

Vergleich von Identifikationsverfahren für konventionelle und Fuzzy-Modelle

Hagen Reuter, Frankfurt und Andreas Kroll, Heidelberg



Dr.-Ing. Hagen Reuter war wissenschaftlicher Mitarbeiter im Fachgebiet Meß-, Steuer- und Regelungstechnik (Prof. Dr.-Ing. H. Schwarz) der Gerhard-Mercator-Universität-GH Duisburg und arbeitet jetzt bei der Mannesmann VDO AG, Bereich Steuer- und Regelsysteme. Hauptarbeitsfelder: Identifikation nicht-linearer Systemmodelle, Expertensysteme, wissensbasierte und heuristische Regelung.

Adresse: Mannesmann VDO AG, Systementwicklung Steuer- und Regelsysteme, Sodener Straße 9, D-65824 Schwalbach. E-mail: hreuter@del.vdogrp.de



Dr.-Ing. Andreas Kroll war wissenschaftlicher Mitarbeiter im Fachgebiet Meß-, Steuer- und Regelungstechnik (Prof. Dr.-Ing. H. Schwarz) der Gerhard-Mercator-Universität-GH Duisburg und arbeitet jetzt im ABB-Forschungszentrum Heidelberg. Hauptarbeitsfelder: Regelung, Modellierung und Simulation.

Adresse: ABB-Forschungszentrum Heidelberg, Informationstechnologie, Speyerer Straße 4, D-69115 Heidelberg. E-mail: akroll@decrc.abb.de

Dieser Beitrag stellt einen Vergleich von Identifikationsverfahren für konventionelle und Fuzzy-Modelle vor. Dazu finden die Meßdaten eines Gasofenprozesses („Box-Jenkins-Daten“) Verwendung, die sich in den letzten Jahren zu einem Benchmark-Problem im Bereich der Identifikation entwickelt haben. Es wird auf Modellgüte, Komplexität von Modell und Algorithmus sowie Anwendungszweck der 23 vorgestellten Modelle eingegangen.

Comparison of identification methods for conventional and fuzzy models

This contribution compares identification methods for conventional and fuzzy models. Therefore, measured data of a gas furnace („Box-Jenkins-data“) is used. Modelling this data became a benchmark problem in the field of identification within the last years. The performance and complexity of the model and the application of the 23 models is discussed.

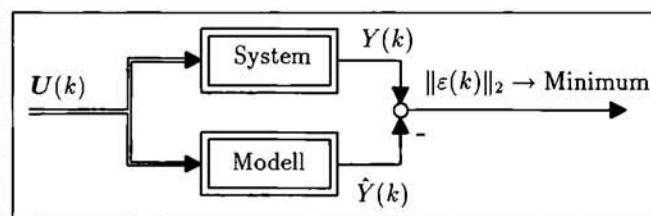
1 Einleitung

Geeignete Modelle, die das statische und dynamische Verhalten von technischen, naturwissenschaftlichen, ökologischen, ökonomischen und anderen Prozessen hinreichend gut beschreiben, sind bei Simulation, Systemanalyse und Reglersynthese nicht nur in der Regelungstechnik unverzichtbar. Konventionelle Modelle bestehen üblicherweise aus Differential- oder

Differenzgleichungen. Für sie gibt es allerdings keinen allgemein anwendbaren Modellansatz. Deshalb muß auf spezielle Modellstrukturen (lineare Systeme Wiener- und Hammerstein-Modelle [6], etc.) zurückgegriffen werden. Für solche Modelle fanden in der letzten Jahren in zunehmendem Maße Parameterschätzverfahren wie z.B. die Prädiktionsfehlerverfahren [11; 13] auch für reale Systeme Anwendung. Eine andere Darstellungsart ist die der Fuzzy-Systeme, die auf der unscharfen Logik nach Zadeh [28] basiert. Sie verwenden zur Beschreibung des Systemverhaltens einen Satz von unscharfen WENN-DANN-Regeln. Auch hier existieren unterschiedliche Modelltypen wie z.B. relationale und funktionale Fuzzy-Modelle. Ihre Prämissen bestehen aus linguistischen Beschreibungen. Während der Folgerungsteil bei Fuzzy-Relational-Modellen eine linguistische Darstellung mit unscharfen Ergebnissen besitzt, stellt er bei Fuzzy-Funktional-Modellen eine funktionale Beschreibung mit scharfen Ausgangswerten dar.

Wegen der Vielzahl von scharfen und unscharfer Modellstrukturen und Identifikationsverfahren ist eine vergleichende Gegenüberstellung von besonderem Interesse, um ihre Vor- und Nachteile für der Anwender aufzuzeigen. Dieser Beitrag stellt 23 wichtige Verfahren gegenüber. Vergleichskriterien stellen Modellgüte (vgl. Bild 1) sowie -komplexität dar. Als Referenzprozeß dienen die Meßdaten eines Gasofenprozesses ([3]; Abschnitt 2), die sogenannter Box-Jenkins-Daten, die sich in den letzten Jahren zu einer Art Benchmarkproblem entwickelt haben. In Abschnitt 3 werden die verwendeten 23 Verfahren und die ihnen zugrunde liegenden Ideen kurz skizziert. Für eine genauere Beschreibung sei an dieser Stelle auf die entsprechende Originalliteratur verwiesen. Auf die zugehörigen Modelle bzw. Modellstrukturen wird größtenteils in [18] näher eingegangen. Anschließend erfolgt eine Gegenüberstellung und kurze Bewertung der mit den einzelnen Verfahren erzielten Ergebnisse (Abschnitt 4).

Bild 1: Identifikationsaufgabe.



2 Der Gasofenprozeß

Bei den sogenannten Box-Jenkins-Daten handelt es sich um Meßdaten eines Gasofenprozesses [3], die insbesondere bei der Fuzzy-Identifikation als Benchmarkproblem und zum Vergleich der Genauigkeit einzelner Verfahren herangezogen werden. Die mit einer Abtastzeit von $T_a = 9$ s aufgenommenen 296 Meßwertpaare beschreiben das Ein-/Ausgangsverhalten eines Gasofenteilprozesses. Die Stellgröße $U(k)$ variiert den Brennstoffstrom (Methan), Ausgangsgröße $Y(k)$ ist der CO_2 -Gehalt des Abgases in Prozent (Bild 2).

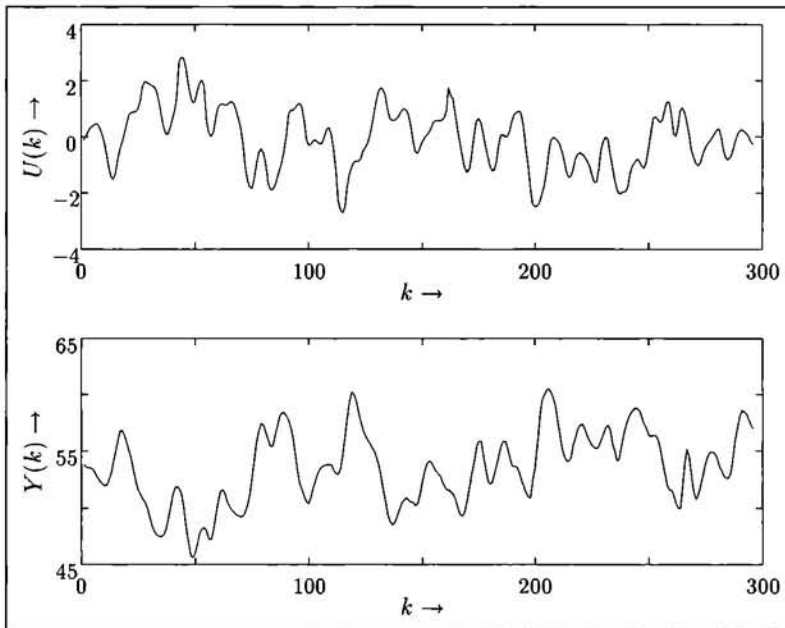


Bild 2: Eingangssignal $U(k)$ und Ausgangssignal $Y(k)$ des Gasofens.

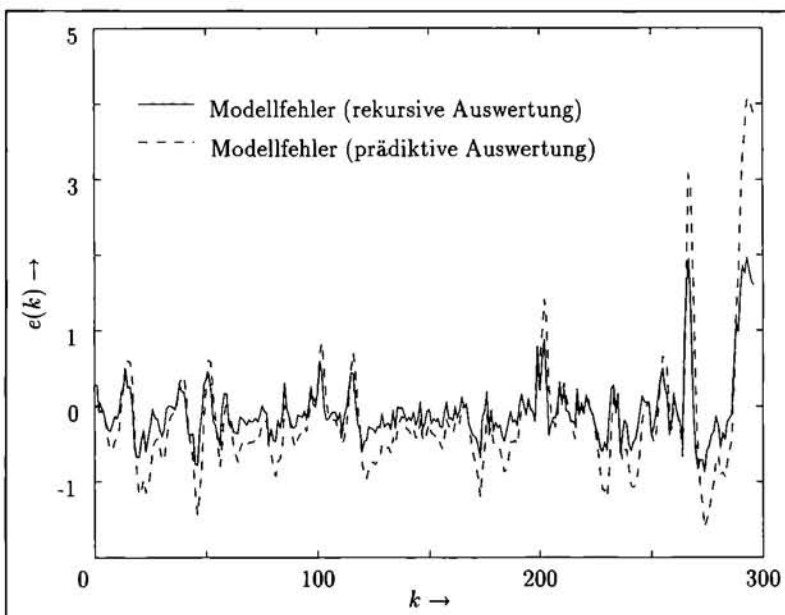


Bild 3: Modellfehler $e(k) = \hat{y}(k) - y(k)$ für rekursive und prädiktive Modellauswertung.

3 Berücksichtigte Verfahren

Die folgende Gegenüberstellung beschränkt sich auf zeitdiskrete Modelle.

Modell 1: Lineares System

Box und Jenkins [3] identifizieren mittels eines iterativen, nichtlinearen Least-Squares-Verfahrens ein lineares Modell

$$y(k) = f(y(k-1), u(k-3), u(k-4), u(k-5)). \quad (3.1)$$

Dieses stellt für die ersten 220 Meßwertpaare eine relativ gute Approximation dar (vgl. Modellfehler in Bild 3). Die anschließend auftretenden großen Abweichungen rühren von nicht im Modell enthaltenen Signalanteilen. Dieses Phänomen trat bei allen identifizierten Modellen auf. □

Modell 2: Lineares Modell mit MATLAB

Zusätzlich wurde ein weiteres lineares Modell

$$A(q^{-1})y(k) = B(q^{-1})q^{-d}u(k) + e(k) \quad (3.2)$$

mit einem Prädiktionsfehlerverfahren nach Ljung [11] identifiziert, dem ein iterativer Gauß-Newton-Algorithmus zugrunde liegt (MATLAB: pem.m, [12]). Das beste Modell ergab sich mit einer Modellordnung $n = 5$ und einer Modelltotzeit $d = 0$ [18]. □

Alternativ besteht die Möglichkeit, das Prozeßverhalten mit unterschiedlichen nichtlinearen Modellstrukturen zu approximieren. Hierbei kann man zwischen Modellen unterscheiden, die dynamische (z.B. bilineare Systeme) oder statische Nichtlinearitäten (z.B. einfache Wiener- und Hammerstein-Modelle) besitzen oder beides (z.B. Polynommodelle). Zur Identifikation solcher Modelle muß wegen ihrer Nichtlinearität in den Parametern auf nichtlineare Optimierungsalgorithmen zurückgegriffen werden. Hierfür bieten sich die Prädiktionsfehlerverfahren (PEM; [11; 13]) besonders an. Für die folgenden drei Modelltypen wurde ein iteratives PEM mit gedämpftem Gauß-Newton-Algorithmus verwendet [17].

Modell 3: Bilineare Modelle

Als geeignet zur Approximation dynamisch nichtlinearen Verhaltens haben sich bilineare Zustandsmodelle

$$\begin{aligned} \mathbf{x}(k+1) &= \mathbf{A}\mathbf{x}(k) + \mathbf{N}\mathbf{x}(k)u(k-d) \\ &\quad + \mathbf{b}u(k-d) \\ y(k) &= \mathbf{c}^T\mathbf{x}(k) \end{aligned} \quad (3.3)$$

herausgestellt [15; 19]. Für die Parameteridentifikation (mit iterativem PEM) muß

aus mehreren Gründen (z.B. Konvergenzverhalten, Identifizierbarkeitsproblem) auf kanonische Formen zurückgegriffen werden [17]. Eine Konvergenz der Parameter gegen ein Minimum des Gütefunktional trat nur für $n = 3$ und $d = 0$ ein [18]. Die bilinearen Anteile N auch von beobachtbarkeitskanonischer Form (**Modell 3a**) und beobachterkanonischer Form (**Modell 3b**) ergeben keinen signifikanten Beitrag zum Übertragungsverhalten. Dies rechtfertigt die Vermutung, daß diese Signalanteile nicht enthalten sind und der Gasofenprozeß nur eine statische Nichtlinearität besitzt. \square

Modell 4: Einfaches Hammerstein-Modell

Mit dem iterativen PEM ergab sich das beste einfache Hammerstein-Modell für eine Modellordnung $n = 5$ des linearen dynamischen Blocks bei einer Polynomordnung $p = 2$ und $d = 0$. \square

Modell 5: Einfaches Wiener-Modell

Für das einfache Wiener-Modell ergibt sich das beste Modell mit $n = 5$, $p = 4$ und $d = 0$ (ebenfalls iteratives PEM). \square

Modell 6: Polynommodell

Der direkte Strukturselektionsalgorithmus von Kortmann [7] sucht die bezüglich des Übertragungsverhaltens signifikanten Parameter aus einem Kolmogorov-Gabor-Polynommodell. Hierbei erfolgt eine Orthogonalisierung der Signalanteile. Die mit einem LS-Verfahren geschätzten Modelle werden mittels statistischer Kriterien bewertet, um eine geeignete Modellgröße zu finden. So erhält man ein Modell

$$\hat{y}(k) = f(y(k-m), u(k-l), u^2(k), u^4(k)), \\ m \in \{1, 2, 3\}, l \in \{2, 3\},$$

mit unterschiedlichen multiplikativen Verknüpfungen. \square

Modell 7: Primitiv-Prädiktor

Mit $\hat{y}(k) = y(k-1)$ wird als Vergleichswert und zur besseren Bewertung der übrigen Ergebnisse der jeweils letzte Meßwert als Vorhersage verwendet. \square

Modell 8: Relational-Modell nach Tong

Tong [24] schätzt die Regeln einer Fuzzy-Struktur, indem er eine sogenannte „logische Prüfung“ verwendet: Ein „Datenmuster“ (hier $[u(k-4); y(k-1); y(k)]$) wird quantisiert, in diskrete Klassen eingeteilt und auf vorher definierte Modellklassen/Mengen bezogen. Man erhält so für jeden Meßdatentupel eine Regel. Für das Modell werden nur „elementare Regeln“ berücksichtigt, für die der Wert der Zugehörigkeitsfunktion 1 beträgt. Ergeben sich aus diesen Regeln Konflikte (z.B. infolge verrauschter Meßwerte, ungünstig gewählter Klassenanzahl, falscher Modellstruktur), muß zu ihrer Auflösung qualitatives Prozeßwissen herangezogen werden. \square

Modell 9: Relational-Modell nach Pedrycz

Modell 9a: Pedrycz [15] führt bezüglich jeder Koordinate des Eingangsgrößenvektors eine Clusterung der

Meßdaten mit dem FCM-Algorithmus [2] zur Bestimmung der Fuzzy-Referenzmengen durch. Im nächsten Schritt ist die Struktur des Fuzzy-Modells mit der Relationalgleichung

$$Y(k) = X_1(k) \circ \dots \circ X_p(k) \circ R(k) \quad (3.4)$$

vorzugeben. Die Relationalmatrix $R(k)$ wird für jeden Meßdatensatz mittels des unscharfen kartesischen Produkts [4] der Vektoren der Möglichkeitsgrade bzw. der Gewichte der erfüllten Regeln bestimmt. Die Teilrelationalmatrizen werden mittels Disjunktion zur Gesamtrelationalmatrix zusammengesetzt. Modelltotzeit d und Kompositionsoperator \circ wählt Pedrycz so aus, daß der quadratische Fehler minimal ist. Zudem beschränkt er sich auf die Folgerung mit dem größten Möglichkeitsgrad bzw. Gewicht pro Regelsatz. Für die Box-Jenkins-Daten verwendet Pedrycz [15] ein Modell $Y(k) = Y(k-1) \circ U(k-3) \circ R$, die MAX-PROD-Komposition sowie 9 Fuzzy-Referenzmengen für jede Eingangsgröße. \square

Modell 9b: Küpper [10] verbessert das Verfahren von Pedrycz, indem er mehrere Folgerungen je Regelsatz zuläßt, die SUM-PROD-Komposition sowie gleichverteilte dreiecksförmige Fuzzy-Referenzmengen heranzieht. \square

Modell 10: Relational-Modell nach Xu und Lu

Modell 10a: Xu und Lu [27] verwenden das Verfahren von Pedrycz [15] zur Bestimmung eines Startmodells (1. Schritt), das iterativ optimiert wird (2. und 3. Schritt): Im 2. Schritt werden die Partialprämissen der Fuzzy-Referenzmengen ausgewählt, deren Erfülltheitsgrade für die Eingangsgrößen eine gewisse Schwelle überschreiten. Dabei werden nur diese Regeln zur Modellauswertung herangezogen, nicht aber die Erfülltheitsgrade der Prämissen. Die scharfe Ausgangsgröße berechnet sich ausschließlich aus den Folgerungsteilen der Regeln. Im 3. Schritt erfolgt beim Überschreiten einer Prädiktionsfehlergrenze eine Aktualisierung der Elemente der Relationalmatrix R . Dabei wird ein Lernfaktor verwendet, der sich aus dem Prädiktionsfehler, einem Gewichtungsfaktor sowie einem zusätzlichen Skalierungsfaktor zusammensetzt. Der Gewichtungsfaktor beschreibt den Anteil einer Fuzzy-Referenzmenge des Ausgangs am Gesamtergebnis. Xu und Lu [27] verwenden die Struktur $Y(k) = Y(k-1) \circ U(k-4) \circ R$ mit jeweils fünf Glockenkurven als Fuzzy-Referenzmengen. \square

Modell 10b: Die von Küpper [10] vorgeschlagene Verbesserung berücksichtigt den Erfülltheitsgrad der Prämissen, wodurch ein deutlich komplexeres Kennfeld des Fuzzy-Modells möglich wird. Zudem verwendet er dreiecksförmige Fuzzy-Referenzmengen ohne Schranke für die Erfülltheitsgrade sowie die SUM-PROD-Komposition. Auch bewirkt seine neue Berechnungsvorschrift für die Ermittlung des Gewichtungsfaktors im Lernschritt eine feinere Anpassung der Möglichkeitsgrade. \square

Modell 11: Funktional-Modell nach Sugeno und Tanaka

Sugeno und Tanaka [21] verwenden eine zweistufige Identifikation für ein Fuzzy-Funktional-Modell nach Takagi und Sugeno [23]:

$$R_i : \text{WENN}(X_1 \text{ IST } A_{1,i}) \text{ UND } \dots \text{ UND}(X_n \text{ IST } A_{n,i})$$

$$\text{DANN } y_i = c_{0,i} + \sum_{j=1}^n c_{j,i} x_j. \quad (3.5)$$

In der ersten Stufe werden mittels eines Verfahrens von Sugeno und Kang [20] die Modellstruktur und ein Startmodell bestimmt: Es erfolgt jeweils eine Struktur- und eine Parameteridentifikation für Voraussetzungsteil (Fuzzy-Partitionierung und nichtlinearer Optimierungsalgorithmus) und Folgerungsteil (LS-Verfahren). Die zweite Stufe des Identifikationsverfahrens von Sugeno und Tanaka gliedert sich wiederum in zwei „Ebenen“, eine Überwachungs- und eine Einstellebene: Die Überwachungsebene gibt mit sogenannten Fuzzy-Anpaß-Regeln ein Konzept für die Parameteranpassung vor: Zuerst wird eine harte Partitionierung abgeleitet, die zwischen Kern- und Flankenbereichen unterscheidet. Hieraus werden dann Grundregeln aufgestellt, wobei die Konklusionen aus den Kernbereichen und die Prämissen aus den Flankenbereichen folgen. Diese Grundregeln werden nun in weiche Fuzzy-Anpaß-Regeln transformiert. Gemäß dieser werden in der Einstellebene die Parameter von Voraussetzungs- und Folgerungsteil mittels gewichtetem RLS-Algorithmus geschätzt. Für die Box-Jenkins-Daten geben Sugeno und Tanaka [21] zwei Modelle an: **Modell 11a** mit $\hat{y}(k) = f(y(k-1), u(k-1))$ und **Modell 11b** mit

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

Die allgemeine Anwendung dieses Verfahrens ist jedoch sehr problematisch [5], was auch von den Entwicklern des Verfahrens bestätigt wurde. □

Modell 12: Positions-Gradienten-Modell

Sugeno und Yasukawa [22] unterscheiden ebenfalls zwischen Strukturidentifikation (mit Aufteilung des Ausgangsraumes durch Clustering sowie Bestimmung geeigneter Modelleingänge) und Parameterschätzung. Zur Clustering des Ausgangsraums wird der FCM-Algorithmus verwendet. Dabei eignen sich die Parameter der Clustering als Startwerte für die Parameterschätzung, wenn man die mehrdimensionalen Cluster auf eindimensionale Fuzzy-Mengen projiziert. Zum Erhalt einer optimalen Clusteranzahl wird diese solange erhöht, bis ein Gütekriterium sein Minimum erreicht. Zur Bestimmung der geeigneten Modelleingänge werden alle möglichen Modelleingänge miteinander gekoppelt. Die Auswahl der „richtigen“ Eingänge erfolgt mittels Güteindizes. Zudem verwenden Sugeno und Yasukawa in ihren Regeln noch Gradientenvariablen:

$$R_i : \text{WENN}(X_j \text{ IST } A_{i,j})$$

$$\text{DANN}(y = B_i) \text{ UND } (\partial y / \partial x_j = C_{i,j}). \quad (3.6)$$

Die Parameterschätzung optimiert dann iterativ die jeweils 4 Parameter der trapezförmigen Zugehörigkeitsfunktionen für das Modell $\hat{y}(k) = f(y(k-1), u(k-3), u(k-4))$. □

Modell 13: Relational-Modell nach Küpper

Küpper [10] verwendet eine Fuzzifizierung über Einermengen und die SUM-PROD-Komposition für ein Fuzzy-Relational-System mit 2 normierten, symmetrischen, dreiecksförmigen Fuzzy-Referenzmengen des Ausgangs. Für diese spezielle Form benutzt er zur Optimierung ein Gradientenverfahren der stochastischen Approximation [25; 13]. Für die Regelsätze

$$\text{WENN } \bigwedge_{i=1}^a (X_i \text{ IST } X_{i,p_i})$$

$$\text{DANN } \bigvee_{j=1}^2 (Y_{j,l} = Y_j) \mid g_{j,l} \quad (3.7)$$

werden die Möglichkeitsgrade bzw. Gewichte $g_{j,l}$ der l Regelsätze identifiziert. So erhält er ein Modell $Y(k) = Y(k-1) \circ U(k-4) \circ R$. □

Modell 14: Arithmetik-Modell nach Bertram

Eine neue Darstellungsart für Fuzzy-Systeme verwendet Bertram [1] mit den Fuzzy-Arithmetik-Modellen. Es handelt sich hierbei um gewichtete Fuzzy-Parametergleichungen

$$Y_l = g_l (X_{1,p_1} \odot M_{1,l} \oplus X_{2,p_2} \odot M_{2,l} \oplus \dots \oplus X_{a,p_a} \odot M_{a,l}). \quad (3.8)$$

Die Fuzzy-Zahlen $M_{i,l}$ gewichten die entsprechenden p_i Referenzmengen einer Fuzzy-Variablen mittels Modifikation von Träger und Kern. Zudem werden spezielle Fuzzy-Operatoren \odot und \oplus [4] verwendet. Zur Parameterschätzung greift Bertram auf eine Evolutionsstrategie [16] zurück. Das Modell besitzt die Eingänge $Y(k-1)$ und $U(k-4)$. □

Modell 15: Funktional-Modell nach Kroll

Kroll [9] verwendet für Modelle

$$R_i : \text{WENN}(\mathbf{x}(k) \text{ IST } \mathbf{v}_i)$$

$$\text{DANN } y_i(\mathbf{x}(k)) = f_i(\mathbf{x}(k)) \quad (3.9)$$

mehrdimensionale Fuzzy-Referenzmengen und eine zweistufige Identifikation. Die erste Stufe beginnt mit der Identifikation der Zugehörigkeitsfunktionen und der Prämissenparameter durch Clustering mit dem FCM-Algorithmus. Als Abstandsnorm verwendet er die Mahalonobisnorm, die statistische Eigenschaften der Meßdaten bewertet. Die Schätzung der Parameter der Konklusionspolynome erfolgt mittels eines gewichteten RLS-Verfahrens. Mit **Modell 15a** ($\hat{y}(k) = f(y(k-1), u(k-3))$) und **Modell 15b** ($\hat{y}(k) = f(y(k-1), y(k-2), y(k-3), u(k-1), u(k-2), u(k-3))$) werden Systeme unterschiedlicher Größe identifiziert. In der zweiten, optionalen Stufe optimiert Kroll die Parameter nach. Dazu wendet er in jedem Iterations-

schrift ein Gradientenverfahren 1. Ordnung [13; 11] für die Prämissenparameter und ein LS-Verfahren für die Konklusionsparameter (**Modell 15c**) an. □

Modell 16: Fuzzifiziertes Polynommodell nach Kroll

Bei dieser Vorgehensweise [9] handelt es sich um eine zweistufige, hybride Identifikation in dem Sinne, daß eine konventionelle Identifikationsmethode (Strukturselektionsalgorithmus für Polynommodelle) und ein Fuzzy-Identifikationsverfahren gemeinsam herangezogen werden. Ergebnis der ersten Stufe ist somit das Polynom aus Modell 6. Nachdem nun die Struktur eines parametrischen Modells vorliegt, wird dieses Modell fuzzifiziert in dem Sinne, daß nunmehr c Konklusionspolynome anstatt von einem die gleichen Argumente aufweisen. Hierfür werden die Koeffizienten geschätzt. Da das Fuzzy-Modell einer gewichteten Überlagerung lokaler Polynommodelle entspricht, ist keine Suche nach einer global perfekt passenden Polynomstruktur erforderlich. Abweichungen bleiben durch das Lokalisitätsprinzip beschränkt – im Gegensatz zu einer einzigen global gültigen Struktur. Eine Begrenzung des Suchraumes des Strukturselektionsalgorithmus ist damit legitim und führt zu einer Verringerung des Rechenaufwandes. Sie ist aber auch notwendig, um die Anzahl der Modellparameter zu begrenzen, da ja c Polynommodelle zu einem Fuzzy-Modell kombiniert werden. □

Modell 17: Fuzzy-Modell mittels statistischer Kriterien

Kortmann und Unbehauen [8] betrachten Fuzzy-Funktional-Modelle (diese enthalten Fuzzy-Relational-Modelle als Untermenge). Das bei Modell 6 verwendete Prinzip von Orthogonalisierung der Signalanteile und die Verwendung statistischer Kriterien zur Bewertung übertragen sie auf die Fuzzy-Modelle. Die Bestimmung der statistisch signifikanten Regelbasis und der Kerne der Prämissen erfolgt über die Auswahl der signifikanten Fuzzy-Basisfunktionen. Die Parameter der Konklusionsfunktionen werden mit Hilfe eines LS-Verfahrens geschätzt. Eingänge für dieses Fuzzy-Funktional-Modell des Gasofenprozesses sind $y(k-1)$, $u(k-3)$ und $u(k-4)$. □

4 Vergleich der Ergebnisse und Bewertung

Tabelle 1 stellt die Anzahl der Parameter und Regeln sowie den mittleren quadratischen Fehler V für die mit den im vorigen Abschnitt kurz skizzierten Verfahren identifizierten Modelle des Gasofenprozesses gegenüber. Dabei wird unterschieden zwischen einer rekursiven Modellauswertung $\hat{y}_{rek}(k) = f(u(k-l), \hat{y}(k-m))$, bei der die geschätzten Ausgänge $\hat{y}(k-m)$ eingehen, und einer prädiktiven Auswertung $\hat{y}_{präd}(k) = f(u(k-l), y(k-m))$ mit den Meßwerten $y(k-m)$ (vgl. Bild 1).

$$V_X = \frac{1}{N} \sum_{k=1}^{N=296} (y(k) - \hat{y}_X(k))^2, \quad X \in \{präd, rek\} \quad (4.1)$$

Tabelle 1: Modellgröße und Güte der berücksichtigten Modelle.

Modell Nr.	Typ: Verfahren	Anz. Regeln/ Parameter	Modellgüte	
			$V_{präd}$	V_{rek}
1	LS: [3]	-/4	0,1970	0,7219
2	LS: [12]	-/10	0,0785	0,6964
3a	BLS: [17]	-/7	0,0661	0,7128
3b	BLS: [17]	-/9	0,0913	0,7070
4	Hammerstein: [17]	-/13	0,0621	0,6834
5	Wiener: [17]	-/15	-	0,6029
6	Polynom: [7]	-/11	0,0519	0,6244
7	Primitiv-Prädiktor	-/-	0,5582	-
8	Relational: [24]	19/-	0,469 ¹	-
9a	Relational: [15]	81/81	0,3200 ¹	-
9b	Relational: [10]	81/729	0,1754	0,8502
10a	Relational: [27]	25/125	0,3280 ¹	-
10b	Relational: [10]	25/125	0,2541	-
11a	Funktional: [21]	2/6	0,359 ¹	-
11b	Funktional: [21]	2/15	0,068 ¹	-
12	Pos.-Grad.-Mod.: [22]	6/96	0,190 ¹	-
13	Relational: [10]	25/50	0,1199	0,8149
14	Arithmetik: [1]	25/225	0,1170 ¹	-
15a	Funktional: [9]	2/10	0,1374	0,8585
15b	Funktional: [9]	2/36	0,0556	-
15c	Funktional: [9]	2/10	0,1170	0,9316
16	Funktional: [9]	8/168	0,0317	0,5641
17	Funktional: [8]	6/60	0,120	-

(¹ Wert der Literatur entnommen).

Wie in Tabelle 1 anhand der Regel- bzw. Parameteranzahl zu erkennen ist, benötigen die Fuzzy-Modelle zum Erreichen einer ähnlich guten Modellgüte wie die konventionellen Modelle deutlich mehr Parameter. Zwar wirken die Parameter der Fuzzy-Modelle signifikant nur lokal, dennoch erfordert die große Parameteranzahl eine hohe Anzahl von Meßwerten. Dies wirkt sich im allgemeinen negativ auf das Konvergenzverhalten der Schätzverfahren aus. Diese lokale Parametergültigkeit besitzt jedoch den Vorteil, daß ein Modell in begrenzten Bereichen an reale Gegebenheiten angepaßt werden kann, ohne das globale Verhalten zu ändern. Dadurch stellen verschiedene Fuzzy-Modelle universelle Approximatoren dar (z.B. [26]). Betrachtet man die Komplexität von Modell und Identifikationsalgorithmus, so sind in der Regel die konventionellen Modelle und Verfahren weniger komplex. Der Grund hierfür liegt darin, daß mit der Wahl eines konventionellen Modells (z.B. Modelle 1-5) schon eine sehr starke (gegebenenfalls falsche) Annahme zur Modellstruktur getroffen wird [17]. Dahingegen beinhalten viele Verfahren für Fuzzy-Modelle (sowie Verfahren 6) eine Struktursuche, die bekanntermaßen das schwierigste Problem beim Identifikationsprozeß darstellt [11; 13; 22; 17]. Zudem lautet

eine sehr wichtige Erfahrungsregel bei der Identifikation, bei ähnlicher Modellgüte das einfachere Modell vorzuziehen [11]. Ein Vergleich des Identifikationsaufwandes (z.B. Programmieraufwand, Rechenzeitbedarf, Suche nach geeigneten Startbedingungen usw.) ist nicht möglich, da bei einem Teil der Verfahren auf Literaturergebnisse zurückgegriffen wurde.

Diese Betrachtungen lassen leicht den vorschnellen Eindruck entstehen, daß konventionelle Modelle und Verfahren vorzuziehen seien. Für die Box-Jenkins-Daten trifft dies in der Regel zwar auch zu. Der Hauptgrund dürfte jedoch in diesem Fall darin zu suchen sein, daß sich diese Daten schon sehr gut durch ein einfaches lineares Modell approximieren lassen. Die besonders bei den letzten ca. 75 Meßdatentupeln auftretenden Abweichungen sind wahrscheinlich auf Auswirkungen unbekannter Eingangs- bzw. Störgrößen zurückzuführen, da sie bei allen betrachteten Modellen in ähnlichem Maße auftreten.

Die beste Modellgüte für die Box-Jenkins-Daten ergab sich mit Hilfe eines „hybriden“ Identifikationsverfahrens (Modell 16), der Kombination eines konventionellen Verfahrens mit einem Fuzzy-Algorithmus: Die Modellstruktur wird konventionell identifiziert, fuzzifiziert und das so strukturierte Modell anschließend parameteroptimiert. Modell 16 zeigt, wie stark der Modellfehler mit einem aufwendigen (und parameterintensiven) Modellansatz reduziert werden kann. Für viele praktische Anwendungen reicht aber eine geringere Modellgüte aus, die sich mit deutlich geringerer Modellkomplexität erreichen läßt (z.B. Modell 6). Somit sind konventionelle und Fuzzy-Verfahren nicht als Konkurrenz sondern als sich ergänzend anzusehen, da ihre Vorteile auf unterschiedlichen Gebieten liegen. In der Regel lassen sich sowohl bei in großem Maße vorhandenem Prozeßwissen oder im Sinne einer Identifikation „gutmütigen“ Prozessen mit konventionellen Modellen gute Ergebnisse erzielen. Im Gegensatz dazu sind gerade bei sehr komplexen Systemen und wenig A-priori-Wissen häufig Fuzzy-Modelle mit ihrer Eigenschaft der universellen Approximation für eine Modellierung erforderlich. Hierbei eignen sich die funktionalen Fuzzy-Modelle besonders. Bei relativ wenig Regeln und Parametern besitzen sie eine vorteilhafte Verbindung von linguistischer Beschreibung im Prämissenteil und konventioneller Polynomdarstellung im Konklusionsteil. Die Stärke der Identifikation funktionaler Fuzzy-Modelle liegt in den Anwendungen, bei denen konventionelle Verfahren aufgrund ihrer relativ starren Struktur und der relativ geringen Approximationsfähigkeit kein zufriedenstellendes Ergebnis liefern. Hierbei handelt es sich in der Praxis häufig um komplexe (industrielle) Prozesse und Anlagen, für die eine für konventionelle Modelle erforderliche, günstige System- und/oder Modellstruktur nicht mit vertretbarem Aufwand gefunden werden kann. So können bereits deutlich ausgeprägte Reibungseffekte die Anwendbarkeit konventioneller Identifikationsverfahren verhindern.

Anhand der Gütewerte kann man zudem erkennen, daß bei ähnlicher Modellgüte von konventionellem und

Fuzzy-Modell die Fuzzy-Modelle bei rekursiver Modellauswertung häufig schlechter abschneiden. Der Grund hierfür liegt darin, daß bei den meisten Fuzzy-Modellen eine Optimierung nur bezüglich der Einzschrittprädiktion erfolgt. Die Optimierung der rekursiven Modellauswertung ist möglich, aber wesentlich aufwendiger [9].

5 Zusammenfassung

Im vorliegenden Beitrag wurden Identifikationsverfahren für konventionelle und Fuzzy-Modelle sowie die Ergebnisse der 23 daraus erhaltenen Modelle für einen Gasofenprozeß gegenübergestellt. Sehr gute Ergebnisse wurden mit konventionellen Modellen erzielt, da sich die Prozeßdaten näherungsweise linear verhalten. Bei den Fuzzy-Modellen eignen sich die funktionalen Modelle sehr gut, insbesondere bei komplexem Prozeßverhalten. Das beste Modell ließ sich jedoch mit einem „hybriden“ Verfahren erzielen. Zu seiner Struktursuche wurde ein konventioneller Strukturselektionsalgorithmus verwendet, das so erhaltene Startmodell mehrdimensional fuzzifiziert und als Fuzzy-Funktional-Modell optimiert.

Hinweis


Die Autoren danken Herrn Dr.-Ing. K. Küpper für die Ergebnisse der Modelle 9b, 10b und 13 sowie die fruchtbaren Diskussionen. In diesen Beitrag flossen direkt Ergebnisse verschiedener Projekte der Förderer DFG, MWF des Landes NRW, BMFT, IMECH GmbH sowie Thyssen Still Otto Anlagentechnik GmbH ein.

Literatur

- [1] *Bertram, T.*: Zur systematischen Analyse und Synthese nichtlinearer Systeme mit Fuzzy-Logik. Fortschr.-Ber. VDI Reihe 8 Nr. 496. VDI-Verlag, Düsseldorf 1995.
- [2] *Bezdek, J. C.*: Pattern recognition with fuzzy objective function algorithms. Plenum Press, New York, London 1981.
- [3] *Box, G. E. P., und Jenkins, G. M.*: Time series analysis – forecasting and control. Überarb. Ausg. (1. Ausg. 1970). Holden-Day, San Francisco 1976.
- [4] *Dubois, D., und Prade, H.*: Fuzzy sets and systems: theory and applications. Academic Press, New York, London, Toronto 1980.
- [5] *Hebisch, H.*: Identifikation eines Fuzzy-Modells am Beispiel einer hydraulischen Regelstrecke. Diplomarbeit Fachgebiet MSRT. Universität Duisburg 1992.
- [6] *Isermann, R.*: Identifikation dynamischer Systeme II. Springer, Berlin 1988.
- [7] *Kortmann, M.*: Die Identifikation nichtlinearer Ein- und Mehrgrößensysteme auf der Basis nichtlinearer Modellansätze. Fortschr.-Ber. VDI Reihe 8 Nr. 177. VDI-Verlag, Düsseldorf 1989.
- [8] *Kortmann, P., und Unbehauen, H.*: Identification of the structure of fuzzy models. Proceedings of Fuzzy'96: Fuzzy logic in engineering and natural sciences, Zittau (25.–27.9.1996). S. 36–47.
- [9] *Kroll, A.*: Fuzzy-Systeme zur Modellierung und Regelung komplexer technischer Systeme. Fortschr.-Ber. VDI Reihe 8 Nr. 612. VDI-Verlag, Düsseldorf 1997.

- [10] *Küpper, K.*: Zur Modellierung technischer Systeme mittels Fuzzy-Logik. Fortschr.-Ber. VDI Reihe 8 Nr. 507. VDI-Verlag, Düsseldorf 1995.
- [11] *Ljung, L.*: System identification – theory for the user. Prentice Hall, Englewood Cliffs/N.J. 1987.
- [12] *Ljung, L.*: MATLAB: System identification toolbox user's guide. The MathWorks, Inc., South Natick/Mass. 1988.
- [13] *Ljung, L.*, und *Söderström, T.*: Theory and practice of recursive identification. 1. Paperback ed. The MIT Press, Cambridge/Mass. 1987.
- [14] *Mohler, R.R.*: Bilinear control processes. Academic Press, New York 1973.
- [15] *Pedrycz, W.*: An identification algorithm in fuzzy relational systems. Fuzzy Sets and Systems 13 (1984), S. 153–167.
- [16] *Rechenberg, I.*: Evolutionsstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution. Frommann-Holsboog, Stuttgart 1973.
- [17] *Reuter, H.*: Zur Identifikation nichtlinearer Systemmodelle mit wenig A-priori-Informationen. Fortschr.-Ber. VDI Reihe 8 Nr. 471. VDI-Verlag, Düsseldorf 1995.
- [18] *Reuter, H.*: Vergleich der Identifikationsverfahren für konventionelle und Fuzzy-Modelle am Beispiel der Box-Jenkins-Daten. Forschungsbericht Nr. 12/95 MSRT. Universität Duisburg 1995.
- [19] *Schwarz, H.*: Nichtlineare Regelungssysteme – Systemtheoretische Grundlagen. Oldenbourg, München 1991.
- [20] *Sugeno, M.*, und *Kang, G. T.*: Structure identification of fuzzy model. Fuzzy Sets and Systems 28 (1985). S. 15–33.
- [21] *Sugeno, M.*, und *Tanaka, K.*: Successive identification of a fuzzy model and its applications to prediction of a complex system. Fuzzy Sets and Systems 42 (1991). S. 315–334.
- [22] *Sugeno, M.*, und *Yasukawa, T.*: A fuzzy logic based approach to qualitative modeling. IEEE Transactions on Fuzzy Systems 1 (1993). S. 1–34.
- [23] *Takagi, T.* und *Sugeno, M.*: Fuzzy identification of systems and its application to modeling and control. IEEE Transactions on Systems, Man, and Cybernetics 15 (1985). S. 116–132.
- [24] *Tong, R. M.*: Synthesis of fuzzy models derived from experimental data. Fuzzy Sets and Systems 4 (1978). S. 1–12.
- [25] *Tsytkin, Y. Z.*: Adaption and Learning in Automatic Systems. Academic Press, New York, London 1971.
- [26] *Wang, L. X.*: Adaptive fuzzy systems and control – design and stability analysis. Prentice Hall, Englewood Cliffs/N.J. 1994.
- [27] *Xu, C.-W.*, und *Lu, Y. Z.*: Fuzzy model identification and self-learning for dynamic systems. IEEE Transactions on Systems, Man, and Cybernetics 17 (1987). S. 683–689.
- [28] *Zadeh, L. A.*: Fuzzy sets. Information and Control 8 (1965). S. 338–353.

Manuskripteingang: 6. Januar 1997.



Hans Spiro

CAD der Mikroelektronik

Simulation, Layout und Testdatenerstellung

1997. 426 Seiten. 284 Abbildungen
52 Tabellen. Zahlreiche Aufgaben mit Lösungen

DM 78,-

ISBN 3-486-24114-1

Die Komplexität moderner Mikroelektronik verlangt unbedingt den Einsatz von Computerprogrammen zur Entwicklung mikroelektronischer Schaltungen. CAD-Programme wie SPICE, CHARLES u. a. werden zur Simulation der zu entwickelnden Schaltungen, andere CAD-Programme zur Konstruktion der Hardware, dem sogenannten Layout von Chips und Platinen, oder zur Erzeugung von Testdaten eingesetzt. Das vorliegende Buch führt in die verschiedenen Methoden und Verfahren der Simulation, der Layoutgestaltung und der Testdatenerstellung ein und erläutert die hierfür am häufigsten ein-

gesetzten Algorithmen durch exemplarische Beispiele und ausgewählte Aufgaben mit Lösungen.

Neu ist das Hauptanliegen des Titels, den Ingenieur, der mit der Entwicklung mikroelektronischer Schaltungen oder Systeme betraut ist, zum entscheidenden Systemdenken hinzuzuführen, ihm somit den Überblick über alle Bereiche der Mikroelektronikentwicklung zu verschaffen und ihm die große Bedeutung von CAD in der Mikroelektronik zu vermitteln.

Aus dem Inhalt:

Die CAD-gestützte Mikroelektronik-Entwicklung – Simulationsebenen – Schaltkreissimulation – Prozeß- und Bauelemente- (Device-) Simulation – Logiksimulation – Register-Transfer-Simulation – High-Level Simulation – Struktur und Aufbau integrierter Schaltungen – Layout auf der Siliziumebene, interne Zellenkonstruktion – Ablauf eines mit CAD-Unterstützung durchgeführten Designs – Partitionierung – Platzierung – Verdrahtung – Entwurfskontrolle – Testdatenerstellung

In Ihrer Buchhandlung oder direkt beim Verlag:

R. Oldenbourg Verlag · Rosenheimer Straße 145 · 81671 München

Internet: <http://www.oldenbourg.de>

FAX 089/4 50 51 - 2 04