

Nutzung von Expertenwissen zur Modellierung eines pneumatischen Antriebs mit Fuzzy- und neuronalen Netzwerken

Thomas Bernd und Carsten Otto

Meß-, Steuer- und Regelungstechnik (Prof. Dr.-Ing. H. Schwarz)

Gerhard-Mercator-Universität Duisburg, D-47048 Duisburg

Tel.: +49 203 379-3423 ; Fax: +49 203 379-3027

E-Mail: bernd@uni-duisburg.de, co@uni-duisburg.de

Kurzfassung

Dieser Beitrag stellt die Modellierung eines pneumatischen Antriebs mit Black-Box-Methoden vor, wobei eine qualitative Analyse des Systems zu einer detaillierteren Modellstruktur und damit höheren Güte beiträgt. Als Black-Box-Strukturen werden zum einen Fuzzy-Netzwerke vom Takagi-Sugeno-Typ mit mehrdimensionalen Zugehörigkeitsfunktionen und zum anderen neuronale Netzwerke in Form des mehrschichtigen Perzeptrons verwendet. Beide Ansätze gestatten die Identifikation nichtlinearer dynamischer Ein-Ausgangs-Modelle und werden hinsichtlich ihrer Approximationseigenschaften in diesem Beitrag miteinander verglichen.

1 Einleitung

Die Modellierung eines technischen Prozesses stellt in vielen Fällen eine komplexe Aufgabe dar, die sich mit verschiedenen Ansätzen lösen läßt. Kriterien wie Modellgüte, Modellkomplexität, physikalische Interpretierbarkeit von Parametern, Modellierungsaufwand, erforderliches Prozeßwissen und Verwendungszweck prägen häufig die Entscheidung für einen speziellen Ansatz. Applikationen, die eine hohe Modellgüte erfordern, auf eine Interpretation von Modellparametern weitgehend verzichten und bei denen Wissen im wesentlichen aus experimentellen Daten verfügbar ist, stellen das Hauptanwendungsgebiet von Black-Box-Ansätzen dar [1], wobei insbesondere Fuzzy-Logik und neuronale Netzwerke in den vergangenen Jahren große Bedeutung erlangten. Durch die Entwicklung effizienter Berechnungsverfahren lassen sich damit unter Zuhilfenahme gemessener Ein- und Ausgangsdaten Modelle identifizieren, die die Wirkungszusammenhänge des Prozesses in vielen Fällen sehr gut nachbilden. Wenn jedoch die Anregung des Prozesses schwierig ist und/oder der Prozeß die Festlegung einer passenden Modellstruktur aufgrund komplexer innerer Dynamik erschwert, ist das Ergebnis unbefriedigend.

Wie dieser Beitrag demonstriert, läßt sich vorhandenes Wissen über innere Wirkungszusammenhänge nutzen, um eine detailliertere Modellstruktur zu erhalten. Im betrachteten Beispiel der Modellierung eines pneumatischen Antriebs verhilft Expertenwissen zu einer Aufteilung des Gesamtsystems in zwei kleinere, einfacher zu modellierende Teilsysteme, die ein abschließender Syntheseschritt zu einem Gesamtmodell verkoppelt. Die Teilsysteme beinhalten weiterhin signifikante Nichtlinearitäten wie Reibungseffekte und komplexe thermodynamische Zusammenhänge, die sich physikalisch nur unter hohem analytischen Aufwand modellieren lassen. Stattdessen kommen sowohl Fuzzy- als auch neuronale Netzwerke zum Einsatz. Auf diese Weise entsteht ein Modell, das der tatsächlichen Systemstruktur näher kommt und aufgrund dessen eine höhere Modellgüte ermöglicht als ein einziges Black-Box-Modell für das Gesamtsystem.

Die Abschnitte 2 und 3 beschreiben die verwendeten Methoden der Black-Box-Modellierung mit Fuzzy- und neuronalen Netzwerken. Abschnitt 4 enthält die Systembeschreibung des pneumatischen Antriebs, und Abschnitt 5 stellt die einzelnen Syntheseschritte der Modellierung vor und vergleicht die verwendeten Ansätze miteinander. Eine Zusammenfassung und ein Ausblick schließen diesen Beitrag ab.

2 Analytische Beschreibung von Fuzzy-Netzwerken

Die hier betrachteten Fuzzy-Netzwerke (Bild 1) basieren auf funktionalen Fuzzy-Systemen vom Takagi-Sugeno-Typ [2]. Diese lassen sich mit Hilfe von WENN-DANN-Regeln

$$\text{WENN } x(k) \text{ IST } v_i, \text{ DANN } y_i = f(x(k)), \quad i = 1, \dots, c \quad (1)$$

beschreiben, die in der Prämisse den Abstand $d_i = \|\mathbf{x}(k) - \mathbf{v}_i\|$ eines Eingangsdatums $\mathbf{x}(k)$ zu einem Referenzpunkt \mathbf{v}_i bewerten. Das Ergebnis der Prämissenbewertung stellt den Erfülltheitsgrad der Regel dar und wird hier über explizit multivariate Zugehörig-




Bild 1: Fuzzy-Netzwerk

keitsfunktionen [3] berechnet, deren mathematische Beschreibung durch

$$\mu_i(\mathbf{x}) = \begin{cases} \frac{1}{\sum_{j=1}^c \left(\frac{d_i(\mathbf{x})}{d_j(\mathbf{x})} \right)^{\frac{2}{\nu-1}}} & \text{für } \mathbf{x} \notin \{\mathbf{v}_1, \dots, \mathbf{v}_c\} \\ 1 & \text{für } \mathbf{x} = \mathbf{v}_i \\ 0 & \text{für } \mathbf{x} \in \{\mathbf{v}_1, \dots, \mathbf{v}_c\} \setminus \{\mathbf{v}_i\} \end{cases} \quad (2)$$

gegeben ist. Der Parameter ν beeinflusst die Unschärfe der entstehenden Partitionierung. Als Konklusionsfunktionen kommen häufig lineare Funktionen der Eingangsgrößen

$$y_i = c_i - \sum_{j=1}^n a_{ij} y(k-j) + \sum_{h=1}^m b_{ih} u(k-h) \quad (3)$$

in Betracht, da sich in diesem Fall die Konklusionsfunktionsparameter besonders einfach identifizieren lassen. Eine Gewichtung der Konklusionen mit den Zugehörigkeitswerten führt schließlich auf die resultierende Ausgangsgröße:

$$\hat{y}(k) = \frac{\sum_{i=1}^c \mu_i(\mathbf{x}) y_i(k)}{\sum_{i=1}^c \mu_i(\mathbf{x})} \quad (4)$$

$$= \sum_{i=1}^c \phi_i(k) y_i(k) \quad \text{mit} \quad \phi_i(k) = \frac{\mu_i(\mathbf{x})}{\sum_{j=1}^c \mu_j(\mathbf{x})} \quad (5)$$

Die Verwendung eines Fuzzy-Netzwerkes zur Black-Box-Modellierung erfordert bei vorgegebener Struktur die Berechnung der zugehörigen Parameter, wobei die Identifikation eines Modells in einem dreistufigem Verfahren erfolgt:

1. *Berechnung der Prototypen \mathbf{v}_i*

Die Analyse der Eingangsdaten $x(k)$, $k = 1, 2, \dots, N$ mit Hilfe von Fuzzy-Clusteralgorithmen liefert die Koordinaten der Referenzpunkte \mathbf{v}_i , die die Partitionierung festlegen. Insbesondere der FCM [4] erweist sich aufgrund der geringen Parameteranzahl als sehr praktikabel. Dieser Clusteralgorithmus berechnet die Prototypen durch Minimierung der Kostenfunktion

$$V = \sum_{k=1}^N \sum_{i=1}^c \mu_i^\nu(\mathbf{x}(k)) \|\mathbf{x}(k) - \mathbf{v}_i\| . \quad (6)$$

2. *Schätzung der Konklusionsfunktionsparameter*

Bei bekannten Referenzpunkten hängt die Modellausgangsgröße nur noch von der Parametrierung der zugeordneten linearen Teilmodelle, d. h. von den Koeffizienten der Konklusionspolynome, ab. Im Falle linearer Konklusionsfunktionen wie in Gleichung (3) besteht ein linearer Zusammenhang zwischen der Ausgangsgröße und

den Konklusionsfunktionsparametern, so daß diese direkt mit dem Verfahren der kleinsten Fehlerquadrate [5] berechnet werden können. Dieses minimiert die Kostenfunktion

$$V = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2 . \quad (7)$$

3. Nichtlineare Optimierung aller Parameter

Während die ersten beiden Stufen mit geringem numerischen Aufwand bereits ein vollständig definiertes Fuzzy-Modell liefern, das für weniger anspruchsvolle Simulationszwecke häufig ausreicht, läßt sich durch Optimierung aller Modellparameter eine erhebliche Verbesserung der Modellgüte erzielen. Hierbei dient wiederum Gleichung (7) als Zielfunktion einer iterativen Parameterberechnung, wobei sich aus Effizienzgründen das Marquardt-Verfahren [6] anbietet.

Neben der gewählten Modellstruktur und den eingesetzten Identifikationsmethoden ist außerdem die Klassifikation der Optimierungsaufgabe ein entscheidender Aspekt. Wie in [7] vorgestellt, ist insbesondere zwischen statischen und dynamischen Approximationsaufgaben zu unterscheiden. Dynamische Systeme lassen sich erfahrungsgemäß nur mit parallelen Modellen zufriedenstellend modellieren, die *prädizierte* Ausgangswerte auf den Eingang zurückführen. Bei der Identifikation stehen zwar auch die gemessenen Werte zur Verfügung, jedoch ergeben sich bei deren Verwendung häufig Modelle, die durch Überanpassung an den Meßdatensatz und unbefriedigende Validierungsergebnisse gekennzeichnet sind. Auf diesen Aspekt geht Abschnitt 5 näher ein.

3 Analytische Beschreibung von neuronalen Netzwerken

In Anlehnung an [8] läßt sich ein neuronales Netzwerk allgemein als ein informationsverarbeitendes System charakterisieren, das aus einfachen Einheiten, den Zellen oder Neuronen besteht, die über gewichtete Verbindungen miteinander kommunizieren. Das mehrschichtige Perzeptron (MLP, *engl.* multilayer perceptron) ist einer der bekanntesten Vertreter neuronaler Netzwerke. Diese Netzarchitektur stellt eine nichtlineare Abbildung aus einem Eingaberaum \mathbb{R}^n in einen Ausgaberaum \mathbb{R}^m dar und eignet sich als universeller Approximator funktionaler Zusammenhänge [9]. Die einzelnen Zellen des MLP-Netzwerkes sind in einer oder mehreren verdeckten Schichten und einer Ausgabeschicht angeordnet und mit den Zellen benachbarter Schichten über gewichtete Verbindungen vernetzt. Die Informationsweitergabe ist von der Eingabe über die verdeckten Schichten hin zur Ausgabeschicht gerichtet.

In Bild 2 ist die Struktur einer Zelle j in der Schicht s des MLP-Netzwerkes dargestellt. Diese erhält die Ausgabesignale $y_{s-1,i}$ der n Zellen der vorhergehenden Schicht und berechnet mit Hilfe der gewichteten Verbindungen w_{ij} das Aktivierungssignal

$$v_{s,j} = w_{0j}y_{s-1,0} + \sum_{i=1}^n y_{s-1,i}w_{ij} , \quad (8)$$

sowie die Aktivierung $a_{s,j}$ über die Aktivierungsfunktion $g(v_{s,j})$, die als Ausgabe $y_{s,j}$ an die Zellen der nachfolgenden Schicht weitergeleitet wird. Die Zellen des MLP-Netzwer-




Bild 2: Struktur einer Zelle

kes besitzen einen Schwellenwert, der als Signal $y_{s-1,0}$ mit konstantem Wert $y_{s-1,0} = 1$ und dem zugehörigen Gewicht w_{0j} realisiert ist [10].

Dieser Beitrag verwendet MLP-Netzwerke mit einer verdeckten Schicht und einer einzelnen Zelle in der Ausgabeschicht (Bild 3). Die Zellen der verdeckten Schicht besitzen den hyperbolischen Tangens

$$g(v_{s,j}) = \tanh v_{s,j} , \quad (9)$$

und die Ausgabezelle besitzt die Identität als Aktivierungsfunktion. Die Ausgabe \hat{y} des Netzwerkes ergibt sich damit als Superposition der einzelnen Ausgaben der Zellen der verdeckten Schicht.

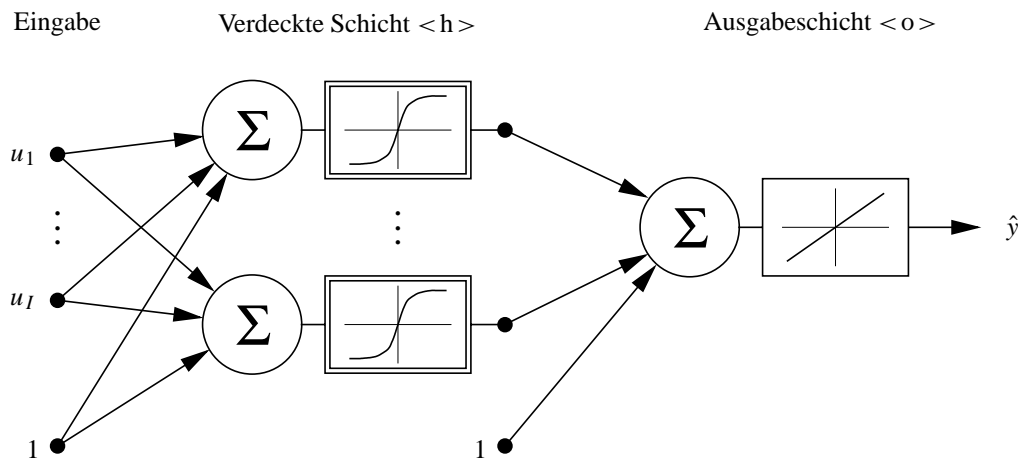


Bild 3: Zweischichtiges MLP-Netzwerk

Der funktionale Zusammenhang zwischen Ausgabe \hat{y} und Eingabe $\mathbf{u} = [u_1, \dots, u_I]$ in Abhängigkeit der Gewichte \mathbf{w} ergibt sich zu

$$\hat{y}(\mathbf{u}, \mathbf{w}) = w_{01}^{<o>} + \sum_{j=1}^H w_{j1}^{<o>} \tanh \left(w_{0j}^{<h>} + \sum_{i=1}^I w_{ij}^{<h>} u_i \right) , \quad (10)$$

wobei I die Anzahl der Eingaben und H die Anzahl der Zellen der verdeckten Schicht beschreiben. Die hochgestellten Indizes $<h>$ und $<o>$ deuten die Zugehörigkeit des jeweiligen Gewichtes zur verdeckten bzw. zur Ausgabeschicht an.

Während einer Trainingsphase erlernt das MLP-Netzwerk den funktionalen Zusammenhang zwischen Ein- und Ausgabe anhand eines Meßdatensatzes. Zur Bewertung des Lern-

erfolges wird die Kostenfunktion

$$V = \frac{1}{N} \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (11)$$

verwendet, die den quadratischen Fehler zwischen der gewünschten Ausgabe y_p und der Ausgabe des MLP-Netzwerkes \hat{y}_p berechnet und über alle N Meßdaten aufsummiert. Das Ziel von Lernverfahren für das MLP-Netzwerk besteht somit in der Minimierung der Kostenfunktion durch Adaption der Gewichte w . Hierzu wird in diesem Beitrag das Levenberg-Marquardt-Verfahren [11] benutzt.


Die Identifikation nichtlinearer dynamischer Systeme erfordert die Erweiterung der zuvor beschriebenen statischen MLP-Netzwerke mit Speicherelementen. Die hier angewandte Methode besteht darin, zum einen die Eingaben u zeitlich zu verzögern und zum anderen die Ausgabe extern zurückzuführen. Letzteres kann, wie in Abschnitt 5 erläutert wird, durch Rückkopplung der gemessenen Ausgabe y oder der vom MLP-Netzwerk prädierten Ausgabe \hat{y} geschehen.

4 Pneumatischer Translationsantrieb

Bei dem betrachteten System handelt es sich um den in Bild 4(a) dargestellten pneumatischen Translationsantrieb, dessen Funktionsweise Bild 4(b) veranschaulicht:



(a) Aufnahme



(b) Prinzipskizze

Bild 4: Pneumatischer Translationsantrieb

Ein beweglicher Kolben teilt das eingeschlossene Volumen eines Pneumatikzylinders in zwei Kammern, die sich mit Luft unterschiedlichen Drucks beaufschlagen lassen. Die entstehende Druckdifferenz bewirkt eine Kraft auf den Kolben und beschleunigt diesen wie auch den über ein Stahlband mit dem Kolben verbundenen Schlitten, der zur Aufnahme von Werkstücken dient. Zwei Servoventile beeinflussen dabei die Kammerdrücke durch Luftzufuhr von einem Druckspeicher oder durch Entlüftung in die Umgebung.

Die Servoventile beinhalten eine konstruktiv umgesetzte Druckrückführung, so daß eine konstante, am Ventil anliegende Steuerspannung einen konstanten Kammerdruck bewirkt. Die zugehörige Kennlinie, vor allem aber das dynamische Verhalten wird durch ausgeprägte Nichtlinearitäten gekennzeichnet. Insbesondere schwer erfassbare Reibkräfte, so-

wie komplexe thermodynamische Gesetzmäßigkeiten erhöhen den Aufwand einer physikalischen Modellierung erheblich.

Für die Identifikation stehen neben der Kolbenposition und den beiden Ventilsteuerspannungen auch die Kammerdrücke zur Verfügung, die mit einer Abtastzeit von $T = 5$ ms gemessen werden. Ziel ist es, die Kolbengeschwindigkeit v , welche sich aus der Differentiation des Positionssignals und gleitender Mittelwertbildung ergibt, in Abhängigkeit der Steuerspannungen u_1 und u_2 zu präzisieren. Bei konstanter Steuerspannung u_1 kann die Bewegung des Kolbens über die Spannung u_2 , die als Eingangsgröße dient und im folgenden die Bezeichnung u trägt, beeinflusst werden. Da für die Kolbenbewegung nicht die einzelnen Kammerdrücke, sondern deren Differenz Δp relevant ist, kann diese als weitere Eingangsgröße Verwendung finden. Alle hier verwendeten Signale sind mittelwertfrei auf das Intervall $[-1, 1]$ normiert.

5 Modellierung des pneumatischen Antriebs

Im folgenden wird die Modellierung des in Abschnitt 4 beschriebenen pneumatischen Antriebs mit den in den Abschnitten 2 und 3 erläuterten Black-Box-Ansätzen vorgestellt. Dabei erfolgt zunächst eine Identifikation des Gesamtsystems, dessen Ergebnis im weiteren als Referenz dient. Eine qualitative Analyse des Systems führt anschließend auf eine Zerlegung in zwei einfacher zu modellierende Teilsysteme.

Das dynamische Verhalten der Black-Box-Modelle wird wesentlich durch die Art der Rückkopplung der Ausgangsgröße auf den Modelleingang bestimmt, wobei zwei häufig in der Literatur anzutreffende Möglichkeiten das seriell-parallele und das parallele Modell sind. Einen ausführlichen Überblick nichtlinearer Black-Box-Ansätze gibt [12].

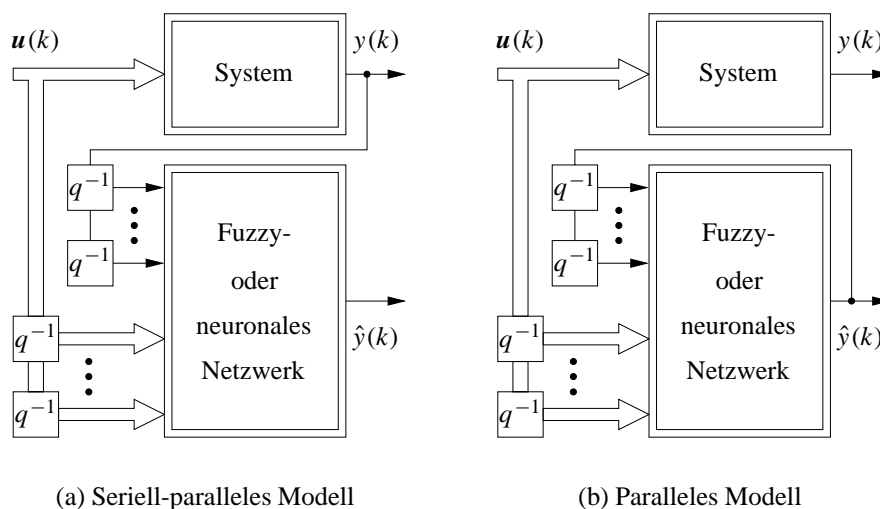



Bild 5: Black-Box-Modelle

Beim parallelen Modell in Bild 5(b) wird der prädierte Ausgang auf den Eingang zurückgekoppelt, d. h. es besteht vollständige Parallelität zwischen Modell und System, wohingegen beim seriell-parallelen Modell in Bild 5(a) nur bezüglich des Eingangs Parallelität herrscht. Der letztgenannte Ansatz bietet den Vorteil, daß im allgemeinen Modelle von hoher Güte identifiziert werden. Steht der gemessene Ausgang für den Einsatz des Modells nicht zur Verfügung, beispielsweise in Simulationsstudien, so ist die Identifikation eines

parallelen Modells vorzuziehen. Nachteilig an diesem Modell ist, daß die zur Optimierung notwendige Gradientenberechnung wesentlich aufwendiger und die Stabilität des Modells nicht sichergestellt ist [13]. Dieser Beitrag verwendet sowohl zur Identifikation als auch zur Validierung der Black-Box-Modelle des pneumatischen Antriebs ausschließlich die parallele Anordnung, weil sich damit erfahrungsgemäß bessere Validierungsergebnisse erzielen lassen.

5.1 Einfaches Antriebsmodell

In [14] wird die Modellierung des pneumatischen Antriebs mit Fuzzy- und neuronalen Netzwerken bereits vorgestellt. Der dort verwendete Ansatz bildet den Ausgangspunkt für die in diesem Beitrag angestrebten Verbesserungen und ist in Bild 6 dargestellt. Dieser ergab sich durch heuristisches Vorgehen ohne Berücksichtigung der inneren Systemstruktur. Das Modell des Antriebs besitzt als Eingang die Spannung u und als Ausgang die Schlittengeschwindigkeit v sowie die in Bild 6 beschriebene Modellstruktur. Für das Fuzzy-Netzwerk werden $c = 4$ Regeln und für das neuronale Netzwerk $H = 6$ Zellen in der verdeckten Schicht vorgegeben, so daß die entsprechenden Modelle 36 bzw. 37 Parameter besitzen. Anhand des



$$\hat{v}(k) = f(\hat{v}(k-1), \hat{v}(k-2), \hat{v}(k-3), u(k-1))$$

Bild 6: Ansatz des einfachen Antriebsmodells

	Fuzzy-Netzwerk	MLP-Netzwerk
Struktur	$c = 4$	$H = 6$
Parameteranzahl	36	37
V_{ide}	$5,43 \cdot 10^{-3}$	$4,76 \cdot 10^{-3}$

Tabelle 1: Vergleich der Black-Box-Ansätze für das einfache Antriebsmodell

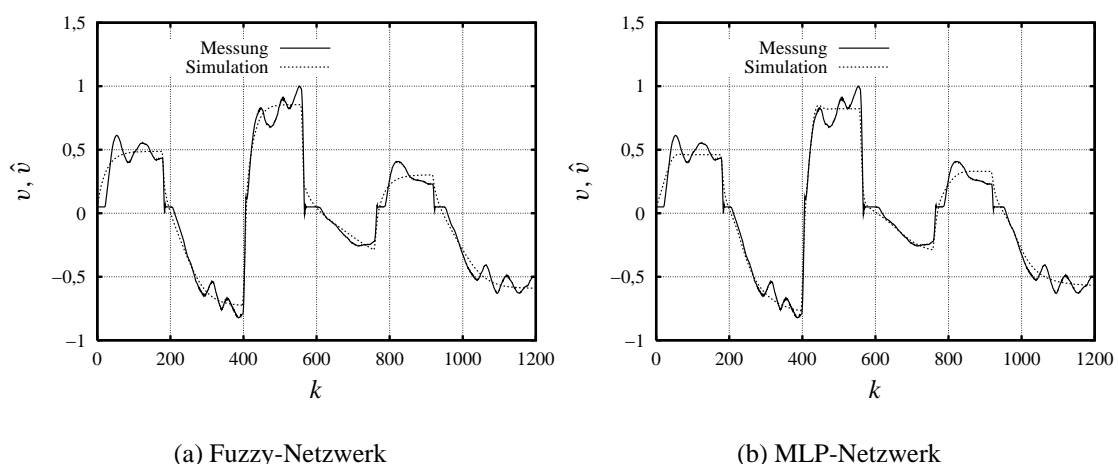


Bild 7: Identifikationsergebnisse für das einfache Antriebsmodell


mittleren quadratischen Fehlers V_{ide} zeigt sich, daß beide Black-Box-Ansätze ähnliche Ergebnisse liefern (Tabelle 1). In Bild 7 sind die Identifikationsergebnisse dargestellt. Es ist zu erkennen, daß keines der beiden Modelle die dynamischen Eigenschaften des Antriebs ausreichend wiedergibt. In den folgenden Abschnitten wird daher angestrebt, durch eine qualitative Analyse des pneumatischen Antriebs seine Modellierung zu verbessern.

5.2 Qualitative Systemanalyse

Die in Abschnitt 5.1 verwendete Modellstruktur entspricht den tatsächlichen Zusammenhängen offensichtlich nur unzureichend. Die Kenntnis innerer Proößgrößen und zugehöriger Zusammenhänge kann zur Verbesserung der Modellstruktur genutzt werden: Die Kolbenbewegung des pneumatischen Antriebs läßt sich mit Hilfe des Differenzdruckes durch eine Differentialgleichung 2. Ordnung beschreiben, in die insbesondere die schwer zu modellierende Reibkraft einfließt. Bei bekannter Druckdifferenz ist eine Modellierung dieses Teilsystems unabhängig von der Ventileinheit möglich, die die Zylinderkammern sowie die zugehörigen Servoventile beinhaltet. Dieses Wissen über die Teilsysteme bzw. Struktur führt im folgenden schrittweise zu einer detaillierteren Modellierung.

5.3 Erweitertes Antriebsmodell

In [15] zeigt sich, daß die Hinzunahme des Differenzdruckes Δp der beiden Kammern als Eingangsgröße gemäß der in Bild 8 beschriebenen Modellstruktur eine deutliche Verbesserung des dynamischen Verhaltens der Modelle ermöglicht. Der Vergleich des mittleren quadratischen Fehlers V_{ide} in Tabelle 2 mit jenen in Tabelle 1 sowie die Verläufe der Schlittengeschwindigkeit für das Fuzzy-Netzwerk (Bild 9(a)) und das neuronale Netzwerk (Bild 9(b)) bestätigen dies. Dem MLP-Netzwerk gelingt eine bessere Identifikation des Antriebs als dem Fuzzy-Netzwerk, wie zum einen der geringere Fehler und zum anderen der simulierte Verlauf der Schlittengeschwindigkeit zeigt, der dem gemessenen Verlauf besser entspricht.



$$\hat{v}(k) = f(\hat{v}(k-1), \hat{v}(k-2), \Delta p(k-1), u(k-1))$$

Bild 8: Ansatz des erweiterten Antriebsmodells

	Fuzzy-Netzwerk	MLP-Netzwerk
Struktur	$c = 7$	$H = 10$
Parameteranzahl	63	61
V_{ide}	$2,79 \cdot 10^{-3}$	$8,70 \cdot 10^{-4}$

Tabelle 2: Vergleich der Black-Box-Ansätze für das erweiterte Antriebsmodell

Die Hinzunahme des Differenzdruckes Δp , der einen inneren Zustand des Antriebs repräsentiert, bringt den Nachteil mit sich, daß diese Größe zunächst durch Messung be-

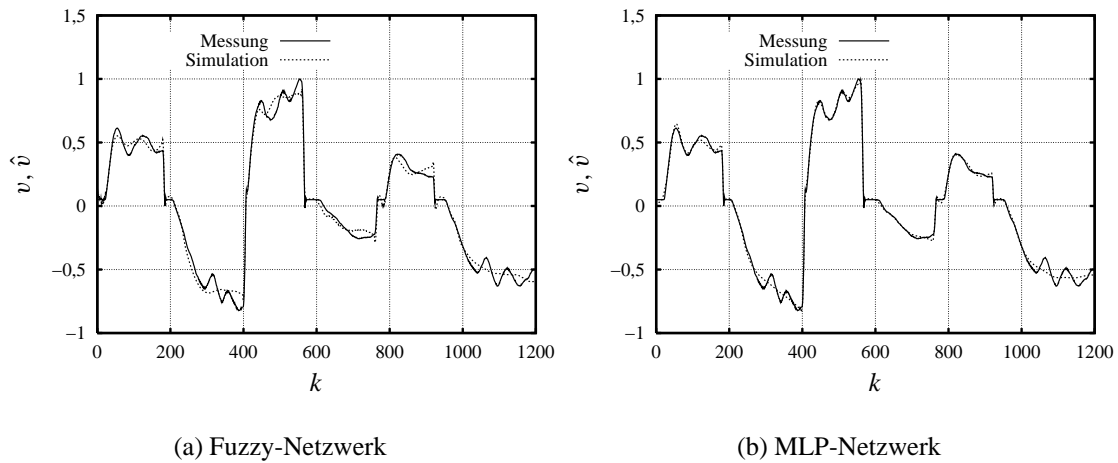


Bild 9: Identifikationsergebnisse des erweiterten Antriebsmodells

reitgestellt werden muß. Dieses bedeutet einerseits einen erhöhten Aufwand und schließt andererseits dieses Modell für Simulationsstudien aus, da es nicht vollständig parallel zum Prozeß ist.

5.4 Servoventileinheit

Die Identifikation eines Modells für die Servoventileinheit zur Schätzung des Differenzdruckes wird in diesem Abschnitt vorgestellt. Es besitzt die in Bild 10 beschriebene Struktur und verwendet die Spannung u als Eingang. In Tabelle 3 sind die Ergebnisse der Modellierung der Servoventileinheit aufgeführt. Für das Fuzzy-Netzwerk werden $c = 6$ Regeln vorgegeben und das MLP-Netzwerk besitzt $H = 8$ Zellen in der verdeckten Schicht, so daß das entsprechende Black-Box-Modell 42 bzw. 41 Parameter besitzt. Neben dem mittleren quadratischen Fehler V_{ide} für die Identifikation ist in Tabelle 3 auch der Fehler V_{val} für einen Validierungsdatensatz angegeben. In der Identifikation haben das Fuzzy-Netzwerk und das MLP-Netzwerk ähnliche Resultate, allerdings weist das MLP-Netzwerk eine bessere Generalisierungsfähigkeit auf. Diese Tatsache bestätigen die Verläufe der Druckdif-



$$\Delta \hat{p}(k) = f(\Delta \hat{p}(k-1), \Delta \hat{p}(k-2), u(k-1))$$

Bild 10: Ansatz des Servoventilmodells

	Fuzzy-Netzwerk	MLP-Netzwerk
Struktur	$c = 6$	$H = 8$
Parameteranzahl	42	41
V_{ide}	$4,90 \cdot 10^{-4}$	$3,99 \cdot 10^{-4}$
V_{val}	$9,82 \cdot 10^{-3}$	$5,63 \cdot 10^{-3}$

Tabelle 3: Vergleich der Black-Box-Ansätze für das Modell der Servoventileinheit

ferenz für die Identifikation in Bild 11 und für die Validierung in Bild 12. Beide Ansätze geben die Eigenschaften der Servoventileinheit gut wieder.




Bild 11: Identifikationsergebnisse des Modells der Servoventileinheit





Bild 12: Validierungsergebnisse des Modells der Servoventileinheit

Mit diesen Modellen ist es nun möglich, den Antrieb basierend auf den in Abschnitt 5.3 vorgestellten Ansätzen zu modellieren, ohne von der Messung der Druckdifferenz abhängig zu sein.

5.5 Antrieb und Servoventileinheit

Im folgenden wird basierend auf den in Abschnitt 5.3 erläuterten Ansätzen ein neues Modell für den pneumatischen Antrieb identifiziert. Der Unterschied zum bisherigen Ansatz besteht darin, daß nicht die gemessene, sondern die von den Modellen in Abschnitt 5.4 geschätzte Kammerdruckdifferenz als zweiter Eingang Verwendung findet (Bild 13). In Tabelle 4 ist aufgeführt, daß die Modelle die gleiche Struktur und Parameteranzahl wie jene in Abschnitt 5.3 besitzen. Die mittleren quadratischen Fehler für Identifikation und Validierung zeigen jedoch, daß die Güte der Modellierung mit geschätzter Druckdifferenz geringer ist, als bei Zuführung der gemessenen Druckdifferenz. Die Ursache hierfür ist

in dem Fehler zwischen Schätzung und Messung der Druckdifferenz begründet, der als Störung im Drucksignal auf die Antriebsmodelle wirkt.



$$\hat{v}(k) = f(\hat{v}(k-1), \hat{v}(k-2), \Delta \hat{p}(k-1), u(k-1))$$

Bild 13: Ansatz für Antrieb und Servoventil

In Bild 14 sind die Verläufe der Schlittengeschwindigkeit für die Identifikation mit dem Fuzzy- bzw. MLP-Netzwerk dargestellt. Ein Vergleich mit den Ergebnissen in Bild 9 bestätigt die geringere Güte der erweiterten Modelle des pneumatischen Antriebs. Das Modell basierend auf dem MLP-Netzwerk ist in der Lage, die Dynamik des Antriebs noch ausreichend wiederzugeben, wohingegen das Fuzzy-Netzwerk deutlich schlechtere Ergebnisse liefert.

	Fuzzy-Netzwerk	MLP-Netzwerk
Struktur	$c = 7$	$H = 10$
Parameteranzahl	63	61
V_{ide}	$3,52 \cdot 10^{-3}$	$1,17 \cdot 10^{-3}$
V_{val}	$2,84 \cdot 10^{-2}$	$3,54 \cdot 10^{-2}$

Tabelle 4: Vergleich der Black-Box-Ansätze für Antrieb und Servoventileinheit

Insbesondere die Validierungsergebnisse in Bild 15 verdeutlichen, daß der Schätzfehler bei unbekanntem Daten noch stärkere Auswirkungen hat. Es ist allerdings festzustellen, daß trotz des Schätzfehlers in der Druckdifferenz, die Dynamik des Antriebs wesentlich besser wiedergegeben wird, als mit der einfachen Modellierung in Abschnitt 5.1.




Bild 14: Identifikationsergebnisse von Antrieb und Servoventileinheit




Bild 15: Validierungsergebnisse von Antrieb und Servoventileinheit

6 Zusammenfassung und Ausblick

Dieser Beitrag demonstriert die Black-Box-Modellierung eines pneumatischen Antriebs mit Fuzzy- und neuronalen Netzwerken. Ausgeprägt nichtlineares Verhalten infolge physikalischer Effekte und innere Dynamik erschweren die Modellierung und führen zu unbefriedigenden Simulationsergebnissen, die sich auch durch Erhöhung der Parameteranzahl bei gleicher Modellstruktur nicht verbessern lassen. Die Kenntnis der Systemstruktur läßt sich jedoch zur Festlegung einer geeigneteren Modellstruktur nutzen. Eine qualitative Systemanalyse mit dem Ziel der Formulierung signifikanter Zwischengrößen und zugehöriger Abhängigkeiten führt hier auf eine Modellierung zweier kleinerer Teilsysteme, ohne die physikalischen Gesetzmäßigkeiten exakt herzuleiten. Jedes Teilsystem läßt sich leichter identifizieren, wobei wiederum die qualitative Kenntnis der Systemdynamik die Festlegung geeigneter Modellstrukturen unterstützt. Das Ergebnis der abschließend zum Gesamtmodell verkoppelten Teilmodelle übertrifft die Modellgüte des ursprünglichen Black-Box-Modells, woraus sich die Motivation zur Nutzung von Expertenwissen bei der Identifikation mit Black-Box-Ansätzen ergibt. Dies bestätigen die dargestellten Ergebnisse der Modellierung mit Fuzzy- und neuronalen Netzwerken, wobei der Vergleich beider Methoden zeigt, daß die Güte der auf den neuronalen Netzwerken basierenden Modelle geringfügig höher ist.

Der erhöhte Aufwand dieser Vorgehensweise stellt einen Nachteil dar. Der in diesem Beitrag eingeschlagene Weg ist nur möglich, wenn die auftretenden Hilfsgrößen tatsächlich meßbar sind, da diese Ein- bzw. Ausgangsgrößen der Teilmodelle bilden. Folglich sind die Teilmodelle nur identifizierbar, wenn entsprechende Meßdaten vorliegen. Ein in zukünftigen Arbeiten zu lösendes Problem stellt die Fehlerfortpflanzung zwischen den identifizierten Teilmodellen dar, die die Erwartung einer hohen Güte des Gesamtmodells nicht bestätigt. Daher ist als Ausgangspunkt für weiterführende Arbeiten zum einen die Verbesserung der Güte der Teilmodelle zu betrachten und zum anderen dürfen die Rückwirkungen der Teilsysteme untereinander nicht vernachlässigt werden. Beispielsweise ist hier die Hinzunahme der prädierten Schlittengeschwindigkeit als Eingang für das Modell der Servoventileinheit im Sinne eines Beobachters zu nennen.

Literatur

- [1] SCHWARZ, H.: *Einführung in die Systemtheorie nichtlinearer Regelungen*. Aachen : Shaker Verlag, 1999
- [2] TAKAGI, T. ; SUGENO, M.: Fuzzy Identification of Systems and Its Applications to Modeling and Control. In: *IEEE Transactions on Systems, Man and Cybernetics* 15 (1985), Nr. 1, S. 116–132
- [3] KROLL, A.: *Fuzzy-Systeme zur Modellierung und Regelung komplexer technischer Systeme*. Düsseldorf : VDI Verlag, 1997 (Fortschritt-Berichte VDI Reihe 8 Nr. 612)
- [4] BEZDEK, J. C.: *Pattern Recognition with Fuzzy Objective Function Algorithms*. New York : Plenum Press, 1981
- [5] ISERMANN, R.: *Identifikation dynamischer Systeme I*. Berlin : Springer-Verlag, 1992
- [6] HOFFMANN, U. ; HOFMANN, H.: *Einführung in die Optimierung*. Weinheim : Verlag Chemie, 1971
- [7] BERND, T. ; KROLL, A. ; SCHWARZ, H.: Approximation nichtlinearer dynamischer Prozesse mit optimierten funktionalen Fuzzy-Modellen. In: *Berichtsband des 7. Workshop Fuzzy-Control des GMA-Fachausschusses 1.4.2*. Dortmund, 1997, S. 179–190
- [8] ZELL, A.: *Simulation neuronaler Netze*. München : R. Oldenbourg Verlag, 1997
- [9] HORNIK, K. ; STINCHCOMBE, M. ; WHITE, H.: Multilayer Feedforward Networks Are Universal Approximators. In: *Neural Networks* 2 (1989), S. 359–366
- [10] HAYKIN, S.: *Neural Networks*. New York : Macmillan College Publishing Company, 1994
- [11] NØRGAARD, M.: *System Identification and Control with Neural Networks*. Lyngby, Denmark, Department of Automation, Technical University of Denmark, Dissertation, 1996
- [12] SJÖBERG, J. [u. a.]: Nonlinear Black-box Modeling in System Identification: a Unified Overview. In: *Automatica* 31 (1995), Nr. 12, S. 1691–1724
- [13] NELLES, O. ; ERNST, S. ; ISERMANN, R.: Neuronale Netze zur Identifikation nichtlinearer, dynamischer Systeme: Ein Überblick. In: *Automatisierungstechnik* 6 (1997), Nr. 45, S. 251–262
- [14] BERND, T. ; KLEUTGES, M. ; KROLL, A.: Nonlinear Black Box Modelling - Fuzzy Networks versus Neural Networks. In: *Neural Computing and Applications* 8 (1999), Nr. 2, S. 151–162
- [15] KLEUTGES, M. ; BERND, T.: Simulation of Technical Processes via Universal Approximators. In: *Simulation News Europe* (1999), Nr. 25, S. 7–11