9 anderen Probanden zu erkennen. Hierbei führt eine geringere Zahl Eigenvektoren (2/3 gegenüber 3/4) zur Minimierung des Rekonstruktionsfehlers, anders als bei bekanntem individuellen Gangbild (vgl. Bild 4). Dargestellt sind der beste und der schlechteste Fall, d.h. der Proband mit der höchsten Ähnlichkeit mit den 9 anderen (Der erste Eigenvektor hat einen mittleren Korrelationskoeffizienten von 0,90.) und derjenige mit der geringsten Ähnlichkeit (mit einem Korrelationskoeffizienten von 0,79).

Abweichungen bestehen zwischen verschiedenen Personen nicht nur in der Form der Gelenkkopplungen, sondern auch in den Auslenkungen und Mittelwerten der Gelenke während des Gehens. Die nötige Mittelwertbereinigung und Normierung der Bewegungsdaten vor der PCA und die anschließende Rücktransformation sind dadurch mit Unsicherheiten behaftet. Allerdings wären diese statistischen Parameter im Gegensatz zu den Kopplungen vermutlich auch noch nachträglich an den Patienten anpassbar, z.B. durch Beobachtung der kontralateralen Körperhälfte und graduelle Anpassung.

3.5 Funktionelles Gehen

Sämtliche Analysen sind bisher im Gelenkraum durchgeführt worden, d.h. die Hüft- und Kniewinkel wurden betrachtet. Gehen ist jedoch eine funktionsorientierte Bewegung. Der Erfolg der beschriebenen Methode hängt, abgesehen von der physiologischen Korrektheit der Bewegung, von ihrer Fähigkeit ab, die Aufgabe der Fortbewegung zu erfüllen. Die resultierende Position des Fußes ist daher insbesondere von Bedeutung. Bild 6 illustriert den bereits in




Bild 6: Vergleich der geschätzten Bewegung (gestrichelt) des linken Beins mit der tatsächlichen Beinbewegung. Die Bewegungsschätzung basiert auf getrennten Kopplungsanalysen für Stand und Schwung in den Gangmustern 9 anderer gesunder Probanden. Dargestellt ist der schlechteste Fall.

Bild 5 b) dargestellten schlechtesten Fall und vergleicht anschaulich die resultierende Bewegung des Beins mit dem Original. Ob und wie gut ein Patient tatsächlich hiermit gehen kann, hängt sicher auch davon ab, wie sehr er sich an die Kopplungen des fremden Gangmusters anpassen kann (solche Effekte können allein durch Simulationen nicht abgebildet werden).

4 Diskussion und Ausblick

In diesem Beitrag wurde ein allgemeiner Ansatz zur Schätzung von Bewegungen auf Basis einer Kopplungsanalyse präsentiert und auf die medizinische Beispielapplikation der Gangrehabilitation angewandt. Die Resultate deuten darauf hin, dass Solltrajektorien für gelähmte oder fehlende, d. h. vom Patienten nicht willkürlich steuerbare Körperteile in Echtzeit aus Bewegungsinformationen gesunder Glieder generiert werden können.

Eine wichtige Frage betrifft die Fähigkeit des Menschen, sein krankes Bein über das gesunde zu steuern. Das hierzu verwendete Kopplungsschema zwischen gesunden und robotisch unterstützten Gliedern ist zwar an gesunde Kopplungen angelehnt, allerdings im Gegenteil dazu rein unidirektional. Diese Frage wurde zum Zeitpunkt der Veröffentlichung bereits teilweise durch praktische Evaluierung erörtert. Hierfür stehen zwei Testszenerien zur Verfügung: Zum einen eine „Fake“-Prothese, d. h. eine Oberschenkelprothese mit abgewinkeltem Schaft zur Aufnahme eines gesunden Beins. Damit können Versuche mit gesunden Probanden in Bezug auf eine Kniebewegungsschätzung durchgeführt werden. Zum anderen werden ähnliche Versuche zur Schätzung der Bewegung eines Beins mit dem Rehabilitationsroboter LOPES der Universität Twente (NL) durchgeführt, welcher aus einem aktuierten 9-DoF-Exoskelett in Verbindung mit einem Laufband besteht [1]. Hierzu wird das linke Bein des Exoskeletts quasi als prothetisches Bein verwendet und vom rechten Bein eines Probanden angesteuert. Erste Ergebnisse mit LOPES wurden bereits in [24] präsentiert. Diese Ergebnisse bestätigen, dass die Steuerung eines Beins über das andere mithilfe der Bewegungsintentionsschätzung intuitiv möglich ist und funktionelles Gehen ermöglicht. Zudem wird zurzeit in einer weiteren Studie untersucht, ob die zunächst verwendete Methode zur Berechnung der Abbildungsfunktion von gesunden auf unterstützte Gliedmaßen auf Basis von PCA in der Praxis Vorteile gegenüber dem besten linearen erwartungstreuen Schätzer (BLES) bietet.

Geplante theoretische Erweiterungen des Algorithmus betreffen eine Segmentierung bzw. ein Clustering der Bewegung über die Unterteilung in Stand und Schwung hinaus. Dies ist besonders für Prothesen von Belang, um auch andere Bewegungsmuster wie z. B. Treppensteigen zu ermöglichen. Eine automatisierte Unterteilung bzw. Erkennung unterschiedlicher Synergien in einzelnen Bewegungen könnte z. B. durch Dynamisches Clustering vorgenommen werden, wobei Methoden wie die „Generalized Principal

Component Analysis“ [25], oder das „Correlation Clustering“ [26] eingesetzt werden könnten.

Eine Möglichkeit zur Verbesserung des Algorithmus im Hinblick auf Funktionalität des Gangs wäre die zusätzliche Einbeziehung kartesischer Koordinaten des Fußes (Obwohl die Information über die Fußposition bereits in den Gelenkwinkeln enthalten ist, kann lineare PCA diese nichtlinearen Zusammenhänge nicht abbilden.) oder kinetischer Variablen wie Bodenreaktionskräfte.

Danksagung

Dank für Unterstützung und Beratung in medizinischen Fragen gebührt Dr. Burgkart, Klinikum Rechts der Isar, München, sowie Dr. Quintern, Neurologische Klinik Bad Aibling. Die in diesem Projekt verwendeten Daten entstammen der Webseite mocap.cs.cmu.edu (Carnegie Mellon University), die durch NSF EIA-0196217 finanziert wurde. Zur Prozessierung und Visualisierung der Daten wurde die „Mocap toolbox for MATLAB“ verwendet, die von N. D. Lawrence, University of Sheffield, UK, entwickelt wurde.

Literatur

- [1] J. F. Veneman, R. Ekkelenkamp, R. Kruidhof, F. van der Helm, and H. van der Kooij. A series elastic- and bowden-cable-based actuation system for use as torque actuator in exoskeleton-type robots. *International Journal of Robotic Research*, 25(3):261–281, 2006.
- [2] H. Kawamoto and S. Kanbe. Power Assist Method for HAL3, Estimating Operator Intention Based on Motion Information. In *Proceedings of IEEE International Workshop on Robot and Human Interactive Communication*, pages 67–72, 2003.
- [3] R. Riener and T. Fuhr. Patient-driven control of fessupported standing up: A simulation study. *IEEE Trans on Rehab Eng*, 6:113–124, 1998.
- [4] H. Kazerooni, J.-L. Racine, L. Huang, and R. Steger. On the control of the berkeley lower extremity exoskeleton (BLEEX). In *Proceedings of the 2005 IEEE International Conference on Robotics and Automation*, pages 4364–4371, April 2005.
- [5] S. Jezernik et al. Automatic gait-pattern adaptation algorithms for rehabilitation with a 4-dof robotic orthosis. *IEEE Transaction on Robotics and Automation*, 20(3):574–582, June 2004.
- [6] C. Azevedo and R. Héliot. Rehabilitation of functional posture and walking: Coordination of healthy and impaired limbs. *Journal of Automatic Control*, 15(Supplement):12–14, 2005.
- [7] A. Alexandrov, A. Frolov, and J. Massion. Axial synergies during human upper trunk bending. *Exp Brain Res*, 118(2):210–220, January 1998.
- [8] N. St-Onge and A. G. Feldman. Interjoint coordination in lower limbs during different movements in humans. *Exp Brain Res*, 148(2):139–149, 2003.
- [9] V. Dietz, K. Fouad, and C. M. Bastiaanse. Neuronal coordination of arm and leg movements during human locomotion. *European Journal of Neuroscience*, 14(11):1906–1914, December 2001.
- [10] D. S. Reisman and J. P. Scholz. Aspects of joint coordination are preserved during pointing in persons with post-stroke hemiparesis. *Brain*, 126(11):2510–2527, November 2003.
- [11] N. Bernstein. *The Coordination and Regulation of Movements*. Pergamon Press Ltd., London, 1967.
- [12] K. Pearson. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2(6):559–572, 1901.

- [13] I.T. Jolliffe. *Principal Component Analysis*. Springer-Verlag, New York, 2 edition, 2002.
- [14] J.E. Duysens and H.W. Van de Crommert. Neural control of locomotion: The central pattern generator from cats to humans. *Gait and Posture*, 7(2):131–141, 1998.
- [15] K. Matsuoka. Mechanisms of frequency and pattern control in the neural rhythm generators. *Biol Cybern*, 56(5-6):345–53, 1987.
- [16] C.D. Mah, M. Hulliger, R.G. Lee, and I.S. O’Callaghan. Quantitative analysis of human movement synergies: Constructive pattern analysis for gait. *J Mot Behav*, 26(2):83–102, June 1994.
- [17] F. Multon, L. France, M.-P. Cani, and G. Debonne. Computer animation of human walking: a survey. *Journal of Visualization and Computer Animation (JVCA)*, 10:39–54, 1999. Published under the name Marie-Paule Cani-Gascuel.
- [18] P. Glardon, R. Boulic, and D. Thalmann. PCA-based walking engine using motion capture data. In *Proceedings of Computer Graphics International 2004*, pages 292–298, June 2004.
- [19] N.F. Troje. Decomposing biological motion: A framework for analysis and synthesis of human gait patterns. *Journal of Vision*, 2:371–387, 2002.
- [20] K. Tatani and Y. Nakamura. Dimensionality reduction and reproduction with hierarchical NLPCA neural networks - extracting common space of multiple humanoid motion patterns. In *Proceedings of the 2003 IEEE International Conference on Robotics & Automation*, pages 1927–1932, Taipei, Taiwan, 2003.
- [21] D. Katic and M. Vukobratovic. Survey of intelligent control techniques for humanoid robots. *Journal of Intelligent and Robotic Systems*, 37:117–141, 2003.
- [22] J. Shan, C. Junshi, and C. Jiapin. Design of central pattern generator for humanoid robot walking based on multi-objective GA. In *Proceedings of the 2000 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 1930–1935, 2000.
- [23] M.P. Murray. Gait as a total pattern of movement. *Am J Phys Med*, 46(1):290–333, February 1967.
- [24] H. Vallery, R. Ekkelenkamp, and H. van der Kooij. Complementary limb motion estimation based on interjoint coordination: Experimental evaluation. In *Proceedings of ICORR 2007*, 2007.
- [25] R. Vidal, Y. Ma, and S. Sastry. Generalized principal component analysis (GPCA). *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(12):1945–1959, december 2005.
- [26] C. Böhm et al. Computing clusters of correlation connected objects. In *ACM SIGMOD Int. Conf. on Management of Data*, 2004.
- [27] C. Fleischer and G. Hommel. Steuerung einer angetriebenen Beinorthese mit Hilfe von EMG-Signalen. *Orthopädie-Technik*, 5:358–365, 2006.

Manuskripteingang: 2. Oktober 2006.



Dipl.-Ing. Heike Vallery ist seit Oktober 2005 Doktorand am Lehrstuhl für Steuerungs- und Regelungstechnik der Technischen Universität München. Wissenschaftliches Interesse: Automatisierte Gangrehabilitation, Funktionelle Elektrische Stimulation.

Adresse: Lehrstuhl für Steuerungs- und Regelungstechnik (LSR), Technische Universität München, 80290 München, E-Mail: heike.vallery@tum.de



Prof. Dr.-Ing./Univ. Tokio Martin Buss ist Ordinarius des Lehrstuhls für Steuerungs- und Regelungstechnik, Institut für Automatisierungstechnik und Autonome Systeme, Fakultät für Elektrotechnik und Informationstechnik, Technische Universität München. Hauptarbeitsgebiete: Automatisierungstechnik, Mechatronik und Robotik, Multimodale Mensch-Maschine-Systeme, Optimierungsverfahren, nichtlineare und hybride diskret-kontinuierliche Regelungssysteme.

Adresse: Lehrstuhl für Steuerungs- und Regelungstechnik (LSR), Technische Universität München, 80290 München, E-Mail: m.buss@ieee.org