

## Walzwerksteuerung mit Neuronalen Netzen

**Thomas Martinetz**, Siemens AG, Zentrale Forschung und Entwicklung,  
Wittelsbacher Platz 2, 80333 München

**Otto Gramckow**, Siemens AG, Unternehmensbereich Anlagentechnik,  
Schuhstr. 60, 91050 Erlangen

**Peter Protzel**, Bayerisches Forschungszentrum für Wissensbasierte Systeme  
(FORWISS), Am Weichselgarten 7, 91058 Erlangen

**Zusammenfassung** Bei der Stahl- und Aluminiumproduktion können durch eine optimierte Prozeßführung erhebliche Einsparungen an Material und Energie erzielt werden. Die Einsatzmöglichkeiten Neuronaler Netze sowohl zur Prozeßmodellierung als auch zur Modelladaption werden anhand von beispielhaften Teilaufgaben der Prozeßführung von Walzstraßen verdeutlicht. Dabei spielt die Integration von Neuronalen Netze mit existierenden mathematischen Modellen sowie die on-line Adaptivität eine wichtige Rolle. Eine Reihe von neuronalen Methoden hat sich bereits im praktischen Einsatz bewährt.

### 1. Einleitung

Bei der Stahl- und Aluminiumproduktion spielt die Optimierung des Walzprozesses eine bedeutende Rolle sowohl hinsichtlich der möglichen Qualitätssteigerungen als auch bezüglich des Kostensenkungspotentials. In den letzten 20 Jahren sind eine Reihe von mechanischen sowie konventionellen, regelungstechnischen Maßnahmen zur Walzwerksautomatisierung verwendet worden, die bereits zu einer beträchtlichen Qualitätssteigerung geführt haben. Diese Verfahren haben jedoch die Grenze ihres Verbesserungspotentials erreicht, so daß eine weitere Optimierung nur mit Hilfe neuer, „intelligenter“ Verfahren möglich ist.


Der erfolgsversprechenste Einsatz dieser neuen Verfahren liegt weniger im Bereich der Basisautomatisierung, obwohl auch dort mit neuronalen Ansätzen experimentiert wird (Neumerkel et al., 1994), sondern vielmehr auf der übergeordneten Prozeßführungsebene (Lindhoff et al., 1994; Hollatz u. Martinetz, 1995). Die zentrale Aufgabe der Prozeßführung einer Walzstraße ist die möglichst genaue Ermittlung der Einstellung der Anlage für das jeweils nächste Band vor dessen Einlauf in die Straße. Diese Einstellungen werden als Führungsgrößen an die Basisautomatisierung übermittelt, die die Regelung auf der untersten Ebene übernimmt. Die Prozeßführung stützt sich auf eine Reihe von Modellen, die den in der Walzstraße ablaufenden technischen Prozeß möglichst exakt beschreiben sollen. Diese Beschreibung wird durch die Komplexität des Prozesses wesentlich erschwert, die sich durch zahlreiche nichtlineare Einflüsse sowie durch die zeitliche Änderung des Prozeßverhaltens ergibt.

Bei der Optimierung der Prozeßführung eines Walzwerks ergeben sich eine Vielzahl

von unterschiedlichen Ansatzpunkten. Im folgenden werden eine Reihe von konkreten Einzelproblemen vorgestellt und die Einsatzmöglichkeiten Neuronaler Netze in diesem Zusammenhang erläutert. Zunächst wird die grundsätzliche Problematik beschrieben, die bei allen nachfolgenden Einzelproblemen auftritt und den Einsatz neuronaler Netze wesentlich motiviert hat.

## 2. On-line Identifikation nichtlinearer, instationärer Prozesse

Neuronale Netze werden in der Prozeßsteuerung und -regelung typischerweise dann eingesetzt, wenn kein oder kein ausreichend genaues Streckenmodell existiert, z.B. weil die Nichtlinearitäten des Prozesses nicht genau bekannt und daher nicht analytisch faßbar sind. Eine der Grundaufgaben Neuronaler Netze bei der Prozeßautomatisierung ist daher die Identifikation von nichtlinearen Prozessen. Diese Aufgabe wird stark erschwert, wenn die Prozesse zusätzlich instationär sind (White u. Sofge, 1992). Bild 1 veranschaulicht das Problem anhand eines einfachen Beispiels eines Prozesses mit einer zeitlich veränderlichen Eingangsgröße  $x(t)$  und einer Ausgangsgröße  $y(x,t)$ , mit  $t$  als Zeit, wobei  $y$  in der Regel wesentlich langsamer mit der Zeit variiert als  $x$ .



**Bild 1.** Verschiedene Ursachen von Nichtlinearität: (a) durch Arbeitspunktverschiebungen und (b) durch instationäres Prozeßverhalten.

Bezüglich der Ausgangsgröße des Prozesses  $y(x,t)$  überlagern sich zwei Effekte:

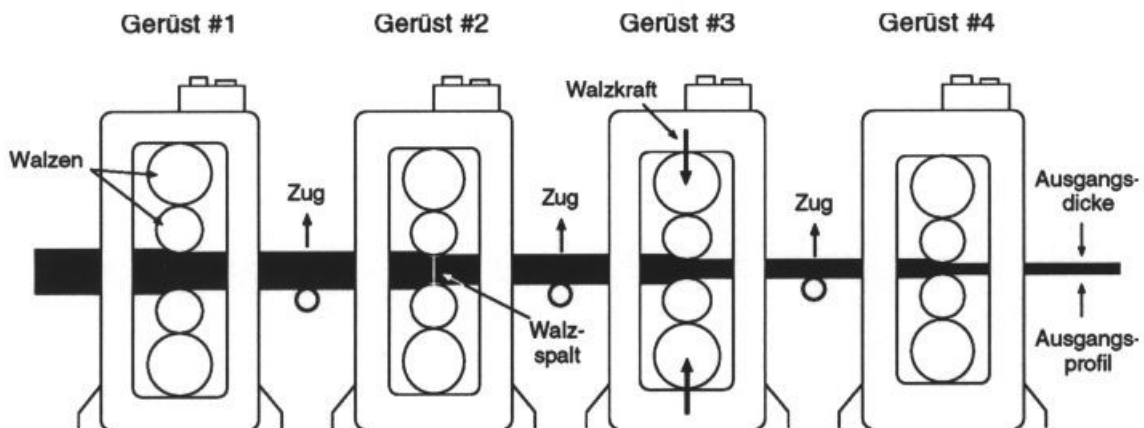
- a) Nichtlinearität durch Arbeitspunktverschiebungen (bei stationärer Prozeßcharakteristik), und
- b) Instationäres Prozeßverhalten (bei konstantem Arbeitspunkt).

Fall a) ist eine „klassische“ Anwendung für statische Neuronale Netze, die die nichtlineare Charakteristik  $y(x)$  im Prinzip beliebig genau nachbilden können, falls ausreichend Trainingsdaten zur Verfügung stehen. Kommt eine Instationarität des Prozesses hinzu, ist eine on-line Adaption erforderlich. Hierbei treten eine Reihe von bekannten Problemen auf, z.B. wie kann sichergestellt werden, daß das Neuro-

nale Netz relevante neue Daten möglichst schnell lernt, ohne alte, immer noch relevante Informationen zu vergessen? (Stabilitäts- vs. Plastizitätsdilemma, (McCloskey u. Cohen, 1989)). Insbesondere wenn beide Effekte, a) und b), auf „ähnlichen“ Zeitskalen auftreten, ist eine on-line Adaption problematisch. Leider tritt genau dieser Fall bei der Walzwerksteuerung häufig auf und ist daher ein aktueller Forschungsschwerpunkt. Die folgenden Abschnitte verdeutlichen diese prinzipielle Problematik anhand einiger ausgewählter Teilprobleme.

### 3. Walzkraftsteuerung

Bild 2 zeigt schematisch die Fertigstraße eines Flachwalzwerks bestehend aus vier Gerüsten. An jedem Gerüst  $n$  muß eine bestimmte relative Dickenreduktion  $\epsilon_n = (d_{n-1} - d_n) / d_{n-1}$  erzielt werden. Dazu wird an jedem Gerüst, bevor das Band einläuft, eine vorgegebene Walzkraft eingestellt. Um die benötigte Dickenreduktion innerhalb einer Toleranz von rund 0,05 Millimeter zu erzielen, muß die Beziehung zwischen Walzkraft  $F_n$  und resultierender relativer Dickenreduktion  $\epsilon_n$  sehr genau bekannt sein, um die richtige Walzkraft voreinstellen zu können. Diese Beziehung jedoch hängt von vielen Einflußfaktoren ab und ist schwierig zu beschreiben. Bis jetzt wurden dazu physikalische Modelle der sich abspielenden Prozesse verwendet, mit unterschiedlichen Modellparameterwerten für die unterschiedlichen Stahlqualitäten. Die erzielte Genauigkeit kann jedoch noch beträchtlich gesteigert werden. Weiterhin erfordert diese Methode eine sehr sorgfältige Buchhaltung der Modellparameter für die vielen hundert verschiedenen Stahlqualitäten, und für jede neue Stahlqualität müssen die Modellparameter von Grund auf neu angepaßt werden.



**Bild 2.** Schematische Darstellung einer Fertigstraße bestehend aus vier Gerüsten. An jedem Gerüst wird eine bestimmte Dickenreduktion durchgeführt. Die Ausgangsdicke, Breite sowie das Profil werden nach dem letzten Gerüst gemessen.

Mit der Entwicklung eines Verfahrens basierend auf Neuronalen Netzen soll nicht nur die Genauigkeit bei der Vorausberechnung der Walzkraft erhöht werden, sondern auch die Schwäche des alten Verfahrens behoben werden, für verschiedene Stahlqualitäten in Einzelfällen sogar verschiedene Modellansätze verwenden zu

müssen. Denn nur dann ist es möglich, bisheriges Wissen über die einzustellenden Walzkkräfte auf neue Stahlqualitäten zu verallgemeinern. Mit einem Neuronalen Netz, welches zwischen verschiedenen Stahlqualitäten anhand ihrer verschiedenen chemischen Zusammensetzungen als Eingangsgrößen unterscheidet, wird es möglich, mit einem einzigen Modell alle Stahlqualitäten abzudecken. Verschiedene Stähle unterscheiden sich dann in ihren Eingabevektoren für das Neuronale Netz, wodurch es möglich wird, auf neue Stähle hin zu verallgemeinern und sogar die eher künstliche Kategorisierung „Stahlqualität“ bzw. „Aluminiumqualität“ völlig zu ersetzen (Poppe u. Martinetz, 1993).

An jedem Gerüst  $n$ , in diesem Fall bestand die Walzstraße aus sieben Gerüsten mit  $n=1, \dots, 7$ , wird ein Neuronales Netzwerk  $N_n(\mathbf{x}_n | \mathbf{w}_n)$  für die Berechnung der an Gerüst  $n$  einzustellenden Walzkraft  $F_n$  eingesetzt. Der 25-dimensionale Eingabevektor  $\mathbf{x}_n$  des Neuronalen Netzes enthält als seine Komponenten die 16 wichtigsten chemischen Elemente des Materials sowie die Werte der physikalischen Einflußfaktoren wie Bandbreite, -dicke, Temperatur etc. am betrachteten Gerüst  $n$ .

Die Neuronalen Netze adaptieren sich über ihre Gewichte  $\mathbf{w}_n$ . Zur Erzielung guter Ergebnisse ist es notwendig, daß sich die Netzwerke mit jedem gewalzten Band online adaptieren. Die Adaption der Netzwerkgewichte  $\mathbf{w}_n$  wird über Gradientenabstieg auf der quadratischen Fehlerfunktion  $(F_n - N_n(\mathbf{x}_n | \mathbf{w}_n))^2$  durchgeführt, womit wir

$$\Delta \mathbf{w}_n = \eta (F_n - N_n(\mathbf{x}_n | \mathbf{w}_n)) \cdot \frac{\partial N_n(\mathbf{x}_n | \mathbf{w}_n)}{\partial \mathbf{w}_n} \quad (1)$$

als Adaptionsregeln erhalten.

Die Meßdaten von 10.000 Bändern, was ungefähr einer Monatsproduktion entspricht, waren zum Vortraining der sieben Netzwerke verfügbar. So konnte jedes der sieben Netzwerke mit Datenpaaren  $(F_n^{(i)}, \mathbf{x}_n^{(i)})$ ,  $i=1, \dots, 10.000$ , vortrainiert werden. Nach diesem Vortraining, welches im *batch mode* durchgeführt werden kann, wurden die Netzwerke auf 53812 Bändern im *on-line* Modus getestet. Während dieses simulierten on-line Tests wurde mit jedem Band der Walzkraftfehler jedes Netzwerkes bestimmt, und anschließend wurde für jedes Netzwerk ein Adaptionsschritt durchgeführt. Der on-line Test simuliert die reale Anwendung an der Walzstraße und liefert exakt den Walzkraftfehler, den man während der fünf Monate, in denen die 53812 Bänder gewalzt wurden, bei Verwendung der neuronalen Netze erzielt hätte. Am Ende des on-line Tests bestimmten wir die mittleren quadratischen Walzkraftfehler der sieben Netzwerke über die 53812 Bänder, die wir dann mit den Fehlern des konventionellen Verfahrens vergleichen konnten. Das Resultat ist in Tabelle 1 dargestellt. Gemittelt über die sieben Gerüste erzielten die neuronalen Netze eine Reduzierung des mittleren quadratischen Walzkraftfehlers um 21%, was eine überaus signifikante Verbesserung bedeutet. Das neuronale Verfahren zur Walzkraftberechnung ist jetzt auch erfolgreich im realen Betrieb bei der Krupp Hoesch Stahl AG, Westfalahütte Dortmund, getestet worden und ist mittlerweile

eine wesentliche Komponente der kommerziell vertriebenen Prozeßautomatisierungssysteme für Warmbandstraßen.

Gerüst	1	2	3	4	5	6	7
Konv. Methode	1005	802	772	763	769	849	859
Neuronales Netz	767	636	557	549	619	736	754
<b>Verbesserung</b>	<b>+24%</b>	<b>+21%</b>	<b>+28%</b>	<b>+28%</b>	<b>+20%</b>	<b>+13%</b>	<b>+12%</b>

**Tabelle 1.** Der mittlere quadratische Walzkraftfehler des konventionellen sowie des neuronalen Verfahrens (in kN). Das neuronale Verfahren ist in der Lage, den Walzkraftfehler um bis zu 28% zu reduzieren.

#### 4. Breitung


Bild 2 zeigt die sogenannte Fertigstraße. In der Fertigstraße mit ihren horizontalen Walzen kann das Band nur auf die gewünschte Dicke hin gewalzt werden, nicht auf die benötigte Breite. Die Bandbreite wird in einem Walzvorgang mit vertikalen Walzen beeinflusst, und zwar bevor das Band in die Fertigstraße einläuft. Das Problem dabei ist, daß sich die Breite beim horizontalen Walzen in der Fertigstraße wieder etwas verändert. Diese Änderung der Breite nennt man Breitung. Um trotzdem die gewünschte Breite am Ende des Walzvorganges zu erzielen, ist es daher notwendig, die Breitung beim horizontalen Walzen in der Fertigstraße abzuschätzen. Eine gute Schätzung dieser Breitung ermöglicht es dann, die Einstellung der vertikalen Walzen genau um diesen Betrag der Breitung zu korrigieren, so daß nach der Fertigstraße dann tatsächlich die gewünschte Breite herauskommt. Mit den bisherigen Methoden ist die Schätzung der Breitung nicht zufriedenstellend. Um sicherzustellen, daß am Ende des Walzvorganges die Breite entlang des gesamten Bandes nirgends unter den geforderten Wert abfällt, ist es notwendig, die gewalzte Breite mit einem Sicherheitsaufschlag von 12mm zu versehen. Nach dem Walzen wird das Band auf die gewünschte Breite zugeschnitten. Um eine höhere Genauigkeit bei der Abschätzung der Breitung zu erreichen, haben wir ein Verfahren auf der Basis eines Neuronalen Netzes entwickelt. Die Eingabe  $\mathbf{x}$  des Neuronalen Netzes, ein 24-dimensionaler Vektor, enthält alle Größen, die einen Einfluß auf die Breitung des Bandes in der Fertigstraße haben könnten. Diese sind, u.a., die Bandtemperatur, die Banddicke, die Dickenreduktion an jedem Gerüst, die Bandbreite, die Walzgeschwindigkeit, der Vorwärts- und Rückwärtszug an jedem Gerüst etc. Die Ausgabe  $N(\mathbf{x} | \mathbf{w})$  des Netzwerkes ist dann der Schätzwert für die Breitung  $\Delta b$  des Bandes in der Fertigstraße.

Zur Erzielung optimaler Resultate ist es wiederum notwendig, das Netzwerk online, d.h. mit jedem gewalzten Band, zu adaptieren. Die Adaption der Netzwerkgewichte erfolgt dabei wieder über Gradientenabstieg auf der quadratischen Fehlerfunktion  $(\Delta b - N(\mathbf{x} | \mathbf{w}))^2$ , mit einem Gleichung (1) entsprechenden Adaptionsschritt. Zum Vortraining des Neuronalen Netzwerkes im batch-mode wurden Datenpaare

( $\Delta b^{(i)}$ ,  $x^{(i)}$ ) von ungefähr einer Monatsproduktion verwendet. Nach dem Vortraining wurde das Netzwerk wieder im on-line Modus getestet, diesmal auf 70306 Bändern. Auf diesen 70306 Bändern erzielte das neuronale Verfahren einen mittleren quadratischen Fehler bei der Schätzung der Breite von 2,7mm, das konventionelle Verfahren dagegen nur von 3,7mm. Das bedeutet, daß das Neuronale Netzwerk gegenüber der konventionellen Methode eine Verbesserung des Schätzfehlers von 27% erzielt. Dadurch wird es möglich, den Sicherheitsaufschlag von 12mm auf die Bandbreite zu reduzieren. Allein eine Reduktion um einen einzigen Millimeter bedeutet bei einer modernen Warmbreitbandstraße bereits eine Materialeinsparung von rund einer Millionen Mark pro Jahr. Das neuronale Verfahren ist mittlerweile mehr als ein Jahr bei Thyssen Stahl AG/Beeckerwehrt erfolgreich im Einsatz.

## 5. Bestimmung des Bandprofils

Neben der Breite und der Dicke ist das Profil das dritte wichtige Gütekriterium für die Geometrie des Walzgutes nach Verlassen der Fertigstraße. Im einfachsten Fall ist das Profil definiert als der Dickenunterschied zwischen der Mitte und den Rändern eines Bandes (Bild 3). Das Ziel ist, das Profil während des Warmwalzens so klein wie möglich zu halten, da es in späteren Kaltwalzprozessen nicht mehr beeinflußt werden kann.

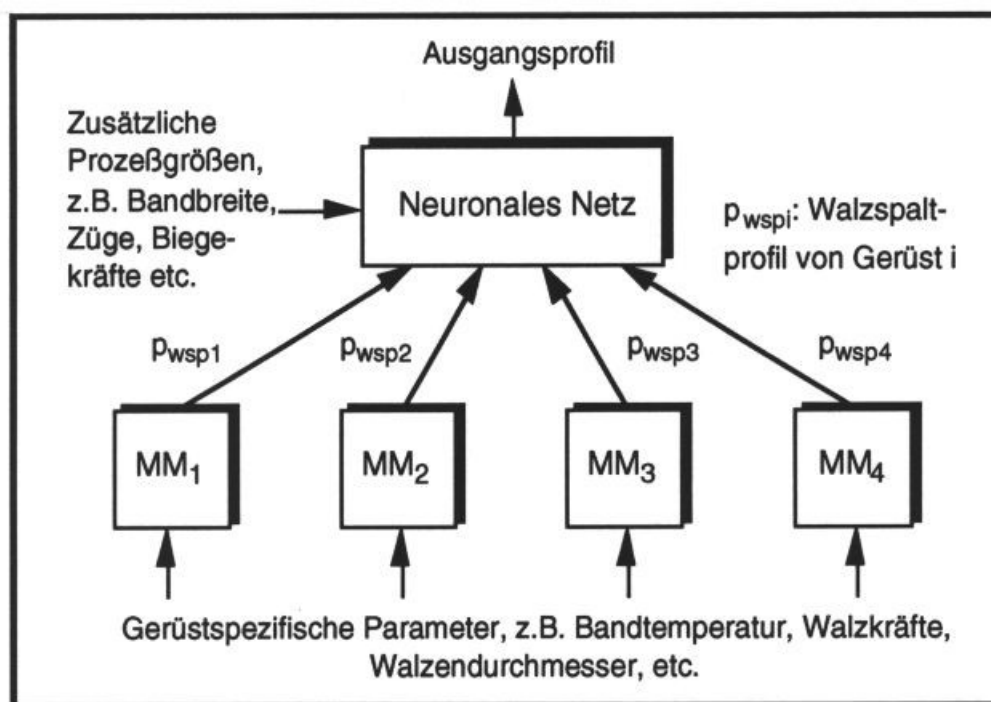


**Bild 3.** Definition des Bandprofils als mittlerer Dickenunterschied zwischen der Mitte und den Rändern eines Bandes.

Das Profil des Walzgutes nach dem Durchlaufen eines Gerüsts ergibt sich als Kombination des Bandprofils beim Eintritt in das Gerüst und dem Profil des Walzspalts. Das Walzspaltprofil resultiert aus einer mechanischen und thermischen Walzenverformung und spiegelt die Prozeßvorgangsgeschichte des Walzvorgangs wider. Die thermische Walzenverformung (thermischer Crown) hängt z.B. von den Temperaturen, Breiten und Pausenzeiten einer ganzen Reihe aufeinanderfolgender Bänder ab.

Die existierenden mathematischen Modelle, beispielsweise zur Berechnung des Walzspaltprofils, beruhen zwar auf der Modellierung der physikalischen Zusammenhänge, jedoch sind in der Praxis viele idealisierte Voraussetzungen für die Gültigkeit der Modelle nicht erfüllt. Dies führt zu der Verwendung von zusätzlichen, heuristischen Modellen mit einer Vielzahl unbekannter Parameter, deren „Feintuning“ durch zeit- und kostenaufwendige Handarbeit erfolgt.

Neuronale Netze können zur Profilbestimmung auf verschiedene Arten eingesetzt werden. Bild 4 zeigt einen hybriden Ansatz, bei dem gerüstspezifische mathematische Modelle ( $MM_1$  bis  $MM_4$  bei insgesamt 4 Gerüsten nach Bild 2) die Walzspaltprofile bestimmen. Diese Ergebnisse bilden zusammen mit weiteren Prozeßgrößen den Eingangsvektor für ein Neuronales Netz, das darauf trainiert wird, anhand dieser Informationen das Profil am Ende der Fertigstraße zu bestimmen. Ein solcher hybrider Ansatz hat den Vorteil, daß existierendes Vorwissen über die physikalischen Prozesse in Form der mathematischen Modelle verwendet werden kann. Die Ungenauigkeiten dieser Modelle können nun jedoch in einem datengetriebenen Lernvorgang kompensiert werden, wobei im Prinzip beliebige zusätzliche Einflußfaktoren in Form von weiteren Netzeingängen berücksichtigt werden können. Die vom Neuronalen Netz gelernte Abbildung stellt quasi einen arbeitspunktabhängigen, nichtlinearen Korrekturfaktor dar, der sich während des on-line Trainings zeitlich ändert.



**Bild 4.** Eine Möglichkeit zur Kombination von mathematischen Modellen (MM) mit einem Neuronalen Netz zur Bestimmung des Profils nach dem Durchlaufen der Fertigstraße.

Simulationsergebnisse mit realen Daten, die über 3 Monate an einem Aluminium

Walzwerk mit 4 Gerüsten gesammelt wurden, haben ergeben, daß die Vorhersage des Endprofils um ca. 20% gegenüber der rein mathematischen Modellierung verbessert werden kann. On-line Experimente an einem laufenden Prozeß sind z. Zt. geplant, um die bisherigen Ergebnisse in der Praxis zu validieren.

## 6. Ausblick

Die oben diskutierten Anwendungen sind Beispiele für den vielfältigen Einsatz Neuronaler Netze im Bereich der Walzwerksautomatisierung. Einige der neuronalen Verfahren sind bereits fester Bestandteil kommerzieller Anlagen und tragen wesentlich zur Qualitätsverbesserung des Walzgutes bei, andere Anwendungen befinden sich noch im Versuchsstadium. Insbesondere bei nichtlinearem und instationärem Prozeßverhalten bieten neuronale Verfahren aufgrund ihrer Fähigkeit zur nichtlinearen Modellierung und Adaption einen interessanten Ansatzpunkt. Unsere Untersuchungen haben gezeigt, daß eine Kombination von mathematischen und neuronalen Modellen die Vorteile beider Methoden auf elegante Weise verbinden kann. Dies stellt aufgrund der Komplexität des Prozesses häufig auch den einzig gangbaren Weg dar. Neben diesen Erfolgen ist jedoch auch deutlich geworden, daß die bei der Walzwerksautomatisierung auftretenden Probleme mit dem gegenwärtigen Stand der Technik der Neuronalen Netze noch nicht abschließend gelöst werden können. Eine Reihe von grundlegenden Fragestellungen, wie z.B. die Stabilität der on-line Adaption, Verfahren zur Integration von Vorwissen oder die geeignete Strukturierung eines hybriden Gesamtsystems, sind weiterhin Gegenstand aktueller Forschungsprojekte.

## Literatur

- Hollatz, J. & Martinetz, T. (1995). „Neuro-Fuzzy in der Prozeßautomatisierung“, Expert Verlag, (in press).
- Lindhoff, D., Sörgel, G., Gramckow, O. & Klode, K.-D. (1994). „Erfahrungen beim Einsatz Neuronaler Netze in der Walzwerksautomatisierung“. Stahl und Eisen, 114, Heft 4, S. 49-53+208.
- McCloskey, M. & Cohen, N. (1989). „Catastrophic Interference in Connectionist Networks: The Sequential Learning Problem“. The Psychology of Learning and Motivation, 24, pp. 109-165.
- Neumerkel, D., Donne, J. & Murray-Smith, R. (1994). „Neural Network Applications for Process Control“. Proc. of the 2nd European Congress on Intelligent Techniques and Soft Computing - EUFIT '94, Aachen, Verlag der Augustinus Buchhandlung, pp. 138-142.
- Poppe, T. & Martinetz, T. (1993). „Estimating Material Properties for Process Optimization“. Proc. of the International Conference on Artificial Neural Networks - ICANN '93, Amsterdam, Springer Verlag, pp. 795-798.
- White, D. & Sofge, D. (Eds.), (1992). „Handbook of Intelligent Control - Neural, Fuzzy, and Adaptive Approaches“, Van Nostrand Reinhold, New York.