

Iterativ Lernende Regelung mit variabler Zykluslänge für FES-basierte Kompensation einer Fußheberschwäche

Iterative Learning Control with Variable Pass Length applied to FES-based Drop Foot Treatment

Thomas Seel*, Thomas Schauer, Jörg Raisch, TU Berlin

* Korrespondenzautor: seel@control.tu-berlin.de

Zusammenfassung Mit funktioneller Elektrostimulation kann die Dorsalflexion des Fußes in der Schwungphase des Ganges unterstützt und dadurch eine Fußheberschwäche kompensiert werden. Um eine möglichst natürliche Fußwinkeltrajektorie zu generieren, wird eine iterativ lernende Regelung eingesetzt. Dieser Artikel betrachtet die Abhängigkeit eines verfrühten Aufsetzens des Fußes vom Stimmulationsprofil des jeweiligen Schrittes und untersucht die sich daraus ergebende verkoppelte Lern- und Zykluslängendynamik. Dazu werden zunächst geeignete theoretische Konzepte diskutiert, anhand derer dann der Reglerentwurf erfolgt. Abschließend

wird experimentell das erreichte Konvergenzverhalten untersucht. ►► **Summary** Functional electrical stimulation can be used to support the dorsiflexion of the foot during the swing phase of gait. Iterative learning control is employed to generate natural foot angle trajectories. In this article we consider early ground contact due to insufficient stimulation and study the resulting coupled dynamics of the error and the pass length. First, adequate theoretical concepts are discussed, which are then used for controller design. Finally, the achievable convergence properties are analyzed experimentally.

Schlagwörter Iterativ lernende Regelung, iterativ lernende Steuerung, variable Zykluslängen, monotone Konvergenz, funktionelle Elektrostimulation, Fußheberschwäche, Medizintechnik ►► **Keywords** Iterative learning control, variable pass length, monotonic convergence, functional electrical stimulation, drop foot syndrome, biomedical engineering

1 Einleitung

Die Phase des Ganges zwischen dem Ablösen der Zehen und dem Wiederaufsetzen des Fußes, in welcher das Bein am anderen Bein vorbei nach vorn schwingt, wird als Schwungphase bezeichnet. In dieser Phase wird der vordere Teil des Fußes beim gesunden Menschen durch Muskeln im Unterschenkel angehoben, um ein

Berühren des Bodens zu vermeiden. Ist diese Fähigkeit, z.B. infolge eines Schlaganfalls und der daraus resultierenden Schädigungen des zentralen Nervensystems, verloren oder eingeschränkt, so spricht man von einer Fußheberschwäche oder einem Fallfuß. Falls die den Muskel innervierenden Nerven noch intakt sind, so kann die notwendige Dorsalflexion mittels funktionel-

ler Elektrostimulation (FES) herbeigeführt werden. Dabei werden selbstklebende Hautelektroden über den beteiligten Muskeln und Nerven platziert und in ihrer Intensität anpassbare Stromimpulse appliziert.

Erste Ergebnisse zur Regelung der FES-unterstützten Fußhebung finden sich in [5] und [7]. Eine über diese Ergebnisse hinausgehende regelungstechnische Herausforderung besteht darin, den zeitlichen Verlauf dieser Intensität so zu wählen, dass sich über die Schwungphase hinweg ein möglichst natürlicher Gelenkwinkelverlauf einstellt. Dies sichert neben einer möglichst physiologischen Anregung und Beanspruchung von Muskeln, Nerven und Gelenk auch ein symmetrisches und unauffälliges Gangbild. Im Vergleich zur Länge einer Schwungphase ist die Stimulationsdynamik, also der Einfluss der Stimulationsintensität auf die Fußhebung, jedoch so langsam, dass statt einer Feedback-Regelung eine von Schritt zu Schritt lernende Steuerung eingesetzt wird. Dabei wird in der Standphase, jeweils auf Grundlage der Abweichung zwischen Soll- und Ist-Winkelverlauf der letzten Schwungphase, der Verlauf der Stimulationsintensität für die nächste Schwungphase so angepasst, dass eben jene Abweichung in einer geeigneten Norm kleiner wird.

Dieses Verfahren wird als iterativ lernende Steuerung oder iterativ lernende Regelung (engl. Iterative Learning Control, ILC) bezeichnet. Eine gute Einführung in die Thematik wird durch den Übersichtsartikel [1] gegeben. Typische ILC-Anwendungen zeichnen sich durch ihre repetitive Natur aus und sind sowohl in der Robotik, z. B. bei pick-and-place-Aufgaben, als auch in der Verfahrenstechnik, z. B. beim Betrieb von Batch-Reaktoren, zu finden. In der Biomedizintechnik werden ILC-Ansätze hingegen erst seit kurzem verfolgt. Beispiele für erfolgreichen Einsatz finden sich in [2; 4; 6; 13].




Bild 1 Einfluss der Stimulationsintensität auf die Länge der Schwungphase. Bei zu schwacher Stimulation setzt der Fuß zu früh auf. Die bis dahin gewonnenen Messdaten müssen genutzt werden, um das Stimulationsprofil für den nächsten Schritt anzupassen.

Für die Fallfußkompensation wurde 2008 durch Nahrstaedt et al. unter vereinfachten Versuchsbedingungen demonstriert, dass das Regelungsproblem mit ILC-Ansätzen lösbar ist [8]. Der sich daran anschließende Einsatz in Experimenten mit Schlaganfall-Patienten hat jedoch eine Reihe von Diskrepanzen zwischen den Grundannahmen der ILC-Theorie und den tatsächlichen Gegebenheiten in der Anwendung aufgezeigt. Insbesondere basieren die verfügbaren Stabilitäts- und Konvergenzbeweise für ILC-Algorithmen auf der Annahme, dass jeder Zyklus gleich lang ist und für jede Aktualisierung der Stelltrajektorie die gleiche Anzahl an Winkel-Messwerten aus der letzten Schwungphase vorliegt. Für die klassischen ILC-Anwendungen kommt diese Annahme einer Selbstverständlichkeit gleich. Im vorliegenden Anwendungsfall ist es jedoch so, dass die Schwungphasen nicht einmal beim Gehen auf dem Laufband dieselbe Länge aufweisen. Dies ist noch weniger der Fall, wenn der Fuß infolge plötzlichen Gleichgewichts- oder Kraftverlustes oder infolge mangelnder Stimulation frühzeitig den Boden berührt, vgl. Bild 1.

Daher müssen Methoden entwickelt werden, die auch bei abgebrochenen Zyklen und unvollständiger Messinformation eine sinnvolle Stellgrößen-Aktualisierung erlauben. Nicht zuletzt aufgrund der Patientensicherheit muss gleichzeitig auch die vorhandene Theorie um entsprechende Konvergenzkriterien und Stabilitätsbeweise für Systeme mit variabler Zykluslänge ergänzt werden. Dieser Artikel beschreibt erste wichtige Schritte in Richtung eines erweiterten ILC-Konzeptes und dessen Anwendung auf die FES-basierte Fallfußkompensation. Im ersten Abschnitt werden grundlegende ILC-Konzepte für Systeme mit variabler Zykluslänge vorgestellt und erste theoretische Ergebnisse zusammengefasst. Anschließend wird der experimentelle Aufbau beschrieben und es werden modellbasiert zwei ILC-Regler entworfen, bevor im letzten Abschnitt die experimentellen Ergebnisse ausgewertet werden.

2 Erweiterung der ILC-Theorie für Systeme mit variabler Zykluslänge

Die Formulierung der grundlegenden Konzepte der ILC erfolgt für gewöhnlich in diskreter Zeit und je nach Autor und Anwendung entweder im Frequenzbereich oder im Zeitbereich. Eine gute Einführung findet sich in [1]. Im vorliegenden Fall ist die Zykluszeit mit maximal 1 s nur wenig größer als die Zeitkonstanten der Streckendynamik und die Abtastfrequenz ist durch die Stimulation auf 50 Hz festgelegt, wodurch sowohl Stell- als auch Ausgangstrajektorie maximal aus 50 Abtastwerten bestehen werden. Daher wählen wir die Beschreibung im Zeitbereich über die sogenannten *lifted vectors* [1].

2.1 Systembeschreibung und Regleransatz

Betrachtet wird ein zu regelndes System mit skalarem Eingang $u(k)$ und skalarem Ausgang $y(k)$. In jedem Zyklus $j = 1, 2, \dots$ laufe die diskrete Zykluszeit k erneut

von $k = 1$ bis zur maximal möglichen Zykluslänge $k = \bar{n}$. Entsprechend definieren wir den *lifted vector* der Ausgangstrajektorie

$$\mathbf{y}_j := [y(k = 1), y(k = 2), \dots, y(k = \bar{n})]^T,$$

der die aufeinanderfolgenden Abtastwerte des Ausgangs im j -ten Zyklus enthält. Das Regelungsziel besteht nun darin, die Abweichung zwischen \mathbf{y}_j und einem vorgegebenen Referenzverlauf $\mathbf{r} \in \mathbb{R}^{\bar{n}}$ von Zyklus zu Zyklus zu verkleinern. Dazu wird folgender Bereich der Stelltrajektorie ausgewählt:

$$\mathbf{u}_j := [u(k = 1 - \phi), u(k = 2 - \phi), \dots, u(k = \bar{n} - \phi)]^T,$$

welcher zeitlich um das sogenannte *phase lead* $\phi \geq 0$ gegenüber \mathbf{y}_j verschoben ist. Bei ϕ handelt es sich um einen Regler-Parameter, der üblicherweise gleich dem relativen Grad m des zeitdiskreten Streckenmodells gewählt wird. Die Verwendung eines *phase lead* impliziert also, dass schon ϕ Zeitschritte vor Zyklusbeginn mit dem Aufgeben der Stelltrajektorie auf das System begonnen wird.

Weiterhin wird ein Lerngesetz formuliert, das beschreibt, wie die Stelltrajektorie jeweils auf Grundlage des zuletzt erhaltenen Fehlers verändert wird. In der klassischen ILC-Theorie steht dazu in jedem Zyklus j der gesamte Ausgangsgrößenverlauf \mathbf{y}_j zur Verfügung. Wir gehen nun stattdessen davon aus, dass infolge eines Zyklusabbruches oder eines Verlustes an Messdaten im j -ten Zyklus nur die ersten $n_j \in [1, \bar{n}]$ Abtastwerte zur Verfügung stehen. Ob und in welcher Weise die Zykluslänge n_j dabei von Systemzuständen abhängt oder ob sie beispielsweise rein zufällig festgelegt wird, kann von System zu System variieren. Unabhängig davon kann folgendes allgemeines Lerngesetz formuliert werden:

$$\mathbf{u}_{j+1} = \mathbf{Q}(\mathbf{u}_j + \mathbf{L}\mathbf{H}_{n_j}\mathbf{e}_j). \quad (1)$$

Der Fehler $\mathbf{e}_j := \mathbf{r} - \mathbf{y}_j$ wird *maximum pass length* (MPL) Fehler genannt und bezeichnet den Fehler, den man ohne Zyklusabbruch, also für $n_j = \bar{n}$, erhalten hätte. Wir führen ihn an dieser Stelle ein, da er für die Konvergenzanalyse eine wichtige Rolle spielt. Tatsächlich sind aber im j -ten Zyklus nur seine ersten n_j Einträge bekannt. Mathematisch wird dies durch Multiplikation mit den diagonalen Matrizen \mathbf{H}_{n_j} abgebildet, die jeweils n_j Einsen gefolgt von $\bar{n} - n_j$ Nullen auf der Diagonalen tragen. Die Zeitpunkte, zu denen im jeweiligen Lernschritt keine Information vorliegt, werden also so behandelt, als wenn dort kein Tracking-Fehler vorläge.¹ Des Weiteren ist $\mathbf{Q} \in \mathbb{R}^{\bar{n} \times \bar{n}}$ der sogenannte Q-Filter und $\mathbf{L} \in \mathbb{R}^{\bar{n} \times \bar{n}}$ die Lernmatrix des ILC-Algorithmus. Während L dem aufgetretenen Fehler eine Stellgrößenänderung zuweist, wird \mathbf{Q} oft in Form eines Tiefpassfilters gewählt, um glatte Stelltrajektorien und erhöhte Robustheit zu erreichen [1]. Beide Matrizen sind im Laufe des Reglerentwurfs festzulegen und entsprechen im einfachsten Fall Diagonalmatrizen.

¹ Hier sind auch andere Strategien denkbar, z. B. den Fehler des n_j -ten Abtastwertes zu extrapolieren. Dies setzt jedoch weitere Annahmen zur Systemdynamik oder zum Störgrößenverlauf voraus.

2.2 Fehlerdynamik und monotone Konvergenz

Sowohl um \mathbf{L} und \mathbf{Q} zu wählen als auch um Aussagen über Konvergenzeigenschaften des Fehlers im geschlossenen Regelkreis zu untersuchen, wird ein Modell des zu regelnden Systems benötigt. Wir nehmen ein für jeden Zyklus $j = 1, 2, \dots$ geltendes, lineares, zeitinvariantes Zustandsmodell an:

$$\begin{aligned} \mathbf{x}_j(k+1) &= \mathbf{A}\mathbf{x}_j(k) + \mathbf{B}\mathbf{u}_j(k-m+1), \\ \mathbf{y}_j(k) &= \mathbf{C}\mathbf{x}_j(k) + d(k), \end{aligned} \quad (2)$$

worin m der relative Grad ist und $d(k)$ eine unbekannte Störgröße darstellt. Ferner sei angenommen, dass sowohl $d(k)$ als auch $\mathbf{x}_0 := \mathbf{x}(k=0)$ in jedem Zyklus dieselben Werte annehmen und dass $y_j(0) = r(0) \forall j$. Im Kontext der *lifted vector* kann die Systemdynamik (2) dann für $\phi = m$ wie folgt umgeschrieben werden:

$$\mathbf{y}_j = \mathbf{P}\mathbf{u}_j + \mathbf{v}. \quad (3)$$

Dabei stellt $\mathbf{P} \in \mathbb{R}^{\bar{n} \times \bar{n}}$ die sogenannte *lifted system matrix* des Systems und $\mathbf{v} \in \mathbb{R}^{\bar{n}}$ ein iterationsinvariantes, von \mathbf{u}_j unabhängiges Signal dar. Um die Äquivalenz beider Darstellungen aufzuzeigen, nutzen wir die Markov-Parameter p_i des Systems mit

$$p_i = \mathbf{C}\mathbf{A}^{i-1}\mathbf{B}, i \in [1, \bar{n}]$$

und schreiben

$$\mathbf{P} = \begin{pmatrix} p_1 & 0 & \dots & 0 \\ p_2 & p_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ p_{\bar{n}} & p_{\bar{n}-1} & \dots & p_1 \end{pmatrix}, \quad \mathbf{P} \in \mathbb{R}^{\bar{n} \times \bar{n}}$$

$$\mathbf{v} = \begin{pmatrix} \mathbf{C}\mathbf{A}\mathbf{x}_0 + d(k=1) \\ \mathbf{C}\mathbf{A}^2\mathbf{x}_0 + d(k=2) \\ \vdots \\ \mathbf{C}\mathbf{A}^{\bar{n}}\mathbf{x}_0 + d(k=\bar{n}) \end{pmatrix}, \quad \mathbf{v} \in \mathbb{R}^{\bar{n}}.$$

Durch Vergleich mit (2) wird ersichtlich, dass im Fall $\phi = m$ beide Darstellungen äquivalent sind. Grundsätzlich kann statt des zeitinvarianten auch ein zeitvariantes Modell verwendet werden, wenn beispielsweise ein nichtlineares System entlang der Referenztrajektorie linearisiert wurde. Dann müssen zeitabhängige Markov-Parameter verwendet werden und \mathbf{P} würde keine Toeplitz-Struktur mehr aufweisen.

Durch Kombination der Systemdynamik (3) und des Lerngesetzes (1) ergibt sich folgende Fehler-Dynamik des geschlossenen Regelkreises:

$$\mathbf{e}_{j+1} = \mathbf{P}\mathbf{Q}\mathbf{P}^{-1}(\mathbf{I} - \mathbf{P}\mathbf{L}\mathbf{H}_{n_j})\mathbf{e}_j + (\mathbf{I} - \mathbf{P}\mathbf{Q}\mathbf{P}^{-1})(\mathbf{r} - \mathbf{v}), \quad (4)$$

worin \mathbf{I} die Einheitsmatrix darstellt. Anhand dieser Gleichung kann analysiert werden, wie sich der MPL-Fehler für ein gegebenes System $\{\mathbf{P}, \mathbf{v}\}$ mit Referenz \mathbf{r} bei Einsatz eines bestimmten ILC-Reglers $\{\mathbf{L}, \mathbf{Q}\}$ entwickelt. Wie be-




Bild 2 Typisches Lernverhalten einer ILC mit variabler Zykluslänge. Da der erste Zyklus schon nach $n_1 = 30$ Zeitschritten abbricht, kann nur im vorderen Bereich gelernt werden. Im hinteren Bereich bleibt die Stelltrajektorie, abgesehen von der Tiefpassfilterung durch \mathbf{Q} , unverändert. Daher wird auch die Abweichung des Ausgangs zur Referenz nur auf den ersten n_1 Abtastwerten deutlich kleiner. Die gestrichelte Fortsetzung von y_1 veranschaulicht den MPL-Fehler, d. h. den Fehler, der bei maximaler Zykluslänge aufgetreten wäre.

reits erwähnt wurde, können die letzten $\bar{n} - n_j$ Abtastwerte dieses Fehlers nur in der Simulation unter Annahme eines bestimmten $\{\mathbf{P}, \mathbf{v}\}$ berechnet, nicht aber am realen System gemessen werden.² Dennoch erweist sich der MPL-Fehler als sehr nützlich für die Konvergenz-Analyse, da er unabhängig von der momentanen Zykluslänge die Güte der Stelltrajektorie im Sinne eines Referenz-Trackings über den gesamten Bereich angibt. Bild 2 zeigt zwei Zyklen mit $n_1 = 30, n_2 = 50$, bei denen die 1-Norm des messbaren Fehlers, die sich jeweils über die Fläche zwischen der Referenz und der durchgezogenen Linie abschätzen lässt, größer wird, obwohl eindeutig ein Lernfortschritt vorliegt. Die 1-Norm des MPL-Fehlers hingegen wird kleiner.

Da auch zwischenzeitliche Verschlechterungen in den meisten Anwendungen unerwünscht sind, wird meist nicht nur Stabilität, sondern die stärkere Eigenschaft der monotonen Konvergenz des Fehlers in mindestens einer Norm gefordert, siehe z. B. [1]. Erste theoretische Ergebnisse für ILC mit variabler Zykluslänge haben wir in [12] vorgestellt. Dort wird der Fall zufällig auftretender Zyklusabbrüche betrachtet und folgendes Kriterium für monotone Konvergenz bei beliebiger Zykluslängenfolge $\{n_j\}$ hergeleitet:

Theorem 1 (Monotone Konvergenz in 1-Norm). Für ein System (3) mit Lerngesetz (1) und $\mathbf{Q} = \mathbf{I}$ ist die 1-Norm des MPL Fehlers \mathbf{e}_j monoton fallend, d. h.

$$\|\mathbf{e}_{j+1}\|_1 \leq \|\mathbf{e}_j\|_1 \quad \forall j, \{n_j\}, \mathbf{v},$$

² Anderenfalls würde man diese Information selbstverständlich in das Lerngesetz einfließen lassen und man erhielte eine klassische ILC mit konstanter Zykluslänge.

genau dann wenn

$$\gamma := \|\mathbf{I} - \mathbf{P}\mathbf{L}\|_1 \leq 1. \quad (5)$$

Im Gegensatz dazu sichert die in der klassischen ILC-Theorie verwendete Bedingung $\|\mathbf{I} - \mathbf{P}\mathbf{L}\|_2 \leq 1$ im Fall variabler Zykluslängen weder für $\|\mathbf{e}_j\|_1$ noch für $\|\mathbf{e}_j\|_2$ monotone Konvergenz. Ferner wurde festgestellt, dass γ ein Maß für die Konvergenzgeschwindigkeit auf den jeweils ersten n_j Abtastwerten ist, dass also

$$\|\mathbf{H}_{n_j} \mathbf{e}_{j+1}\|_1 \leq \gamma \|\mathbf{H}_{n_j} \mathbf{e}_j\|_1 \quad \forall j. \quad (6)$$

gilt. Deshalb kann der Entwurf der Lernmatrix bei gegebener Systemdynamik \mathbf{P} über Minimierung von γ erfolgen. In zweierlei Hinsicht sind diese ersten Ergebnisse jedoch dringend auszubauen:

Erstens ist der Einsatz eines Q-Filters in Form eines nicht-kausalen Tiefpassfilters sinnvoll [1; 11]. Daher sind Konvergenz-Kriterien für ILC-Algorithmen mit $\mathbf{Q} \neq \mathbf{I}$ Gegenstand unserer aktuellen Forschung. Erste Ergebnisse deuten darauf hin, dass bei schnell genug eingestelltem Q-Filter nahezu die gleiche Bedingung wie in Theorem 1 verwendet werden kann.

Zweitens wurde bisher stets von zufällig schwankender Zykluslänge ausgegangen. Die Möglichkeit, dass der Abbruch der Zyklen direkt vom Systemverhalten abhängt, wurde nicht betrachtet. Dieser Fall zeichnet sich dadurch aus, dass hier neben der Fehlerdynamik von \mathbf{e}_j auch die damit verkoppelte Dynamik der Zykluslänge n_j analysiert werden muss. In diesem Beitrag werden erste experimentelle Untersuchungen an ILC-Systemen mit variabler Zykluslänge durchgeführt, bei denen der Zyklus genau dann abbricht, wenn der Ausgang y_j einen bestimmten zykluszeitabhängigen Grenzwert $\mathbf{c} \in \mathbb{R}^{\bar{n}}$ unterschreitet. Dabei ist $\mathbf{c} < \mathbf{r}$ elementweise erfüllt und deren minimaler Abstand $\Delta := \min_k (r(k) - c(k+1)) > 0$ ist groß genug, um auszuschließen, dass der Ausgang innerhalb eines Abtastintervalls vom Referenzwert auf den Grenzwert springt. Der maximal mögliche Anstieg $\delta_y := \max_k (y_j(k+1) - y_j(k))$ des Ausgangssignals wird dabei sowohl durch die Trägheit der Strecke als auch durch die Bandbreite des Q-Filters begrenzt. Wenn $\delta_y < \Delta$ und $\gamma < 1$ erfüllt sind, so folgt schließlich aus (6), dass in endlich vielen Zyklen die maximale Zykluslänge und eine beliebig kleine Fehlernorm $\|\mathbf{e}_j\|_1$ erreicht wird.³ Inwiefern sich diese Aussagen experimentell bestätigen lassen, werden die folgenden Abschnitte zeigen.

3 Experimenteller Aufbau

Der gesunde Proband sitzt mit frei herabhängenden Unterschenkeln und Füßen auf einem Tisch, siehe Bild 3. Weder Versuchsparameter noch Mess- oder Stellgröße sind für ihn einsehbar. Er wird aufgefordert, während

³ Widerspruchsbeweis: Wenn unendlich viele Zyklen mit $n_j < \bar{n}$ auftreten, dann sei \hat{n} die größte Zykluslänge, die unendlich oft auftritt. Aus (6) folgt, dass nach endlich vielen Zyklen $\|\mathbf{H}_{\hat{n}} \mathbf{e}_j\|_1 < \Delta - \delta_{y_{\max}}$ gilt, aber dann ist $n_j > \hat{n}$.

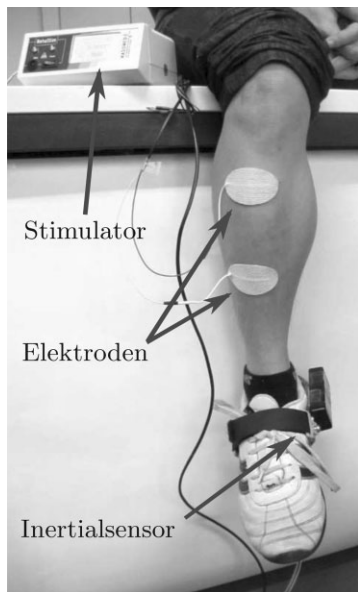


Bild 3 Experimenteller Aufbau zur Fußhebung durch funktionelle Elektrostimulation mit Inertialsensor-basierter Fußwinkelmessung. Der Proband sitzt und bleibt passiv. Gangphasen und Bodenkontakt werden wie in einer Hardware in the Loop Umgebung vom angeschlossenen PC simuliert. Dadurch kann am realen Muskel isoliert die Wechselwirkung zwischen mangelnder Stimulation und verfrühtem Bodenkontakt untersucht und andere Phänomene und Störfaktoren minimiert werden.

der Experimente passiv zu bleiben, also keine seiner Beinmuskeln willentlich zu kontrahieren.

Die Stimulation erfolgt über zwei selbstklebende Hautelektroden, die auf der Vorderseite des Unterschenkels über dem musculus tibialis anterior angebracht sind. Mit einer Stimulationsfrequenz von 50 Hz werden bipolare Stromimpulse mit fester Amplitude von 20 mA und variabler Pulsbreite verabreicht. Letztere nimmt typischerweise Werte zwischen 20 μ s und 300 μ s an und ist bei konstanter Amplitude ein Maß für die Stimulationsintensität. Als einer der ersten Schritte werden manuell die minimale Pulsbreite, die eine Kontraktion auslöst, und die maximale Pulsbreite, die vom Probanden toleriert wird, bestimmt⁴. Zur besseren Vergleichbarkeit zwischen verschiedenen Experimenten wird die Stellgröße $u_j(k) \in [0, 1]$ auf diesen Bereich skaliert.

Über einen Inertialsensor⁵ am Fuß des Probanden wird der Nickwinkel des Fußes, also der Winkel des Fußes mit der Horizontalen in der Sagittalebene, erfasst. Da der Unterschenkel nicht bewegt wird, geht dieser Fußwinkel nach Ende jeder Stimulationsphase nahezu auf seinen Ausgangswert zurück. Auch hier werden manuell der Minimal- und Maximalwert bestimmt und der tatsächliche Wert auf diesen Bereich skaliert. Aus Ganganalyse-Experimenten steht ein annähernd natürlicher Schwungphasen-Fußwinkelverlauf zur Verfügung,

⁴ Um die Fehler- und Zykluslängendynamik ohne Stellgrößenbegrenzung zu untersuchen, wurde ein Proband gewählt, bei dem dieser Wert deutlich über der für eine Fußhebung benötigten Stimulationsintensität liegt.

⁵ RazorIMU 9DoF, Sparkfun, United Kingdom

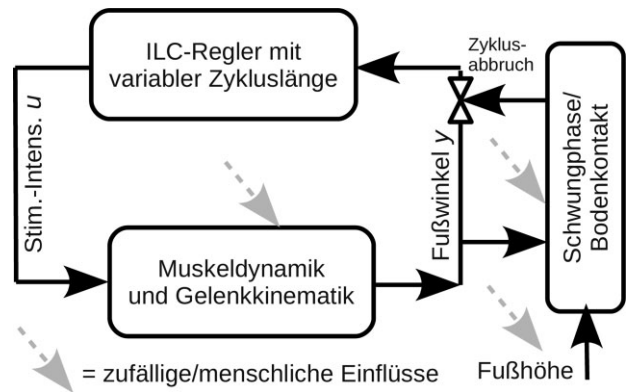


Bild 4 Wechselwirkung zwischen Lernverhalten und Zykluslänge. Wenn der Fuß infolge mangelnder Stimulation zu früh aufsetzt, stehen nur verkürzte Ausgangstrajektorien zum Lernen zur Verfügung. Nur wenn es der ILC gelingt, den Fußwinkelverlauf dennoch zu verbessern, tritt auch der Zyklusabbruch zu einem späteren Zeitpunkt auf.

der im ILC-Algorithmus als Referenz verwendet wird. Außerdem wird, anhand der Sprunggelenkshöhe und der Fußlänge, für jeden Moment in der Schwungphase derjenige Fußwinkel berechnet, bei dem jeweils die Zehen den Boden berühren würden.

Da in diesem vereinfachten experimentellen Aufbau keine Gangereignisse wie initialer Fersenkontakt oder Ablösen der Zehen auftreten, werden Schwungphasen von einer festen maximalen Länge von 0,8 s simuliert. Über diese Schwungphasen hinweg lernt ein ILC-Algorithmus mit variabler Zykluslänge, den gewünschten Winkelverlauf durch Anpassung des Stimulationsprofils einzustellen. Im ersten Zyklus wird ein trapezförmiges Profil⁶ appliziert, in den darauffolgenden Zyklen das jeweils durch Aktualisierung mit (1) erhaltene neue Stimulationsprofil. Während der gesamten Schwungphase wird kontinuierlich überwacht, ob der Fußwinkel oberhalb des Wertes liegt, bei dem jeweils die Zehen den Boden berühren würden. Sobald eine Unterschreitung auftritt, wird der Zyklus abgebrochen und nur die bis dahin gemessenen Abtastwerte des Fußwinkels der ILC zum Lernen zur Verfügung gestellt. In der Praxis führt mangelnde Stimulation in der Tat zum früheren Aufsetzen des Fußes, da der Patient kaum spürt, wie stark die Fußhebung gerade ist und somit nicht spontan den Fuß insgesamt höher heben wird. Darüber hinaus beeinflussen viele weitere Faktoren – insbesondere zufällige Schwankungen in der Beinbewegung, Bodenbeschaffenheit und variierende Eigenaktivität – die tatsächliche Fußbewegung und damit die Zykluslänge. Mit dem beschriebenen Aufbau simulieren wir unter möglichst isolierten Bedingungen nur diese eine Wechselwirkung zwischen mangelnder Dorsalflexion und verfrühtem Bodenkontakt.

Ob und unter welchen Bedingungen bei performance-abhängigen Zyklusabbrüchen die maximale Zykluslänge erreicht und der Referenzverlauf erlernt werden kann, ist

⁶ Eine geeignete Profilhöhe kann aus groben Schätzwerten für $\{P, v\}$ ermittelt werden.

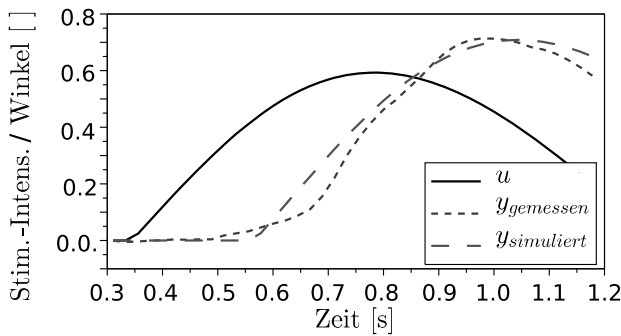


Bild 5 Identifikation der Stimulationsschwingung von der Intensität u der Elektrostimulation zum gemessenen Fußwinkel y .

unklar und wurde unseres Wissens bisher weder theoretisch noch praktisch untersucht. Einen ersten Schritt in diese Richtung stellen die Untersuchungen aus Abschnitt 2.2 und die Experimente in Abschnitt 5 dar. Im Folgenden werden dafür zunächst geeignete Lernmatrizen und Q-Filter entworfen.

4 Systemidentifikation und Reglerentwurf

Die Systemdynamik von der Stimulationsschwingung zum Fußwinkel ist sowohl nichtlinear als auch zeitvariant. Ursachen sind unter anderem die Rekrutierung der motorischen Einheiten und die Kinematik des Gelenkes, aber auch Effekte wie Ermüdung und verschiedene durch die Stimulationsschwingung ausgelöste Reflexe. Ein vollständiges Modell dieser Prozesse wäre nur unter vielen vereinfachenden Annahmen möglich und würde andererseits eine große Menge Parameter liefern, deren Identifikation am individuellen Probanden sehr aufwendig wäre. Da die meisten ILC-Ansätze relativ robust gegenüber Modellfehlern sind, wird stattdessen eine lineare Übertragungsfunktion erster Ordnung mit Totzeit angesetzt und eine experimentelle Identifikation anhand aufgezeichneter Eingangs- und Ausgangsdaten durchgeführt. Dazu werden direkt vor den Experimenten aufgenommene typische Stimulationsschwingungen und deren Antworten verwendet, um das Systemverhalten in der Nähe des Referenzverlaufes abzubilden. Die erhaltene Übertragungsfunktion lautet:

$$G(z) = \frac{1,0494z - 1,0174}{z - 0,9816} z^{-10} \quad (7)$$

Um anhand der identifizierten Übertragungsfunktion den Reglerentwurf durchzuführen, berechnen wir deren Markov-Parameter und stellen die *lifted system matrix* \mathbf{P} auf. Als Lernmatrix wird zunächst eine Diagonalmatrix angesetzt:

$$\mathbf{L}_{\text{diag}}(\lambda) := \lambda \mathbf{I}, \mathbf{L}_{\text{diag}} \in \mathbb{R}^{\tilde{n} \times \tilde{n}}, \lambda \in \mathbb{R}.$$

Mit Hilfe des in Theorem 1 definierten Konvergenz-Indikators γ wird untersucht, inwiefern mit \mathbf{L}_{diag} bei variabler Zykluslänge monotone Konvergenz erreicht werden kann. Bild 6 zeigt, dass dies im Bereich $\lambda \in [0, 1,35]$ der Fall ist und dass für $\lambda \approx 0,95$ die mit




Bild 6 Konvergenzrate in Abhängigkeit der Reglerparameter. Eine diagonale Lernmatrix $\mathbf{L}_{\text{diag}}(\lambda)$ liefert für $\lambda < 1,3$ monotone Konvergenz des MPL-Fehlers. Mit inversionsbasierter Lernmatrix $\mathbf{L}_{\text{inv}}(l_1, l_2)$ lässt sich zumindest theoretisch doppelt so schnelle Konvergenz erreichen.

$\gamma \approx 0,4$ schnellste Konvergenz zu erwarten ist. Hier wird die Norm $\|\mathbf{H}_{n_j} \mathbf{e}_j\|_1$ des Fehlers auf den jeweils ersten n_j Abtastwerten in jedem Zyklus um mindestens 60% reduziert (vgl. (6)).

Noch höhere Konvergenzraten lassen sich mit einem inversionsbasierten Ansatz erreichen. Für $\mathbf{L} = \mathbf{P}^{-1}$ wird der Fehler auf den jeweils ersten n_j Abtastwerten in nur einer Iteration zu Null (vgl. (6) und [12]). Wir berechnen die Inverse der Matrix \mathbf{P} und stellen fest, dass sie annähernd die Struktur folgender zweiparametrischer Lernmatrix aufweist:

$$\mathbf{L}_{\text{inv}}(l_1, l_2) = \begin{pmatrix} l_1 & 0 & 0 & \dots & 0 \\ l_2 & l_1 & 0 & \dots & 0 \\ \frac{(\tilde{n}-2)l_2}{\tilde{n}-1} & l_2 & l_1 & \ddots & 0 \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \frac{l_2}{\tilde{n}-1} & \frac{2l_2}{\tilde{n}-1} & \dots & l_2 & l_1 \end{pmatrix},$$

$$\mathbf{L}_{\text{inv}}(0,9, -0,01) \approx \mathbf{P}^{-1}.$$

Erneut berechnen wir γ , um zu bestimmen, für welche Parameter l_1, l_2 monotone Konvergenz zu erwarten ist, siehe Bild 6. Für $l_1 \approx 0,9, l_2 \approx -0,01$ wird – zumindest für die identifizierte Streckendynamik – sogar eine Fehlerreduktion um mindestens 80% pro Zyklus vorausgesagt.

Abschließend wird ein Q-Filter in Form eines nicht-kausalen Tiefpassfilters entworfen. Analog zu [8] filtern wir einen Einheitsimpuls vorwärts und rückwärts mit einem Butterworth-Filter zweiter Ordnung, um die Einträge der symmetrischen Toeplitzmatrix \mathbf{Q} zu erhalten. Dadurch wird eine Tiefpassfilterung ohne Phasenverschiebung erreicht [1; 3]. Die Grenzfrequenz des Filters wird mit 5 Hz deutlich schneller als die Streckendynamik und der Referenzverlauf gewählt. Dadurch werden die Auswirkungen des Q-Filters auf die zuvor getroffenen Konvergenzaussagen minimiert.

5 Experimentelle Ergebnisse

In wiederholten Experimenten wird die Konvergenz der Zykluslänge für verschiedene Reglereinstellungen und unterschiedliche initiale Stimulationsschwingungen \mathbf{u}_1

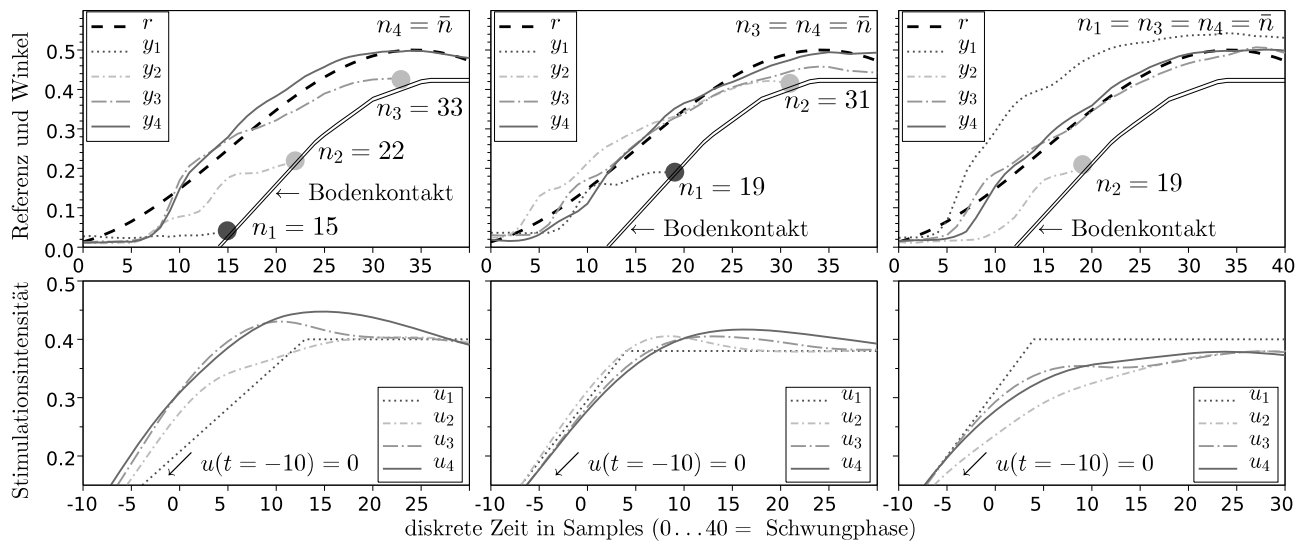


Bild 7 Stimulationsprofile und Winkelverläufe für ILC-geregelte (diagonale Lernmatrix mit *phase lead*, $\lambda = 0,6$, $\phi = 10$) Fußhebung bei einem gesunden Probanden. *Links*: Die ILC erlernt aus drei abgebrochenen Zyklen das nahezu zum gewünschten Winkelverlauf führende Stimulationsprofil. *Mitte*: Bei besser gewähltem u_1 wird die volle Zykluslänge früher erreicht. *Rechts*: Wählt man u_1 jedoch zu hoch, wird $y_1 > r$ und der folgende Lernschritt kann zum Zyklusabbruch führen.

untersucht. Bei etwas zu niedrig eingestelltem Stimulationsprofil bricht der erste Zyklus entsprechend früh ab und die gekoppelte Lern- und Zykluslängendynamik kann untersucht werden. Für die diagonale Lernmatrix L_{diag} wird hinreichend schnelles Erreichen der maximalen Zykluslänge für Verstärkungen $\lambda \in [0,3, 0,7]$ festgestellt. Die experimentell ermittelten mittleren Konvergenzraten liegen je nach Versuch zwischen 0,2 und 0,7. Im Bereich $\lambda \in [0,1, 0,2]$ tritt sehr langsame Konvergenz, d. h. $n_j < \bar{n} \forall j < 10$, auf. Für $\lambda \in [0,8, 1,1]$ kommt es im Wechsel mit sehr guter Fehlerreduktion auch immer wieder zu einem Aufschwingen des Fehlers und dadurch zur Verringerung der Zykluslänge.

Einige Ergebnisse für $\lambda = 0,6$ sind in Bild 7 dargestellt und unter [14] als Videos verfügbar. In Abhängigkeit vom initialen Stimulationsprofil wird in zwei bis drei Lernschritten der gesamte Referenzverlauf erlernt. Allerdings fällt auf, dass die Ausgangstrajektorien trotz des vereinfachten Versuchsaufbaus zufälligen Schwankungen unterliegen, die die Analyse erschweren. Unter anderem deshalb kann für die inversionsbasierte Lernmatrix L_{inv} trotz einiger Zyklen mit sehr guter Fehlerreduktion kein signifikant verbessertes Konvergenzverhalten nachgewiesen werden.

Des Weiteren lässt Bild 7 deutliche Unterschiede zwischen den Stimulationsprofilen, die im jeweiligen Versuch zum gewünschten Fußwinkelverlauf führten, erkennen. Auch nach dessen Erreichen wurden jeweils langsame Veränderungen im Stellgrößenprofil beobachtet. Dies lässt auf iterationsvariante Störungen und/oder Dynamik schließen, die neben Ermüdung der Muskeln noch viele weitere Ursachen haben können. Die Veränderungen sind jedoch langsam genug, sodass die ILC das Stimulationsprofil entsprechend anpassen kann.

6 Zusammenfassung und Diskussion

In diesem Beitrag wurde die iterativ lernende Regelung der Dorsalflexion des Fußes über funktionelle Elektrostimulation betrachtet. Speziell wurde untersucht, ob und wie trotz verfrühten Bodenkontakts infolge unzureichender Stimulation der gewünschte Fußwinkelverlauf durch iteratives Verbessern des Stimulationsprofils erreicht werden kann. Geeignete ILC-Konzepte für Systeme mit variablen Zykluslängen wurden vorgestellt und angewendet, um Aussagen über die Konvergenz der gekoppelten Lern- und Zykluslängendynamik zu treffen. Basierend auf neuen Kriterien für die monotone Konvergenz solcher Systeme wurden zwei Lernmatrizen und ein Q-Filter entworfen und unter idealisierten experimentellen Bedingungen erprobt.

Einerseits wurden einige Unterschiede zwischen den Vorhersagen der Theorie und den experimentellen Ergebnissen aufgezeigt, die sich vor allem durch die geringe Modellgüte und die FES-typischen zufälligen Schwankungen in der Ausgangstrajektorie erklären lassen. Andererseits zeigen Theorie und Experiment übereinstimmend, dass sich auch bei unzureichendem initialen Stimulationsprofil in wenigen Lernschritten maximale Zykluslänge und ein hinreichend kleiner Tracking-Fehler erreichen lassen. Das ist insofern bedeutend, als dass es aufgrund der hohen Individualität und Zeitvarianz der Stimulationsdynamik in der Praxis selten möglich ist, ein gutes initiales Stimulationsprofil vorherzusagen.

In Fällen, in denen verfrühter Bodenkontakt aufgrund der damit einhergehenden Sturzgefahr um jeden Preis zu vermeiden ist, besteht ein möglicher Ansatz für weitere Untersuchungen darin, absichtlich ein zu hohes initiales Stimulationsprofil einzusetzen und ein asymmetrisches Lerngesetz zu verwenden, bei dem sich ein zu hoher Fuß-

winkel weniger stark auf die Stellgröße auswirkt als ein um denselben Betrag zu kleiner Fußwinkel. Letzteres wäre nötig um „Rückfälle“ wie in Bild 7, rechter oberer Teil, zu vermeiden.

Die Tatsache, dass trotz des kurzen Zeithorizonts und iterationsvarianter Einflüsse der gewünschte Fußwinkelverlauf eingestellt werden konnte, verdeutlicht, dass eine kontinuierliche iterative Anpassung des Stimulationprofils durch ILC-Algorithmen für die Regelung der FES-unterstützten Fußhebung eine gute Strategie darstellt. Neben dem hier untersuchten Phänomen des verfrühten Bodenkontakts infolge mangelnder Stimulation treten jedoch in der realen Anwendung eine Reihe weiterer Herausforderungen auf, die hier durch den vereinfachten Versuchsaufbau ausgeschlossen wurden. Unter anderem Stellgrößenättigung, variierende Ganggeschwindigkeit und die Erzeugung einer möglichst geraden Fußhebung, d. h. ohne Inversion und Eversion des Fußes, stellen ungelöste Probleme dar und werden Gegenstand weiterer theoretischer und experimenteller Untersuchungen sein.

Auf der technologischen Seite ist in diesem Kontext einerseits der Einsatz eines Elektrodenarrays zu erwägen. Andererseits könnte im Hinblick auf die Anwendung während des Gehens die Verwendung weiterer Inertialsensoren sinnvoll sein, um zusätzlich die Unterschenkelbewegung bzw. den Gelenkwinkel zu erfassen oder den kontralateralen Fußwinkelverlauf zu bestimmen und als Referenz für die ILC einzusetzen.

Danksagung

Vielen Dank an unsere Gutachter für die wertvollen Hinweise, an Ahn Tuan Le für die Unterstützung bei den Experimenten und an Sophia Rudorf für die Gestaltung der ersten Abbildung.

Literatur

- [1] D. A. Bristow, M. Tharayil, A. G. Alleyne. A Survey of Iterative Learning Control. *IEEE Control Systems Magazine*, 26(3):69–114, 2006.
- [2] A. Duschau-Wicke, A. Morger, H. Vallery, R. Riener. Adaptive Patient Support for Rehabilitation Robots. *at – Automatisierungstechnik*, 58(5):260–268, 2010.
- [3] H. Elci, R. W. Longman, M. Q. Phan, J. N. Juang, R. Ugoletti. Simple Learning Control Made Practical by Zero-Phase Filtering: Applications to Robotics. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 49(6):753–767, 2002.
- [4] C. T. Freeman, A.-M. Hughes, J. H. Burridge, P. H. Chappell, P. L. Lewin, E. Rogers. Iterative learning control of FES applied to the upper extremity for rehabilitation. *Control Engineering Practice*, 17(3):368–381, 2009.
- [5] M. Hayashibe, Q. Zhang, C. Azevedo-Coste. Dual predictive control of electrically stimulated muscle using biofeedback for drop foot correction. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 1731–1736, 2011.
- [6] C. Klauer, T. Schauer, J. Raisch. High Performance Motion Control by Neuro-Muscular Electrical Stimulation Applied to the Upper-Limb. *Proceedings of the 15th Annual IFESS Conference and 10th Vienna Int. Workshop on FES*, 318–320, 2010.
- [7] N. Mourselas, M. H. Granat. Correction of Drop Foot Using a Fuzzy Logic Controlled Miniature Stimulator. *Proc. of the 5th Annual Conference of the International FES Society*, 140–141, 2000.
- [8] H. Nahrstaedt, T. Schauer, S. Hesse, J. Raisch. Iterativ Lernende Regelung einer Gang-Neuroprothese. *at – Automatisierungstechnik*, 56(9):494–501, 2008.
- [9] H. Nahrstaedt, T. Schauer, R. Shalaby, S. Hesse, J. Raisch. Automatic Control of a Drop-Foot Stimulator Based on Angle Measurement Using Bioimpedance. *Artificial Organs*, 32(8):649–654, 2008.
- [10] N.-O. Negård. Controlled FES-assisted gait training for hemiplegic stroke patients based on inertial sensors. *Doctoral Thesis*, TU Berlin, 2009.
- [11] W. Paszke, E. Rogers, K. Galkowski. On the Design of ILC Schemes for Finite Frequency Range Tracking Specifications. *IEEE Conf. on Decision & Control*, 2010.
- [12] T. Seel, T. Schauer, J. Raisch. Iterative Learning Control for Variable Pass Length Systems. *IFAC World Congress*, pp. 4880–4885, 2011. <http://dx.doi.org/10.3182/20110828-6-IT-1002.02180>.
- [13] Y. Wang, E. Dassau, F. J. Doyle 3rd. Closed-Loop Control of Artificial Pancreatic Beta-Cell in Type 1 Diabetes Mellitus Using Model Predictive Iterative Learning Control. *IEEE Trans Biomed Engin*, 57(2):211–9, 2010.
- [14] http://www.control.tu-berlin.de/ILC_of_FES-Assisted_Gait.

Manuskripteingang: 15. Oktober 2012



Dipl.-Ing. Thomas Seel hat Systemtechnik und technische Kybernetik an der OvGU Magdeburg und der UCSB studiert und ist seit 2010 am Fachgebiet Regelungssysteme der TU Berlin. Hauptarbeitsgebiete: Theorie und Anwendung von ILC in der Biomedizintechnik und Inertialsensorbasierte Bewegungsanalyse.

Adresse: Fachgebiet Regelungssysteme, Einsteinufer 17 EN11, D-10587 Berlin,
E-Mail: seel@control.tu-berlin.de



Dr. Thomas Schauer ist wissenschaftlicher Mitarbeiter und Leiter der Arbeitsgruppe Technische Assistenzsysteme in der Medizin am Fachgebiet Regelungssysteme an der Technischen Universität Berlin. Hauptarbeitsgebiete: Mess- und Automatisierungstechnik in der Medizin, Neurologische Rehabilitation.

Adresse: Fachgebiet Regelungssysteme, Einsteinufer 17 EN11, D-10587 Berlin,
E-Mail: schauer@control.tu-berlin.de



Prof. Dr.-Ing. Jörg Raisch leitet das Fachgebiet Regelungssysteme an der Fakultät für Elektrotechnik und Informatik der TU Berlin. Er ist externes wissenschaftliches Mitglied des Max-Planck-Instituts für Dynamik komplexer technischer Systeme in Magdeburg und leitet dort die Fachgruppe System- und Regelungstheorie.

Adresse: Fachgebiet Regelungssysteme, Einsteinufer 17 EN11, D-10587 Berlin,
E-Mail: raisch@control.tu-berlin.de