

Sonderdruck aus
„atp – Automatisierungstechnische Praxis“ 38 (1996),
Heft 10, Seite 28–42

Neuronale Netze zur Steuerung von Walzstraßen

Thomas Martinetz
Otto Gramckow
Peter Protzel
Günter Sörgel

Neuronale Netze zur Steuerung von Walzstraßen

Thomas Martinetz, München, Otto Gramckow, Peter Protzel und Günter Sörgel, Erlangen

Dr. rer. nat. Thomas Martinetz ist in der Zentralen Forschung und Entwicklung der Siemens AG Assistent des Vorstands. Zuvor leitete er in der Gruppe „Neuronale Informationsverarbeitung“ das Projekt „Neuronale Verfahren in der Prozeßautomatisierung“. Seine Interessenschwerpunkte sind biologische Informationsverarbeitungskonzepte, ihre theoretische Analyse und ihre industriellen Anwendungsmöglichkeiten.

Dr.-Ing. Otto Gramckow ist bei der Siemens AG im Unternehmensbereich Anlagentechnik, Geschäftsgebiet Grundstoffindustrie, als Segmentleiter im Stammhaus Erlangen verantwortlich für die Entwicklung mathematischer Modelle für Prozeßführungssysteme in der Hüttenindustrie.

Dr.-Ing. Peter Protzel ist Leiter des Bereichs „Neuronale Netze und Fuzzy Logik“ beim Bayerischen Forschungszentrum für Wissensbasierte Systeme (FORWISS) in Erlangen. Arbeitsschwerpunkte: Einsatz von Neuronalen und Fuzzy Methoden zur Wissensbasierten Prozeßführung, in Adaptiven Systemen und zur Mustererkennung und Prognose.

Dipl.-Ing. Günter Sörgel ist bei der Siemens AG im Unternehmensbereich Anlagentechnik, Geschäftsgebiet Grundstoffindustrie, als Abteilungsleiter im Stammhaus Erlangen verantwortlich für den Geschäftszweig Prozeßautomatisierung und Prozeßleittechnik in der Hüttenindustrie.

Eine optimierte Prozeßführung in der Stahl- und Aluminiumherstellung kann zu erheblichen Einsparungen an Material und Energie sowie Verbesserungen der Produktqualität führen. Der Artikel beschreibt schwerpunktmäßig, wie Neuronale Netze im industriellen Einsatz an Walzstraßen eine Verbesserung sowohl der Prozeßmodellierung als auch der Prozeßmodelladaption ermöglichen. Die vorgestellten neuronalen Verfahren verbessern die Walzbandgeometrie, das heißt, Banddicke, Bandbreite sowie Bandprofil. Entscheidend bei der Ausschöpfung des Verbesserungspotentials ist die besonders ausgeprägte Fähigkeit Neuronaler Netze zur on-line-Adaption sowie die Möglichkeit, Neuronale Netze mit existierenden mathematischen Modellen zu verknüpfen. Die vorgestellten neuronalen Verfah-

ren sind mittlerweile fester Bestandteil von kommerziell vertriebenen Prozeßautomatisierungssystemen für Walzstraßen.

Neural networks for control of rolling mills

Optimized process control in steel and aluminium production can lead to significant material- and energy savings as well as significant improvements in product quality. The paper describes how Neural Networks in industrial operation at hot strip rolling mills improve process modelling and allow process model adaptation. The neural process control schemes which are presented lead to increased accuracy of the steel strip's geometry, including its thickness, width and profile. Crucial for the successful exploitation of the improvement potential is the Neural Networks' outstanding capability for on-line adaptation and the possibility to combine Neural Networks with existing mathematical models. The neural control schemes which are presented are now part of the commercially available process automation systems for rolling mills.

1. Einleitung

Stahl und Aluminium gehören zu den wesentlichen Grundstoffen unserer Industriegesellschaft. Mit 725 Millionen Tonnen Weltjahresproduktion war die Stahlerzeugung auch im Jahr 1993 weiter ansteigend, und mit 18,5 Millionen Tonnen (1992) ist die Bundesrepublik weltweit der größte Stahlexporteur. Der Schwerpunkt der Exporte liegt bei hochwertigen Qualitätsstählen. Gleichzeitig gehört die Herstellung

von Stahl und Aluminium zu den energieintensivsten Branchen in der Bundesrepublik und ist besonders abhängig vom Energiepreinsniveau. Daher spielen zunehmend Verfahren eine Rolle, die es erlauben, den Herstellungsprozeß, und damit auch das im folgenden betrachtete Walzen von Bändern, hinsichtlich Qualität sowie Energie- und Materialeinsatz zu optimieren.

In den letzten 20 Jahren sind eine Reihe von mechanischen und regelungstechnischen Methoden zur verbesserten Walzwerksteuerung entwickelt worden, die bereits zu einer beträchtlichen Optimierung des Walzprozesses geführt haben. Diese Methoden sind mittlerweile jedoch im wesentlichen ausgereizt.

Eine weitere Optimierung verspricht man sich durch den Einsatz neuer, „intelligenter“ Verfahren der Informationsverarbeitung, wie sie künstliche Neuronale Netze darstellen. Der erfolgversprechendste Einsatz Künstlicher Neuronaler Netze liegt dabei weniger im Bereich der Basisautomatisierung, obwohl auch dort mit neuronalen Ansätzen experimentiert wird [1], sondern vielmehr auf der übergeordneten Prozeßführungsebene [2; 3; 4]. Die zentrale Aufgabe der Prozeßführungsebene einer Walzstraße ist im Bild 1 dargestellt. Die zentrale Aufgabe der Prozeßführung besteht darin, ausgehend von Primärdaten und Sollwerten sowie basierend auf Modellen bzw. Tabellen, die für das jeweils nächste Band erforderliche Voreinstellung der Anlage vor dessen Einlauf in die Walzstraße möglichst genau zu berechnen. Diese vorausgerechneten Voreinstellungen werden als Führungsgrößen an die Basisautomatisie-

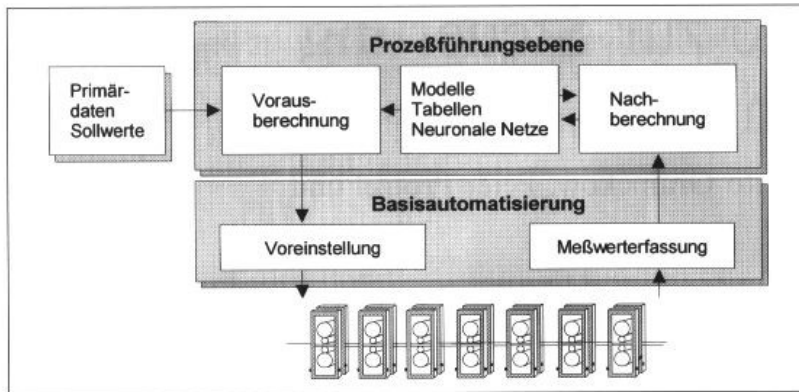


Bild 1: Arbeitsprinzip der Prozeßführung von Walzstraßen.

...ung übermittelt, die darauf aufbauend die gesamte Regelung und Steuerung übernimmt. Mit der Meßwerterfassung der Basisebene können die Modelle und Tabellen über die sogenannte Nachberechnung nach Walzen des Bandes modifiziert werden.

Die Prozeßführung stützt sich auf eine Reihe von Modellen, welche die in der Walzstraße ablaufenden physikalischen Prozesse mehr oder weniger gut, jedoch niemals vollständig, beschreiben. Die Beschreibung wird insbesondere durch zahlreiche nichtlineare Einflüsse sowie die zeitliche Änderung des Prozeßverhaltens erschwert. Häufig sind die unterliegenden physikalischen Prozesse derart komplex und wenig verstanden, daß das „Modell“ im wesentlichen schlicht einer Tabelle entspricht, deren Werte über die zyklische Nachberechnung zunächst ermittelt und danach ständig den zeitvarianten Prozessen angepaßt werden. Neuronale Netze stellen eine vorteilhafte Alternative zu diesen Modellen und Tabellen dar, denn sie eignen sich in besonderer Weise für die Modellierung nichtlinearer, von vielen Einflußfaktoren abhängiger Prozesse und zeichnen sich durch hervorragende on-line-Adaptionsfähigkeiten aus. Man verspricht sich daher vom Einsatz Neuronaler Netze in der Walzwerksteuerung eine Reihe von Vorteilen. Zum einen verspricht man sich natürlich höhere Genauigkeiten bei der Vorausberechnung sowie eine bessere Adaption an die zeitvarianten Prozesse, das heißt, an die sogenannte

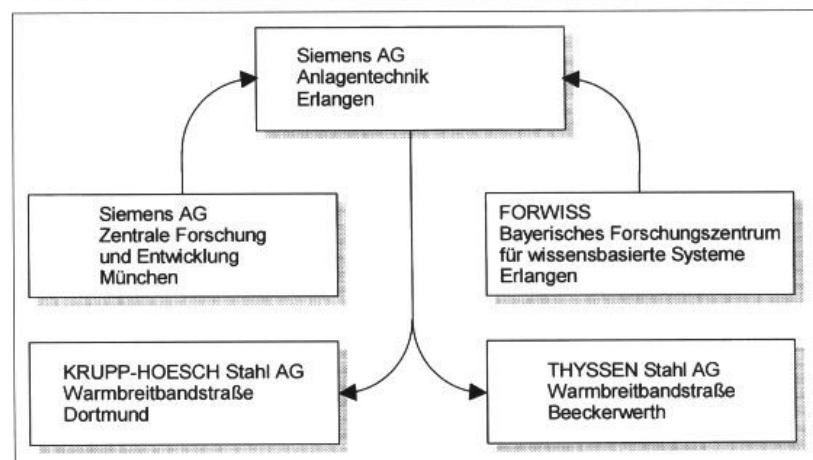
„Tagesform“ einer Walzstraße. Des weiteren erwartet man aufgrund der Fähigkeit Neuronaler Netze zur Selbstadaption aber auch eine einfachere, schnellere und damit kostengünstigere Inbetriebnahme.

Es gibt verschiedene Anforderungen an das Ergebnis des Walzprozesses, welche bei einer Verbesserung der Walzgutqualität berücksichtigt werden müssen. Zum einen sind es Anforderungen an die Werkstoffeigenschaften, wie zum Beispiel Festigkeit, Zähigkeit und Schweißbarkeit. Diese werden nicht nur durch die Materialzusammensetzung, sondern insbesondere auch durch die Art der Walzung beeinflusst. Neben der Materialkonsistenz muß jedoch auch die Geometrie des gewalzten Bandes vorgegebenen Kriterien genügen. Insbesondere für Dicke, Breite und das sogenannte Dickenprofil des Bandes,

seinen Querschnitt, werden vor dem Walzprozeß Zielwerte vorgegeben; Abweichungen von den Zielwerten bedeuten eine Qualitätsminderung des Bandes. Mit welcher Präzision dazu der Walzprozeß gesteuert werden muß, wird deutlich, wenn man bedenkt, daß beispielsweise aus einem Stahlblock (Bramme) von rund 20 cm Dicke, 1 m Breite und 10 m Länge ein etwa 1 km langes und 1 m breites Stahlband von etwa 2 mm Dicke gewalzt wird, wobei die vorgegebene Dicke auf 10 µm genau getroffen werden muß. Im folgenden wird gezeigt, wie durch den Einsatz Neuronaler Netze die geometrischen Zielgrößen des Walzprozesses deutlich genauer getroffen werden können als mit den bisherigen, konventionellen Verfahren.

Bild 2 nennt die Beteiligten an den hier vorgestellten Arbeiten. Die Gesamtkoordinierung liegt im Siemens-Bereich Anlagentechnik. Die wesentlichen Grundlagen werden vorzugsweise von der Zentralen Forschung und Entwicklung der Siemens AG erarbeitet. Am Projekt zur Bestimmung des Banddickenprofils ist FORWISS maßgeblich beteiligt. An der Warmbreitbandstraße von Krupp-Hoesch AG in Dortmund ist die neuronale Walzkraftsteuerung und an der Warmbreitbandstraße von Thyssen Stahl AG in Beeckerwerth die neuronale Breitungsvorhersage langfristig erprobt und zwischenzeitlich für den routinemäßigen Einsatz über-

Bild 2: Die Partner: vertikale (Forschung, Vertrieb, Kunde) als auch horizontale (Siemens ZFE, FORWISS) Kooperation mit Siemens Anlagentechnik als Koordinator.



nommen worden. Bevor wir die einzelnen Verfahren vorstellen, wollen wir zunächst im nächsten Abschnitt die grundsätzliche Problematik beschreiben, 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 am häufigsten dann eingesetzt, wenn kein oder kein ausreichend genaues Streckenmodell existiert, zum Beispiel weil die Nichtlinearitäten des




Bild 3: Verschiedene Ursachen von Nichtlinearität: (i) durch Arbeitspunktverschiebungen und (ii) durch instationäres Prozeßverhalten.

Prozesses nicht genau bekannt und daher nicht analytisch faßbar sind. In diesen Fällen kann die besondere Fähigkeit Neuronaler Netze ge-

nutzt werden, unbekannte nichtlineare Zusammenhänge an Hand stichprobenartiger Meßdaten, sogenannter Trainingsdaten, adaptiv nachzubilden (siehe Kasten „Die Mathematik zu Neuronalen Netzen“). Diese Aufgabe wird allerdings stark erschwert, wenn die Prozesse zusätzlich zeitlich veränderlich sind [5]. Bild 3 veranschaulicht das Problem an Hand eines einfachen Beispiels eines Prozesses mit einer zeitlich variierenden Eingangsgröße x (z. B. Bandbreite) und einer Ausgangsgröße $y = f_t(x)$, mit t als Zeit. $f_t(x)$ beschreibt den sich zeitlich verändernden Zusammenhang zwischen Eingangsgröße x und Ausgangsgröße y , wobei $f_t(x)$ in der Regel wesentlich langsamer mit der Zeit variiert als die Eingangsgröße x .

Die Mathematik zu Neuronalen Netzen

Die wesentliche Funktionsweise eines Neuronalen Netzes besteht darin, ausgehend von einem in der Regel mehrdimensionalen Eingangsvektor x ein Ausgabesignal $\hat{y} = N(x|\mathbf{w})$ zu generieren, und zwar abhängig von sogenannten Netzwerkgewichten $\mathbf{w} = (w_1, \dots, w_G)$. Bei dem am häufigsten verwendeten Netzwerktyp, dem Multilayer Perceptron ([7] gibt einen umfassenden Überblick), wird zum Beispiel der Ausgabewert durch eine lineare Überlagerung M sigmoider Funktionen, durch

$$\hat{y} = \sum_{\mu=1}^M w_{\mu} \sigma(w_{\mu} \cdot x - \theta_{\mu}),$$

mit $\sigma(\cdot) = 1/(\exp^{-\cdot} + 1)$ und $w_{\mu} \cdot x$ als Skalarprodukt, gebildet. w_{μ} , w_{μ} , θ_{μ} sind die Netzwerkgewichte \mathbf{w} des Multilayer Perceptrons. Es ist gezeigt worden, daß mit solch einer Überlagerung sigmoider Funktionen jeder stetige nichtlineare Zusammenhang beliebig genau nachgebildet werden kann, wenn die Anzahl M dieser sigmoiden Funktionen entsprechend hoch gewählt wird.

Die adaptive Modellierung eines zunächst unbekanntes Zusammenhanges $y = f(x)$ zwischen einer Größe y und einer Reihe von Einflußfaktoren $x = (x_1, \dots, x_D)$ geschieht dabei in zwei zyklisch ablaufenden Schritten: (i) einer Ausgabegrößengenerierung und (ii) einer anschließenden Adaption. Aus einem Pool von in der Regel gemessenen Stichproben (y_i, x_i) , $i = 1, \dots, I$, I möglichst groß, wird dem Neuronalen Netz einer der aus den Einflußfaktoren bestehenden Vektoren x_i als Eingabe präsentiert. Daraufhin generiert das Neuronale Netz ein Ausgabesignal $\hat{y}_i = N(x_i|\mathbf{w})$. Dieses Ausgabesignal sollte

bei korrekter Modellierung des Zusammenhanges $f(x_i)$ dem Wert y_i der gewählten Stichprobe entsprechen, weicht jedoch zumindest in der Trainingsphase mehr oder weniger stark von y_i ab. Daher werden in einem nachfolgenden Schritt die Netzwerkgewichte derart adaptiert, daß die Abweichung $(y_i - \hat{y}_i)$ sich vom Betrag reduziert. Dies wird gezielt über Gradientenabstieg in den Gewichten \mathbf{w} auf der quadratischen Fehlerfunktion

$$E(\mathbf{w}) = (y_i - N(x_i|\mathbf{w}))^2$$

erreicht. Als Adaptionregel für die Gewichte ergibt sich

$$\Delta \mathbf{w} = \varepsilon (y_i - N(x_i|\mathbf{w})) \frac{\partial N(x_i|\mathbf{w})}{\partial \mathbf{w}},$$

mit ε als Adaptionsschrittweite.

Nach der Adaption wird eine nächste Stichprobe aus dem gegebenen Pool von Trainingsdatenpaaren präsentiert, wiederum generiert das Neuronale Netz eine Ausgabegröße, und über die Abweichung von der Sollausgabegröße y_i werden die Netzwerkgewichte ein weiteres Mal adaptiert (trainiert). Durch vielfaches Wiederholen von Ausgabegrößengenerierung und anschließender Adaption paßt sich das Neuronale Netz langsam an den zu modellierenden Zusammenhang $f(x)$ an. Die Stichproben (y_i, x_i) werden entweder für ein off-line-Training vorher gesammelt oder, wie hier im Fall der Walzwerksteuerung, in zeitlich diskreten Abständen, das heißt, mit jedem gewalzten Band, dem System entnommen (on-line-training).

Bezüglich der Ausgangsgröße des Prozesses, $y = f_i(x)$, überlagern sich bei der Walzwerksteuerung zwei Effekte: (i) Nichtlinearität durch Arbeitspunktverschiebungen (Änderung von x bei stationärer Prozesscharakteristik $f_i(x)$) und (ii) instationäres Prozeßverhalten $f_i(x)$ (bei konstantem Arbeitspunkt x). Fall (i) ist eine klassische Anwendung statischer Neuronaler Netze, welche die nichtlineare Charakteristik $f(x)$ im Prinzip beliebig genau nachbilden können. Kommt eine Instationarität des Prozesses hinzu, ist eine on-line-Adaption erforderlich. Die Modellierung muß in diesem Fall permanent der zeitlichen Veränderung des globalen Zusammenhanges $y = f_i(x)$ folgen, und zwar an Hand von diesen Zusammenhang $y = f_i(x)$ beschreibenden Trainingsdaten. Dazu ist es notwendig, daß das Neuronale Netz relevante neue Daten möglichst schnell lernt, ohne alte, immer noch relevante Informationen zu vergessen (Stabilitäts- vs. Plastizitätsdilemma [6]). Besonders der Fähigkeit Neuronaler Netze zur on-line-Adaption an die „Tagesform“ der Walzstraße sind die Verbesserungen zuzuschreiben, über die in den folgenden Abschnitten berichtet wird.

3. Walzkraftsteuerung

Bild 4 zeigt schematisch die Fertigstraße eines Warmbreitbandwalzwerkes, bestehend aus (vereinfacht) vier Gerüsten. In der Fertigstraße solch eines Warmbreitbandwalzwerkes wird das Band bei Temperaturen um 1000 °C auf die ge-

wünschte Dicke gewalzt. Im Rahmen einer zyklischen Vorausberechnung – durchgeführt jeweils vor Bandeinlauf – wird jedem Gerüst n eine bestimmte Dickenreduktion $d_n - d_{n-1}$ des Bandes zugewiesen. Um zu gewährleisten, daß bereits zu Beginn des Walzprozesses und nicht erst nach Einschwingen der Dickenregelung die benötigten Dickenreduktionen erzielt werden, wird jedes Gerüst n möglichst genau voreingestellt. Dabei ist es wichtig zu wissen, daß bei gleicher Walzenanstellung die letztendliche Weite des Walzspaltes, die dann gleich der auslaufenden Banddicke ist, ganz erheblich von der Belastung des Gerüsts, also von der Walzkraft, abhängt. Dies liegt unter anderem an der elastischen Auffederung des Gerüsts. Mit anderen Worten: Die genaue Voreinstellung eines Walzgerüsts verlangt eine sehr genaue Kenntnis der zu erwartenden Walzkraft.

Bei der Vorausberechnung der Walzkraft geht es um den sogenannten Bandkopf. Entlang des Bandkopfes, der die ersten rund 30 m des Bandes bezeichnet, stehen noch keine on-line-Meßwerte zur Verfügung, auf denen die Dickenregelung aufsetzen könnte. Ohne eine exakte Walzkraft ist die Dicke in diesem Bereich jedoch fehlerhaft, was zu einer Qualitätsminderung des Bandes führt und bedeutet, daß der Kunde, z. B. die Autoindustrie, die ersten 30 m des Bandes nicht verwenden kann. Diese sind dann Ausschuß und müssen wieder eingeschmolzen werden.


Der Zusammenhang zwischen Walzkraft F_n und resultierender re-

lativer Dickenreduktion $\varepsilon_n = d_n / d_{n-1}$ hängt von vielen Einflußfaktoren ab und ist schwierig zu beschreiben. Bislang wurden dazu physikalische Modelle der ablaufenden Prozesse verwendet, mit unterschiedlichen Modellparameterwerten für die unterschiedlichen Stahlqualitäten. Die erzielte Genauigkeit läßt jedoch noch Spielraum für weitere Verbesserungen. Weiterhin erfordert diese Methode eine sehr sorgfältige Buchhaltung der Modellparameter für die verschiedenen Stahlqualitäten, und für jede neue Stahlqualität müssen die Modellparameter von Grund auf neu angepaßt werden.

Mit der Entwicklung eines Verfahrens zur Walzkraftvorausberechnung basierend auf Neuronalen Netzen sollte nicht nur die Genauigkeit bei der Bestimmung der erforderlichen Walzkraft erhöht werden, sondern auch die Schwäche des alten Verfahrens behoben werden, für verschiedene Stahlqualitäten verschiedene Modellparameterwerte oder in Einzelfällen sogar verschiedene Modellansätze verwenden zu müssen. Denn nur ein globales, für alle Stahlqualitäten zuständiges Modell ist in der Lage, vorhandenes Wissen über sich einstellende Walzkraften auf neue Stahlqualitäten zu verallgemeinern. Mit einem Neuronalen Netz, welches zwischen verschiedenen Stahlqualitäten an Hand der chemischen Materialzusammensetzung unterscheidet, wird es möglich, mit einem einzigen (neuronalen) Modell alle Stahlqualitäten abzudecken. Der Eingabevektor für das Neuronale Netz enthält nun unter anderem die Konzentrationen der chemischen Komponenten des Materials, womit sich verschiedene Stähle dann in ihren Eingabevektoren für das Neuronale Netz unterscheiden. Dadurch wird es möglich, auf neue Stähle hin zu verallgemeinern und auf die eher künstliche Kategorisierung „Stahlqualität“ bzw. „Aluminiumqualität“ mit einem jeweils eigenen Modellparametersatz oder sogar Modellansatz zu verzichten.

An jedem Gerüst n – die im folgenden betrachtete Fertigstraße der Westfalenhütte von Krupp-Hoesch

Bild 4: 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.



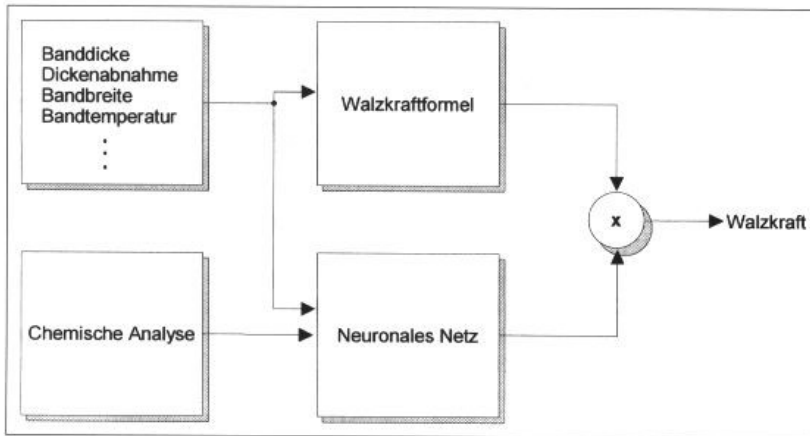


Bild 5: Multiplikative Verknüpfung des physikalischen Modells (Walzkraftformel) mit dem Neuronalen Netz zur Berechnung der Walzkraft. Über das Neuronale Netz können jetzt auch die Ergebnisse aus der chemischen Analyse des Materials berücksichtigt werden.

in Dortmund besteht aus sieben Gerüsten $n = 0, \dots, 6$ – wird ein Neuronales Netzwerk $N_n(x_n | w_n)$ für die Berechnung der an Gerüst n zu erwartenden Walzkraft F_n eingesetzt. Der 25-dimensionale Eingabevektor x_n des Neuronalen Netzes enthält als Komponenten die 16 wichtigsten chemischen Elemente des Materials, die Werte der physikalischen Einflußfaktoren Bandbreite, Banddicke, Bandtemperatur usw. am betrachteten Gerüst n , sowie natürlich die an diesem Gerüst gewünschte Dickenabnahme. Der Vektor w_n besteht aus den Gewichten des Neuronalen Netzes.


Die Walzkraftberechnung wird nun nicht allein basierend auf dem Neuronalen Netz durchgeführt, sondern es wird ein als Walzkraftformel bezeichnetes starres mathematisches Modell angesetzt, welches durch das Neuronale Netz multiplikativ korrigiert wird. Dies ist im Bild 5 schematisch dargestellt. Dieser Ansatz ermöglicht es, in einfacher Weise bereits vorhandenes Vorwissen über den zu modellierenden Zusammenhang einfließen zu lassen. In unserem Fall beschreibt die Walzkraftformel, basierend auf den physikalischen Einflußfaktoren, den für alle Stahlarten grob geltenden globalen Zusammenhang, und das Neuronale Netz lernt die für jede Stahlart spezifisch notwendige Korrektur.

Zunächst wurden die sieben Netzwerke im Labor vortrainiert. Dazu standen Meßdaten von 10000

Bändern zur Verfügung, was ungefähr einer Monatsproduktion der betrachteten Fertigstraße entspricht. Von jedem der 10000 Bänder lagen vor die an jedem Gerüst gemessene Walzkraft F_n sowie die Werte der Komponenten des Eingangsvektors x_n , das sind die 16 wichtigsten chemischen Elemente, Bandbreite, Banddicke, Bandtemperatur, Dickenabnahme usw. an Gerüst n . So konnte jedes der sieben Netzwerke zunächst im Labor mit Datenpaaren $(F_n(i), x_n(i))$, $i = 1, \dots, 10000$, auf die am entsprechenden Walzgerüst gegebene Walzkraftcharakteristik hin voradaptiert werden.

Nach diesem Vortraining wurden die Netzwerke an der Warmbreitbandstraße der Westfalahütte Dortmund, Krupp Hoesch Stahl AG, installiert und nach sorgfältigen Tests im Mai '94 „scharfgeschaltet“. Das dabei erzielte Ergeb-

Bild 6: Die mit der neuronalen Walzkraftvorausberechnung im realen Betrieb erzielte Verbesserung. Aufgetragen ist für das neuronale (Quadrate) und das konventionelle Verfahren (Kreise) die Wurzel aus dem mittleren quadratischen Walzkraftfehler an jedem Gerüst.



nis, die Verringerung des Walzkraftfehlers relativ zum konventionellen Verfahren, ist im Bild 6 dargestellt. Dort ist der mittlere Walzkraftfehler an jedem Gerüst, gemittelt über 2000 sogenannte Umstellungsbänder, für das neuronale als auch das bisherige konventionelle Verfahren aufgetragen. Das alte Verfahren lief für den Vergleichstest weiterhin passiv mit. Der Walzkraftfehler ist dabei auf den mittleren Walzkraftfehler des konventionellen Verfahrens am letzten Gerüst bezogen.

Einbezogen in den Vergleich beider Verfahren wurden nur sogenannte Umstellungsbänder, bei denen die Berechnung der erforderlichen Walzkraft besonders schwierig ist. Es werden immer möglichst mehrere Bänder annähernd gleicher Stahlqualität und annähernd gleicher Geometrie hintereinander gewalzt (Kommission). Entscheidend und schwierig ist die Walzkraftberechnung jeweils für das erste Band einer solchen Kommission, also bei der Umstellung von einer Stahlqualität und Geometrie auf eine andere. Für diese Umstellungsbänder werden die höheren Verfahren zur Walzkraftberechnung benötigt. Bei den sogenannten Folgebändern einer Kommission kann man einfach auf die Walzkraft des Vorgängerbandes zurückgreifen, denn diese werden sich bei einem annähernd gleichen Folgeband nur unwesentlich ändern.

Relativ zum konventionellen Ansatz erzielt das neuronale Verfahren die in Tabelle 1 für jedes Gerüst aufgeführten prozentualen

Tabelle 1: Die an jedem Gerüst erzielte prozentuale Verbesserung gegenüber der konventionellen Walzkraftvorausberechnung.

Gerüst	0	1	2	3	4	5	6
Verbesserung	+32%	+27%	+29%	+28%	+25%	+19%	+32%

Verbesserungen der Walzkraftberechnung. Die neuronale Walzkraftberechnung verringert den Walzkraftfehler des konventionellen Verfahrens um die in Tabelle 1 aufgeführten Prozentpunkte. Gemittelt über alle sieben Gerüste ergibt sich eine Reduzierung des mittleren Walzkraftfehlers um 27%, was eine überaus signifikante Verbesserung bedeutet. Besonders hoch wird die am letzten Gerüst erzielte überdurchschnittliche Verbesserung von 32% bewertet, denn am letzten Gerüst muß die Walzkraft besonders exakt getroffen werden, da sich insbesondere dort die Genauigkeit der Enddicke des Bandes entscheidet.

Bild 7 zeigt den mittleren Walzkraftfehler des konventionellen sowie des neuronalen Verfahrens für verschiedene Stahlsorten. Auch bei separatem Test auf verschiedenen Stählen, hier aufgeteilt nach acht verschiedenen Stahlgruppen, ist das neuronale Verfahren durchweg besser als die konventionelle Walzkraftberechnung. Beide Verfahren sind gut bei sehr häufig gewalzten Stählen (Stahlgruppe 5) und schlechter bei seltenen Stahlsorten (Stahlgruppe 1 und 8). Dies liegt einfach daran, daß die spezifische Adaption an die Walzkraftcharakteristik von

Stahlgruppe 5 weitgehender und vollständiger erfolgt als bei Stahlgruppe 1 und 8. Bei der Bewertung der bis zu fünfzigprozentigen Verbesserungen ist allerdings zu bedenken, daß die statistische Sicherheit der Ergebnisse für verschiedene Stahlgruppen sehr unterschiedlich ist.

4. Bestimmung der natürlichen Breitung

Bild 4 skizziert, wie gesagt, die sogenannte Fertigstraße. In der Fertigstraße mit ihren horizontalen Walzen kann das Band nur auf die gewünschte Dicke hin gewalzt werden, nicht jedoch auf die benötigte Breite. Die Bandbreite wird in einer sogenannten Vorstraße mit zusätzlichen vertikalen Walzen beeinflusst, und zwar bevor das Band in die Fertigstraße einläuft. Das Problem bei dieser sequentiellen Vorgehensweise ist, daß die in der Vorstraße eingestellte Breite sich beim horizontalen Walzen in der Fertigstraße wieder etwas ändert. Diese Änderung der Breite in der Fertigstraße nennt man natürliche Breitung. Dabei wirken zwei gegenläufige Prozesse: Der Walzdruck verbreitert das Band, die Züge zwischen den

Walzgerüsten führen zu einer Versmälnerung. In der Regel überwiegt der Einfluß der Züge und die natürliche Breitung ist negativ. Um trotz dieses Breitungseffekts ein Stahlband mit der gewünschten Bandbreite zu erzielen, wird das Ausmaß der natürlichen Breitung in der Fertigstraße vorher abgeschätzt. Eine genaue Schätzung der Breitung ermöglicht es dann, die Einstellung der Vorstraße vorab so zu korrigieren, daß nach der Fertigstraße tatsächlich die gewünschte Bandbreite herauskommt.

Die – wie auch immer realisierte – Schätzung der natürlichen Breitung ist natürlicherweise fehlerbehaftet. Um dennoch sicherzustellen, daß die geforderte Mindestbreite über die gesamte Länge des Fertigbandes eingehalten wird, arbeitet der praktische Walzbetrieb mit einem Sicherheitsaufschlag von mehreren Millimetern auf die Sollbreite. Nach dem Walzen wird das Band dann auf die gewünschte Breite zugeschnitten.

Um eine höhere Genauigkeit bei der Abschätzung der natürlichen Breitung zu erzielen, wurde ein Verfahren auf der Basis eines Neuronalen Netzes entwickelt. Da konventionelle Modelle zur Vorhersage der Breitung besonders bei breiten Bändern sehr unzuverlässig arbeiten, wird hier, im Gegensatz zur Walzkraftvorausberechnung, allein ein Neuronales Netz zur Modellierung des Breitungsverhaltens und nicht eine Kombination von mathematischem Modell mit Neuronalem Netz angesetzt. Die Eingabe 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 unter anderem die Bandtemperatur, Banddicke, Dickenreduktion an jedem der sieben Gerüste der Fertigstraße, Bandbreite, Walzgeschwindigkeit, Vorwärts- und Rückwärtszug an jedem Gerüst usw. Der Ausgangswert $N(x|w)$ des Netzwerkes ist dann der Schätzwert für die natürliche Breitung Δb des Bandes.

Wie die Netzwerke zur Walzkraftvorausberechnung wurde auch das Netzwerk zur Vorhersage der

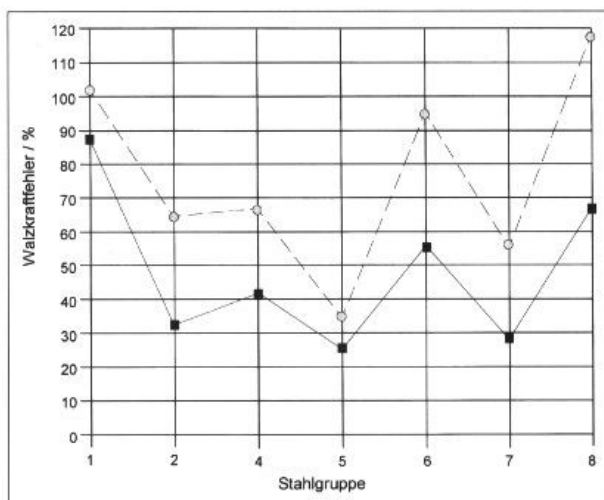


Bild 7: Die mit der neuronalen Walzkraftvorausberechnung jeweils für verschiedene Stahlsorten erzielte Verbesserung. Für acht verschiedene Stahlgruppen ist die Wurzel aus dem mittleren quadratischen Walzkraftfehler aufgetragen, sowohl des neuronalen (Quadrate) als auch des konventionellen Verfahrens (Kreise).

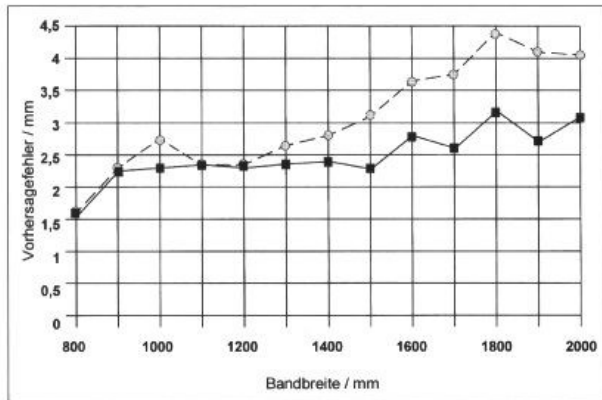


Bild 8: Die mit dem Neuronalen Netz im realen Betrieb erzielte Verbesserung bei der Vorhersage der natürlichen Breite. Für verschiedene Bandbreiten ist die Wurzel aus dem mittleren quadratischen Vorhersagefehler aufgetragen, sowohl des Neuronalen Netzes (Quadrate) als auch des konventionellen Verfahrens (Kreise).




Bild 9: Definition des Bandprofils als mittlerer Dickenunterschied zwischen der Mitte und den Rändern eines Bandes.

Breitung zunächst im Labor mit Meßdaten von der Walzstraße offline vortrainiert. Zum Vortraining des Neuronalen Netzwerks wurden wieder Meßdaten von ungefähr einer Monatsproduktion verwendet, diesmal Datenpaare $(\Delta b_i, x_i)$ bestehend aus der gemessenen Breite Δb_i bei Band i sowie den dazugehörigen Werten des Eingangsvektors x_i , wie Bandtemperatur, Banddicke, Dickenreduktion usw. Nach dem Vortraining im Labor wurde das Netzwerk an der Warmbreitbandstraße Beeckerwerth, Thyssen Stahl AG, installiert und nach kurzzeitiger Erprobung auch „scharfgeschaltet“. Mittlerweile ist das Neuronale Netz dort seit zwei Jahren erfolgreich im Einsatz. Die Auswertung von 70000 Bändern, gewalzt im Zeitraum April bis Oktober '94, zeigt Bild 8. Aufgetragen ist dort für das Neuronale Netz sowie für das konventionelle Verfahren der mittlere Fehler bei der Vorhersage der natürlichen Breite von verschiedenen breiten Bändern. Das konventionelle Verfahren lief zum Zwecke des Leistungsvergleiches nebenher mit. Bild 8 zeigt, daß das neuronale Verfahren, insbesondere bei den sehr breiten Bändern, signifikante Verbesserungen bringt. Im Mittel über alle Bänder erzielt das neuronale Verfahren einen Vorhersagefehler von 2,41 mm, das konventionelle Verfahren dagegen nur von 2,97 mm. Das bedeutet, daß das Neuronale Netzwerk gegenüber der

konventionellen Methode eine Verbesserung des Fehlers bei der Vorhersage der Breite von knapp 20% erzielt. Bei Breiten über 1500 mm, wo sich die Vorhersage der natürlichen Breite als besonders schwierig erweist, wird sogar eine Verbesserung von 25% erzielt. Relativ zur Breite ist der Breitenfehler jetzt bei breiten Bändern sogar geringer als bei schmalen.

Durch den verbesserten Vorhersagefehler wurde es möglich, den Sicherheitszuschlag auf die Bandbreite zu reduzieren. Allein eine Reduktion um einen einzigen Millimeter bedeutet erhebliche Material- und damit Kosteneinsparungen, denn der Jahresdurchsatz einer modernen Warmbreitbandstraße beträgt etwa $4 \cdot 10^6$ Tonnen bei einem Marktpreis um die 500 DM pro Tonne Warmband.

Das neuronale Verfahren ist mittlerweile auch an anderen Warmbandstraßen im Einsatz.

5. Bestimmung des Bandprofils

Neben der Breite und der Dicke ist das Profil das dritte wichtige Qualitätskriterium für die Geometriegüte 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 9). Ziel ist es, das Profil während des Warmwalzens so klein

wie möglich zu halten, da es in späteren Kaltwalzprozessen nicht mehr beeinflusst werden kann.

Das Profil des Walzgutes nach Durchlaufen eines Gerüsts ergibt sich aus einer Kombination des Bandprofils beim Eintritt in das Gerüst und dem Profil des Wälzspaltes unter Last (Lastwälzspaltprofil). Das Lastwälzspaltprofil resultiert aus einer mechanischen und thermischen Walzenverformung. Die thermische Walzenverformung (thermische Balligkeit) spiegelt die vergangenen Walzvorgänge wider und hängt z. B. von den Temperaturen, Breiten, Walzzeiten und Pausenzeiten der zuvor gewalzten Bänder ab. Der Einfluß der Vergangenheit, das „Gedächtnis“ der Walzstraße, stellt das besondere Problem bei der Bestimmung des Bandprofils dar. Hierin liegt auch ein entscheidender Unterschied zu den zwei vorherigen Problemstellungen. Die existierenden mathematischen Modelle zur Berechnung der Profile versuchen, über die Modellierung der physikalischen Zusammenhänge die Vergangenheit der Walzstraße miteinfließen zu lassen. Dabei werden jedoch idealisierte Voraussetzungen gemacht, die in der Praxis nicht wirklich erfüllt sind. Dies führt dazu, daß zusätzlich heuristische Modelle eingeführt werden müssen, deren Parameter vorab aufgrund von Plausibilitätsüberlegungen nur grob abgeschätzt werden können und deren „fine-tuning“ zeit- und damit ko-

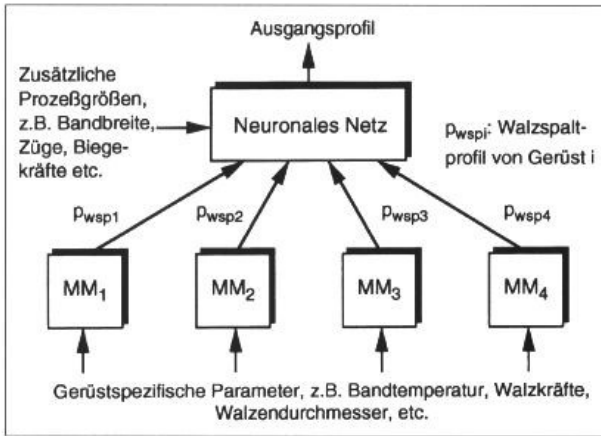


Bild 10: Eine, neben der im Bild 5 gezeigten, weitere Möglichkeit zur Kombination mathematischer Modelle (MM) mit Neuronalen Netzen, diesmal zur Bestimmung des Bandprofils nach Durchlaufen der Fertigstraße.

stenaufwendige Inbetriebsetzungsarbeit erfordert.

Neuronale Netze können zur Profilbestimmung auf verschiedene Arten eingesetzt werden. Bild 10 zeigt einen hybriden Ansatz, bei dem gerüstsspezifische mathematische Modelle (MM1 bis MM4 bei insgesamt 4 Gerüsten nach Bild 4) die Lastwalzspaltprofile bestimmen. Die sich aus diesen Modellen ergebenden Werte für die Walzspaltprofile bilden zusammen mit weiteren Prozeßgrößen den Eingangsvektor für ein Neuronales Netz, das darauf trainiert wird, an Hand dieser Informationen das Profil am Ende der Fertigstraße zu bestimmen. Ein solcher hybrider Ansatz hat, ähnlich wie bei der Vorausberechnung der Walzkraft, den Vorteil, daß bereits existierendes Vorwissen über die physikalischen Prozesse in Form mathematischer Modelle berücksichtigt werden kann. Die Ungenauigkeiten dieser Modelle können nun durch das

Neuronale Netz über einen datengetriebenen Lernvorgang kompensiert werden, wobei im Prinzip beliebige zusätzliche Einflußfaktoren in Form von weiteren Netzeingängen berücksichtigt werden können. Der vom Neuronalen Netz gelernte Zusammenhang zwischen Bandprofil und dessen Einflußfaktoren stellt quasi eine arbeitspunktabhängige, nichtlineare Korrektur dar, die sich während des on-line-Trainings zeitlichen Veränderungen anpassen kann.

Simulationen mit realen Daten, die über drei Monate an einem Aluminium-Walzwerk mit vier Gerüsten gesammelt wurden, haben ergeben, daß die Vorhersage des Endprofils um etwa 20% gegenüber der rein mathematischen Modellierung verbessert werden kann. On-line-Experimente an einem im Bau befindlichen Steckelkaltwalzwerk sind geplant, um die bisherigen Ergebnisse in der Praxis zu überprüfen.

Bild 11: Verschiedene Einsatzmöglichkeiten Neuronaler Netze im Bereich der Vorstraße, Fertigstraße und Kühlstrecke einer Warmbandstraße.

Anwendungsbereich -stufe	Vorausberechnung Vorstraße	Vorausberechnung Fertigstraße	Vorausberechnung Kühlstrecke
in Entwicklung		Banddickenprofil	Wärmeübergangskoeffizient
in betrieblicher Erprobung	Staucher-Fahrkurve (Schopfoptimierung)		
in produktiver Nutzung	natürliche Breite in der Fertigstraße	Walzkraft Walzguttemperatur	

6. Weitere Einsatzfelder und Ausblick

Die oben diskutierten Anwendungen sind Beispiele für die vielfältigen Einsatzmöglichkeiten Neuronaler Netze im Bereich der Walzwerkautomatisierung. Einige der neuronalen Verfahren sind jetzt fester Bestandteil industrieller Anlagen und tragen wesentlich zur Qualitätsverbesserung des Walzgutes bei, andere Anwendungen befinden sich noch im Versuchsstadium oder in der Entwicklung. Eine Übersicht für Warmbandstraßen gibt Bild 11. Neben der beschriebenen Methode zur Vorhersage des Banddickenprofils in der Vorstraße befindet sich auch ein neuronales Verfahren zur Bestimmung des Wärmeübergangskoeffizienten in der Kühlstrecke in der Entwicklung. Ein neuronales Verfahren zur Berechnung der Staucher-Fahrkurve in der Vorstraße wird derzeit industriell erprobt. In produktiver Nutzung befinden sich seit längerem drei neuronale Verfahren: neben der beschriebenen Vorausberechnung der Walzkräfte und Vorhersage der natürlichen Breite noch ein neuronales Verfahren zur Vorhersage der Walzguttemperatur.

Die hier präsentierten Erfolge zeigen, daß insbesondere bei nichtlinearem und instationärem Prozeßverhalten Neuronale Netze aufgrund ihrer Fähigkeit zur nichtlinearen Modellierung und on-line-Adaption eine interessante Alternative zu konventionellen Prozeßmodellierungsverfahren darstellen. Bei Problemstellungen, wo keinerlei Kenntnisse über die zugrundeliegenden Zusammenhänge vorhanden sind, können Neuronale Netze mit ihren selbstlernenden Eigenschaften die Lücke schließen und eine Prozeßmodellierung überhaupt erst ermöglichen. Unsere Untersuchungen haben weiterhin gezeigt, daß eine Kombination von mathematischen und neuronalen Modellen die Vorteile beider Methoden auf elegante Weise verbinden kann. Dies stellt, falls analytisches Wissen über den Prozeß vorhanden ist, aufgrund der Komple-

xität der Prozesse häufig auch den bestmöglichen Ansatz dar.

Eine Reihe der neuronalen Verfahren sind mittlerweile im industriellen Einsatz und fester Bestandteil der kommerziell vertriebenen Prozeßautomatisierungssysteme für Walzstraßen, weitere neuronale Verfahren sind in der Entwicklung und Erprobung mit Aussicht auf baldigen Einsatz. Neben diesen Erfolgen ist jedoch auch deutlich geworden, daß verschiedene der bei der Walzwerkautomatisierung auftretenden Probleme mit dem gegenwärtigen Stand der Technik der Neuronalen Netze noch nicht abschließend gelöst sind. Eine Reihe von grundlegenden Fragestellungen verlangen weitere intensive

Forschungs- und Entwicklungsarbeit. Zu nennen sind da insbesondere das oben bereits erwähnte Stabilitäts-Plastizitätsdilemma bei der on-line-Adaption, sowie das Problem der Strukturierung großer Netze zur Lösung hochdimensionaler Problemstellungen.

Literatur

- [1] *Neumerkel, D., Donne, J. und Murray-Smith, R.*: 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 1994, pp. 138–142.
- [2] *Lindhoff, D., Sörgel, G., Gramckow, O. und Klode, K.-D.*: Erfahrungen beim Einsatz Neuronaler Netze in der Walzwerksautomatisierung. Stahl und Eisen 114 (1994), Heft 4, S. 49–53 und 208.
- [3] *Poppe, T. und Martinetz, T.*: Estimating Material Properties for Process Optimization. Proc. of the International Conference on Artificial Neural Networks – ICANN '93, Amsterdam 1993, Springer Verlag, pp. 795–798.
- [4] *Hollatz, J. und Martinetz, T.*: Neuro-Fuzzy in der Prozeßautomatisierung. In: Neuro-Fuzzy: Grundlagen und Anwendungen in der industriellen Automatisierung, Bonfig, K. W. (ed.), Expert-Verlag, Renningen-Malmsheim 1995, pp. 120–129.
- [5] *White, D. und Sofge, D.* (Eds.): Handbook of Intelligent Control – Neural, Fuzzy and Adaptive Approaches. Van Nostrand Reinhold, New York 1992.
- [6] *McCloskey, M. und Cohen, N.*: Catastrophic Interference in Connectionist Networks: The Sequential Learning Problem. The Psychology of Learning and Motivation 24 (1989), pp. 109–165.
- [7] *Zell, A.*: Simulation Neuronaler Netze, Addison Wesley, Bonn 1994. ●