

Schneider, Bernd

Working Paper

Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme

Arbeitsberichte des Instituts für Wirtschaftsinformatik, No. 22

Provided in Cooperation with:

University of Münster, Department of Information Systems

Suggested Citation: Schneider, Bernd (1993) : Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme, Arbeitsberichte des Instituts für Wirtschaftsinformatik, No. 22, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Münster

This Version is available at:

<https://hdl.handle.net/10419/59314>

Standard-Nutzungsbedingungen:

Die Dokumente auf EconStor dürfen zu eigenen wissenschaftlichen Zwecken und zum Privatgebrauch gespeichert und kopiert werden.

Sie dürfen die Dokumente nicht für öffentliche oder kommerzielle Zwecke vervielfältigen, öffentlich ausstellen, öffentlich zugänglich machen, vertreiben oder anderweitig nutzen.

Sofern die Verfasser die Dokumente unter Open-Content-Lizenzen (insbesondere CC-Lizenzen) zur Verfügung gestellt haben sollten, gelten abweichend von diesen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Terms of use:

Documents in EconStor may be saved and copied for your personal and scholarly purposes.

You are not to copy documents for public or commercial purposes, to exhibit the documents publicly, to make them publicly available on the internet, or to distribute or otherwise use the documents in public.

If the documents have been made available under an Open Content Licence (especially Creative Commons Licences), you may exercise further usage rights as specified in the indicated licence.

Arbeitsberichte des Instituts für Wirtschaftsinformatik

Herausgeber: Prof. Dr. J. Becker, Prof. Dr. H. L. Grob, Prof. Dr. K. Kurbel,
Prof. Dr. U. Müller-Funk, Prof. Dr. R. Unland, Prof. Dr. G. Vossen

Arbeitsbericht Nr. 22

**Neuronale Netze für betriebliche Anwendungen:
Anwendungspotentiale und existierende Systeme**

Bernd Schneider

Institut für Wirtschaftsinformatik der Westfälischen Wilhelms-Universität Münster,
Grevener Str. 91, 48159 Münster, Tel. (0251) 83-9750, Fax (0251) 83-9754
November 1993

Inhalt

1	Einleitung	4
2	Prognosen mit neuronalen Netzen	5
2.1	Die Anwendung neuronaler Netze	7
2.2	Kurzeinführung in die Prognose	10
2.3	Prognose von Aktienkursen auf Jahresfrist	12
2.4	Prognose des DM-Dollar-Wechselkurses	12
2.5	Prognose von Aktienkursen	13
2.6	Abschließende Bemerkungen zu Prognosen	13
3	Datenanalysen mit neuronalen Netzen	14
3.1	Kreditwürdigkeitsanalyse	14
3.2	Analyse betriebswirtschaftlicher Kennzahlen und Kennzahlenverdichtung	16
3.3	Marktsegmentierung	17
3.4	Konstruktionsunterstützung	17
4	Optimierung mit neuronalen Netzen	19
4.1	Grundlagen	19
4.2	Tourenplanung für die Vertriebsaußendienststeuerung	20
4.3	Maschinenbelegungsplanung	20
4.4	Abschließende Bemerkung zur Optimierung	22
5	Mustererkennung i.e.S.	22
5.1	OCR (Optical Character Recognition)	23
5.2	Bildverarbeitung	23
5.3	Verarbeitung akustischer oder anderer sensorischer Signale	26
5.3.1	Grundlagen	26
5.3.2	Verarbeitung sensorischer Signale - Diagnose von Verbrennungsmotoren	27
5.3.3	Verarbeitung sensorischer Signale - Getriebe-Diagnose	28
5.3.4	Verarbeitung akustischer Signale - Testen von Elektromotoren	28
5.4	Abschließende Bemerkungen	29
6	Überblick und Klassifikation	30
7	Zusammenfassung	32
	Literatur	33

Zusammenfassung

Der vorliegende Arbeitsbericht zeigt eine Auswahl neuronaler Netze für betriebliche Anwendungen. Aufbauend auf der Vorstellung einiger Systeme wird sowohl vom konkreten Anwendungsgebiet als auch von der konkreten Architektur des neuronalen Netzes abstrahiert, um so ein Übertragen der Erkenntnisse auf andere, ähnlich gelagerte Anwendungsprobleme zu ermöglichen. Anhand der abstrahierten Beschreibung ist es möglich, neue betriebliche Anwendungspotentiale neuronaler Netze aufzudecken. Dazu wird überprüft, inwieweit eine neue, potentielle Anwendung denselben Kriterien genügt. Aufgrund der Analogien erhält man neben einer „Machbarkeitsstudie“ ggf. bereits Hinweise auf die geeignete Wahl eines Netzwerktyps und der zugehörigen Netzwerkparameter für das neue Anwendungsproblem.

1 Einleitung

Neuronale Netze sind biologisch motivierte Modelle, die sich an Grundprinzipien der Arbeitsweise eines Gehirns anlehnen. Neuronale Netze bestehen i.a. aus einer Menge einfach aufgebauter und komplex miteinander verknüpfter Verarbeitungseinheiten (*Neuronen*), die über gewichtete Verbindungen *Signale* miteinander austauschen. Die Stärke eines Signals ist vom Gewicht der Verbindung sowie von der sogenannten *Aktivierung* des sendenden Elementes abhängig, die wiederum von dessen Eingangssignalen beeinflusst wird. Die Gewichte der Verbindungen zwischen den Knoten eines neuronalen Netzes werden entweder in einer *Trainings-* oder *Lernphase* ermittelt oder aber direkt berechnet¹⁾. Zu Beginn einer Informationsverarbeitung werden bestimmte Knoten des Netzes, die *Input-Neuronen*, extern aktiviert. Die Aktivierungsänderung löst eine Neuberechnung der Aktivierungen aller mit den Input-Neuronen verbundenen Knoten aus. Das Ergebnis der Informationsverarbeitung kann an bestimmten, nach außen sichtbaren Knoten, den *Output-Neuronen*, abgelesen werden²⁾.

Neue Technologien, wie die neuronalen Netze, müssen sich im praktischen Einsatz erst bewähren. Hier zeigen sich auf den ersten Blick Parallelen zur Fuzzy-Logik: Nach Jahren der Grundlagenforschung waren die theoretischen Grundlagen soweit gefestigt, daß praktische Anwendungen entwickelt werden konnten. Heute hat sich die Fuzzy-Logik nicht nur in schmalen „Nischen“ etabliert, sondern zunehmend auch dort durchgesetzt, wo sie in Konkurrenz zu bereits bestehenden Anwendungen tritt. Stellvertretend für viele industrielle Anwendungen seien Fuzzy-Staubsauger, Fuzzy-Waschmaschinen, Fuzzy-Kameras und Fuzzy-Straßenbahnen³⁾ genannt. Aber auch in betrieblichen Bereichen findet man zunehmend Fuzzy-Anwendungen, z.B. in der Produktionsplanung und -steuerung⁴⁾ und Montagesteuerung⁵⁾.

Sehr ähnlich sieht der Werdegang der neuronalen Netze aus: Über einen längeren Zeitraum hinweg erfolgte eine intensive Grundlagenforschung und prinzipielle Anwendungspotentiale wurden mittels Forschungsprototypen aufgezeigt. Echte Anwendungen aber, die sich im täglichen Einsatz befinden, sind jedoch noch recht selten.

Gegenstand des Hauptteils dieses Arbeitsberichts ist eine Sammlung von betrieblichen Anwendungen neuronaler Netze. Dabei wird jedoch zugunsten einer kompakten Darstellung auf die detaillierte Darstellung des jeweiligen Problemgebiets und auf die Vermittlung spezifischer

1) Vgl. z.B. Dorffner (1991), Hertz et al. (1991) oder Takefuji (1992).

2) Vgl. Kemke (1988). Hier wird auch die Unterscheidung zwischen "neuronalen Netzen" und "konnektionistischen Modellen" vorgenommen: Die Anwendung eines neuronalen Netzes wird als konnektionistisches Modell bezeichnet.

3) Vgl. z.B. von Altrock (1991), Zimmermann (1993).

4) Vgl. z.B. Nickel (1990), Günter, Toggweiler (1993).

5) Vgl. z.B. Lipp (1991), Fischer (1993).

Grundlagen neuronaler Netze verzichtet. Auch bei neuronalen Netzen zeigt die Entwicklung, daß sie zunächst Nischen ausfüllen und dann zunehmend in Bereiche drängen, in denen sie in Konkurrenz zu bestehenden Anwendungen treten. Dort müssen sie ihre Eignungsfähigkeit und nicht zuletzt auch ihre Wirtschaftlichkeit unter Beweis stellen.

In den Kapiteln 2 bis 5 werden Anwendungen neuronaler Netze für betriebliche Problemstellungen vorgestellt. Die Anwendungen sind grob unterteilt in die Sparten Prognose (Kapitel 2), Datenanalyse (Kapitel 3), Optimierung (Kapitel 4) und Mustererkennung im engeren Sinne (Kapitel 5). In den einzelnen Abschnitten steht weniger die komplette Beschreibung einzelner Systeme im Mittelpunkt, sondern die für eine Anwendung in diesem Bereich notwendigen Grundlagen. Dazu gehören die Auswahl geeigneter Netztypen, Beschaffung und Kodierung der Trainingsdaten, ggf. aber auch die Einbindung in eine vorhandene Unternehmensstruktur.

Kapitel 6 zeigt die beschriebenen und einige weitere Anwendungen übersichtsartig auf und kategorisiert sie anhand von betriebswirtschaftlichen Hauptfunktionen einerseits und der Systemfunktionalität andererseits.

2 Prognosen mit neuronalen Netzen

Bei wirtschaftlichen Prognosen besteht die Aufgabe darin, einen Ausschnitt der Wirklichkeit zu modellieren, um Vorhersagen (Prognosen) über zukünftige Entwicklungen in diesem Ausschnitt treffen zu können. Für Fachleute ist es zwar häufig einfach anzugeben, von welchen Faktoren eine Entwicklung abhängig ist; eine vollständige oder selbst partielle Analyse und Beschreibung der Abhängigkeit kann jedoch oft nicht erfolgen. Dies betrifft sowohl die Abhängigkeiten der Zielgröße von den Eingabegrößen als auch Abhängigkeiten der Eingabegrößen untereinander⁶⁾.

Die (bisher) für einfache Prognoseaufgaben angewendeten mathematischen und statistischen Verfahren behandeln im wesentlichen zwei spezielle Problemtypen⁷⁾: Entweder läßt sich das Problem durch sehr viele lineare Variablen beschreiben, die jedoch nur in einfachen (linearen) Wechselwirkungen stehen, oder das Problem läßt sich durch einige wenige Variablen beschreiben, deren Wechselwirkungen jedoch komplexer Natur sind.

Aufgrund der Restriktionen sind Verfahren für die Bearbeitung der oben genannten Problemtypen auf viele praktische Aufgabenstellungen nicht anwendbar. Beispielsweise wirken nach Ex-

6) Vgl. Zimmermann (1991).

7) Vgl. Zimmermann (1991).

pertenschätzungen auf die Zinsentwicklung rd. 80 Faktoren ein⁸⁾, die in verschiedenen nicht-linearen Wechselwirkungen zueinander stehen. Gleiches gilt für viele andere ökonomische Systeme gleichermaßen. Daher ist ein Einsatz mathematischer und statistischer Verfahren ohne eine u.U. entstellende Vereinfachung für solche Problemstellungen nur schwer oder gar nicht vorstellbar.

Betrachtet man hingegen den Einsatz wissensbasierter Systeme für Prognoseprobleme, so ergibt sich das Problem, daß ein Expertensystem das Wissen aus Sicht des Experten darstellt, das Wissen also durchaus subjektiv geprägt ist. Dies ergibt sich aus den Eigenschaften des Experten, der ein für die Problemlösung notwendiges Strukturverständnis besitzt. Je nach Reife des Experten verändert sich auch das Strukturverständnis. Daher werden auch die Entscheidungen (Prognosen) entsprechend dem Reifegrad ausfallen.

Wird jedoch das für eine Entscheidungsfindung nötige Wissen durch Beobachtung der realen Welt erworben⁹⁾, so ist zwar ein Strukturverständnis an keiner Stelle explizit abgebildet, jedoch ist dieses in den beobachteten Beispieldaten implizit enthalten. Durch induktive Lernverfahren wie Verfahren des maschinellen Lernens¹⁰⁾ oder neuronale Netze kann aus den Beobachtungen ein Strukturverständnis abgeleitet werden. Werden nun Entscheidungen auf der Basis des abgeleiteten Wissens getroffen, so ist die Güte der Entscheidungen ausschließlich von der Vollständigkeit und Genauigkeit des beobachteten Wissens und von der Art und Weise der Entscheidungsfindung abhängig. Bei einer vollständigen, detaillierten und repräsentativen Menge von Beobachtungen sind gute Entscheidungen zu erwarten¹¹⁾, die häufig die Qualität von Experten-Entscheidungen übertreffen.

Abbildung 1 verdeutlicht die beiden unterschiedlichen Wege zur Modellierung eines Ausschnitts der Wirklichkeit. Der Weg über die qualitative Struktur entspricht dabei dem Vorgehen bei der Erstellung eines Expertensystems; der Weg über die quantitativen Beobachtungen entspricht der Vorgehensweise, bei der ein neuronales Netz zur Modellierung der Wirklichkeit verwendet wird. Dieser Weg soll im folgenden Abschnitt genauer beschrieben werden.

Ein neuronales Netz zur Vorhersage zukünftiger Entwicklungen wird mit Gegenwarts- und Vergangenheitsdaten trainiert. Es lernt also, wie sich Zustände der Vergangenheit entwickelt haben. Geht man weiterhin davon aus, daß die der Entwicklung innewohnende Struktur - zumindest über einen gewissen Zeitraum - konstant ist, so sind die Entwicklungen der Vergangenheit auf

8) Vgl. Zimmermann (1991), Pintaske (1991).

9) Hierbei ist nicht die systematische und strukturverständnisfördernde Beobachtung gemeint, sondern vielmehr das einfache "Notieren" von Merkmalen, Einflüssen und Wirkungen, wie z.B. beim maschinellen Lernen. Vgl. Michalski (1983).

10) Vgl. z.B. Michalski (1983), Quinlan (1983).

11) Vgl. Zimmermann (1991), Schöneburg, Straub (1993), Wong, Tan (1992).

Entwicklungen der Gegenwart oder Zukunft übertragbar. Für das Anlernen eines neuronalen Netzes muß also eine ausreichende und repräsentative Menge von Daten gesammelt, eine zur Problemstellung adäquate Netztopologie entworfen und diese dann mit den gesammelten und ggf. aufbereiteten Daten angelernt werden.

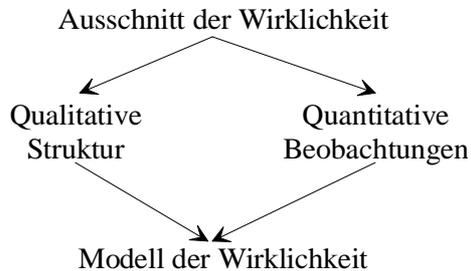


Abb. 1: Zwei Wege zum Modell¹²⁾

2.1 Die Anwendung neuronaler Netze

Der erste Schritt auf dem Weg zu einem neuronalen Netz zur Prognose besteht darin, die Trainingsmenge aufzubauen. Dazu werden über einen gewissen Zeitraum hinweg die Entwicklungen beobachtet und die Einflußgrößen (oder ein wichtiger Teil von ihnen) protokolliert. Auf diese Weise erhält man eine Menge von Tupeln bestehend aus altem Zustand, Einflußfaktoren und sich daraus ergebendem neuen Zustand. Ein Datensatz der Trainingsmenge ist dann eine Anordnung aufeinanderfolgender Tupel. Nach dem Training ist das Netz in der Lage, die weitere Entwicklung der trainierten Verlaufsreihe (eine Folge alter Zustände und Einflußfaktoren, s.o.) zu prognostizieren¹³⁾, d.h., aus der Angabe der bisherigen Zustände wird ein Folgezustand ermittelt. Ob der so ermittelte Folgezustand der Realität entspricht, hängt von der Netztopologie, der Wahl der Netzparameter, der Zusammensetzung der Trainingsmenge und der Art der zu prognostizierenden Entwicklung selbst ab (vgl. Kapitel 2.2).

Bevor mit dem Training des neuronalen Netzes begonnen werden kann, ist die Netztopologie festzulegen. Prinzipiell sind alle neuronalen Netze, die mittels Assoziationen lernen¹⁴⁾, für diese Aufgabe anwendbar. In der Praxis findet man jedoch (fast) ausschließlich zwei Netztypen: Backpropagation-¹⁵⁾ und Kohonen-Netze¹⁶⁾. Die beiden Netztypen unterscheiden sich neben den

12) Vgl. Zimmermann (1991).

13) Vgl. de Groot, Würtz (1991).

14) Durch Assoziation lernen bedeutet, daß der Zusammenhang zwischen Ein- und Ausgaben gelernt wird. Dabei sollen ähnliche Eingaben auch zu ähnlichen Ausgaben führen (Generalisierungsfähigkeit).

15) Vgl. z.B. Hecht-Nielsen (1990), Tvetter (1991).

16) Vgl. z.B. Kohonen (1982), Kohonen (1984). In diesem Arbeitsbericht wird statt *Topologically correct Feature Map* der Name *Kohonen-Netz* synonym verwendet.

netztypischen Eigenschaften im wesentlichen dadurch, daß bei Backpropagation-Netzen die Prognose (der Wert der vorhergesagten Entwicklung) in der Output-Schicht abgebildet wird, während Kohonen-Netze die Prognose als Teil der Input-Schicht abbilden.

Backpropagation-Netze werden während des Trainings so überwacht, daß die Eingaben an den Input-Neuronen und die gewünschten Ausgaben an den Output-Neuronen angelegt werden. Daraufhin lernt das Backpropagation-Netz die Assoziationen zwischen Ein- und Ausgaben. Backpropagation-Netze bestehen außer aus den Input- und Output-Neuronen noch aus einer beliebigen Anzahl von Hidden-Neuronen. Die Hidden-Neuronen sind ihrerseits ebenfalls wieder in Schichten angeordnet. Jede Schicht - auch die Input- und Output-Schicht - ist mit der ihr folgenden¹⁷⁾ vollständig verbunden, andere Verbindungen existieren i.d.R. nicht. Sowohl die Anzahl der Hidden-Schichten als auch ihre Größe (Anzahl der Neuronen) sind in Abhängigkeit von der konkreten Problemstellung zu dimensionieren.

Exakte Berechnungsformeln für die Anzahl und Größe(n) der Hidden-Schicht(en) existieren nicht, vielmehr ist der Anwender auf eine Trial-and-error-Strategie angewiesen, um eine gute Netztopologie zu finden. Eine schlechte Netztopologie äußert sich darin, daß nicht alle gewünschten Zusammenhänge gelernt werden können. In diesem Fall ist i.d.R. die Hidden-Schicht zu vergrößern oder eine weitere Hidden-Schicht einzuführen. Aber auch dann, wenn das neuronale Netz die Trainingsmenge vollständig gelernt hat, muß nicht zwangsläufig eine gute Netztopologie gefunden worden sein: Das Netz kann z.B. überspezialisiert sein, d.h., es hat quasi nur auswendig gelernt (*Overfitting*), ohne ähnliche Eingaben zu generalisieren. Ein solcher Fall kann nur identifiziert werden, wenn zusätzlich zur Trainingsmenge noch eine Testmenge, bestehend aus nicht angelernten Datensätzen, vorhanden ist.

Die meisten Anwendungen kommen jedoch mit einer oder zwei Hidden-Schichten aus, einige wenige benötigen noch eine dritte Schicht. Abbildung 2 zeigt ein Backpropagation-Netz aus sechs Input-, vier Output- und acht Hidden-Neuronen in der jeweiligen Schicht.

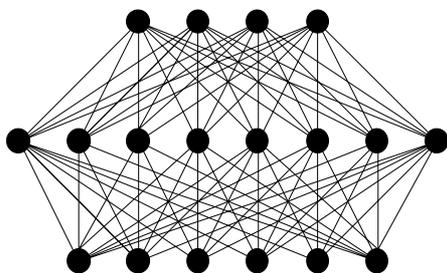


Abb. 2: Backpropagation-Netz

17) Dabei wird eine Sichtweise von der Input-Schicht zur Output-Schicht vorausgesetzt.

Kohonen-Netze bestehen aus nur zwei Schichten: den Input-Neuronen und der Kohonen-Map. Für Prognose-Aufgaben läßt sich das Kohonen-Netz einsetzen, wenn der komplette Trainingsdatensatz an den Input-Neuronen angelegt und gelernt wird. Lernen bedeutet, daß die Werte der Input-Neuronen so in die Kohonen-Map abgebildet werden, daß ähnliche Werte auch in räumlicher Nähe in der Kohonen-Map abgebildet werden. Nach Abschluß des Trainings werden dann nicht alle Input-Neuronen mit Eingaben (Werten) belegt, sondern nur diejenigen Neuronen, für die die Werte bekannt sind. Dieser nur teilweise gefüllte Datensatz - zumindest fehlen die vorherzusagenden Werte - wird nun in die Kohonen-Map abgebildet. Dabei wird der Punkt in der Kohonen-Map gefunden, dessen Daten dem zu bearbeitenden Datensatz am ähnlichsten sind (*best match*). Dann werden die freien Stellen des angelegten Datensatzes mit den entsprechenden Werten des ähnlichsten Datensatzes belegt (*Prädiktion*¹⁸⁾). Waren beim angelegten Datensatz die Input-Neuronen, die die Prognose repräsentieren, unbelegt, so enthalten sie nach der Prädiktion die Prognose.

Abbildung 3 zeigt ein Kohonen-Netz mit sechs Input-Neuronen und einer Kohonen-Map der Größe 11 x 10. Jedes Input-Neuron ist mit jedem Neuron der Kohonen-Map verbunden (dargestellt ist jedoch nur ein Ausschnitt der Verbindungen), und jedes Neuron der Kohonen-Map ist mit seinen Nachbarn verbunden.

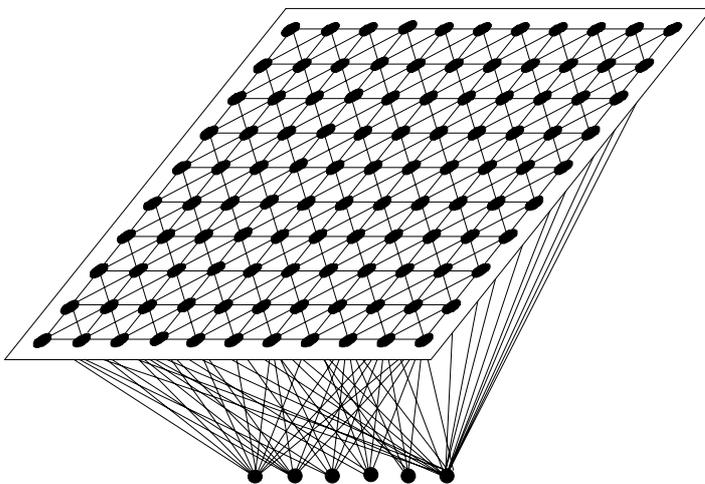


Abb. 3: Kohonen-Netz

Die Bestimmung der Größe der Kohonen-Map ist analog zu den Hidden-Schichten der Backpropagation-Netze problemabhängig vorzunehmen. Ist die Kohonen-Map zu klein, können die einzelnen Entwicklungen nicht sauber getrennt werden, ist die Kohonen-Map zu groß, findet nur eine unvollkommene Generalisierung statt. Beides äußert sich in einem schlechteren Lernergebnis. Es können dann z.B. nicht alle trainierten Beispiele korrekt wiedererkannt werden.

18) Vgl. Ultsch (1990).

An die Erhebung der zum Training des neuronalen Netzes erforderlichen Daten schließt sich i.d.R. eine Aufbereitung an. Vor der sinnvollen Verwendung dieser Daten muß eine Normierung (Skalierung) erfolgen, da die meistens verwendeten Backpropagation-Netze Neuronen verwenden, die einen sigmoiden Verlauf der Aktivierung besitzen¹⁹⁾. Daher ist es sinnvoll, die Daten auf das Intervall [-1,1] oder auf ein Teilintervall davon zu skalieren. Schöneburg schlägt eine Skalierung in Form einer linearen Transformation der Werte auf das Intervall [0.1, 0.9] wie folgt vor²⁰⁾:

$$\text{Skalierungsfaktor} = \frac{0.8}{\max(\text{Wert}) - \min(\text{Wert})}$$

$$\text{Offset} = 0.1 - \text{Skalierungsfaktor} * \min(\text{Wert})$$

$$\text{neuer Wert} = \text{Wert} * \text{Skalierungsfaktor} + \text{Offset}$$

Die Umrechnungen erfolgen also einmal für die Trainingsmenge und jedesmal für eine Anfrage an das neuronale Netz. Bei einer Anfrage müssen die ermittelten Werte für Skalierung, Offset usw. nicht neu ermittelt werden, sondern die für die Skalierung der Trainingsmenge benutzten Werte werden verwendet. Die Ausgabe des neuronalen Netzes muß natürlich anschließend wieder rücktransformiert werden, um die richtigen Werte für den prognostizierten Verlauf zu erhalten.

2.2 Kurzeinführung in die Prognose

Prognosen lassen sich auch als Vorhersage mehr oder weniger stark verrauschter Zeitreihen interpretieren, wobei den Zeitreihen eine implizite Gesetzmäßigkeit zugrunde liegt²¹⁾. Da selbst zufällig aussehende Zeitreihen wie die Aktivität von Sonnenflecken relativ sicher durch neuronale Netze vorausgesagt werden können²²⁾, liegt es nahe, auch die Vorhersage von Kursverläufen zu untersuchen. Bei der Prognose vieler ökonomischer Sachverhalte sind sich auch Experten uneinig, ob sich die zukünftigen Entwicklungen überhaupt prognostizieren lassen, d.h., ob die für eine zuverlässige Prognose nötigen Informationen überhaupt vorhanden bzw. erfaß- oder meßbar sind²³⁾. Dies zeigt sich auch in der Diskussion um die Gültigkeit der schwachen und der halbstrengen Informationseffizienzthese²⁴⁾. Aus der Diskussion der beiden Informationseffizi-

19) D.h., die Aktivierung verhält sich für Werte außerhalb des Intervalls [-1, 1] asymptotisch.

20) Vgl. Schöneburg (1991), S. 52.

21) Vgl. Schöneburg (1991).

22) Vgl. Wiegend et al. (1990), Lapedes, Farber (1987).

23) Vgl. Rehkugler, Poddig (1991).

24) Die schwache Informationseffizienzthese besagt, daß in den Entwicklungen der Vergangenheit keine Informationen über die zukünftige Entwicklung enthalten sind. Dagegen besagt die halbstarke Informationseffizienzthese, daß auch nach Auswertung zusätzlicher, öffentlicher Informationsquellen (Jahresabschlüsse, Bilanzen, Pressemitteilungen etc.) keine höhere als die Markttrendite zu erwarten ist. Vgl. Rehkugler, Poddig (1990), Rehkugler, Poddig (1991).

enzthesen wird deutlich, daß neben der Erstellung des eigentlichen Prognoseverfahrens (Anlernen und Befragen des neuronalen Netzes) der Datenerhebung (Aufbau der Trainingsmenge) die wesentliche Aufmerksamkeit zukommen muß. Unabhängig von der Gültigkeit der beiden Thesen für die Prognose ökonomischer Größen sollen im folgenden kurz Anwendungen aus dem Bereich der Finanzwirtschaft aufgezeigt werden, die nach Aussagen der jeweiligen Autoren den bekannten statistischen Verfahren überlegen sind²⁵⁾.

Unter der Voraussetzung der Verfügbarkeit aller Informationen können bei der Prognose drei Fälle nach dem Ort, an dem die Informationen verfügbar sind, unterschieden werden: Entweder sind die Informationen nur innerhalb (a), nur außerhalb (b) oder sowohl innerhalb als auch außerhalb (c) des zu prognostizierenden Systems verfügbar²⁶⁾. Viele Entwicklungen lassen sich nicht mit ausreichender Sicherheit prognostizieren²⁷⁾, so daß man schließen könnte, daß entweder

- a) alle bekannten Analyseverfahren - egal ob Statistik, maschinelles Lernen oder neuronale Netze - ungeeignet sind, diese Entwicklungen vorherzusagen, oder
- b) nicht alle tatsächlichen Einflußfaktoren auch als solche erkannt und in die zu analysierenden Daten aufgenommen wurden, oder
- c) nicht alle tatsächlichen Einflußfaktoren öffentlich verfügbar und somit nutzbar sind, oder
- d) die Entwicklungen einem mehr oder weniger großen Einfluß des Zufalls unterliegen.

Somit ist die Prognose keine allgemein lösbare Aufgabe, sondern es muß von Fall zu Fall entschieden werden, ob eine Prognose überhaupt möglich ist. Doch wenn schon kein exaktes Wissen für eine Prognose zur Verfügung steht, so kann immer noch zielgerichtet „geraten“ werden, worauf die Anwendung neuronaler Netze in einem solchen Fall hinausläuft.

Im folgenden werden beispielhaft zwei Anwendungen neuronaler Netze zur Prognose ökonomischer Größen beschrieben. Eine weitere Gruppe von Prognose-Systemen wurde von Siemens-Nixdorf als Anwendung für die Entwicklungsumgebung SENN++ erstellt²⁸⁾. Die Anwendungen

25) Vgl. z.B. Schöneburg, Straub (1993).

26) Z.B.: Es soll die Kursentwicklung einer Aktie prognostiziert werden. Wenn sich die Kursentwicklung der Aktie aus der Kenntnis des bisherigen Kursverlaufs ergibt, liegt (a) vor. Erfolgt die Kursentwicklung ausschließlich aufgrund der Einflüsse beispielsweise anderer Aktien, so liegt (b) vor. Bei Vermischung beider Typen liegt (c) vor.

27) Vgl. Rehkugler, Poddig (1991).

28) Vgl. z.B. o. V. (1992).

aus dem Bereich der Finanzwirtschaft können in die folgenden Bereiche unterschieden werden:
Prognose von

- Aktien- und Devisenkursen,
- Konjunktur- und Preisentwicklungen und
- Absatzzahlen und Auftragserwartungen.

2.3 Prognose von Aktienkursen auf Jahresfrist

Rehkugler und Poddig²⁹⁾ beschreiben eine Anwendung, deren Ziel die Prognose der Veränderungsrichtung von Aktienkursen ist. Ausgehend von den Daten der vergangenen 24 Quartale wird die Veränderungsrichtung - also steigend, fallend oder keine Aussage - des Aktienmarktes in vier Quartalen prognostiziert. Die der Anwendung zugrundeliegende Idee läßt sich recht einfach darstellen: auf die Teilnehmer des Aktienmarktes strömen laufend Informationen ein, aus denen - u.U. mit einer Verzögerung - Kauf-, Verkauf- oder Halteentscheidungen resultieren. Bei den den Teilnehmern zur Verfügung stehenden Informationen handelt es sich ausschließlich um solche Informationen, die nicht aus dem Aktienmarkt selbst resultieren - Rückkopplungen der Kursentwicklung auf die weitere Kursentwicklung sind somit nicht modellierbar. Aufgrund statistischer Tests wurde eine Beschränkung auf drei Einflußgrößen vorgenommen: einen Zins-, einen Stimmungs- und einen Liquiditätsindikator. Zur Charakterisierung der Entwicklung wurde der Aktienindex des statistischen Bundesamtes verwendet³⁰⁾.

2.4 Prognose des DM-Dollar-Wechselkurses

Ebenfalls von Rehkugler und Poddig³¹⁾ stammt eine Anwendung zur Prognose des DM-Dollarwechselkurses. Auf der Basis von monatsweise erhobenen ökonomischen Indikatoren soll eine „steigt/fällt/keine Aussage“ Prognose für das Niveau des DM-Dollar-Wechselkurs in genau drei Monaten erstellt werden. Als Datenbasis dienen die Finanzstatistiken des Weltwährungsfonds („International Financial Statistics“ des IMF). Ansonsten entsprach der Modellversuch den bereits oben erwähnten und von denselben Autoren durchgeführten Versuchen. Die Eingabedaten repräsentieren auch hier wieder die vergangenen 24 Quartale.

29) Nach Rehkugler, Poddig (1991).

30) Der Aktienindex des statistischen Bundesamtes ist um Dividendenzahlungen und Bezugsrechte bereinigt. Aufgrund der Vielzahl der berücksichtigten Unternehmen weist er gegenüber anderen Aktienindices eine größere Repräsentativität auf und die Daten sind bis weit in die Vergangenheit zurück verfügbar. Vgl. Rehkugler, Poddig (1991).

31) Vgl. Rehkugler, Poddig (1991). Ein weiteres Beispiel findet sich Lawrence (1992), S. 167 ff.

2.5 Prognose von Aktienkursen

In den beiden vorangegangenen Abschnitten wurden neuronale Netze für längerfristige Prognosen angewendet. Bei einer Anwendung zur kurzfristigen Prognose, z.B. einer tageweisen Aktienkursprognose, tritt folgendes Problem auf: Die Grundlage einer Prognose bildet die Ermittlung eines Trends aus dem Kursverlauf der Vergangenheit. Dabei muß der Verlauf von „Störungen“ durch politische oder wirtschaftliche Einflüsse geglättet werden. Bei der Glättung besteht das Problem zu erkennen, welche Schwankung aus einer Störung resultiert und welche Schwankung zum Verlauf selbst gehört. Dies ist bei einer nur tageweisen Prognose wesentlich schwieriger bzw. Fehler wirken sich wesentlich stärker als bei mittel- oder langfristigen Prognosen aus³²⁾.

Schöneburg³³⁾ beschreibt eine Anwendung von Backpropagation-Netzen zur kurzfristigen Prognose. Für die Prognose wurden verschiedene Architekturen (Variation der Anzahl und Größe(n) der Hidden-Schicht(en)) von Backpropagation-Netzen eingesetzt. Von den Autoren wurden damit u.a. der Dollarkurs (siehe auch Kapitel 2.3), der Rentenindex der Commerzbank, Bayer-, BASF- und Mercedes-Aktien untersucht, wobei nach abschließenden Untersuchungen folgende Aussage getroffen werden konnte³⁴⁾: „Das beste neuronale Netz übertraf mit einer Trefferquote von 56,6% [...] die besten klassischen Prognoseverfahren [...] um 0.6% [...] und weitere klassische Verfahren (gleitende Durchschnitte, Same-Change, [...]) um mindestens 3.9%.“ Weiterhin mündeten die Untersuchungen des Autors in das System *Neuro-Chart*³⁵⁾, ein System zur Zeitreihenanalyse mittels neuronaler Netze.

2.6 Abschließende Bemerkungen zu Prognosen

In den vorangegangenen Abschnitten wurde verschiedene Systeme zur Prognose ökonomischer Verläufe skizziert. Alle Systeme schlagen dabei bekannte klassische bzw. statistische Prognoseverfahren in der Qualität ihrer Prognosen. Unabhängig davon, ob nun Kursverläufe etc. überhaupt vorhersagbar sind (vgl. Kapitel 2.2), scheinen die neuronalen Netze aufgrund ihrer Fähigkeiten zur Generalisierung und Selbstorganisation gegenüber den bisher verwendeten Verfahren die für eine Prognose wichtigeren Eigenschaften zu besitzen. Dies resultiert sicherlich zu einem großen Teil aus den beispielsweise für die Anwendung statistischer Verfahren notwendigen

32) Vgl. White (1990).

33) Vgl. Schöneburg (1991).

34) Vgl. Schöneburg (1991), S. 57.

35) Neuro-Chart ist eine Umgebung zum Aufbau von Anwendungen zur Zeitreihenanalyse, speziell Aktienkursprognosen. Neuro-Chart wird von der Fa. Neuro-Informatik GmbH in Berlin vertrieben.

mehr oder weniger starken Vereinfachungen der zu prognostizierenden „Welt“ und der den neuronalen Netzen eigenen subsymbolischen Arbeitsweise.

3 Datenanalysen mit neuronalen Netzen

Im folgenden Abschnitt werden Anwendungen zum Thema Datenanalyse beschrieben. Datenanalyse bezeichnet hierbei die Analyse betrieblicher und betriebswirtschaftlicher Größen mit dem Ziel der Klassifikation bzw. der Entscheidungsunterstützung.

Datenanalyse und Prognose sind eng miteinander verwandt. Sie unterscheiden sich dadurch, daß in der Datenanalyse die Assoziation von Merkmalen eines „Ausschnitts der Welt“ (vgl. Abb. 1) mit einer Empfehlung oder anders gearteten Ausgabe ermittelt wird, während bei der Prognose die zukünftige Entwicklung vorhergesagt wird. Für die Festlegung der Netztopologie und ggf. Skalierung, Normierung etc. gilt das in Kapitel 2.2 Gesagte gleichermaßen.

3.1 Kreditwürdigkeitsanalyse

Entscheidungen bzgl. der Kreditwürdigkeit werden i.d.R. aufgrund von subjektiven (persönlichen) und objektiven (ökonomischen) Kriterien³⁶⁾ getroffen. Während die objektiven Kriterien absolut meßbar sind, variiert die Beurteilung aufgrund subjektiver Kriterien von Sachbearbeiter zu Sachbearbeiter. Einer Objektivierung des *gesamten* Aufgabenbereichs der Kreditvergabe steht die fehlende Kenntnis *aller* Zusammenhänge zwischen den Kriterien und der Entscheidung „kreditwürdig“ bzw. „nicht kreditwürdig“ entgegen. Fehlentscheidungen erhöhen die Kosten bzw. mindern den Erlös. Erhöhte Kosten treten auf, falls ein Kredit nicht, nur zum Teil oder nicht termingerecht zurückgezahlt wird. Eine Minderung des Erlöses tritt dann auf, wenn die Kreditvergabe abgelehnt wird, obwohl der Kunde termingerechte Tilgungen und Zinszahlungen vornehmen würde.

Der Einsatz computergestützter Entscheidungssysteme erfolgt i.w. mit den folgenden Zielen:

- a) Objektivierung der Entscheidung, d.h., alle Sachbearbeiter sollen die Entscheidung aufgrund des gleichen Wissensstands vornehmen.

36) Vgl. Pintaske (1991), Wilbert (1991).

- b) Minimierung der Fehlentscheidungen, also Verringern der Anzahl „falsch“ bewilligter Kredite und gleichzeitig erhöhen der Anzahl „richtig“ bewilligter Kredite.

Bisher wurden hauptsächlich statistische Verfahren - wie die lineare Diskriminanzanalyse - eingesetzt. Zunehmend erfolgt auch der Einsatz von Expertensystemen³⁷⁾. Aufgrund der Prämissen der linearen Diskriminanzanalyse, wie stochastische Unabhängigkeit der Daten, Linearität der Merkmalszusammenhänge und Vollständigkeit der Ausgangsdaten, sind die Einsatzpotentiale der darauf basierenden Verfahren begrenzt. Demgegenüber liegt die Schwäche der eingesetzten regelbasierten Expertensysteme in der Behandlung unscharfen Wissens sowie in der schwierigen und aufwendigen (Wissens-) Akquisition der komplexen Zusammenhänge. Da neuronale Netze sowohl mit fehlenden oder „verrauschten“ Daten umgehen als auch komplexe Merkmalszusammenhänge erkennen (erlernen) können, erscheint der Einsatz neuronaler Netze zur Kreditwürdigkeitsprüfung möglich und sinnvoll³⁸⁾.

Beim Einsatz neuronaler Netze bildet die Struktur der Eingabedaten immer ein wesentliches Kriterium für die Güte der durch das neuronale Netz erzielten Ergebnisse (vgl. auch Kapitel 2.2). Die Trainingsmenge für ein neuronales Netz zur Kreditwürdigkeitsprüfung wird aus alten Kreditverträgen gebildet. Zu diesen Verträgen sind sowohl die kundenspezifischen Merkmale (Fragebögen) als auch der Kapitalrückfluß bekannt. Das neuronale Netz lernt dann, anhand welcher Kriterien sich gute von schlechten Kreditnehmern unterscheiden.

Ebenso wie bei den Prognoseproblemen sind auch hier wieder zwei unterschiedliche Netzarchitekturen möglich: Entweder wird die Ausgabe „kreditwürdig/nicht kreditwürdig“ - ggf. auch feiner nach Risikogruppen unterteilt - durch Output-Neuronen oder durch zusätzliche Input-Neuronen kodiert. Bei einer Kodierung durch Output-Neuronen ist ein Backpropagation-Netz zu verwenden, während sich bei einer Kodierung durch Input-Neuronen die Verwendung eines Kohonen-Netzes anbietet. Über die Größe und Anzahl der Hidden-Schichten beziehungsweise die Dimension der Kohonen-Map gelten die in Kapitel 2.2 gemachten Aussagen entsprechend.

3.2 Analyse betriebswirtschaftlicher Kennzahlen und Kennzahlenverdichtung

Betrachtet man das in Kapitel 3.1 vorgestellte Aufgabengebiet nicht von der Aufgabenbeschreibung (Kreditwürdigkeitsanalyse) her, sondern stellt die Daten in den Mittelpunkt, so läßt sich die Kreditwürdigkeitsanalyse wie folgt als *Kennzahlenverdichtung* darstellen: Die Entscheidung „kreditwürdig“ bzw. „nicht kreditwürdig“ kann als eine einzige binäre Größe interpretiert wer-

37) Vgl. Krallmann (1990), Breuker et al. (1990), Kalefeld (1991).

38) Vgl. Wilbert (1991).

den. In diesem Fall werden die Unternehmen auf der Basis ihrer Bilanzdaten in solvente und insolvente Unternehmen, je nachdem, ob bei den Unternehmen ein Konkurs, Vergleich, Moratorium oder Scheck- oder Wechselprotest vorlag oder nicht.

Die Trainingsmenge wird also aus den Bilanzdaten der Vergangenheit gebildet, wobei ein oder mehrere zusätzliche Klassifikationsmerkmale („Insolvenz: ja/nein“) ergänzt werden. Die Ausprägung dieses Klassifikationsmerkmals ist aufgrund der Kenntnis der Vergangenheit bekannt³⁹⁾. Die Aufgabe des neuronalen Netzes ist also wieder das Erlernen der Zusammenhänge zwischen Eingabedaten (Bilanzdaten) und Ausgabedaten (Klassifikationsmerkmal).

Im allgemeinen legen Kennzahlen systembezogene Tatbestände offen und dienen als Kontroll-, Steuerungs- und Entscheidungskriterien. Reichmann und Lachnit definieren beispielsweise Kennzahlen so⁴⁰⁾: „Kennzahlen werden als jene Größen betrachtet, die quantitativ erfassbare Sachverhalte in konzentrierter Form erfassen.“ Im Bereich der Betriebswirtschaft werden Kennzahlen normative, beschreibende und dokumentierende Funktionen zugeordnet⁴¹⁾. Im folgenden wird insbesondere die beschreibende Funktion der Kennzahlen betrachtet. Sie ermöglicht aus der Interpretation von Zuständen eine Aufdeckung möglicher Schwachstellen und die Ermittlung kausaler Zusammenhänge zwischen Kennzahlen. So kommt nach Bischoff u.a.⁴²⁾ insbesondere der Bilanzanalyse sowohl innerhalb (interne Bilanzanalyse, z.B. zur Investitionsrechnung oder Finanzplanung) als auch außerhalb (externe Bilanzanalyse, z.B. zur Kreditwürdigkeitsprüfung, siehe Kapitel 3.1) der Unternehmung eine große Bedeutung zu. Reichmann⁴³⁾ unterscheidet beispielsweise in eine finanzwirtschaftliche Bilanzanalyse (Investitions-, Finanzierungs- und Liquiditätsanalyse) und eine erfolgswirtschaftliche Bilanzanalyse (Ergebnis-, Rentabilitäts-, Wertschöpfungs- und Break-even-Analyse). Die Grenzen der Bilanzanalyse werden dort erreicht, wo der Informationsbedarf des Analytikers die verfügbaren Informationen übersteigt. Dies resultiert insbesondere aus der mangelnden Zukunftsbezogenheit, Unvollständigkeit und Verzerrungen (Vorsichtsprinzip) der Bilanz sowie aus politischen Grenzen, Spielräumen und Wahlrechten bei der Erstellung der Bilanz.

Anwendungen neuronaler Netze sind beispielsweise im Bereich des Kreditwesens (Kreditwürdigkeitsprüfung⁴⁴⁾, Kreditvergabe, Bewilligung von Kreditkarten) zur Insolvenzprüfung⁴⁵⁾ und zur Vorhersage von Bankkonkursen⁴⁶⁾ bekannt.

39) Vgl. Erxleben et al. (1992), Bischoff et al. (1991).

40) Reichmann, Lachnit (1976), S. 706.

41) Vgl. Bischoff et al. (1991).

42) Vgl. Bischoff et al. (1991).

43) Vgl. Reichmann (1990), S. 14 ff.

44) Vgl. Wilbert (1991), Pintaske (1991).

3.3 Marktsegmentierung

Mit Marktsegmentierung wird die Aufteilung des Marktes in Verbrauchergruppen bezeichnet, die sich bzgl. ihrer für das spezielle Angebot relevanten Merkmale ähneln oder gleichen. Gesucht sind also Regelmäßigkeiten, mit denen eine Zuordnung von Verbrauchern zu Marktsegmenten erfolgen kann. Ein Marktsegment entspricht einem homogenen Teilstück des Gesamtmarkts, d.h., die zu einem Segment gehörenden Personen reagieren auf ähnliche Art und Weise. Ein Marktsegment läßt sich also durch die Angabe der psychografischen und soziodemografischen Variablen⁴⁷⁾ beschreiben. Die Marktsegmentierung ist im weiteren Grundlage für Entscheidungen bzgl. Produktgestaltung, Werbebotschaft, Media-Selektion usw. Der Erfolg dieser Maßnahmen ist in großem Umfang von der Qualität der Marktsegmentierung abhängig.

Die Aufgabe des neuronalen Netzes ist das Lernen von Zuordnungen zwischen Eingabedaten (psychografischen und soziodemografischen Variablen) und Ausgabedaten (Marktsegment), wie dies in den vorangegangenen Abschnitten bereits beschrieben wurde. Hruschka und Natter beschreiben ein neuronales Netz zur Marktsegmentierung⁴⁸⁾.

3.4 Konstruktionsunterstützung

Becker und Prischmann⁴⁹⁾ beschreiben ein System zur Konstruktionsunterstützung mit Namen VESKONN (Verteiltes System zur Konstruktionsunterstützung mit neuronalen Netzen). Durch VESKONN wird der Konstrukteur bei seiner Arbeit im wesentlichen durch zwei Funktionen unterstützt: zum einen durch eine konstruktionsbegleitende Kalkulation und zum anderen durch eine Wiederholteilesuche. Die Wiederholteilesuche dient der direkten Unterstützung des Konstrukteurs, indem ihm ähnliche Konstruktionsfälle aus der Vergangenheit zur Übernahme angeboten werden. Konstruktionsfälle werden durch Produkteigenschaften wie Größe, Funktionalität, eingesetzte Produktionstechnik usw. charakterisiert. Ergänzend zu den physikalischen Produkteigenschaften werden auch betriebliche Angaben, wie die mit der Herstellung verbundenen Kosten und Zeiten, verwendete (Produktions-) Techniken usw. aufgenommen. Da die für die Herstellung eines Produkts erforderliche Zeit von der Auslastung der Produktionsanlagen abhängig ist, ist auch diese als zusätzliche Angabe zu speichern.

45) Vgl. Erxleben et al. (1992) und Steiner, Wittkemper (1993), S. 460.

46) Vgl. Steiner, Wittkemper (1993), S. 460.

47) Psychografische Variablen beziehen sich auf eine Auskunftsperson und auf ihr Verhältnis zu einem Produkt(-feld) oder Marken, z.B.: Persönlichkeitsbild, allgemeiner Lebensstil. Soziodemografische Variablen sind beispielsweise Einkommen, Ausbildung, Beruf, aber auch Größe des Wohnortes usw.

48) Vgl. Hruschka, Natter (1993).

49) Vgl. Becker, Prischmann (1993).

Für eine gute konstruktionsbegleitende Kostenrechnung fehlt also „nur“ noch ein Verfahren, das die Zuordnung von Produktdimensionen zu Kosten und Zeit vornimmt. Diese Zuordnung wird durch ein Backpropagation-Netz realisiert. Da der Umfang und die Struktur der eingehenden Informationen fest vorgegeben ist, kann dieses Netz nicht direkt zur konstruktionsbegleitenden Kalkulation verwendet werden. Man benötigt für jede Stufe des Konstruktionsprozesses (die Stufen unterscheiden sich durch den Detaillierungsgrad der Produktbeschreibung) ein eigenes Netz, trainiert mit den spezifischen Informationen der Produktbeschreibung, die auf der entsprechenden Stufe verfügbar sind. Um den somit nötigen hohen Aufwand an Netzen, Trainingsdaten etc. zu vermeiden und wieder zu einem Backpropagation-Netz bzw. einer Schätzfunktion zu gelangen, schlagen Becker und Prischmann einen anderen Weg ein: Die Schätzfunktion wird jeweils nur auf eine komplette Produktbeschreibung der höchsten Detaillierungsstufe angewendet. Um die Schätzfunktion auch in den Stufen geringerer Detaillierung anwenden zu können, ist ein automatisches Auffüllen der aufgrund des geringeren Detaillierungsgrads fehlenden Produktangaben nötig. Dies erfolgt wieder mittels der Wiederholteilesuche, wobei zu einer Produktbeschreibung die ähnlichste bereits vorhandene Produktbeschreibung gesucht wird und deren Angaben quasi als Default-Werte für das aktuelle Konstruktionsobjekt dienen. So gelangt man auf jeder Konstruktionsstufe zu einer von Struktur und Umfang her identischen Produktbeschreibung, die mit einer für alle Konstruktionsstufen identischen Schätzfunktion bearbeitet werden kann.

Die Ermittlung der ähnlichsten Produktbeschreibung erfolgt mit Hilfe eines Assoziativspeichers, in dem alle bereits produzierten Teile abgelegt sind. Der Assoziativspeicher wird durch ein neuronales Netz realisiert (Boltzmann-Maschine). Mit diesem Assoziativspeicher ist es möglich, dem Konstrukteur in jeder Stufe der Konstruktion einen Vorschlag zu machen, wie die zu bearbeitende Aufgabe zuvor schon bearbeitet wurde, d.h., es wird nach dem ähnlichsten Auftrag gesucht. Der Konstrukteur kann nun entweder die Auswahl des ähnlichsten Teils bestätigen, was der Verwendung eines bereits geplanten und auch schon produzierten Teils gleichkommt, oder die Auswahl ablehnen, weil z.B. einige Eigenschaften des zu planenden Produkts nicht mit dem bereits gefertigten Produkt übereinstimmen.

In diesem Fall ist jedoch das Wissen, das mit dem „alten“ Produkt verknüpft ist, für die aktuelle Arbeit nicht wertlos, sondern kann quasi als Default-Wert für eine Produktbeschreibung für die konstruktionsbegleitende Kalkulation verwendet werden (s.o.). Die Default-Werte werden durch aus der aktuellen Konstruktion ermittelte Werte überschrieben. An den Stellen, an denen aus der aktuellen Konstruktion noch keine Werte bekannt sind, behalten die Default-Werte ihre Gültigkeit. Somit ist in jeder Phase der Konstruktion eine komplette Produktbeschreibung verfügbar, für die eine Kosten- und Zeitabschätzung mittels des eingangs beschriebenen neuronalen Netzes durchgeführt werden kann.

4 Optimierung mit neuronalen Netzen

Mit Optimierung wird i.a. die Suche nach einem optimalen Zustand bzgl. eines vorgegebenen Ziels bezeichnet. Zur Optimierung betrieblicher Problemstellungen wurden bisher insbesondere Verfahren des Operations Research wie Simplex-Verfahren, Branch-and-Bound, aber auch heuristikbasierte Verfahren verwendet. In neuerer Zeit gelangen auch künstliche neuronale Netze⁵⁰⁾ und genetische Algorithmen⁵¹⁾ zur Anwendung. Mit diesen Verfahren ist es möglich, in angemessener Zeit gute, i.d.R. aber nur suboptimale Lösungen für Probleme zu erstellen, für die eine Anwendung von Optimierungsverfahren aus Komplexitätsgründen ausscheidet.

4.1 Grundlagen

I.d.R. wird ein Optimierungsproblem durch eine Zielfunktion und eine Menge von Nebenbedingungen über einer Menge von Variablen beschrieben, wobei die Variablen Zustände des Optimierungsproblems darstellen. Die Nebenbedingungen stellen die Zulässigkeit ermittelter Lösungen sicher. Sowohl die Nebenbedingungen als auch die Zielfunktion werden als Funktionen über der Menge der Variablen formuliert.

Als geeigneter Netztyp zur Realisierung bieten sich Hopfield-Netze⁵²⁾ und daraus abgeleitete bzw. darauf aufbauende Netztypen (bspw. Meanfield-Netze) an. Diese Netze bestehen aus einer Menge von Neuronen in einer vollkommen verbundenen Schicht, wobei alle Verbindungen symmetrisch sind. Das Netz ist jedoch frei von Rückkopplungen⁵³⁾. Während bei den anderen, nicht zum Bereich der Optimierung gehörenden Anwendungen die Identifikation einer geeigneten Netztopologie ein wesentliches Problem bei der Erstellung eines Systems darstellt, ist dies bei neuronalen Netzen für Optimierungsaufgaben trivial. Jedoch werden „geeignete“ Netzparameter i.d.R. nur nach längerem Experimentieren gefunden.

4.2 Tourenplanung für die Vertriebsaußendienststeuerung

Das der Tourenplanung zugrundeliegende Problem wird in der Literatur als das Problem des Handlungsreisenden (TSP: Travelling Salesman Problem) bezeichnet. Die Aufgabe beim Problem des Handlungsreisenden besteht darin, eine optimale Reihenfolge anzugeben, in der eine

50) Vgl. z.B. Durbin, Willshaw (1987), Ruppel, Siedentopf (1992).

51) Vgl. Nakano, Yamada (1991), Bierwirth et al. (1993).

52) Vgl. Hopfield, Tank (1985), Hopfield (1982).

53) Vollkommen verbunden heißt: Jedes Neuron ist mit jedem Neuron verbunden. Symmetrisch bedeutet, daß das Gewicht der Verbindung zwischen den Neuronen i und j gleich dem Gewicht der Verbindung zwischen j und i ist. Rückkopplungsfrei heißt ein Netz, falls kein Neuron eine Verbindung zu sich selbst hat.

vorgegebene Anzahl von Orten besucht werden soll. Die Aufstellung effizienter Tourenpläne stellt eine wichtige Aufgabe im Rahmen der industriellen Vertriebslogistik und auch bei anderen Dienstleistern⁵⁴⁾ dar. Nachdem das Problem des Handlungsreisenden mittels neuronaler Netze gelöst wurde⁵⁵⁾, entstanden Anwendungen zur Lösung von auf dem Grundproblem aufbauenden Problemstellungen, wie die nachfolgend beschriebene Vertriebsaußendienststeuerung.

Pietsch und Teubner⁵⁶⁾ demonstrieren mittels zweier Prototypen, einmal auf Basis eines Hopfield-Netzes und einmal auf Basis eines Kohonen-Netzes, die prinzipielle Anwendbarkeit konnektionistischer Verfahren für Aufgabenstellungen, die auf dem Problem des Handlungsreisenden aufbauen. Eine Besonderheit des vorgestellten Systems ist die simultane Besuchs- und Tourenplanung. Während bisher davon ausgegangen wird, daß es nicht möglich ist, Kundenauswahl und Tourenplan simultan zu optimieren⁵⁷⁾, wird im vorgestellten Prototyp eine Erstellung des Tourenplans bei gleichzeitiger Berücksichtigung der Wichtigkeit der Kunden realisiert. Darüber hinaus ist es möglich, auch mehrere Pläne gleichzeitig zu optimieren, wodurch die Möglichkeit eröffnet wird, das ermittelte Besuchskontingent auf mehrere Reisen zu verteilen.

4.3 Maschinenbelegungsplanung

Gegeben ist eine Menge von Betriebsmitteln, wobei ähnliche oder gleiche Betriebsmittel zu Betriebsmittelgruppen zusammengefaßt werden. Alle Betriebsmittel bilden die Produktionsumgebung. Die einzelnen Betriebsmittel einer Gruppe können sich z.B. durch ihren Leistungsgrad unterscheiden. Weiterhin ist eine Menge von Fertigungsaufträgen gegeben, die das Produktionsprogramm für einen gewissen Zeitraum festlegen. Jeder Fertigungsauftrag besteht aus einer Menge von Arbeitsgängen, die in einer bestimmten Reihenfolge ausgeführt werden müssen. Die Reihenfolge, in der die Arbeitsgänge verschiedener Fertigungsaufträge die Betriebsmittel durchlaufen, kann unterschiedlich sein (different routing, job shop).

Gesucht ist nun für ein solches Szenario eine optimale oder zumindest eine möglichst gute Zuordnung von Fertigungsaufträgen zu Betriebsmitteln, zusammen mit der Reihenfolge ihrer Bearbeitung auf dem jeweiligen Betriebsmittel. Ein solcher Plan heißt Maschinenbelegungsplan.

54) Vgl. Mertens (1991), S. 37 ff.

55) Vgl. z.B. Aarts, Korst (1987), Xu, Tsai (1990), Fritzke, Wilke (1992).

56) Vgl. Pietsch, Teubner (1991).

57) Bei konventionellen Systemen wird der eigentlich simultan durchzuführende Planungsprozeß sequenziert, d.h., zuerst werden die zu besuchenden Kunden ausgewählt und dann der Reiseplan ermittelt. Die Interdependenzen zwischen den beiden Entscheidungsparametern bleiben somit unberücksichtigt. Dies äußert sich z.B. darin, daß ein Kunde nicht besucht wird, obwohl er an der ermittelten Reiseroute liegt. Vgl. Mertens (1991), S. 41.

Vorausgesetzt, die Produktionsumgebung besteht aus m Maschinen und das Produktionsprogramm umfaßt Fertigungsaufträge mit zusammen n Arbeitsgängen, so benötigt man $n \cdot n \cdot m$ Neurone für das Hopfield-Netz. Ordnet man die Neuronen entsprechend in einem Quader⁵⁸⁾ mit den Kantenlängen n , n und m an, so lassen sich die Neuronen entsprechend ihrer Koordinaten numerieren. Hat das Neuron mit den Koordinaten (i,j,k) die Aktivierung 1, so ist dies gleichbedeutend mit der Aussage: „Arbeitsgang i wird als j -ter Arbeitsgang überhaupt ausgeführt und zwar auf Betriebsmittel k “.

Nun formuliert man die Energiefunktion als durch konstante Faktoren (Penalty-Terme) gewichtete Summe aus der Zielfunktion und den Nebenbedingungen⁵⁹⁾. Bei der Einstellung der Penalty-Terme ist zu beachten, daß harte Bestrafungen zwar das Finden zulässiger Lösungen unterstützen, das Finden optimaler Zustände jedoch eher behindern. Dies ist vor allem im Hinblick auf das Lernverfahren des *Simulated Annealing* zu beachten, da dieses das „Überspringen“ bzw. Verlassen lokaler Minima ermöglicht. Voraussetzung für eine gute Arbeitsweise des Simulated Annealing ist das Aufstellen eines wohlüberlegten Abkühlplans (Cooling Schedule). Die Aufstellung hat in Abhängigkeit von der gewählten Problemstellung zu erfolgen und beeinflusst wesentlich die Effizienz des Verfahrens und die Güte der gefundenen Lösungen.

Ein wesentlicher Vorteil der neuronalen Netze im Vergleich zu klassischen Verfahren des Operations Research besteht darin, daß zu jedem Zeitpunkt des Problemlösungsprozesses eine Lösung verfügbar ist und diese Lösung nicht erst am Ende eines Berechnungsprozesses vorliegt. Bei der Evaluierung einer konnektionistischen Feinplanungskomponente⁶⁰⁾ wurden beispielsweise Maschinenbelegungspläne mit Laufzeiten im Sekundenbereich ermittelt, während die auf identischer Hardwareplattform durchgeführten Lösungen mittels Simplex-Verfahren dagegen Laufzeiten im Stundenbereich erforderten. Die Güte der Lösungen unterschieden sich jedoch nur um maximal 5%.

58) Das soll jedoch nicht heißen, daß das neuronale Netz geschichtet ist, wie z.B. ein Backpropagation-Netz. Bei Backpropagation-Netzen unterscheiden sich die Neuronen der einzelnen Schichten, während hier die Anordnung in Form eines Quaders eine rein gedankliche Vorstellung ist.

59) Für die Formulierung der Nebenbedingungen bestehen zwei Möglichkeiten: a) Die Nebenbedingungen werden durch geeignete Wahl der Verbindungsgewichte repräsentiert, oder b) die Nebenbedingungen werden wie auch die Zielfunktion als Funktion über den Aktivierungen der Neuronen formuliert. Im Fall b) können die Gewichte vernachlässigt werden, da sie keine relevante Information mehr enthalten. M.a.W.: Alle Gewichte erhalten den Wert 1 und können so bei der Berechnung der Aktivierung anderer Neuronen unberücksichtigt bleiben.

60) Die konnektionistische Feinplanungskomponente wurde im Rahmen eines von der DFG geförderten Forschungsvorhabens am Institut für Wirtschaftsinformatik der Universität Münster entwickelt.

4.4 Abschließende Bemerkung zur Optimierung

Bei der Erstellung eines konnektionistischen Systems zur Maschinenbelegungsplanung (vgl. Kapitel 4.3) ergab sich u.a., daß die Lösung mit Hopfield-Netzen zwar möglich, jedoch ineffizient⁶¹⁾ ist. Die Ineffizienz resultiert aus der großen Anzahl erforderlicher Neurone und der Vielzahl der auf den Neuronen erforderlichen Operationen. Bei den Operationen hat sich insbesondere die Überprüfung der Konsistenzbedingungen als sehr zeitaufwendig erwiesen. Daher wurde eine andere, wesentlich effizienter zu verarbeitende Struktur entwickelt, die die Grundgedanken des Hopfield-Ansatzes übernimmt, jedoch nicht mehr problemunabhängig wie das Hopfield-Netz ist.

Die neue Darstellungsweise wurde erst nach gründlichem Studium der Arbeitsweise der Hopfield-Netze für das konkrete Problem gefunden. Das Vorgehen, zuerst eine Problemlösung mittels Hopfield-Netz vorzunehmen und diese dann auf eine neue und u.U. besser geeignete Darstellung zu übertragen scheint auch für andere (Reihenfolge-) Probleme anwendbar zu sein⁶²⁾. Wichtig beim Wechsel der Darstellung ist, daß die Vorteile weitestgehend beibehalten und die Nachteile nach Möglichkeit vermieden werden.

5 Mustererkennung i.e.S.

Mustererkennung im engeren Sinne, also das Erkennen von Regelmäßigkeiten in akustischen, optischen oder sonstigen sensorischen Signalen ist im betrieblichen Umfeld an vielen Stellen möglich. Bei den in den folgenden Abschnitten dargestellten Anwendungen wird zwischen Bildverarbeitung (Verarbeitung optischer Signale) bzw. OCR (*Optical Character Recognition*, Erkennen geschriebener Zeichen) und der Verarbeitung anderer Muster unterschieden.

Im folgenden Abschnitt werden Grundlagen und Anwendungen der Bildverarbeitung aufgezeigt. Das nächste Kapitel zeigt am Beispiel der Qualitätssicherung Anwendungen neuronaler Netze, die auf der Verarbeitung akustischer und anderer sensorischer Daten basieren.

61) Vgl. Ruppel, Siedentopf (1992).

62) Vgl. Kurbel (1993)

5.1 OCR (Optical Character Recognition)

Aus dem Aufleben der neuronalen Netze resultieren Fortschritte in der Bildverarbeitung allgemein und auch gerade im Bereich des OCR⁶³). Im betrieblichen Bereich findet man im wesentlichen Aufgabengebiete wie die automatische Erfassung von Belegen, Lieferscheinen, Aufträgen etc. sowie das Lesen von Identifikationsnummern in der laufenden Produktion (vgl. auch Kapitel 5.2) zwecks Produktionsüberwachung und Qualitätskontrolle.

Im Bereich der Banken ist auch der maschinelle Vergleich von Unterschriften ein Anwendungsgebiet. Jedoch steht hierbei nicht der reine Vergleich der fertig geschriebenen Unterschrift im Mittelpunkt, sondern vielmehr der dynamische Prozeß des Unterschreibens:

- An welchen Stellen wird der Stift angehoben und aufgesetzt?
- Mit welcher Geschwindigkeit werden Linien bzw. Linienzüge erstellt?
- Mit welchem Druck auf den Stift wird geschrieben?

Durch die zusätzliche Erfassung dieser dynamischen Parameter der Unterschrift soll eine neue Ära der Sicherheit gegenüber Unterschriftenfälschungen möglich werden⁶⁴).

Auf eine genauere Darstellung der Systeme soll an dieser Stelle verzichtet und stattdessen auf die angeführte Literatur verwiesen werden⁶⁵).

5.2 Bildverarbeitung

Bei der Bildverarbeitung mit neuronalen Netzen lassen sich vier Dimensionen unterscheiden, wobei die Dimension „Beschriftung“ bereits im vorangegangenen Kapitel erläutert wurde:

Eine wesentliche Anwendung der Bildverarbeitung im betrieblichen Umfeld liegt im Bereich der Qualitätskontrolle. Dabei ist insbesondere eine geeignete Beleuchtung der Prüflinge und eine hohe Verarbeitungsgeschwindigkeit des Kontrollsystems wichtig. Schließlich soll bei einer Linienfertigung nicht die Produktionsgeschwindigkeit durch das Kontrollsystem verringert werden.

An die Erfassung der Daten (digitalisiertes Kamera-Bild, häufig zwischen 64 und 256 Graustufen) schließt sich eine Datenaufbereitung an: beispielsweise kann hier das Bild segmentiert

63) Vgl. z.B. Schreiber (1988), Sarnow (1990), Haruki, Hatano (1990), Lee (1990), Zhu et al. (1990), o. V. (1991), Fukushima (1992).

64) Vgl. o. V. (1991).

65) Beispielsweise bietet Klitscher (1993) einen guten Überblick.

werden und jedes Segment von einem anderen neuronalen Netz (parallel) geprüft werden. Die Datenaufbereitung dient - wie auch schon im vorangegangenen Kapitel beschrieben - der Merkmalsextraktion und Datenreduktion. Zur Anwendung gelangen beispielsweise Verfahren, die aus den Daten (Bildern) Histogramme der Helligkeits- oder Farbverteilung erzeugen, oder auch die Fourier-Transformation. Die so erhaltenen Merkmale können dann dem neuronalen Netz zugeführt werden.

Dimension	Anwendungspotentiale
<u>Textur</u> (Beschaffenheit einer Oberfläche)	Überprüfen von Schweißnähten und Lackierungen, Suchen nach Webfehlern, Kantenrissen bei Metallbändern und Gußlunkern
<u>Maßhaftigkeit</u> (Einhalten bestimmter Soll-Maße)	Maß- und Formenprüfung bei Backwaren
<u>Vollständigkeit</u> (Überprüfung der Ausführung aller Arbeiten)	Alle Löcher gebohrt, alle Schrauben eingedreht, Platine vollständig bestückt
<u>Beschriftung</u> (Erfassen der Objekt Nummer zur Identifikation des Objekts im laufenden Prozeß)	Lesen unbekannter Zeichenketten oder Vergleich von gelesener mit bekannter Beschriftung (Soll-Ist-Vergleich)

Abb. 4: Die vier Dimensionen der Bildverarbeitung⁶⁶⁾

Ein anderer Ansatz, der vom oben beschriebenen abweicht, verwendet neuronale Klassifikatoren zur Bildverarbeitung. Klassifikatoren erkennen lokale Eigenschaften von Pixeln in Bildern anhand ihrer Beziehung zur Pixel-Umgebung. Die Beziehungen zwischen den Pixeln werden mittels *lokaler Operatoren* untersucht. In der Bildverarbeitung werden solche lokalen Operatoren schon länger eingesetzt. Dieser Ansatz verzichtet auf die Bildaufbereitung zur Merkmalsextraktion, stattdessen liegt das aufgenommene Bild in Form einer Pixel-Matrix vor. Jedes Pixel wird als ein Merkmal interpretiert, für das Helligkeits- und/oder Farbwerte gespeichert sein können. Man definiert nun ein Operatorfenster, das den „Arbeitsbereich“ des Operators darstellt. Das Operatorfenster wird pixelweise über das Bild geschoben. Dabei werden die neuen Werte der Pixel berechnet.

Ein linearer Klassifikator besteht aus einer quadratischen Matrix ungerader Dimension (damit das betrachtete Pixel im Mittelpunkt der Matrix liegt). Der Wert des Pixels im bearbeiteten Bild ergibt sich aus der Summe der Pixel-Werte, die unter der Matrix liegen, multipliziert mit den Werten, die an der entsprechenden Position in der Matrix stehen. Abbildung 6 zeigt einen linea-

66) Vgl. Petri (1993).

ren Klassifikator zur Hervorhebung der Kanten in einem Grauwertbild, den sog. Laplace-Operator. Das Pixel erhält einen umso höheren Wert, je mehr Pixel in seiner direkten Umgebung (darüber, darunter, rechts bzw. links daneben) nicht aktiviert sind. Somit werden also Ecken und Kanten verstärkt, während ausgefüllte Flächen abgeschwächt werden. Je nachdem, ob die Pixel des neuen Bilds echte Grauwert- oder nur Schwarz-Weiß-Informationen repräsentieren sollen, erfolgt die Aktivierung ggf. in Abhängigkeit eines Schwellenwerts.

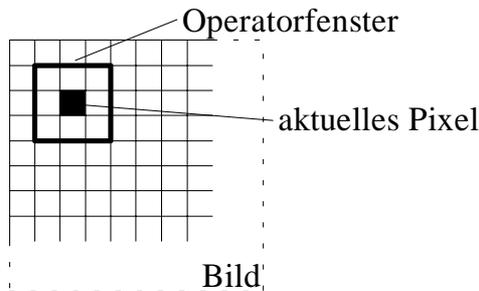


Abb. 5: linearer Klassifikator

Das Erstellen von Klassifikatoren ist i.d.R. nicht einfach, zumal für viele Anwendungen die Überlagerung mehrerer Operatoren notwendig ist (z.B. ergibt sich der Sobel-Operator aus der Überlagerung mehrerer Matrizen⁶⁷⁾). Aufgrund der Struktur des Problems (die Pixel des Operatorfensters sind die Input-Neuronen, das neue Pixel ist das Output-Neuron und die Gewichte entsprechen den Werten in der Matrix) lassen sich solche Klassifikatoren durch ein einfaches neuronales Netz lernen. Beim Training werden dem neuronalen Netz Bildausschnitte in der Größe des Operatorfensters zusammen mit der Angabe des neuen Pixelwertes präsentiert.

0	-1	0
-1	4	-1
0	-1	0

Abb. 6: Laplace-Operator

5.3 Verarbeitung akustischer oder anderer sensorischer Signale

Dem Problemkreis der Qualitätssicherung bzw. Qualitätsprüfung kommt in der letzten Zeit eine steigende Bedeutung zu. Dies resultiert u.a. aus dem Trend zu immer weiter automatisierten Montagen. Während sonst der Mensch bei vielen Arbeitsgängen bereits Produktionsfehler aus früheren Stufen bemerkt und entsprechend reagieren kann, entfällt bei den hoch-automatisierten

67) Vgl. Petri (1993).

Montagestraßen der „menschliche“ Kontrolleur. Zur Vermeidung von unnötigen Kosten oder Schäden⁶⁸⁾ ist häufig eine automatische Qualitätskontrolle wünschenswert.

Sowohl durch den Gesetzgeber (Produkthaftung) als auch durch die Kunden (Verfügbarkeit, Effizienz) wird eine Qualitätsprüfung auf Seiten des Herstellers gefordert⁶⁹⁾.

5.3.1 Grundlagen

Unabhängig davon, ob Einzelprüfungen oder Gesamtprüfungen produktionsbegleitend oder als Endkontrollen durchgeführt werden, kann man einen abstrakten Qualitätssicherungsarbeitsplatz mit neuronalen Netzen konzipieren. Die Wahl eines geeigneten neuronalen Netzes ist von der konkreten Problemstellung, der gewünschten Ausgabe sowie der Komplexität der abzubildenden Beziehungen zwischen Ein- und Ausgaben abhängig. Aus der konkreten Problemstellung lassen sich die Anzahl der zu betrachtenden Merkmale (Input-Neuronen, beispielsweise Signale von Sensoren, Fourier-transformierte Schwingungen etc.) und die gewünschte Ausgabe⁷⁰⁾ (Output-Neuronen) ableiten. Die Komplexität der Beziehungen zwischen Ein- und Ausgaben beeinflusst die Anzahl und die Größe der Hidden-Schichten. Für die Dimensionierung der Hidden-Schicht(en) existiert neben der Heuristik „je komplexer eine Beziehung, desto größer sind die Hidden-Schichten zu wählen bzw. umso mehr Hidden-Schichten sind zu wählen“ keine feste Regel.

Die Erfassung der Eigenschaften des Prüflings erfolgt mittels Sensoren (Mikrofon, Kamera, spezielle Sensoren). Ein nachgeschalteter Prüf- oder Prozeßrechner übernimmt die Aufbereitung der von den Sensoren aufgenommenen Daten (z.B.: Analog-Digital-Wandlung) und leitet sie an den eigentlichen Prüfarbeitsplatz weiter. Dort werden die Daten ggf. nochmals speziell für das neuronale Netz transformiert (z.B. kodiert oder normiert). Das neuronale Netz klassifiziert dann anhand des in der Trainingsphase erlernten Wissens den Prüfling und stößt die weitere Bearbeitung - Aussondern oder Einschleusen in einen Reparatur- oder Nachbesserungszyklus und Ausgabe eines Fehlerprotokolls etc. - an.

Nach diesen prinzipiellen Überlegungen folgt in den nächsten Abschnitten eine Vorstellung real existierender Systeme.

68) Unnötige Kosten entstehen beispielsweise dadurch, daß ein Produkt die komplette Fertigung durchläuft, obwohl bereits in einer frühen Stufe ein funktionswichtiges Teil fehlerhaft montiert wurde. Schäden können an Maschinen verursacht werden, falls ein Produkt nicht die geforderten Eigenschaften besitzt, z.B. kann keine Schraube eingedreht werden, wo weder Bohrung noch Gewinde sind.

69) Vgl. Lutz (1993) und Schmid-Lutz, Schöneburg (1993).

70) Einfache Ausgaben könnten lauten: "Prüfung bestanden" bzw. "Prüfung nicht bestanden" oder "Prüfung bestanden" bzw. "Nachbesserung notwendig" gefolgt von einer Arbeitsanweisung (Fehlerdiagnose).

5.3.2 Verarbeitung sensorischer Signale - Diagnose von Verbrennungsmotoren

Aufgrund der gestiegenen Anforderungen an Motoren erfolgt bei den Herstellern die Endprüfung der Motoren in letzter Zeit in gefeuertem Zustand, d.h., entsprechend ihrer Eigenschaft als Verbrennungsmotor. Ein Prüfstand für diese Testmethode heißt *Hot-Test-Prüfstand*. Der Hot-Test hat drei wesentliche Nachteile⁷¹⁾:

- Hohe Prüf- und Reparaturkosten infolge zu später Fehlererkennung, unzureichender Fehlerdiagnose und mangelhaftem Informationsfluß.
- Gefahr der Beschädigung bzw. Zerstörung von Motoren und Prüfstand im Hot-Test.
- Vorbeugende Maßnahmen zur Fehlervermeidung sind nicht ableitbar.

Nicht zuletzt aus wirtschaftlichen Gründen ist es daher sinnvoll, den Hot-Test so selten wie möglich anzuwenden. Ein alternatives, kostensparendes und materialschonendes Testverfahren basierend auf Einzel-Funktionstests wird mit Cold-Test bezeichnet. Dabei wird der Motor durch einen Elektromotor angetrieben. Diverse Sensoren zeichnen Druck-, Kompressions- und Drehmomentverläufe usw. auf und leiten diese gleichzeitig an ein neuronales Netz. Werden sowohl von Motoren, die den Endfunktionstest bestehen, als auch von mangelbehafteten Motoren die Daten der Sensoren aufgezeichnet, so erhält man eine Menge von Szenarien. Die Szenarien können zum Anlernen eines neuronalen Netzes verwendet werden. Wichtig ist dabei, daß nicht nur *ein* Motor getestet wird, der in Ordnung ist, sondern daß durchaus mehrere solcher Motoren getestet werden, um so auch die Streuung der Parameter abzudecken. Problematisch ist u.U. das Beschaffen der Szenarien von fehlerhaften Motoren, da diese (im Sinne des Herstellers) möglichst selten auftreten sollen. Entweder man protokolliert die Testläufe über einen ausreichend langen Zeitraum mit, oder man „schleust“ absichtlich fehlerbehaftete Motoren in den Prüfbetrieb ein. Während der Prüfungen wird zusammen mit den Meßwerten auch das Untersuchungsergebnis (m.a.W. die gewünschte Reaktion, „Fehler“ oder „in Ordnung“, ggf. ergänzt um zusätzliche Reparaturangaben) festgehalten. Damit sind die Trainingsdaten aufgezeichnet.

Für jede aufgezeichnete Größe muß nun ein Input-Neuron und für jede gewünschte Ausgabe ein Output-Neuron angelegt werden. Über die Anzahl und Größe der Hidden-Schichten gibt es keine feste Regel. I.a. reichen jedoch ein bis zwei Hidden-Schichten aus. Die Festlegung der Größe (Anzahl der Neuronen) je Hidden-Schicht ist abhängig von der Komplexität der Zusammenhänge zwischen Ein- und Ausgabe. Hier hilft eigentlich nur die Trial-and-error-Methode, um ein Netz bestmöglich an die gegebene Aufgabenstellung anzupassen.

71) Vgl. Lutz (1993)

5.3.3 Verarbeitung sensorischer Signale - Getriebe-Diagnose

Das im folgenden beschriebene Diagnosesystem dient dem Test von Automatik-Getrieben für den Nutz- und Schwerfahrzeugbereich. Automatik-Getriebe bestehen in der Regel aus einem hydrodynamischen Drehmomentwandler mit nachgeschaltetem Planetengetriebe, die von einer elektronischen Steuerung über eine Hydraulik in Abhängigkeit von der Motorbelastung und der Fahrgeschwindigkeit geschaltet werden.

Da im Nutzfahrzeugbereich sehr hohe Kilometerleistungen gefordert werden, ist es unerlässlich, jedes Getriebe einzeln auf einem Prüfstand zu testen. Dabei ist insbesondere das Volllastschaltverhalten der Getriebe von ausschlaggebender Bedeutung⁷²⁾. Selbst geringfügige Abweichungen - von getriebespezifischen Toleranzen abgesehen - müssen erkannt werden. Als Trainingsdaten dienen Aufzeichnungen der Schaltvorgänge, m.a.W. eine Kurve der Turbinendrehzahl, normiert anhand einer festen Zeitbasis. Dieser kontinuierliche Verlauf der Turbinendrehzahl muß nun diskretisiert (in Intervalle eingeteilt) werden, wobei jede Zeiteinheit (Intervall) durch ein Input-Neuron repräsentiert wird. Die Output-Neuronen repräsentieren die gewünschten Ausgaben usw. Über die Beschaffung der Trainingsdaten und die Wahl einer „guten“ Netztopologie gilt das im vorhergehenden Abschnitt Gesagte.

5.3.4 Verarbeitung akustischer Signale - Testen von Elektromotoren

Bei der Produktion hochwertiger Elektromotoren für den Einsatz im Automobilbau ist eine Qualitätskontrolle unerlässlich. Produktionsfehler äußern sich einerseits in einer reduzierten Lebensdauer und andererseits in einer mangelnden Laufruhe der Motoren. Besonders gravierend sind solche Produktionsfehler beispielsweise bei der Verwendung der Motoren zur Betätigung von Schiebedächern⁷³⁾.

Eine automatische Qualitätskontrolle unter Verwendung eines neuronalen Netzes ersetzt das Ohr des Kontrolleurs durch ein Mikrofon. Nach einer Analog-Digital-Wandlung der elektrischen Impulse können diese per Computer weiterverarbeitet werden. Zur Reduktion des Datenvolumens und zur Extraktion bzw. Bildung relevanter Merkmale bietet sich die Fourier-Transformation an⁷⁴⁾. Die so extrahierten Merkmale werden dem neuronalen Netz in der Lernphase präsentiert, ergänzt durch eine Beurteilung des Kontrolleurs, ob das untersuchte Signal zu einem guten

72) Vgl. Lutz, Schmid-Lutz (1993).

73) Vgl. Verweyer-Frank, Teschers (1992).

74) Vgl. Beth (1984). Die Grundidee der Fourier-Transformation ist, daß sich ein periodisches Signal durch Überlagerung einer sinusförmigen "Grundschwingung" mit einer Menge von sinus- oder cosinusförmigen "Ergänzungsschwingungen" ergibt. Durch die Angabe der Frequenz, Amplitude und Phasenverschiebung der jeweiligen Schwingungen läßt sich somit das ursprüngliche Signal beschreiben.

oder schlechten Objekt gehört. Der Kontrolleur übernimmt hier auch gleichzeitig die Funktion des Lehrers⁷⁵). Während der Arbeitsphase des neuronalen Netzes erfaßt dieses die Laufgeräusche und klassifiziert die Motoren selbständig gemäß dem gelernten Wissen. Dabei ist es unerheblich, ob eine Klassifikation nur in die Gruppen tauglich/untauglich oder zusätzlich noch in verschiedene Schadensklassen erfolgt (falls das Netz hierauf trainiert wurde).

Bei der Festlegung der Netztopologie entspricht die Anzahl der Output-Neuronen den Schadensklassen. Die Größe der Input-Schicht ergibt sich aus der Art und der Kodierung der Eingabedaten (Ergebnis der Fourier-Transformation). Die Anzahl der Hidden-Schichten sowie ihre jeweilige Größe ist problemabhängig zu wählen.

5.4 Abschließende Bemerkungen

Gerade im Zuge steigender Anforderungen der Kunden und des Gesetzgebers (Produkthaftung) kommt dem Bereich der Qualitätsprüfung eine wichtige Bedeutung zu. Jedoch zeichnen sich umfangreichere Kontrollen auch i.d.R. durch höhere Kosten aus. Hinzu kommt die Fehlerrate bei einer Qualitätskontrolle durch den Menschen - vor allem bei hohen zu testenden Stückzahlen. Die Fehlerrate resultiert hauptsächlich aus Ermüdungserscheinungen und Nachlassen der Konzentration.

Der Bereich der Qualitätsprüfung läßt sich in drei Kategorien aufspalten:

- a) *Akustische Qualitätsprüfung*: I.d.R. erfolgt die Erfassung der Geräusche mit einem Mikrofon. Die erfaßten Signale werden Analog/Digital-gewandelt und dem Computer zugeführt. Häufig erfolgt jetzt eine Fourier-Transformation, wodurch eine Reduktion des Datenvolumens und eine Merkmalsextraktion erfolgt. Anhand der Merkmale wird dann das neuronale Netz zur Unterscheidung guter von schlechten Objekten trainiert. Anwendungsgebiete sind überall dort, wo entweder anhand der Betriebsgeräusche eines Objekts auf dessen Qualität geschlossen werden kann (z.B. Motoren), oder wo durch geeignete Behandlung Objekte zur Abgabe von Geräuschen angeregt werden können, die Rückschlüsse auf die Qualität zulassen (z.B. Produkte der Glas-, Porzellan- oder Keramikindustrie).
- b) *Optische Qualitätsprüfung*: Innerhalb dieses Gebiets gibt es zwei verschiedene Wege: Weg 1 folgt der Idee der akustischen Qualitätsprüfung, indem mittels geeigneter Verfahren aus dem aufgenommenen Bild Merkmale extrahiert werden. Das neuronale Netz lernt dann die

75) Das Erfassen der Lerndaten und das Anlernen des neuronalen Netzes kann selbstverständlich sowohl räumlich als auch zeitlich getrennt stattfinden.

Assoziation zwischen diesen Merkmalen und der gewünschten Ausgabe. Der zweite Weg basiert auf einer pixelweisen Betrachtung des digitalisierten Bildes. Durch neuronale Klassifikatoren werden die Regionen des Bildes, die einen Defekt aufweisen, herausgearbeitet, so daß eine Fehlererkennung mit traditionellen Verfahren (z.B. Linienerkennung) möglich wird. Das neuronale Netz dient dabei nur dem Design eines lokalen Operators zur Bildverarbeitung.

- c) *Qualitätsprüfung mit spezifischen Sensoren:* Häufig kann die Qualität von Objekten nicht allein oder gar nicht aus ihrem optischen oder akustischen Erscheinungsbild abgeleitet werden (siehe Kapitel 2.4.2 und 2.4.3). Da auch der Mensch solche Produkte nur anhand von Meßwerten, die mittels spezifischer Sensoren erfaßt werden, beurteilen kann, können diese Meßwerte - geeignet aufbereitet - auch einem neuronalen Netz zugeführt werden. Die „geeignete Aufbereitung“ der erfaßten Signale ist die schwierigste Aufgabe bei der Entwicklung von Systemen mit neuronalen Netzen zur Qualitätsprüfung. Für die Bild- und Geräuschverarbeitung existieren gängige Verfahren (z.B. Fourier-Transformation), mit denen man zumindest beginnen kann. Die Aufbereitung der Signale ist jedoch nur konkret und anwendungsspezifisch zu lösen.

6 Überblick und Klassifikation

Die in den vorhergehenden Kapiteln dargestellten Anwendungen sind grob nach ihrer Funktionalität gegliedert, wie dies die horizontale Struktur der Abbildung 7 wiedergibt. Die vertikale Struktur zeigt zusätzlich, in welchem betriebswirtschaftlichen Bereich die jeweiligen Anwendungen angesiedelt sind.

Die Bereiche Prognose, Datenanalyse und Mustererkennung i.e.S. lassen sich zu einer Gruppe Musterverarbeitung (an anderer Stelle findet man auch die Begriffe Funktionsapproximation, Zuordnungs- oder Klassifikationsproblemen) zusammenfassen, wenn man von der Struktur der Eingabedaten abstrahiert. Beispielsweise unterscheiden sich Anwendungen im Bereich Prognose von denen im Bereich Datenanalyse nur dadurch, daß bei der Prognose die Bestimmung zukünftiger Entwicklungen aus der Kenntnis der Entwicklungen der Vergangenheit erfolgen soll. Diese Trennung läßt sich auch nicht exakt und scharf durchführen, wie das Beispiel VESKONN (Kapitel 3.5) zeigt. Dort werden zwar zu erwartende Fertigungskosten und -zeiten prognostiziert, also ein zukünftiger Wert vorhergesagt, jedoch erfolgt dies nicht auf der Basis von Zeitreihen, sondern die bestimmenden Faktor sind die Produkteigenschaften.

Ebenso verhält es sich mit der Mustererkennung i.e.S. Gerade die beschriebenen Anwendungen aus dem Bereich der Qualitätssicherung zeigen deutlich, daß das wesentliche an den jeweiligen

Systemen das Erlernen der Zusammenhänge zwischen Ein- und Ausgabedaten ist, es ist also eine Systembeschreibung einer Fehlerklasse zu zuordnen.

	Finanzwirtschaft	Produktionswirtschaft	Absatzwirtschaft
Prognose	Aktien-, Devisen-, Wechsel und Wertpapierkurse div. volkswirtschaftliche Kenngrößen ⁷⁶⁾	Lagerbestände Auftragsserwartungen	Umsatzerwartungen Preisentwicklungen
Datenanalyse	Insolvenzprüfung Vorhersage von Bankkonkursen Kreditwürdigkeitsprüfung Vergabe von Kreditkarten Risikoprüfung für Versicherungen Betriebswirtschaftl. Kennzahlenanalyse Money Management	Konstruktionsunterstützung Angebotsplanung Kosten- und Lieferterminabschätzung kurz- und mittelfristige Personalbedarfsplanung	Marketingunterstützung durch Trenderkennung
Optimierung		Maschinenbelegungsplanung	Logistik und Tourenplanung bei der Warendistribution Dezentrale Vertriebsaußendienststeuerung
Mustererkennung i.e.S.	OCR, Belegerfassung Unterschriftenerkennung	Qualitätssicherung OCR zur automatischen BDE	

Abb. 7: Anwendungen klassifiziert nach betriebswirtschaftlichen Funktionsbereichen und Anwendungsbereichen neuronaler Netze

Auf den ersten Blick fallen die Anwendungen neuronaler Netze zur Bildverarbeitung (neuronale Operatoren) aus dieser Einordnung heraus: Führt man sich jedoch vor Augen, daß die neuronalen Operatoren nichts anderes sind als kleine neuronale Netze, die gelernt haben, ob ein gegebener Bildausschnitt zu einer Fehlerzone gehört oder nicht, so lassen sich auch diese Anwendungen mit den anderen zusammenfassen. Alle Anwendungen haben die Gemeinsamkeit, daß sie überwacht lernen, d.h., sie lernen eine durch die Trainingsmenge vorgegebene Zuordnung zwischen Ein- und Ausgabedaten und gehören demnach in die Gruppe der induktiven Lernverfahren (Lernen aus Beispielen, induktives Lernen).

Eine eigene Gruppe bilden die Anwendungen aus dem Bereich Optimierung. Der wesentliche Unterschied liegt im verwendeten Verarbeitungsprinzip: Während die anderen Anwendungen anhand einer Trainingsmenge angelernt werden - die neuronalen Netze also die Strukturen, die für eine Problemlösung notwendig sind, selbst erlernen - werden die neuronalen Netze zur Optimierung nicht trainiert. Bei diesen Netzen wird nur spezifiziert, welche Eigenschaften eine Lösung besitzen muß, das Generieren der Lösung und somit die Navigation im Lösungsraum übernimmt das Netz.

76) Vgl. Steiner, Wittkemper (1993), S. 460.

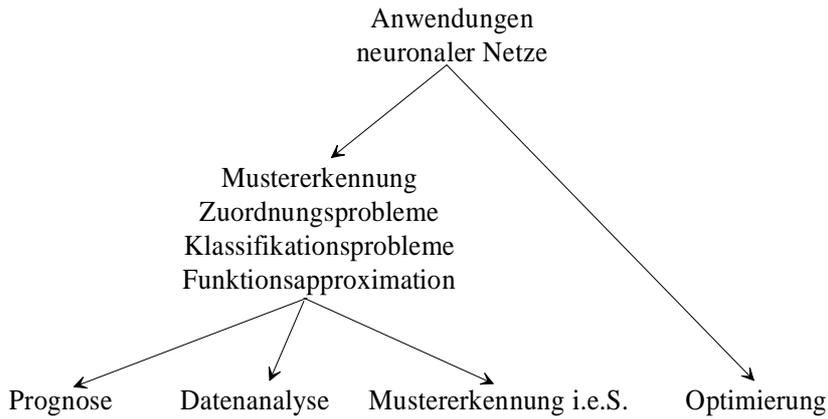


Abb. 8: Hierarchisches Klassifikationsschema für Anwendungen neuronaler Netze

7 Zusammenfassung

Der vorliegende Arbeitsbericht entstand als Ergebnis einer Literaturrecherche über betriebliche Anwendungen neuronaler Netze und aufgrund eigener Erfahrungen bei der Entwicklung neuronaler Netze. Die vorgestellten Anwendungen entstammen den Bereichen Finanz-, Absatz- und Produktionswirtschaft. Innerhalb des Arbeitsberichtes wurden sie nach Prognose, Datenanalyse, Mustererkennung i.e.S. und Optimierung geordnet. Eine genauere Betrachtung der den Anwendungen zugrundeliegenden Verfahren und eine Abstraktion von der Struktur der zugrundeliegenden (Trainings-) Daten ergab eine Zusammenfassung der drei erstgenannten Anwendungsgruppen zu einer einzigen Gruppe.

Allgemein kann gesagt werden, daß sich Anwendungen neuronaler Netze häufig in solchen Problembereichen etablieren, in denen eine algorithmische Formulierung der Problemlösungsfähigkeit schwierig oder sogar unmöglich ist, wie die Beispiele und Ausführungen aus dem Bereich der Prognose, Datenanalyse und Mustererkennung i.e.S. zeigen. Ebenfalls sehr deutlich wird dies bei den Anwendungen aus dem Bereich der Optimierung. Für die Anwendungen wird lediglich formuliert, wie die Güte einer Lösung ermittelt wird, nicht jedoch wie eine Lösung verbessert werden kann.

Literatur

- Aarts, E.H.L., Korst, H.M.: Boltzmann Machines and Their Applications; Parallel architectures and languages Europe; London, Paris (1987), S. 34-50.
- von Altrock, C.: Über den Daumen gepeilt: Fuzzy Logic - scharfe Theorie der unscharfen Mengen; c't (1991) 3, S. 188-206.
- Becker, J., Prischmann, M.: Supporting the design process with Neural Networks - A complex application of cooperating Neural Networks and its implementation; Journal of Information Science and Technology 3 (1993) 1.
- Beth, T.: Verfahren der schnellen Fourier-Transformation: die allgemeine diskrete Fourier-Transformation, ihre algebraische Beschreibung, Komplexität und Implementierung; Stuttgart 1984.
- Bierwirth, Ch., Kopfer, H., Mattfeld, D., Utecht, Th.: Genetische Algorithmen und das Problem der Maschinenbelegung - eine Übersicht und ein neuer Ansatz; Fachbericht des Lehrstuhls für Logistik der Universität Bremen, Bremen 1993.
- Bischoff, R., Bleile, C., Graalfs, J.: Der Einsatz Neuronaler Netze zur betriebswirtschaftlichen Kennzahlenanalyse; Wirtschaftsinformatik 33 (1991) 5, S. 375-385.
- Breuker, J., Büttel-Dietsch, I., Kohl, A., Mertens, P., Ponader, M.: Wissensbasierte Finanzierungsberatung; Geldinstitute (1990) 11, S. 30-34.
- de Groot, C., Würtz, D.: Analysis of univariate time series with connectionist nets: A case study of two classical examples; Neurocomputing (1991) 3, S. 177-192.
- Dorffner, G.: Konnektionismus: von neuronalen Netzwerken zu einer "natürlichen KI"; Stuttgart 1991.
- Durbin, R., Willshaw, D.: An Analogue Approach to the Travelling Salesman Problem Using an Elastic Net Method; Nature (1987) 326, S. 689-691.
- Erxleben, K., Baetge, J., Feidicker, M., Koch, H., Krause, C., Mertens, P.: Klassifikation von Unternehmen: Ein Vergleich von Neuronalen Netzen und Diskriminanzanalyse; ZfB 62 (1992) 11, S. 1237-1262.
- Fischer, B.: Ein Werkzeug zur auftragsbezogenen Generierung von Fuzzy Petri-Netz Modellen einer Fertigungssteuerung; VDI Bericht 1035 (1993), S. 91-108.
- Fritzke, B., Wilke, P.: FLEXMAP - A Neural Network For The Traveling Salesman Problem With Linear Time And Space Complexity; in: Neuroprose - a machine readable repository 1992.
- Fukushima, K.: Character recognition with neural networks; Neurocomputing, (1992) 4, S. 221-233.
- Günter, R., Toggweiler, J.: Ein Fuzzy Ansatz für die operative Führung eines Montagebandes im Fahrzeugbau; VDI-Berichte 1035, 1993, S. 73-89.
- Haruki, K., Hatano, H.: Pattern Recognition of Handwritten Phonetic Japanese Alphabet Characters; in: Caudill, M. (Ed.): International Joint Conference on Neural Networks, Volume II, Washington, DC 1990, S. 515-518.

- Hecht-Nielsen, R.: Theory of the Backpropagation Neural Network; in: Caudill, M. (Ed.): International Joint Conference on Neural Networks, Volume I, Washington, DC 1990, S. 593-601.
- Hertz, J., Krogh, A., Palmer, R.G.: Introduction to the theory of neural computations; Redwood City, CA, 1991.
- Hopfield, J. J., Tank, D. W.: Neural Computation of Decisions in Optimization Problems; Biological Cybernetics (1985) 52, S. 147-152.
- Hopfield, J. J.: Neural Networks and Physical Systems with Emergent Collective Computational Abilities; in: Proceedings of the National Academy of Science (USA) (1982) 79, S. 2254-2258.
- Hruschka, H., Natter, M.: Analyse von Marktsegmenten mit Hilfe konnexionistischer Modelle; ZfB 63 (1993) 5, S. 425-442.
- Kalefeld, K.: Expertensystem im flächendeckenden Einsatz; Geldinstitute (1991) 2, S. 24-27.
- Kemke, C.: Der neuere Konnektionismus, Ein Überblick; Informatik Spektrum 11 (1988) 3, S. 143-162.
- Klitscher, C.: OCR mit neuronalen Netzwerken; in: Schöneburg, E. (Hrsg): Industrielle Anwendungen Neuronaler Netze; Bonn, Paris u.a. 1993, S. 75-88.
- Kohonen, T.: Self-Organized Formation of Topologically Correct Feature Maps; Biological Cybernetics (1982) 43, S. 59-69.
- Kohonen, T.: Self-Organization and Associative Memory; Berlin u.a. (1984).
- Krallmann, H.: Modellierung informationstechnischer Anforderungen bei Banken; Geldinstitute (1990) 9, S. 35-38.
- Kühn, M.: Gewagte Geschäfte: Neuronale Netze an der Börse; c't (1991) 12, S. 62-66.
- Kurbel, K.: Maschinenbelegungsplanung auf Basis neuronaler Netze - ein Vergleich mit konventionellen Verfahren; erscheint in: Wagner, H. (Hrsg.): Betriebswirtschaftslehre und Unternehmensforschung, Wiesbaden 1994.
- Lapedes, A.S., Farber, R.M.: Nonlinear Signal Processing using Neural Networks; Technical Report, Los Alamos 1987.
- Lawrence, J.: Neuronale Netze - Computersimulation biologischer Intelligenz; München 1992.
- Lipp, H.-P.: Eine operative Montagesteuerung auf der Grundlage von zeitbewerten Fuzzy Petri-Netzen; Wissenschaftliche Schriftreihe der TU Chemnitz 33 (1991) 6, S. 835-842.
- Lutz, J., Schmid-Lutz, V.: Getriebediagnose mit Neuronalen Netzen; in: Schöneburg, E. (Hrsg): Industrielle Anwendungen Neuronaler Netze; Bonn, Paris u.a. (1993), S. 43-56.
- Lutz, J.: Motor-Diagnose mit Neuronalen Netzen, in: Schöneburg; E. (Hrsg): Industrielle Anwendungen Neuronaler Netze; Bonn, Paris u.a. (1993), S. 29-40.

- Mertens, P.: Integrierte Informationsverarbeitung, Bd. 1: Administrations- und Dispositionssysteme in der Industrie; 8. Aufl. Wiesbaden 1991.
- Michalski, R.S.: A Theory and Methodology of Inductive Learning; in: Michalski, R.S., Carbonell, J.G., Mitchell, T.M. (Eds.): Machine Learning: An Artificial Intelligence Approach; Los Altos 1983, S. 83-133.
- Nakano, R., Yamada, T.: Conventional Genetic Algorithms for Job Shop Problems; in: Belew, R., Booker, L. (Eds.): International Joint Conference on Genetic Algorithms and their Applications; San Mateo 1991, S. 474-479.
- Nickel, W.: Ein wissensbasiertes System zur Produktionsplanung und -steuerung in der Papierindustrie; Düsseldorf 1990.
- o. V.: Belege erkennen, lesen und verarbeiten: Bald jede Schrift lesbar?; Geldinstitute (1991) 4, S. 24.
- o. V.: Neuronales Netz sagt Zinsentwicklung voraus; Geldinstitute (1992) 6, S. 100.
- Pietsch, W., Teubner, A.: Konnektionistische Tourenplanung für die dezentrale Vertriebsaußendienststeuerung; in: Gaul, W., Bachem, A., Habenicht, W., Runge, W., Stahl, W.W. (Hrsg.): Operations Research Proceeding 1991, Berlin u.a. 1992, S. 346-353.
- Pintaske, J.: Neuronale Netze in der Praxis: Bonitätsprüfung - Subjektive Gratwanderung?; Geldinstitute (1991) 11, S. 14-18.
- Quinlan, J.R.: Learning efficient classification procedure and their application to chess end games; in: Michalski, R.S., Carbonell, J.G., Mitchell, T.M. (Eds.): Machine Learning: An Artificial Intelligence Approach; Los Altos 1983, S. 463-482.
- Reichmann, Th., Lachnit, L.: Planung , Steuerung und Kontrolle mit Hilfe von Kennzahlen; ZfbF 28 (1976), S. 705-723.
- Reichmann, Th.: Controlling mit Kennzahlen: Grundlagen einer systemgestützten Controlling-Konzeption; 2., verb. Auflage, München 1990.
- Rehkugler, H., Poddig, T.: Künstliche Neuronale Netze in der Finanzanalyse: Eine neue Ära der Kursprognosen?; in: Wirtschaftsinformatik 33 (1991) 5, S. 365-374.
- Rehkugler, H., Poddig, T.: Statistische Methoden versus Künstliche Neuronale Netzwerke zur Aktienkursprognose; Bamberger betriebswirtschaftliche Beiträge (1990) 73, Otto-Friedrich-Universität Bamberg.
- Ruppel, A., Siedentopf, J.: Konnektionistisch motivierte Reihenfolgeplanung in Fertigungsleitständen; in: Görke, W., Rininsland, H., Syrbe, M. (Hrsg.): Information als Produktionsfaktor, Berlin u.a. 1992, S. 554-563.
- Sarnow, K.: Schrifterkennung mit neuronalen Netzen; c ' t (1990) 4, S. 218-236.
- Schmid-Lutz, V., Schöneburg, E.: Ein hybrides Diagnosesystem; in: Schöneburg, E. (Hrsg.): Industrielle Anwendungen Neuronaler Netze; Bonn, Paris u.a. 1993, S. 57-73.

- Schöneburg, E., Straub, R.: Zeitreihenanalyse und -prognose; in: Schöneburg, E. (Hrsg.): Industrielle Anwendungen Neuronaler Netze; Bonn, Paris u.a. 1993, S. 247-281.
- Schöneburg, E.: Aktienkursprognosen mit neuronalen Netzen; HMD 28 (1991) 159, S. 43-59.
- Schreiber, S.B.: Ein Computer lernt buchstabieren: Mustererkennung mittels Matrixgedächtnis; c't (1988) 7, S. 114-125.
- Steiner, M., Wittkemper, H.-G.: Neuronale Netze: Ein Hilfsmittel für betriebswirtschaftliche Probleme; DBW 53 (1993) 4, S. 447-463.
- Takefuji, Y.: Neural Network Parallel Computing; Boston et al. 1992.
- Tveter, D.: Getting a fast break with Backprop; AI Expert (1991) July, S. 36-43.
- Ultsch, A. (Hrsg): Kopplung deklarativer und konnektionistischer Wissensrepräsentation; Forschungsbericht Nr. 352, Institut für Informatik, Universität Dortmund, Dortmund 1990.
- Verweyen-Frank, H., Teschers, A.: Elektromotoren auf dem Prüfstand: Qualitätsprüfung und -sicherung mit künstlichen neuronalen Netzen; Zwf 87 (1992) 11, S. 618-621.
- Weigend, A.S., Huberman, B.A., Rumelhart, D.E.; Predicting the Future, a Connectionist Approach; Stanford University, Standford 1990.
- White, H.: Economic prediction using neural networks: the case study of IBM daily stocks returns; in: Anderson, J., Pellionisz, A., Rosenfeld, E. (Eds.): Neurocomputing 2: Directions of Research, Boston 1990, S. 669-675.
- Wilbert, R.: Kreditwürdigkeitsanalyse im Konsumentenkreditgeschäft auf der Basis Neuronaler Netze; ZfB 61 (1991) 12, S. 1377-1393.
- Wong, F., Tan, Y.: Neural Networks And Genetic Algorithm For Economic Forecasting; in: Neuroprose - a machine readable repository 1992.
- Xu, X., Tsai, W. T.: An Adaptive Neural Algorithm for Travelling Salesman Problem; in: Caudill, M. (Ed.): International Joint Conference on Neural Networks, Volume II, Washington, DC 1990, S. 716-719.
- Zhu, X.-Y. Yamauchi, K., Jimbo, T., Umeno, M.: Feature Detector and Application to Handwritten Character Recognition; in: Caudill, M. (Ed.): International Joint Conference on Neural Networks, Volume II, Washington, DC 1990, S. 457-460.
- Zimmermann, H. G.: Neue Wege zum Wissen: Neuronale Netzwerke; Geldinstitute (1991) 11, S. 6-13.
- Zimmermann, H.-J. (Hrsg.): Fuzzy-Technologien - Prinzipien, Werkzeuge, Potentiale; Düsseldorf 1993.

Arbeitsberichte des Instituts für Wirtschaftsinformatik

- Nr. 1 Bolte, Ch., Kurbel, K., Moazzami, M., Pietsch, W.: Erfahrungen bei der Entwicklung eines Informationssystems auf RDBMS- und 4GL-Basis; Februar 1991.
- Nr. 2 Kurbel, K.: Das technologische Umfeld der Informationsverarbeitung - Ein subjektiver 'State of the Art'-Report über Hardware, Software und Paradigmen; März 1991.
- Nr. 3 Kurbel, K.: CA-Techniken und CIM; Mai 1991.
- Nr. 4 Nietsch, M., Nietsch, T., Rautenstrauch, C., Rinschede, M., Siedentopf, J.: Anforderungen mittelständischer Industriebetriebe an einen elektronischen Leitstand - Ergebnisse einer Untersuchung bei zwölf Unternehmen; Juli 1991.
- Nr. 5 Becker, J., Prischmann, M.: Konnektionistische Modelle - Grundlagen und Konzepte; September 1991.
- Nr. 6 Grob, H.L.: Ein produktivitätsorientierter Ansatz zur Evaluierung von Beratungserfolgen; September 1991.
- Nr. 7 Becker, J.: CIM und Logistik; Oktober 1991.
- Nr. 8 Burgholz, M., Kurbel, K., Nietsch, Th., Rautenstrauch, C.: Erfahrungen bei der Entwicklung und Portierung eines elektronischen Leitstands; Januar 1992.
- Nr. 9 Becker, J., Prischmann, M.: Anwendung konnektionistischer Systeme; Februar 1992.
- Nr. 10 Becker, J.: Computer Integrated Manufacturing aus Sicht der Betriebswirtschaftslehre und der Wirtschaftsinformatik; April 1992.
- Nr. 11 Kurbel, K., Dornhoff, P.: A System for Case-Based Effort Estimation for Software-Development Projects; Juli 1992.1
- Nr. 12 Dornhoff, P.: Aufwandsplanung zur Unterstützung des Managements von Softwareentwicklungsprojekten; August 1992.
- Nr. 13 Eicker, S., Schnieder, T.: Reengineering; August 1992.
- Nr. 14 Erkelenz, F.: KVD2 - Ein integriertes wissensbasiertes Modul zur Bemessung von Krankenhausverweildauern - Problemstellung, Konzeption und Realisierung; Dezember 1992.
- Nr. 15 Horster, B., Schneider, B., Siedentopf, J.: Kriterien zur Auswahl konnektionistischer Verfahren für betriebliche Probleme; März 1993.
- Nr. 16 Jung, R.: Wirtschaftlichkeitsfaktoren beim integrationsorientierten Reengineering: Verteilungsarchitektur und Integrationschritte aus ökonomischer Sicht; Juli 1993.
- Nr. 17 Miller, C., Weiland, R.: Der Übergang von proprietären zu offenen Systemen aus Sicht der Transaktionskostentheorie; Juli 1993.
- Nr. 18 Becker, J., Rosemann, M.: Design for Logistics - Ein Beispiel für die logistikgerechte Gestaltung des Computer Integrated Manufacturing; Juli 1993.
- Nr. 19 Becker, J., Rosemann, M.: Informationswirtschaftliche Integrationsschwerpunkte innerhalb der logistischen Subsysteme - Ein Beitrag zu einem produktionsübergreifenden Verständnis von CIM; Juli 1993.
- Nr. 20 Becker, J.: Neue Verfahren der entwurfs- und konstruktionsbegleitenden Kalkulation und ihre Grenzen in der praktischen Anwendung; Juli 1993.
- Nr. 21 Becker, K., Prischmann, M.: VESKONN - Prototypische Umsetzung eines modularen Konzepts zur Konstruktionsunterstützung mit konnektionistischen Methoden; November 1993

Nr. 22 Schneider, B.: Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme; November 1993.