

Online-Schätzung von mechanischen Parametern und Kennlinien durch Integration von Basisfunktionsnetzwerken in Erweiterte Kalman-Filter

Stephan Beineke, Frank Schütte, Horst Grotstollen

Leistungselektronik und elektrische Antriebstechnik

Universität Paderborn, FB 14 LEA

Pohlweg 47–49, 33098 Paderborn, Germany

Tel.: ++49-5251-602212

Fax.: ++49-5251-603443

e-mail: beineke@lea.uni-paderborn.de

Kurzbiographie:

Stephan Beineke, geboren 1967 in Höxter, Deutschland. Studium der Elektrotechnik mit Schwerpunkt Nachrichtentechnik an der Universität Paderborn von 1988 bis 1994.

Seit 1994 arbeitet er als wissenschaftlicher Mitarbeiter im Fachgebiet Leistungselektronik und elektrische Antriebstechnik bei Prof. Dr.-Ing. H. Grotstollen im Bereich der Regelung und Identifikation von elektrischen Antriebssystemen, wobei insbesondere Erweiterte Kalman-Filter und gut interpretierbare neuronale Netze (Neuro-Fuzzy-Techniken) eingesetzt werden.

Online-Schätzung von mechanischen Parametern und Kennlinien durch Integration von Basisfunktionsnetzwerken in Erweiterte Kalman-Filter

Dipl.-Ing. Stephan Beineke, Dipl.-Ing. Frank Schütte, Prof. Dr.-Ing. Horst Grotstollen
Universität Paderborn, FB 14 LEA, Pohlweg 47–49, 33098 Paderborn, Germany
Tel.: ++49-5251-602212, Fax: ++49-5251-603443, e-mail: beineke@lea.uni-paderborn.de

Kurzfassung:

Erweiterte Kalman-Filter werden zur Schätzung mechanischer Parameter angewandt und für deterministische Parameter- und Lastmomentvariationen optimiert, indem Basisfunktionsnetzwerke in die gewöhnliche Kalman-Filter Struktur integriert werden. Das Prinzip und die erzielten Verbesserungen werden für starre mechanische Systeme (Einmassensysteme) anhand der Schätzungen einer Reibkennlinie und einer Kennlinie, die die Variation des Massenträgheitsmomentes beschreibt, vorgestellt und bewertet.

1 Einleitung

Werden in industriellen Servoreglern Antriebsregelungen mit verbessertem Führungs- und Störverhalten implementiert, so können Taktraten erhöht und die Qualität von Produkten verbessert werden. Die zu entwickelnden Drehzahlregelungen mit höherer Dynamik und Genauigkeit müssen an die wesentlichen mechanischen Eigenschaften (z. B. Elastizitäten, Reibung und Lose) der Arbeitsmaschine und der mechanischen Übertragungselemente angepaßt werden [1].

Ändern sich im laufenden Betrieb die Parameter durch den Prozeß bedingt arbeitspunktabhängig oder durch Verschleiß und Umwelteinflüsse, so sind die Reglerparameter zu adaptieren, um weiterhin eine gleichzeitig hochdynamische und robuste Regelung gewährleisten zu können. Hierzu wird in diesem Beitrag eine adaptive Regelung mit Online-Identifikation vorgestellt, die in sich ebenso die Möglichkeit zur modellgestützten Überwachung und Fehlerdiagnose durch Auswertung der Identifikationsergebnisse einschließt.

Bezüglich der Online-Identifikation ergeben sich folgende prinzipielle Schwierigkeiten:

- Zur Identifikation muß stets genügend Systemanregung sichergestellt sein, da anderenfalls die Schätzergebnisse divergieren. Für die Auslegung des Online-Schätzverfahrens muß also die durch den Prozeß gegebene Anregung analysiert werden.
- Veränderliche Lastmomente wirken auf den Schätzalgorithmus als Störungen, wenn sie durch den Modellansatz nicht berücksichtigt werden, wodurch die Schätzergebnisse vorübergehend gestört, bei ständigem Auftreten sogar stark verfälscht werden können.

Innerhalb dieses Beitrags wird zunächst davon ausgegangen, daß stetige Systemanregung vorhanden ist. Falls diese Annahme nicht zutrifft, sind einfache Erweiterungen, mit denen ausreichende Systemanregung überwacht bzw. sichergestellt werden kann, in [3] dargestellt.

Als Adaptionalgorithmus eignet sich das Erweiterte Kalman-Filter (EKF) [3] prinzipiell sehr gut zur schnellen Online-Identifikation. In vielen Anwendungsfällen sind die Variationen von Lastmomenten und Parametern im wesentlichen vom Arbeitspunkt abhängig und können durch einen nichtlinearen Zusammenhang in Form einer Kennlinie beschrieben werden. Dieses motiviert die hier vorgestellte neue Struktur, nämlich Erweiterte Kalman-Filter mit integrierten Basisfunktionsnetzwerken, die eine deutliche Verbesserung der Online-Schätzergebnisse bei deterministischen Last- oder Parametervariationen und eine Identifikation nichtlinearer Kennlinien ermöglicht.

2 Erweitertes Kalman-Filter mit Basisfunktionsnetzwerken

Die Kombination aus Erweitertem Kalman-Filter (EKF) [3] als Adaptionalgorithmus und Basisfunktionsnetzwerken (BFN) [6] zur Speicherung der nichtlinearen Kennlinien wurde aus folgenden Gesichtspunkten gewählt:

Das EKF berücksichtigt alle vorhandenen Kenntnisse über Modellstruktur, bekannte Modellparameter und abzuschätzende Modellunsicherheiten und stellt aufgrund seiner rekursiven Formulierung einen effizienten Algorithmus für Online-Anwendungen dar. Für die Schätzaufgaben besitzt das in [3] ausführlich vorgestellte, kontinuierlich-diskrete EKF eine angepaßte Struktur, weil zum einen der mechanische Teil des Antriebs als kontinuierliches System mit Hilfe eines Integrationsverfahrens im Prädiktionsschritt nachgebildet werden kann, was die durch die Diskretisierung verursachten Modellungenauigkeiten minimiert, und zum anderen der Korrekturschritt aufgrund der diskreten Meßwerterfassung nur zu bestimmten Zeitpunkten erfolgen kann. Beim EKF wird der Vektor der Zustandsgrößen x_S um den Vektor der zu schätzenden Parameter x_P augmentiert, so daß sich formal der mathematische Zustandsvektor $x = (x_S, x_P)^T$ ergibt. Parameter- und Lastmomentvariation werden innerhalb des EKF mit Hilfe eines modellierbaren (deterministischen) Anteils $f_P(x, u)$ und eines a-priori unbekanntes (stochastischen) Anteils $q_P(t)$, der als weißes Rauschen angenommen wird, berücksichtigt:

$$\frac{dx_P}{dt} = f_P(x, u) + q_P(t) \quad (1)$$

Liegen keine Vorkenntnisse vor, so ist nur der stochastische Anteil vorhanden.

Das Ein/Ausgangsverhalten eines BFN ist durch die gewichtete Summierung des durch die Basisfunktionen Φ_i transformierten Eingangsvektors u_N gegeben:

$$y_N(u_N, t_k) = \sum_i \Phi_i(u_N, t_k) \hat{w}_i(t_k) = \Phi^T(u_N, t_k) \hat{w} \quad (2)$$

Ein BFN ist somit in der Lage, beliebige nichtlineare Kennlinien, z. B. die in Bild 1 dargestellte Reibkennlinie, zu approximieren. Mit Hilfe des sehr einfachen Least-Mean-Squares-Verfahrens (LMS) [6] werden die Gewichte \hat{w} des BFN online adaptiert. Da sich das LMS-Verfahren einfach analysieren läßt, kann das BFN gut in Beobachterstruk-

turen [2] sowie in Erweiterte Kalman-Filter integriert werden. Die Eingangsgrößen des BFN können in diesem Fall direkt meßbare Größen \mathbf{u} oder wiederum intern geschätzte Zustandsgrößen \mathbf{x} sein, es gilt also $\Phi(\mathbf{u}_N) \rightarrow \Phi(\mathbf{u}, \mathbf{x})$. Verschiedene Strukturen für die Integration von BFN in EKF sind bereits in [4] ausführlich behandelt worden.

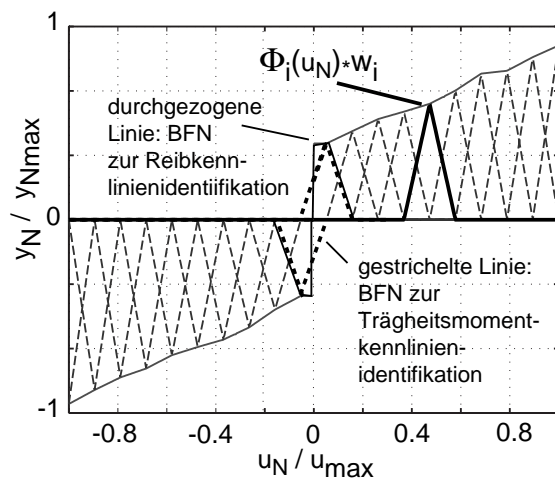


Bild 1: Basisfunktionen zur Approximation der nichtlinearen Kennlinien

Dargestellt sind die gewichteten Basisfunktionen und das Schätzergebnis für eine Reibkennlinie.

Die gestrichelt gezeichneten Basisfunktionen ergeben das Netzwerk, das zur Identifikation der Massenträgheitsmomentkennlinie verwendet wurde

Das Prinzip der integrierten Struktur besteht darin, die neuen Meßdaten zunächst zur Adaption (Korrekturschritt) des EKFs zu benutzen, und dann diese neu gewonnene Information im BFN als Kennlinie abzuspeichern. Wird die im BFN gespeicherte Information wiederum vom EKF (im Prädiktionsschritt) verwendet, so muß sich das EKF bei ständigen Arbeitspunktänderungen nicht jeweils neu adaptieren, sondern das EKF kann die bereits gespeicherte Information für die Prädiktion nutzbar machen (Gedächtnisfunktion). Da das gesamte adaptive Modell (EKF mit integriertem BFN) sowohl die Fähigkeit zur Adaption als auch diese Gedächtnisfunktion beinhaltet, kann es als „lernfähig“ bezeichnet werden. Dies geschieht formal durch die Integration der neu gewonnenen Erkenntnisse in die Systemfunktion, so daß sich durch partielle Ableitung für die Parameter- bzw. Lastmomentvariationen die Systemgleichung

$$\frac{d}{dt} \mathbf{x}_P = \frac{d}{dt} \mathbf{y}_N(\mathbf{x}, \mathbf{u}) + \mathbf{q}_P = \frac{\partial \mathbf{y}_N}{\partial \mathbf{x}} \cdot \frac{d\mathbf{x}}{dt} + \frac{\partial \mathbf{y}_N}{\partial \mathbf{u}} \cdot \frac{d\mathbf{u}}{dt} + \mathbf{q}_P \quad (3)$$

ergibt. Mit dieser Maßnahme können nach und nach die Kennlinien im BFN gelernt und die Schätzergebnisse des EKFs verbessert werden.

3 Modellierung der Mechanik und Implementierung der Algorithmen

Die erzielbaren Verbesserungen sollen anhand zweier experimenteller Beispiele demonstriert werden. Um die grundlegende Idee des Ansatzes zu zeigen, werden die Ergebnisse für den relativ einfachen Fall einer starren Mechanik vorgestellt, die als Einmassensystem modelliert wurde, so daß im wesentlichen das Lastmoment M_L als Zustandsgröße und das Gesamtträgheitsmoment J_Σ als Parameter zu schätzen sind. Das dem EKF-Entwurf zugrunde liegende Modell wird durch die Gleichung

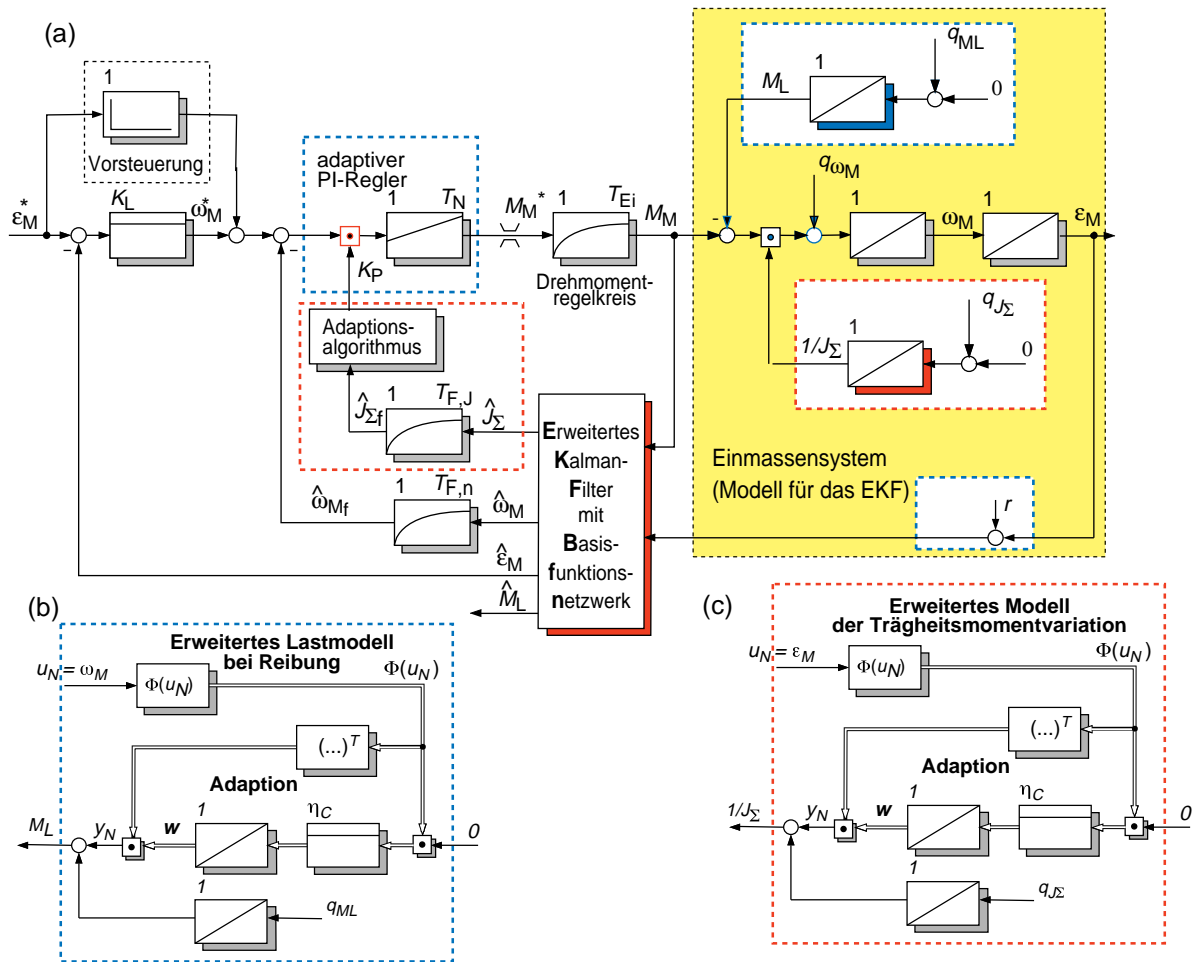


Bild 2: Struktur des adaptiven Lageregelkreises und Modell des Einmassensystems für den EKF-Entwurf (a); BFN als erweiterte Modelle für die Variation von Lastmoment (b) und Trägheitsmoment (c)

$$\frac{d}{dt} \begin{bmatrix} \varepsilon_M \\ \omega_M \\ M_L \\ 1/J_\Sigma \end{bmatrix} = f(x, u) + q = \begin{bmatrix} \omega_M \\ 1/J_\Sigma \cdot (-M_L + K_M \cdot i_q) \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} q_{\varepsilon M} \\ q_{\omega M} \\ q_{M_L} \\ q_{J_\Sigma} \end{bmatrix} \quad (4)$$

beschrieben und ist in Bild 2 als Wirkungsplan dargestellt. Die Inverse des Trägheitsmomentes wird als Zustandsgröße verwendet, um den Linearisierungsfehler möglichst gering zu halten. Als meßbare Größen stehen die drehmomentbildende Stromkomponente i_q bzw. das Motormoment $M_M = K_M \cdot i_q$ als Eingangsgröße des Modells und die Motorlage ε_M als Ausgangsgröße zur Verfügung, woraus als Meßgleichung

$$y(t) = \varepsilon_M(t) + r(t) \quad (5)$$

resultiert. Es wird davon ausgegangen, daß a-priori nicht bekannt ist, wie sich Trägheits-

moment und Lastmoment ändern werden, so daß diese Größen im Modell als Ausgänge von Integratoren mit einem deterministischen Anteil 0 und einem Rauschanteil q_{ML} bzw. $q_{J\Sigma}$ angenommen werden. Dem im Bild 2 ebenfalls dargestellten P-Lageregler mit Vorsteuerung der Drehzahl und unterlagertem PI-Drehzahlregelkreis wird bei den Experimenten jeweils eine Solltrajektorie vorgegeben. Durch diese Trajektorie ist ausreichende Systemanregung zur Parameterschätzung sichergestellt, was im konkreten Fall bedeutet, daß die erzielte Beschleunigung des Antriebs zur Bestimmung des Trägheitsmomentes hinreichend ist. Die P-Verstärkung des Reglers wird in Abhängigkeit vom gefilterten geschätzten Parameter J_Σ adaptiert und für die Regelung werden die vom EKF gefilterten Größen verwendet. Die Algorithmen wurden auf einem DSP Board (dSPACE DS1003) mit TMS320C40 Signalprozessor implementiert, und die Messungen wurden an einem geeigneten mechanischem Aufbau mit einer permanent erregten Synchronmaschine (PSM) durchgeführt. Das EKF wird mit einer Abtastzeit von $500\mu s$ berechnet und zur Abarbeitung des Algorithmus werden $61\mu s$ benötigt. Da die lokalen Basisfunktionen gemäß Bild 1 verwendet werden und somit jeweils nur 2 Gewichte zu adaptieren sind, wird durch die Integration des BFN die Gesamtrechnenzeit kaum verlängert und im wesentlichen der Programmcode beeinflusst. Die Implementierung wird durch die Verwendung von Floating-Point Arithmetik wesentlich vereinfacht. Die Daten des Antriebs und die Parameter der im Bild 2 dargestellten Regelungsstruktur sind gegeben durch:

PSM: $J_{\Sigma, off} = 0,0137 kgm^2$, $i_{qmax} = 15A$, $K_M = 1,272 Nm/A$, $M_N = 7 Nm$
 Zeitkonstanten der Filter: $T_{E,i} = 0,2ms$, $T_{F,J} = 1ms$, $T_{F,n} = 1,5ms$
 Reglerparameter: $K_L = 28/s$, $T_N = 8,9ms$, $K_P(t) = 2(J_{\Sigma f}(t)/(T_N K_M))$

4 Identifikation einer Parameterkennlinie

In dem ersten Experiment ist das Trägheitsmoment des Antriebs als Funktion des Winkels ε_M gegeben. Um diese Kennlinie identifizieren zu können, wird der einfache Integrator zur Modellierung der Parametervariation durch ein BFN mit dem Winkel ε_M als Eingangsgröße und dem inversen Trägheitsmoment $1/J_\Sigma$ als Ausgangsgröße gemäß Bild 2 (c) ersetzt.

Die Varianz R des Meßrauschens $r(t)$ wird direkt von der effektiven Auflösung des Inkrementalgebers (ca. 17 bit/Umdrehung) abgeleitet, und man erhält $R = 5,75e^{-10} rad^2$.

Die Rauschmatrix Q ist ein Maß für die Modellunsicherheiten und zusätzliche Störungen. Zur Vereinfachung wird unkorreliertes Rauschen angenommen, so daß sich Q als Diagonalmatrix mit den 4 Rauschparametern $Q = diag(q_{\varepsilon M}, q_{\omega M}, q_{ML}, q_{J\Sigma})$ ergibt.

Dabei bestimmt q_{ML} direkt die Dynamik der Lastmomentschätzung und $q_{J\Sigma}$ die entsprechende Dynamik der J_Σ -Schätzung. Der Parameter $q_{\varepsilon M}$ wird zu Null gesetzt, da die Gleichung $d\varepsilon_M/dt = \omega_M$ offensichtlich exakt ist, also kein Rauschen enthält. $q_{J\Sigma}$ wird anhand des aktuellen Schätzwertes J_Σ zum Zeitpunkt t_k und bezogen auf das offline bestimmte oder abgeschätzte Anfangsträgheitsmoment $J_{\Sigma off}$ adaptiert. Da die Parameteränderung während dieses Experimentes relativ schnell ist (Verzehnfachung innerhalb von 0,7 s), wird für $q_{J\Sigma}$ ein sehr großer Wert gewählt:

$$q_{J\Sigma}(t_k) = \tilde{q}_{J\Sigma} \cdot (\tilde{J}_\Sigma(t_k)/J_{\Sigma off})^2, \text{ mit } \tilde{q}_{J\Sigma} = 5(kgm^2)^{-2} \quad (6)$$

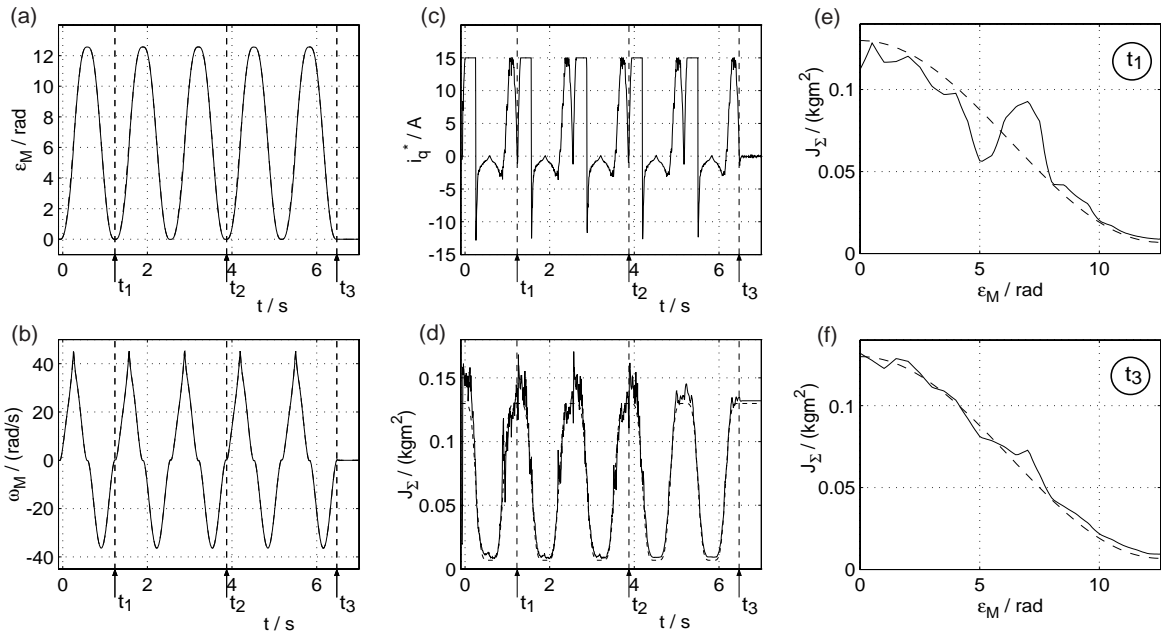


Bild 3: Identifikation einer Trägheitsmomentkennlinie

Werden zusätzlich Annahmen bezüglich des Fehlers in der Gleichung für die Variation $d\omega_M/dt$ getroffen, die an dieser Stelle nicht näher erläutert werden sollen, so wird die Kovarianzmatrix aus diesen physikalischen Betrachtungen vervollständigt:

$$\mathbf{Q} = (0, 5e^{-5}(\text{rad/s})^2, 5e^{-4}(\text{Nm})^2, q_{J_\Sigma}(t_k)). \quad (7)$$

Die Variation des Trägheitsmomentes wird mittels Hardware-in-the-Loop-Simulation durch einen starr gekoppelten Belastungsantrieb nachgebildet.

Im Bild 3 sind die Verläufe von Solltrajektorie (a), Geschwindigkeit (b) und drehmomentbildendem Strom (c), sowie der Verlauf des geschätzten Trägheitsmomentes (d) angegeben. Zunächst wird der vom EKF geschätzte Verlauf des Trägheitsmomentes lediglich im BFN gespeichert, aber nicht für die Prädiktion verwendet. Damit ergibt sich zum Zeitpunkt t_1 die in Bild 3 (e) gespeicherte Kennlinie, die bei alleiniger Schätzung mit dem EKF nicht weiter verbessert wird. Die relativ schlechte Schätzung im mittleren Bereich der Kennlinie ist dadurch zu erklären, daß gerade an diesen Stellen nur geringe Systemanregung vorliegt. Eine Verbesserung der Schätzung wird nun dadurch erzielt, indem das BFN so integriert wird, daß es auch zur Prädiktion verwendet wird. Zu Beginn wird das Netzwerk mit einer normalisierten Lernrate von $\eta = 1$ trainiert. Man erkennt, daß das Rauschen in der Schätzung im Intervall $[t_1, t_2]$ nahezu konstant bleibt. Weil nun die im BFN gespeicherte Information zur Prädiktion verwendet wird, wird die Unsicherheit in der Schätzung von J_Σ und damit das Systemrauschen verkleinert, und die Lernrate kann weiter verringert werden. In der Tat wirken sich beim EKF mit integriertem BFN eine Verringerung des Rauschparameters q_{J_Σ} und eine Reduzierung der Lernrate η sehr ähnlich aus. Im Intervall $[t_2, t_3]$ wird $\eta = 0,1$ gewählt und es ergibt sich der in Bild 3 (d) gezeigte wesentlich geringer verrauschte Schätzverlauf. Das BFN bewirkt also eine zusätzliche Filterung und es resultiert die in Bild 3 (f) dargestellte, zum Zeitpunkt t_3 im BFN gespeicherte Kennlinie. Man erkennt, daß die Kennlinie gut gelernt werden kann

und der Algorithmus in der Lage ist, auch der sehr schnellen Änderung von J_{Σ} zu folgen. Das hier dargestellte Vorgehen in mehreren Schritten erweist sich als sehr effektiv:

1. Schritt: das BFN wird lediglich dazu verwendet, um den vom EKF geschätzten Verlauf zu speichern (sogenannte parallele Struktur), der Verlauf wird grob gelernt
2. Schritt: das Schätzergebnis wird durch eine Integration des BFN in den Prädiktions-schritt des EKF sukzessive verbessert. Eine verbesserte Filterung erhält man durch Reduzierung der Lernrate.

Diese Resultate lassen die Schlußfolgerung zu, daß insbesondere bei schneller Parametervariation und geringer Systemanregung die erzielbaren Ergebnisse durch die Integration der BFN in das EKF wesentlich verbessert werden können.

5 Verbesserung des Schätzverhaltens bei Reibung und Identifikation einer Reibkennlinie

Im zweiten Beispiel soll der Parameter J_{Σ} bei vorhandener Reibung geschätzt werden. Die Reibkennlinie wird durch ein BFN mit der geschätzten Geschwindigkeit ω_M als Eingangs- und dem Lastmoment M_L als Ausgangsgröße und einer normalisierten Lernrate $\eta = 0,1$ identifiziert.

Die Rauschparameter sind ähnlich gewählt wie im vorausgegangenem Abschnitt, lediglich der Parameter $q_{J_{\Sigma}}$ wird verkleinert, da im Voraus bekannt ist, daß der Parameter J_{Σ} sich nur relativ langsam ändert und zum anderen der bei den nachfolgenden Messungen zu beobachtende, störende Einfluß der Coulombschen Reibung verringert werden soll. Als Kovarianzmatrix des Systemrauschens ergibt sich:

$$\mathbf{Q} = \text{diag}\left(0, 5e^{-5}\left(\frac{\text{rad}}{\text{s}}\right)^2, 5e^{-4}(\text{Nm})^2, q_{J_{\Sigma}}(t_k)\right) \text{ mit } q_{J_{\Sigma}}(t_k) = 1e^{-3}(\text{kgm}^2)^{-2} \cdot \left(\frac{\hat{J}_{\Sigma}(t_k)}{J_{\Sigma\text{off}}}\right) \quad (8)$$

Zur Durchführung der Experimente wird der PSM-Antrieb über einen Zahnriemen mit einem zweiten Motor gekoppelt, an dessen Schwungscheibe axial eine mechanische Bremse angebracht wird. Die resultierende Eigenfrequenz von $f_e = 85\text{Hz}$ bedeutet ein zusätzliches Systemrauschen, da diese Dynamik nicht innerhalb des EKF modelliert wird. Um das Schätzverhalten des normalen EKF (mit parallelem BFN) und des EKF mit integriertem BFN unmittelbar vergleichen zu können, wird auf eine Adaption des Drehzahlreglers verzichtet, da somit dieselben Eingangssignale für beide Schätzungen vorliegen. Wiederum wird die in Bild 4 (a) dargestellte Lagetrajektorie als Sollwert vorgegeben, so daß sich die darunter dargestellten Verläufe der Geschwindigkeit (b) und des drehmomentbildenden Motorstromes (c) ergeben.

Zunächst erfolgt die Schätzung mit dem normalen EKF, wobei die Ergebnisse des EKF im BFN lediglich abgespeichert und nicht für die Prädiktion des EKFs benutzt werden (sogenannte parallele Struktur). Das Trägheitsmoment (f) wird aufgrund der vorhandenen Reibung nicht richtig geschätzt, weil durch die im Modell nicht berücksichtigte Coulombsche Reibung ständige, annähernd sprungförmige Störungen auf den Schätzalgorithmus einwirken. Diese werden durch das EKF nicht nur mit dem Lastmoment korreliert, sondern in diesem Fall als zusätzliches Trägheitsmoment interpretiert. Dies wirkt sich wiederum auf den Verlauf der Lastmomentschätzung (d) aus, so daß auch die Reib-

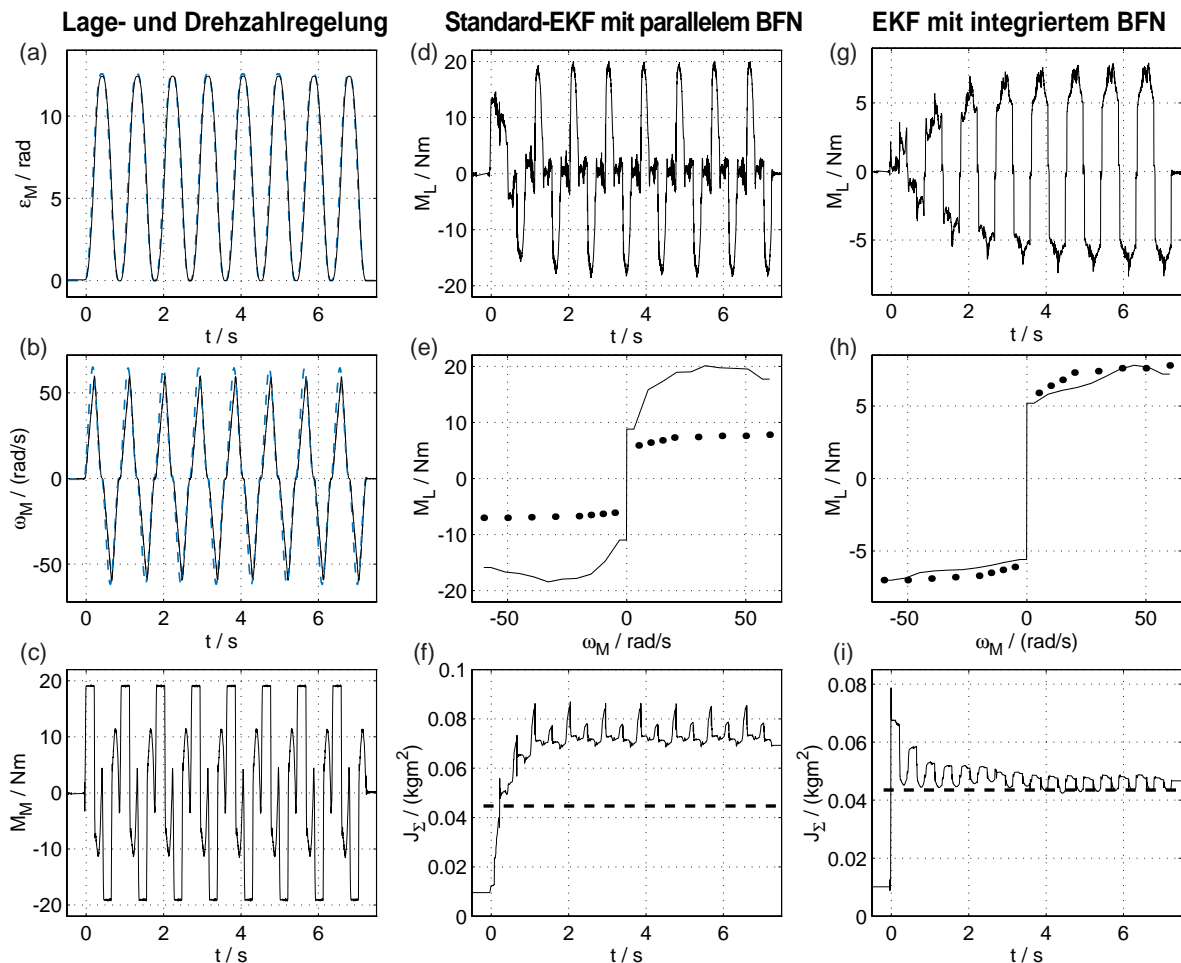


Bild 4: Schätzergebnisse für die Identifikation des Trägheitsmomentes und einer Reibkennlinie

kennlinie (e) nicht richtig geschätzt werden kann.

Berücksichtigt man nun die Reibung, indem als Störgrößenmodell anstelle des einfachen Integrators ein BFN mit der geschätzten Geschwindigkeit als Eingangsgröße und dem Lastmoment als Ausgangsgröße gemäß Bild 2 (b) verwendet und dieses in das EKF integriert wird (integrierte Struktur), so wird nach und nach die Kennlinie erlernt, wie aus dem Verlauf des geschätzten Lastmomentes in Bild 4 (g) ersichtlich, und das Schätzergebnis für J_{Σ} wird verbessert (i). Die am Ende des Experimentes im BFN gespeicherte Reibkennlinie ist in (h) dargestellt. Die Punkte in (e) und (h) geben die durch stationäre Messungen bestimmten Reibwerte des Antriebs an.

Da das verwendete Entwurfsverfahren auf einer Linearisierung im Arbeitspunkt beruht, ist eine Adaption für nicht differenzierbare Kennlinien kritisch. Daher wird im Bereich sehr kleiner geschätzter Drehzahlen ($|\hat{\omega}_M| < 0,3 \text{ rad/s}$) eine Totzone für die Adaption des BFN eingeführt, um Grenzyklen in der Schätzung, wie sie bekanntermaßen bei schaltenden Reglern auftreten können, zu vermeiden.

Daher ist mit diesem Schema eine Identifikation der Reibung bei sehr kleinen Drehzahlen bislang nicht möglich.

6 Bewertungen

Für die Bewertung der Einsatzmöglichkeiten von Online-Schätzverfahren erscheint es sinnvoll, zwischen den durch den Prozeß bedingten und den durch den verwendeten Algorithmus bedingten Faktoren für die Qualität der Schätzergebnisse zu unterscheiden.

Im Hinblick auf den Prozeß muß in erster Linie die gegebene Anregung des Systems analysiert werden. Ohne ausreichende Anregung ist keine Parameteridentifikation möglich. Wie in diesem Beitrag anhand des Reibungseinflusses gezeigt, können sich nicht modellierte Störungen sehr negativ auf das Schätzergebnis auswirken.

Durch die Wahl des adaptiven Modells hat der Anwender die Möglichkeit, die Grenzen zu beeinflussen, bei welcher Anregung und bei welchen Störeinflüssen die Güte der Schätzungen noch ausreichend ist.

Dabei ist ein adaptives Modell gekennzeichnet

- durch seine Struktur (Vorwärtszweig, Prädiktionsschritt) und
- durch den verwendeten Schätzalgorithmus (Rückwärtszweig, Korrekturschritt).

Hinsichtlich der Struktur bieten adaptive Modelle, die wie das Erweiterte Kalman-Filter auf Beschreibungen im Zustandsraum basieren, gegenüber den häufig verwendeten Ansätzen mit Hilfe von Differenzgleichungen den Vorteil, daß die Beschreibungsform auf das kontinuierliche System und die diskrete Meßwerterfassung besser angepaßt ist und darüber hinaus leicht erweitert bzw. vereinfacht werden kann.

So wurde gezeigt, wie sich durch eine Anpassung der Struktur, in dem Fall deterministischer Parameteränderungen die Integration von BFN in EKF, die Schätzergebnisse deutlich verbessern lassen. Insbesondere das Beispiel mit dem integrierten BFN zur Schätzung der Reibkennlinie macht deutlich, daß durch eine Erweiterung des Lastmodells eine ausreichend gute Trägheitsmomentschätzung möglich wird.

Schließlich sei darauf hingewiesen, daß diese neue Struktur aber auch zur schnellen Ermittlung von nichtlinearen Kennlinien während einer automatisierten Inbetriebnahme eingesetzt werden kann [5]. Im Gegensatz zu bekannten Offline-Identifikationsverfahren, mit denen die Parameter in genügend vielen Arbeitspunkten bestimmt werden, um aus den einzelnen Identifikationsresultaten eine Parameterkennlinie zu ermitteln, können mit Hilfe der neuen Struktur entsprechende Kennlinien unmittelbar, z. B. durch wenige Testfahrten unter Verwendung eines Stützreglers geringer Bandbreite, ermittelt werden, da die Meßdaten online verarbeitet werden können.

Die Schätzergebnisse lassen sich durch die Entwurfparameter des Schätzalgorithmus, in diesem Fall durch die Wahl der entsprechenden Rauschparameter, beeinflussen. Zu ihrer Bestimmung eignen sich die hier angedeuteten und in [3] genauer diskutierten physikalischen Überlegungen. Umso geeigneter diese Rauschparameter gewählt werden, desto geringer wird die zur Identifikation notwendige Systemanregung und desto besser werden Störungen kompensiert. Derzeit haben sich die theoretischen Ansätze für die Bestimmung optimaler Rauschparameter noch nicht als praxistauglich erwiesen, jedoch können heuristische, auf physikalischen Überlegungen basierende Maßnahmen zu ihrer Evaluierung herangezogen werden.

Die hier zusammengefaßten Ergebnisse und Aussagen sind in [7] ausführlich darge-

stellt.

Aufgrund der Tatsache, daß die Schätzergebnisse durch die Eigenschaften des jeweiligen Prozesses maßgeblich beeinflusst werden, bleibt als Ausblick festzuhalten, daß es einen allgemein besten Ansatz zur Online-Schätzung mechanischer Parameter vermutlich nicht geben wird. Die stets notwendige Anpassung an den Prozeß erschwert insbesondere die Inbetriebnahme. Somit ist noch großes Forschungspotential sowohl bei der Entwicklung von adaptiven Modellen, insbesondere von deren Entwurfsmethoden, als auch bei ihrer Optimierung im Hinblick auf bestimmte Anwendungen vorhanden.

Literatur:

- [1] U. Schäfer: *„Entwicklung von nichtlinearen Drehzahl- und Lageregelungen zur Kompensation von Coulomb-Reibung und Lose bei einem elektrisch angetriebenen, elastischen Zweimassensystem“*, Diss. Techn. Universität München, 1992.
- [2] F. Schütte, S. Beineke, M. Henke, H. Grotstollen: *„Drehzahlregelung eines elastischen Zweimassensystems mit On-line-Identifikation lastseitiger Reibung und aktiver Schwingungsdämpfung bei Stellgrößenbegrenzung“*, SPS/IPC/DRIVES 1996, Sindelfingen, Germany, pp. 303-315.
- [3] F. Schütte, S. Beineke, A. Rolfsmeier, H. Grotstollen: *„Online Identification of Mechanical Parameters Using Extended Kalman Filters“*, IAS 1997, New Orleans, USA, pp. 501-508.
- [4] S. Beineke, F. Schütte, H. Grotstollen: *„Online Identification of Nonlinear Mechanics Using Extended Kalman Filters with Basis Function Networks“*, IECON 1997, New Orleans, USA, pp. 316-321.
- [5] S. Beineke, H. Wertz, S. Schütte, H. Grotstollen, N. Fröhleke: *„Identification of Nonlinear Two-Mass Systems for Self-Commissioning Speed Control of Electrical Drives“*, IECON 1998, Aachen, Germany.
- [6] Brown M., Harris C.: *Neurofuzzy Adaptive Modelling and Control*, Prentice Hall, 1994.
- [7] S. Beineke: *„Online-Schätzung von mechanischen Parametern, Kennlinien und Zustandsgrößen drehzahl geregelter elektrischer Antriebe“*, Dissertation Universität Paderborn, erscheint 1999.