

LEHRSTUHL FÜR
ALLG. BWL UND WIRTSCHAFTSINFORMATIK
UNIV.-PROF. DR. HERBERT KARGL

Strecker, Stefan; Schwickert, Axel C.

Künstliche Neuronale Netze

***Einordnung, Klassifikation
und Abgrenzung aus
betriebswirtschaftlicher Sicht***

ARBEITSPAPIERE WI
Nr. 4/1997

Schriftleitung:
Dr. rer. pol. Axel C. Schwickert

Information

- Reihe:** Arbeitspapiere WI
- Herausgeber:** Univ.-Prof. Dr. Axel C. Schwickert
Professur für BWL und Wirtschaftsinformatik
Justus-Liebig-Universität Gießen
Fachbereich Wirtschaftswissenschaften
Licher Straße 70
D – 35394 Gießen
Telefon (0 64 1) 99-22611
Telefax (0 64 1) 99-22619
eMail: Axel.Schwickert@wirtschaft.uni-giessen.de
<http://wi.uni-giessen.de>
- Bis Ende des Jahres 2000 lag die Herausgeberschaft bei:
- Lehrstuhl für Allg. BWL und Wirtschaftsinformatik
Johannes Gutenberg-Universität Mainz
Fachbereich Rechts- und Wirtschaftswissenschaften
Welderweg 9
D - 55099 Mainz
- Ziele:** Die Arbeitspapiere dieser Reihe sollen konsistente Überblicke zu den Grundlagen der Wirtschaftsinformatik geben und sich mit speziellen Themenbereichen tiefergehend befassen. Ziel ist die verständliche Vermittlung theoretischer Grundlagen und deren Transfer in praxisorientiertes Wissen.
- Zielgruppen:** Als Zielgruppen sehen wir Forschende, Lehrende und Lernende in der Disziplin Wirtschaftsinformatik sowie das IuK-Management und Praktiker in Unternehmen.
- Quellen:** Die Arbeitspapiere entstanden aus Forschungsarbeiten, Diplom-, Studien- und Projektarbeiten sowie Begleitmaterialien zu Lehr- und Vortragsveranstaltungen des Lehrstuhls für Allg. Betriebswirtschaftslehre und Wirtschaftsinformatik Univ. Prof. Dr. Herbert Kargl an der Johannes Gutenberg-Universität Mainz.
- Hinweise:** Wir nehmen Ihre Anregungen und Kritik zu den Arbeitspapieren aufmerksam zur Kenntnis und werden uns auf Wunsch mit Ihnen in Verbindung setzen.
Falls Sie selbst ein Arbeitspapier in der Reihe veröffentlichen möchten, nehmen Sie bitte mit dem Herausgeber (Gießen) unter obiger Adresse Kontakt auf.
Informationen über die bisher erschienenen Arbeitspapiere dieser Reihe und deren Bezug erhalten Sie auf dem Schlußblatt eines jeden Arbeitspapiers und auf der Web Site des Lehrstuhls unter der Adresse <http://wi.uni-giessen.de>

Arbeitspapiere WI Nr. 4/1997

- Autoren:** Strecker, Stefan; Schwickert, Axel C.
- Titel:** Künstliche Neuronale Netze – Einordnung, Klassifikation und Abgrenzung aus betriebswirtschaftlicher Sicht
- Zitation:** Strecker, Stefan; Schwickert, Axel C.: Künstliche Neuronale Netze – Einordnung, Klassifikation und Abgrenzung aus betriebswirtschaftlicher Sicht, in: Arbeitspapiere WI, Nr. 4/1997, Hrsg.: Lehrstuhl für Allg. BWL und Wirtschaftsinformatik, Johannes Gutenberg-Universität: Mainz 1997.
- Kurzfassung:** In den letzten Jahren ist das Interesse an neuen betriebswirtschaftlichen Problemlösungsverfahren enorm gestiegen. Herkömmliche Verfahren aus dem Operations Research (OR) und der Statistik bieten angesichts hochkomplexer Probleme oft nur unbefriedigende Ergebnisse. Verfahren aus dem Forschungsgebiet der Künstlichen Intelligenz dringen zunehmend in betriebswirtschaftliche Problemstellungen vor. Künstliche Neuronale Netze (KNN) stellen „intelligente“ Problemlösungsverfahren dar, die sich besonders für nicht-konservative Aufgabenstellungen eignen, bei denen kein exaktes Modell der Ursache-Wirkungszusammenhänge vorliegt. Die Verfahren zeichnen sich durch eine breite Anwendbarkeit in betrieblichen Aufgabengebieten aus. Das vorliegende Arbeitspapier soll eine grundlegende Einordnung und Klassifikation von KNN vornehmen und damit einen Einstieg in die Thematik ermöglichen. Zunächst werden KNN als intelligente Informationssysteme im wissenschaftlichen Umfeld der Kognitionswissenschaften, des Konnektionismus und der Künstlichen Intelligenz positioniert. Nach der Darstellung des historischen Hintergrundes werden KNN aufgrund ihrer immanenten Eigenschaften und betriebswirtschaftlichen Anwendungsbereichen klassifiziert, um sodann mit der Beschreibung anderer potentieller Verfahren für Intelligente Informationssysteme der wissenschaftlich-begrifflichen Einordnung von KNN eine inhaltliche Abgrenzung hinzuzufügen.
- Schlüsselwörter:** Künstliche Neuronale Netze, Kognitionswissenschaften, Konnektionismus, Künstliche Intelligenz, Intelligente Informationssysteme, Expertensysteme, Fuzzy Logic, Evolutionäre Algorithmen

Inhaltsverzeichnis

1	Ziel und Aufbau.....	3
2	Eine wissenschaftliche Positionierung von KNN.....	3
2.1	KNN als konnektionistische Systeme	3
2.2	KNN im subsymbolischen KI-Paradigma	5
2.3	KNN für Intelligente Informationssysteme	7
3	Historischer Hintergrund von KNN	9
4	Zur Klassifikation von KNN.....	12
4.1	Klassifikation als Orientierungshilfe.....	12
4.2	Klassifikation nach Eigenschaften von KNN.....	14
4.3	Klassifikation von KNN aus betriebswirtschaftlicher Sicht.....	16
	- Optimierung	16
	- Prognose.....	18
	- Prüfung und Beurteilung.....	18
	- Steuerung und Regelung	19
5	Abgrenzung KNN zu anderen intelligenten Verfahren	21
5.1	Expertensysteme (XPS).....	21
5.2	Fuzzy Logic	23
5.3	Evolutionäre Algorithmen (EA).....	25
6	Entwicklungstendenzen Intelligenter Informationssysteme.....	26
	Literaturverzeichnis.....	27

1 Ziel und Aufbau

In den letzten Jahren ist das Interesse an neuen betriebswirtschaftlichen Problemlösungsverfahren enorm gestiegen. Herkömmliche Verfahren aus dem Operations Research (OR) und der Statistik bieten angesichts hochkomplexer Probleme oft nur unbefriedigende Ergebnisse. Verfahren aus dem Forschungsgebiet der Künstlichen Intelligenz dringen zunehmend in betriebswirtschaftliche Problemstellungen vor. Künstliche Neuronale Netze (KNN) stellen „intelligente“ Problemlösungsverfahren dar, die sich besonders für nicht-konservative Aufgabenstellungen eignen, bei denen kein exaktes Modell der Ursache-Wirkungszusammenhänge vorliegt. Die Verfahren zeichnen sich durch eine breite Anwendbarkeit in betrieblichen Aufgabengebieten aus. Auch wenn KNN i. d. R. heuristischen Charakter besitzen, lassen sich mit ihrer Hilfe oftmals bessere Ergebnisse erzielen als mit herkömmlichen Verfahren.

Die vorliegende Arbeit soll eine grundlegende Einordnung und Klassifikation von KNN vornehmen und damit einen Einstieg in die Thematik ermöglichen. Zunächst werden KNN als intelligente Informationssysteme im wissenschaftlichen Umfeld der Kognitionswissenschaften, des Konnektionismus und der Künstlichen Intelligenz (Abschnitt 2) positioniert. Nach der Darstellung des historischen Hintergrundes (Abschnitt 3) werden KNN aufgrund ihrer immanenten Eigenschaften und betriebswirtschaftlichen Anwendungsbereichen klassifiziert (Abschnitt 4), um sodann mit der Beschreibung potentieller Verfahren für Intelligente Informationssysteme (Abschnitt 5) der wissenschaftlich-begrifflichen Einordnung von KNN eine inhaltliche Abgrenzung hinzuzufügen.

Wesentliches Ziel des Arbeitspapiers ist es, die notwendigen Informationen in einer sinnvollen Verdichtung zu präsentieren. Der interessierte Leser sei auf das Literaturverzeichnis verwiesen, in dem die entsprechenden weiterführenden Quellen angegeben sind. Außerdem befinden sich unter dem Stichwort „Neural Networks and other intelligent systems“ eine Reihe von Verweisen auf Online-Ressourcen im World Wide Web unter der URL <http://wi.bwl.uni-mainz.de/~strecker/bookmark.htm>

2 Eine wissenschaftliche Positionierung von KNN

2.1 KNN als konnektionistische Systeme

Der Oberbegriff "Kognitionswissenschaften" (Cognitive Sciences) umfaßt ursprünglich und im wesentlichen die wissenschaftlichen Disziplinen der Neurologie, Neurophysiologie, Biologie, Psychologie, und Philosophie. Die rasanten Fortschritte der Informatik in den letzten Jahrzehnten tragen dazu bei, daß auch Teilgebiete dieser Disziplin den Kognitionswissenschaften zugeordnet werden. Die einzelnen Kognitionswissenschaften setzen sich vorrangig aus ihrer jeweils eigenen wissenschaftlichen Sicht mit der Modellierung und Erforschung kognitiver Prozesse auseinander. Kognitive Prozesse sind Lei-

stungen des menschlichen Gehirns ausgehend von Sinneswahrnehmungen wie z. B. das Bilden von Assoziationen oder Leistungen der Mustererkennung.¹

Im Mittelpunkt der Kognitionswissenschaften stehen die natürlichen Intelligenzleistungen des Menschen. Daneben werden "Neurowissenschaften" (Neurosciences) als weitgefächter Sammelbegriff für alle Disziplinen verstanden, die sich an der Struktur und Funktion von Nervennetzen lebender Organismen, speziell des menschlichen Gehirns widmen. Aufgrund zahlreicher Parallelen und Überschneidungen sollen die Begriffe "Kognitionswissenschaften" und "Neurowissenschaften" hier als Synonyme betrachtet werden.

Der Begriff "Konnektionismus" bezeichnet ein interdisziplinäres Forschungsgebiet der einzelnen Kognitionswissenschaften. Kognitive Prozesse werden hier durch die Kombination verschiedener Wissenschaftsdisziplinen in konnektionistischen Systemen erforscht. Konnektionistische Systeme werden aus der Analyse biologischer neuronaler Netze, insbesondere des menschlichen Gehirns, entwickelt. Das biologische neuronale Netz "Gehirn" besteht aus bis zu 100 Milliarden vernetzten Neuronen. Jede dieser Nervenzellen verfügt durchschnittlich über 10.000 Ein- und Ausgänge, so daß sich bis zu 1.000 Billionen Neuronen-Verbindungen ergeben. Neuronen kommunizieren untereinander über elektrisch induzierte biochemische Neurotransmitter; die Gesamtheit dieser Signale an mehreren Tausend Eingängen eines Neurons determiniert einen der beiden Zustände ("aktiv", "inaktiv"), die ein Neuron annehmen und über seine Ausgänge wiederum verbundenen Neuronen als deren Zustandsdeterminanten (aktionsfördernd oder aktionshemmend) mitteilen kann. Die Geschwindigkeit der Neuronen bei der Verarbeitung ihrer Signale ist technisch gesehen um ein Vielfaches geringer (ca. 1.000fach) als die auf den Chips moderner Computer. Dennoch sind bei (den meisten) Menschen relative geringe Antwortzeiten z. B. beim Abruf gespeicherten Wissens die Regel, was auf eine flächendeckende massiv-parallele Verarbeitungsorganisation des Gehirns zurückgeführt wird. Ein Kennzeichen konnektionistischer Systeme ist demnach die hochgradig parallele Informationsverarbeitung durch Verbindung vieler einfacher, identischer Verarbeitungselemente zur Modellierung kognitiver Prozesse.²

Das Ziel konnektionistischer Modelle ist es, die Struktur- und Funktionsprinzipien des menschlichen Gehirns abzubilden und damit dessen technische Nachbildung in künstlichen neuronalen Netzen zu ermöglichen. Besonders aus Sicht der Informatik sind daher "Künstliche neuronale Netzwerke" den konnektionistischen Systemen zuzuordnen. Der in diesem Zusammenhang anzutreffende Begriff "Neurocomputing" stellt besonders die Lernfähigkeit und damit Adaptivität neuronaler Netze der Programmierung konventioneller Informationssysteme gegenüber.³ Die Begriffe "Konnektionismus" und "Künstliche neuronale Netzwerke" (KNN) unterscheiden sich demzufolge lediglich durch verschiedene Blickwinkel auf das gleiche Betrachtungsfeld. Der Konnektionismus liefert

1 Becker, J.; Prischmann, M.: Konnektionistische Modelle - Grundlagen und Anwendungen, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 5, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., September 1991, S. 3.

2 Vgl. Kemke, C.: Der neuere Konnektionismus, in: Informatik Spektrum, 11/1988, S. 144.

3 Vgl. Hecht-Nielsen, R.: Neurocomputing, Reading, MA et al.: Addison-Wesley 1990, S. 12.

die kognitionswissenschaftlichen, modelltheoretischen Grundlagen für Künstliche Neuronale Netzwerke als technische Konkretisierungen konnektionistischer Modelle.⁴ Der Informationsaustausch zwischen den beteiligten Wissenschaftsdisziplinen vollzieht sich dabei wechselseitig. Die Erkenntnisse über biologische neuronale Netze geben Impulse für die Entwicklung von KNN, die (Simulations-) Ergebnisse realisierter konnektionistischer Systeme lassen Rückschlüsse auf die tatsächliche Informationsverarbeitung im menschlichen Gehirn zu.

2.2 KNN im subsymbolischen KI-Paradigma

Die KI umfaßt Methoden und Techniken der Informatik, mit denen bestimmte abstrakte Aspekte intelligenter menschlicher Erkenntnis-, Lern-, Sprach- und Denkprozesse auf Computern nachgebildet werden können. Ziel ist es, mit Hilfe von Computern Probleme zu lösen, die Intelligenzleistungen voraussetzen. Mit der Herleitung aus Abschnitt 2.1 lassen sich KNN dem Bereich der "Künstlichen Intelligenz" (KI, englisch AI = Artificial Intelligence) in der Informatik zuordnen. In der KI herrschen zwei Paradigmen vor: das symbolische und das subsymbolischen Paradigma.⁵

Die klassische Künstliche Intelligenz modelliert die Objekte der realen Welt mit Hilfe von Symbolen; Abhängigkeiten zwischen den Objekten werden mittels formaler Regeln dargestellt. Die Entscheidungsfindung (Inferenz) basiert auf der Ableitung von Lösungen durch Manipulation der Symbole anhand von Regeln. Dabei muß zur Beschreibung der realen Welt ein Modell formuliert werden, in dem die funktionalen Zusammenhänge explizit und vorab festgelegt sind. Dabei wird Wissen verarbeitet, ohne Rücksicht auf diejenigen Mechanismen zu nehmen, die dieses Wissen erzeugen.⁶ Dieser Ansatz wird als symbolisches Paradigma der Künstliche Intelligenz bezeichnet. Regelbasierte Expertensysteme sind typische Vertreter der symbolischen Künstlichen Intelligenz.

Das subsymbolische Paradigma nimmt dagegen biologische Vorbilder zum Anlaß, Probleme der realen Welt nicht durch Ex-ante-Analyse und fixierte Modelle zu beschreiben, sondern durch konnektionistische Modelle selbst lösen zu lassen. Die Wissensrepräsentation realer Objekte findet nicht durch einzelne komplexe Entitäten, sondern durch eine Gesamtheit einfacher Verarbeitungselemente statt (verteilte Repräsentation).⁷ Funktionale Zusammenhänge und Faktenwissen werden nicht durch ein explizites Regelwerk, sondern implizit durch den Zustand der Verarbeitungselemente und Verbin-

4 Vgl. Becker, J.; Prischmann, M.: Konnektionistische Modelle - Grundlagen und Anwendungen, a. a. O., S. 3.

5 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, Reading, MA et al.: Addison-Wesley 1995, S. 81 und Kratzer, K.-P.: Neuronale Netze - Grundlagen und Anwendungen, 2., durchges. Aufl., München et al.: Hanser 1993, S. 6.

6 Vgl. Caudill, M.; Butler, C.: Naturally Intelligent Systems, Cambridge, MA: MIT Press 1990, S. 26.

7 Vgl. Niedereichholz, J.; Kruse, H.; Mechler, B.: Kombination symbolischer und subsymbolischer Systeme in Entscheidungsunterstützungssystemen, in: Wirtschaftsinformatik: Beiträge zur modernen Unternehmensführung; Festschrift zum 60. Geburtstag von Franz Steffens, Hrsg: Niedereichholz, J.; Schumann, W., Frankfurt am Main et al.: Campus 1993, S. 105.

dungsgewichte eines konnektionistischen Systems beschrieben.⁸ In konnektionistischen Systemen sind Fakten und Regeln daher nicht einzelnen Verarbeitungseinheiten und Verbindungsgewichten persistent zuzuordnen.⁹ KNN sind typische Vertreter der subsymbolischen Künstlichen Intelligenz.

Die genannten Paradigmen beschreiben zwei unterschiedliche Abstraktionsebenen der Wissensverarbeitung in der Künstlichen Intelligenz. Beide sind daher als alternative Ansätze nebeneinander zu sehen, die für jeweils eigene Aufgabengebiete geeignet sind. Die symbolische Wissensverarbeitung löst z. B. Diagnose- und Planungsaufgaben auf hoher Abstraktionsebene, während die subsymbolische Verarbeitung Aufgaben niedrigerer Abstraktion wie z. B. Sprachverarbeitung und Mustererkennung übernimmt.¹⁰

Die Mustererkennung (Pattern Recognition) wird in enger Verbindung zum Konnektionismus häufig als eigenständiges Forschungsfeld innerhalb der Künstlichen Intelligenz gesehen. Wie der Konnektionismus ist auch die Mustererkennung durch die Verarbeitungsleistung des Gehirns bei kognitiven Prozessen initiiert und interdisziplinär entwickelt worden. Da viele kognitive Prozesse Mustererkennungsaufgaben sind (z. B. die Bilderkennung aufgrund visueller Wahrnehmung), ergeben sich zwischen konnektionistischen Systemen und Verfahren der Mustererkennung Überschneidungen immer dann, wenn Künstliche Neuronale Netze zum Zweck der Mustererkennung eingesetzt werden. Bestimmte KNN zählen daher zu den Verfahren der Mustererkennung.¹¹ Bei der Mustererkennung kommen neben konnektionistischen Modellen auch Verfahren der symbolischen Künstlichen Intelligenz und der Statistik zur Anwendung.¹² Methodisch existieren Parallelen zwischen Konnektionismus und Mustererkennung. Beide Gebiete benutzen lernfähige Verfahren und dabei teilweise identische Lernparadigmen, u. a. überwachtes und selbständiges Lernen aus Beispielen.¹³

Bei der Mustererkennung im betriebswirtschaftlichen Bereich wird von kognitiven Vorgängen abstrahiert und ein Muster als Kombination von Merkmalen interpretiert. Mustererkennungsaufgaben setzen immer ein Klassifikationsproblem voraus. Ein Muster wird dann durch Merkmalsausprägungen beschrieben, die in einem bestimmten funktionalen Zusammenhang miteinander stehen.

8 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 82.

9 Vgl. Kemke, C.: Der neuere Konnektionismus, a. a. O., S. 146.

10 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 82.

11 Vgl. Krause, C.: Kreditwürdigkeitsprüfung mit Neuronalen Netzen, Düsseldorf: IDW 1993, S. 13.

12 Vgl. Mertens, P.: Die Theorie der Mustererkennung in den Wirtschaftswissenschaften, in: Schmalenbachs Zeitschrift für Betriebswirtschaftliche Forschung, 29/1977, S. 782 und Pao, Y.-H.: Adaptive pattern recognition and neural networks, Reading, MA et al.: Addison-Wesley 1989, S. 16.

13 Vgl. Mertens, P.: Die Theorie der Mustererkennung in den Wirtschaftswissenschaften, a. a. O., S. 779ff.

2.3 KNN für Intelligente Informationssysteme

Neben der Erforschung biologischer Vorgänge beginnen konnektionistische Modelle als universelle Problemlösungsverfahren andere Aufgabenbereiche zu erobern.¹⁴ Im Bereich der Betriebswirtschaft abstrahiert man vollkommen von biologischen Grundlagen und versteht konnektionistische Modelle als Alternativen zu bekannten Verfahren für komplexe, nicht-konservative Probleme.¹⁵ Diese Probleme zeichnen sich durch unbekannte Ursache-Wirkungs-Zusammenhänge aus. Lösungsmodelle sind deshalb explizit nicht modellierbar und die klassischen Lösungsverfahren z. B. aus dem Operations Research (OR) und der symbolischen Künstlichen Intelligenz erzielen oftmals nur unbefriedigende Ergebnisse.¹⁶

Aus betriebswirtschaftlicher Sicht wird daher nach Informationssystemen geforscht, die mit eigenen Intelligenzleistungen zur Entscheidungsunterstützung in Unternehmen eingesetzt werden können. Unter solchen „intelligenten Informationssystemen“ werden einzelne oder kombinierte Verfahren der KI verstanden, die über Intelligenz im Sinne von Lernfähigkeit verfügen, d. h., die Systeme schaffen Problemlösungen ohne zuvor explizit Lösungsstrategien zu kennen.¹⁷

Goontilake identifiziert fünf idealtypische Merkmale von intelligenten Informationssystemen:¹⁸

- *Anpassungsfähigkeit:* Intelligente Informationssysteme erkennen selbständig Umweltveränderungen und berücksichtigen diese bei aktuellen und zukünftigen Problemlösungen.
- *Lernfähigkeit:* Intelligente Informationssysteme sind in der Lage, Probleme zu lösen, ohne zuvor explizite Lösungsstrategien zu kennen. Anhand der vorliegenden Daten werden selbständig neue Problemlösungen abgeleitet.
- *Flexibilität:* Intelligente Informationssysteme arbeiten auch mit unvollständigen, inkorrekten, unscharfen und verrauschten Daten hinreichend zuverlässig und sind nicht unbedingt auf exakte Eingaben angewiesen. Dies imitiert menschliche Entscheidungsfindung.

14 Vgl. Arbeitskreis „Softcomputing in der Betriebswirtschaft“, in: Tagungsband zum 3. Göttinger Symposium Softcomputing am 27. Feb. 1997 an der Universität Göttingen, Hrsg.: Biethahn, J.; Kuhl, J.; Leisewitz, M.-C.; Nissen, V.; Tietze, M., S. VI.

15 Vgl. Wilbert, R.: Interpretation und Anwendung neuronaler Netze in den Wirtschaftswissenschaften, Frankfurt a. M. et al.: Peter Lang 1996, S. 99.

16 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 86 und Niedereichholz, J.; Kruse, H.; Mechler, B.: Kombination symbolischer und subsymbolischer Systeme in Entscheidungsunterstützungssystemen, a. a. O., S. 101.

17 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 15ff. und Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, in: Intelligent Systems in Finance and Business, Hrsg.: Goontilake, S.; Treleaven, P., Chichester et al.: John Wiley & Sons 1995, S. 8ff.

18 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 4ff.

- *Nachvollziehbarkeit*: Zusammen mit den Problemlösungen werden auch die beschrittenen Lösungswege transparent und nachvollziehbar dargelegt.
- *Entdeckungsfähigkeit (Knowledge discovery)*: Intelligente Informationssysteme legen unbekannt funktionale Zusammenhänge offen, die implizit in den Daten enthalten sind. Die neuen Erkenntnisse dienen als Ausgangspunkte für die eigenständige Wissenserweiterung der Systeme.

Mit diesen Prämissen kommen für Intelligente Informationssysteme vier wissensbasierte, lernfähige Problemlösungsverfahren in Betracht: Expertensysteme, Fuzzy Logic, Künstliche Neuronale Netze und Evolutionäre Algorithmen. Die drei letztgenannten "intelligenten" Verfahren werden unter dem Begriff des „Soft Computing“ zusammengefaßt, der auf die Verarbeitung unscharfer, unpräziser Informationen fokussiert und der ausschließlichen Behandlung exakter, „harter“ Werte gegenüberstellt.¹⁹

Insbesondere der Kombination verschiedener intelligenter Verfahren in hybriden Systemen werden hohe Effektivität und effiziente Entscheidungsunterstützung zugeschrieben. Zum Beispiel könnte die Problematik der Nachvollziehbarkeit von Entscheidungen bei KNN durch ein hybrides System mit Expertensystemkomponente vermieden werden.²⁰ Ökonomische Anwendungsmöglichkeiten Intelligenter Informationssysteme finden sich insbesondere bei komplexen, nicht-konservativen Problemen, die ohne Modell der exakten Ursache-Wirkungszusammenhänge vorliegen (Beispiel: Prognosen am Kapitalmarkt in der Finanzwirtschaft).²¹

Im realen unternehmerischen Umfeld sollte die Ausgestaltung eines Intelligenten Informationssystems mit der Erkenntnis erfolgen, daß nicht ein einzelnes überlegenes, sondern alternative Problemlösungsverfahren existieren, aus denen problemspezifisch das Geeignete auszuwählen ist. Die Verfahren stehen daher nebeneinander und nicht in Konkurrenz. Bei vielen Problemstellungen ergibt sich erst aus der Kombination der Verfahren eine anforderungsgerechte Lösung betrieblicher Probleme.

Abbildung 1 zeigt die bisher dargelegten Zusammenhänge im Überblick. Nach einer Betrachtung der KNN-Historie (Abschnitt 3) befaßt sich Abschnitt 4 dieses Arbeitspapiers mit der Klassifikation von KNN, um sodann mit der Beschreibung der vorgenannten potentiellen Verfahren für Intelligente Informationssysteme (Abschnitt 5) der wissenschaftlich-begrifflichen Einordnung von KNN eine inhaltliche Abgrenzung hinzuzufügen.

19 Der Begriff „Soft Computing“ geht auf Lotfi Zadeh, den Begründer der Fuzzy Logic, zurück. Vgl. Vorwort zu Medsker, L. R.: Hybrid Intelligent Systems, Boston: Kluwer 1995.

20 Vgl. Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 22.

21 Vgl. auch Wilbert, R.: Interpretation und Anwendung neuronaler Netze in den Wirtschaftswissenschaften, a. a. O., S. 99.

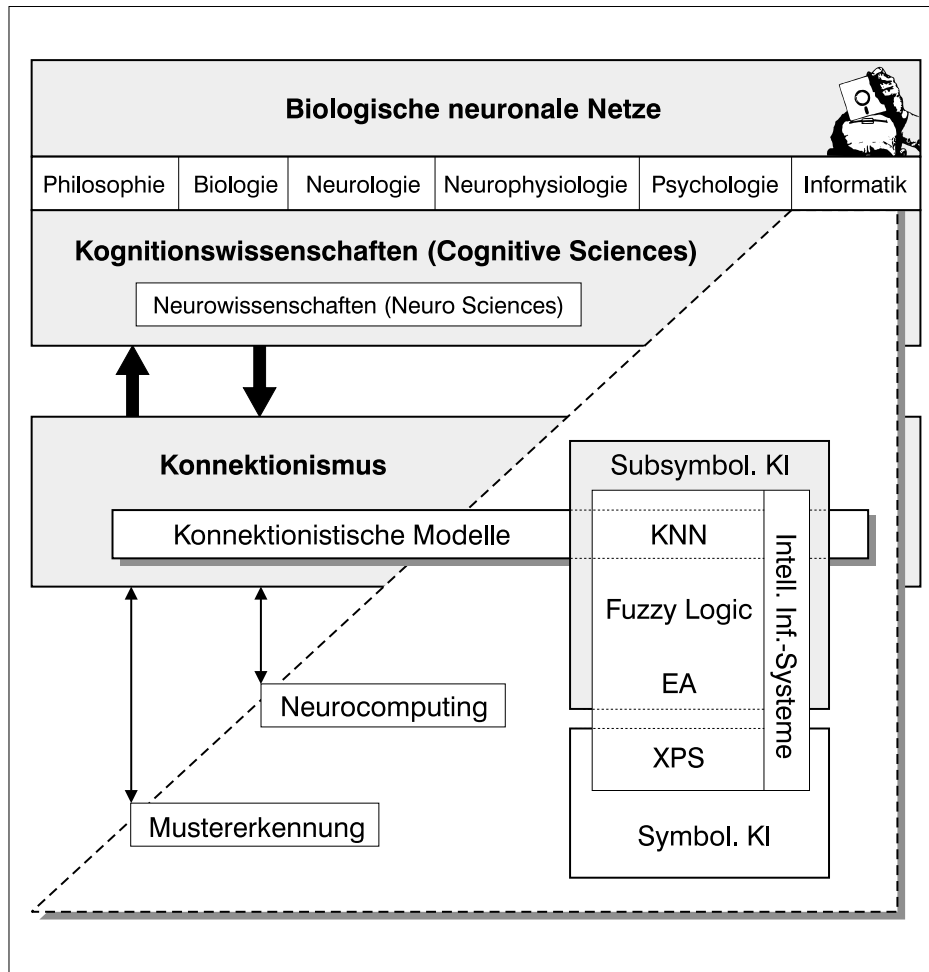


Abb. 1: Eine wissenschaftliche Positionierung von KNN

3 Historischer Hintergrund von KNN

Erste Erkenntnisse über die Verarbeitungsvorgänge des menschlichen Gehirns ergaben sich Ende des vergangenen Jahrhunderts. Unter anderem führte William James 1890 die Leistung des menschlichen Gehirns auf die gegenseitige Verstärkung von Signalen zurück.

Die eigentliche Entwicklung der KNN begann in den 40er Jahren. Als Grundstein gelten Arbeiten von Warren McCulloch & Walter Pitts, Donald Hebb und Karl Lashley. Der Neurophysiologe McCulloch und der Mathematiker Pitts abstrahierten von den biologischen Vorgängen und schufen ein Modell des essentiellsten Gehirnbausteins auf Basis logischen Kalküls, das künstliche Neuron. Obwohl die praktische Anwendbarkeit von den Autoren nicht hervorgehoben wurde, ist das Neuron in der Lage, prinzipiell logische Operationen zu lösen.²²

²² Vgl. Hecht-Nielson, R.: Neurocomputing, a. a. O., S. 14f.

1949 formulierte Donald Hebb, ebenfalls ein Neurophysiologe, ein Modell des menschlichen Lernens, das die Lernvorgänge mit der Anpassung von Neuronenverbindungen bei gleichzeitiger Aktivität der Neuronen begründet. Das Modell wurde als Hebbsche Lernregel bekannt und ist heute noch in Verwendung.

Ein Jahr später erschien Karl Lashleys Forschungsbericht über die Lokalität des Gedächtnisses im Gehirn. Lashley ging davon aus, daß bestimmte Gehirnregionen für Erinnerungen zuständig sind. Im Laufe der Zeit stellte sich heraus, das zwar bestimmte Lokalitäten im Gehirn spezielle Aufgaben übernehmen, aber Erinnerungen dezentral gespeichert werden. Aus diesen Überlegungen entstand die Idee der verteilten Informationsspeicherung.²³

Die Arbeiten der 40er Jahre interessierten Forscher verschiedener Gebiete, darunter den Entdecker des modernen Computermodells, John von Neumann, und den Begründer der Kybernetik, Norbert Wiener. Der Psychologe Frank Rosenblatt kombinierte das McCulloch-Pitts-Neuron in einem Netzwerk und beschrieb 1958 das „Perceptron“. Das Perceptron gilt als das „Ur-Neuronenmodell“.²⁴ Alle grundlegenden Merkmale heutiger Künstlicher Neuronaler Netze sind enthalten: Lernfähigkeit, Selbstorganisation, Generalisierungsfähigkeit und Fehlertoleranz. Das Perceptron wurde in der damaligen Hardwaretechnologie als Mark I Perceptron implementiert und erkannte Zeichen auf einer 20x20 Leuchtpunktmatrix.²⁵

Das erste praktisch einsetzbare Künstliche Neuronale Netz konstruierten Bernard Widrow und Marcian „Ted“ Hoff. Ihr ADALINE (ADaptive LINEar Element) konnte einfache Klassifizierungsaufgaben ausführen und kam zum Beispiel für die Dämpfung des Echos in Telefonleitungen zur Anwendung.²⁶ Wichtigster Schritt für die Entwicklung der KNN war jedoch eine neue Lernregel, die gegenüber dem Perceptron Vorteile aufwies. ADALINE benutzt den kleinsten quadratischen Fehler zwischen gewünschtem und erzeugtem Output als Fehlermaß. Die Widrow-Hoff-Regel ist deshalb auch als Delta-Regel bekannt. Widrow und Hoff ergänzten später ihr Modell durch eine Zwischenschicht zum Multiple ADALINE Modell (MADALINE).

1969 erlitt die Erforschung Künstlicher neuronaler Netze einen Einbruch. Marvin Minsky und Seymour Papert, die zuvor den Begriff „Artificial Intelligence“ geprägt hatten, veröffentlichten eine vernichtende Kritik an den existierenden Neuronen-Modellen mit dem Erfolg, daß zwischen 1970 und 1982 nur noch sehr wenige Forscher voneinander getrennt in einzelnen Disziplinen weiterarbeiteten.²⁷ Andere wanderten völlig ab und suchten sich neue Betätigungsfelder, unter ihnen John von Neumann und Ted Hoff.

23 Vgl. Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, Haar bei München: Markt & Technik 1990, S. 69.

24 Vgl. Kemke, C.: Der neuere Konnektionismus, a. a. O., S. 143.

25 Vgl. Hecht-Nielsen, R.: Neurocomputing, a. a. O., S. 14f.

26 Vgl. Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, a. a. O., S. 70.

27 Vgl. Maren, A. J.; Harston, C.; Pap, R.: Handbook of Neural Computing Applications, San Diego: Acad. Press 1990, S. 17.

Jahr	Forscher	Forschungsgebiet	Anmerkung
1890	William James	Neurologie	Verstärkung eines Signals bei gleichzeitiger Aktivität zweier „Gehirnprozesse“
1943	Warren McCulloch und Walter Pitts	Neurophysiologie, Mathematik	Theoretische Begründung der Fähigkeiten eines Neurons
1949	Donald Hebb	Psychologie	Erklärung des menschlichen Lernens durch Verstärkung im Netzwerk
1950	Karl Lashley	Neurologie	Vorausdenker für verteilte Wissensspeicherung
1958	Frank Rosenblatt	Psychologie	Kombination von Neuronen zu Perzeptron
1960	Bernard Widrow und Ted Hoff	Informatik	ADALINE und MADALINE mit delta-Lernregel
1969	Marvin Minsky und Seymour Papert	Informatik (KI)	„Perceptrons“ kritisiert die Leistungsfähigkeit des Rosenblatt'schen Perzeptrons
1972	Teuvo Kohonen	Elektrotechnik, Informatik	Selbstorganisierende KNN
1972-1977	James Anderson	Psychologie	Brain-State-in-a-Box nach biologischem und psychologischem Vorbild als anpaßbares KNN
1974-1977	Paul Werbos	Informatik	Grundlagen für Backpropagation-Algorithmus
1982	John Hopfield	Physik	Hopfield-Netzwerk (Assoziativspeicher)
1968-1988	Stephen Grossberg und Gail Carpenter	Informatik, Psychologie	Adaptive Resonance Theory (ART) für versch. Anwendungen

Tab. 1: Historische Entwicklung von KNN

In den 70er Jahren entstanden richtungsweisende Arbeiten, die aber aufgrund der Kritik Minskys und Paperts unbeachtet blieben. Teuvo Kohonen entwickelte Neuronen-Modelle für Steuerungsaufgaben. James Anderson entwickelte den linearen Assoziator und das Brain-State-in-a-Box Netzwerk in Anlehnung an natürliche biologische und psychologische Anpassungsvorgänge. Stephen Grossberg orientierte sich ebenfalls an den biologischen Erkenntnissen über die Gehirnfunktionen und entwarf das ART (Adaptive Resonance Theory), das stark am biologischen Vorbild orientiert ist und als das am weitesten entwickelte KNN gilt.²⁸

Die Renaissance der KNN begann zwischen 1979 und 1982. Wissenschaftler verschiedener Disziplinen (Biologen, Neurologen, Physiker, Mathematiker) entdeckten ein ge-

28 Vgl. Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, a. a. O., S. 71.

meinsames Interesse an der Forschung nach neuen Neuronen-Modellen. Allerdings entstand erst 1982 ein merklicher Schub für die Neuronale Forschung als der renommierte Physiker John Hopfield Neuronen-Modelle für die Erklärung physikalischer Phänomene benutzte. Das Hopfield-Modell führte zur Entwicklung weiterer Netzwerkmodelle, die sich an den physikalischen Energiegesetzen orientierten.

Der entscheidende Durchbruch für die KNN kam 1985 als Rumelhart und Hinton eine neue Lernregel, die generalisierte Delta-Regel, vorstellten, die die Kritik am Perceptron aufhob.²⁹ Kurz darauf veröffentlichten 1986 Rumelhart und McClelland eine Sammlung neuerer Forschungsergebnisse in zwei Bänden,³⁰ die dem Forschungsgebiet endgültig Anerkennung verschaffte. Einen Überblick über wichtige Stationen der historischen Entwicklung Künstlicher Neuronaler Netze gibt Tabelle 1.

4 Zur Klassifikation von KNN

4.1 Klassifikation als Orientierungshilfe

Ein vollständiger Überblick zu allen existierenden Modellen von KNN ist angesichts der unüberschaubaren Anzahl bekannter, modifizierter und vollkommen neuer Typen kaum mehr möglich. Eine Klassifikation von KNN-Modellen nach markanten methodischen Merkmalen gibt eine erste Orientierungshilfe (siehe Abbildung 2).³¹

Für die Identifizierung betriebswirtschaftlicher KNN-Anwendungsbereiche erscheint es sinnvoll, aus zwei verschiedenen Blickwinkeln Aufgabenkategorien für KNN zu bilden. Die Kategorienbildung soll zunächst aus der Sicht der KNN nach den immanenten Eigenschaften von KNN als Assoziativspeicher und als Optimierungsalgorithmen erfolgen (siehe Abschnitt 4.2). KNN erfüllen eine Assoziativspeicher-Funktion, wenn sie Muster in den Eingabedaten vorhalten und verarbeiten. Dagegen nutzen KNN als Optimierungsalgorithmen nicht die Speicherfähigkeit, sondern die Fähigkeit Funktionsoptimierungen vornehmen zu können.

Ergänzend dazu werden Aufgabenkategorien für KNN aus betriebswirtschaftlicher Sicht gebildet; hier dienen die beiden grundlegenden betriebswirtschaftlichen Problemlösungsstrategien Mustererkennung (i. w. S.) und Optimierung als Kriterien für die Klassifikation.³²

29 Vgl. Kratzer, K.-P.: Neuronale Netze - Grundlagen und Anwendungen, a. a. O., S. 16.

30 Vgl. Rumelhart, D. E.; McClelland, J. L., et al.: Parallel Distributed Processing. Volume 1: Foundations, Cambridge, MA et al.: MIT Press 1986 und Rumelhart, D. E.; McClelland, J. L. et al.: Parallel Distributed Processing. Volume 2: Psychological and Biological Models, Cambridge, MA et al.: MIT Press 1986.

31 In Anlehnung an Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, a. a. O., S. 75 und Graszynski, R.: Betriebswirtschaftliche Anwendungen Neuronaler Netze, Diplomarbeit, Johann Wolfgang Goethe-Universität, Frankfurt am Main: Fachbereich Wirtschaftswissenschaften 1993, S. 19.

32 Vgl. Rehkugler, H.; Poddig, T.: Anwendungsperspektiven und Anwendungsprobleme von Künstlichen Neuronalen Netzwerken, in: Information Management, 2/1992, S. 54.

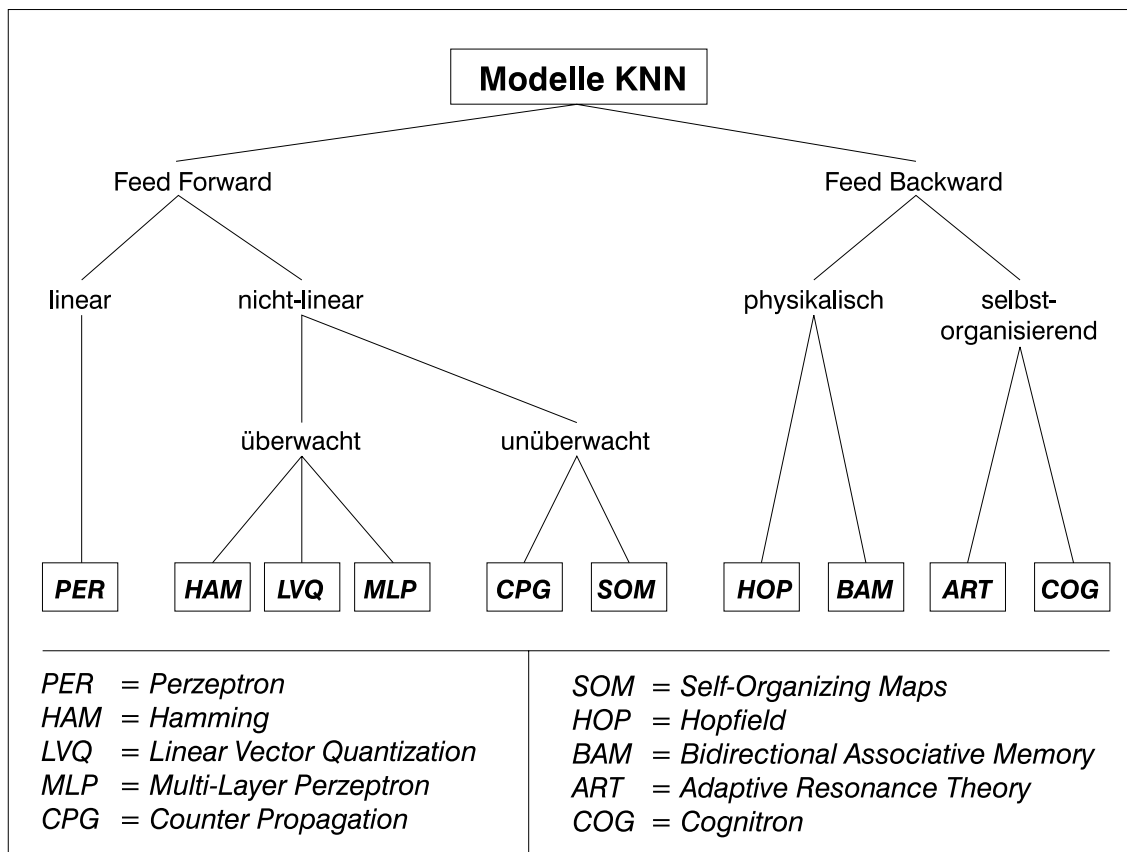


Abb. 2: Klassifikation von KNN-Modellen nach methodischen Merkmalen

Aufgrund der Komplexität von KNN und stark einzelfallabhängigen betrieblichen Problemstellungen konnte sich bis dato kein allgemein anerkanntes Klassifikationsschema für KNN durchsetzen. Auch die in den Abbildungen 2, 3 und 4 graphisch dargestellten Klassifikationen von KNN geben lediglich grobe Anhaltspunkte zu KNN-Einsatzgebieten; sie können jedoch als Orientierungshilfen dienen, wenn im konkreten Fall die Verwendung von KNN im Unternehmen evaluiert werden soll.

Eine detailliertere Klassifikation ist möglich, wenn das Anwendungsproblem nach betriebswirtschaftlichem Problemtyp, konkreter Problemstellung und vorhandenem Datenmaterial differenziert dargestellt wird. Schneider et al. haben dazu ein dreistufiges Klassifikationsschema entwickelt, mit dem eine feinere Zuordnung von betriebswirtschaftlichen Problemen zu konnektionistischen Modellen vorgenommen wird.³³ Allerdings fehlen in ihrer Darstellung nachvollziehbare Zuordnungsvorschriften.

³³ Vgl. Horster, B.; Schneider, B.; Siedentopf, J.: Kriterien zur Auswahl konnektionistischer Verfahren für betriebliche Probleme, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 15, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., März 1993, S. 7ff.

4.2 Klassifikation nach Eigenschaften von KNN

Die KNN-Modellen immanente Assoziativspeicher-Eigenschaft liegt Kategorien mit einzelnen KNN-Aufgaben zur heteroassoziativen Speicherung, autoassoziativen Speicherung und zur Funktionsapproximation zugrunde. Eine vierte Kategorie von KNN-Aufgaben resultiert aus der lösungsoptimierenden Eigenschaft von KNN (vgl. Abbildung 3).³⁴

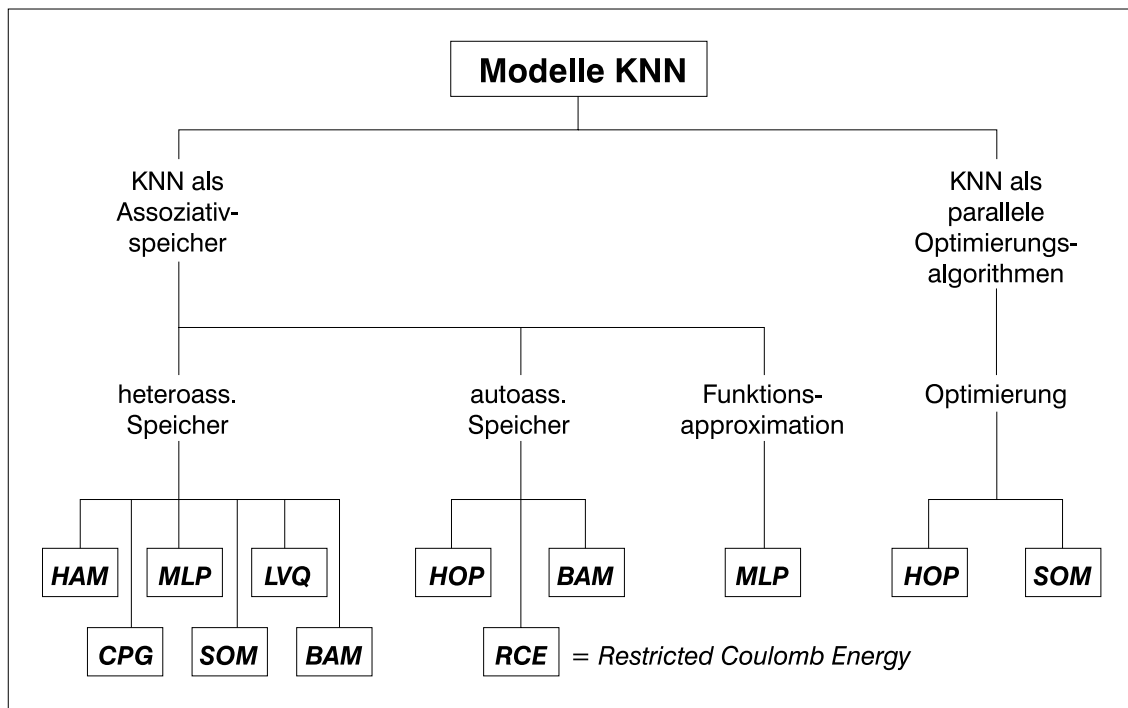


Abb. 3: Klassifikation nach KNN-Eigenschaften

- **Aufgabenkategorie 1: Heteroassoziative Speicherung**

Allgemein formuliert soll jedem Eingabemuster ein davon unterschiedliches Ausgabemuster zugeordnet werden. Falls die Eingabedaten in der Verarbeitungsphase nur gelernte Muster enthalten, dient das KNN als heteroassoziativer Speicher, der n Eingabemuster m Ausgabemustern zuordnet. Unterkategorien bilden die Generalisierung und die Klassifikation:

³⁴ Vgl. Schneider, B.: Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 22, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., November 1993, S. 32. Vgl. auch Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, in: Betriebswirtschaftliche Forschung und Praxis, 3/1995, S. 313 f. und Faißt, J.: Hierarchische Planung unter Einsatz Neuronaler Netze - Illustriert an Untersuchungen zum flexiblen Personalmanagement, Heidelberg: Physica 1993, S. 220 und Maren, A. J.; Harston, C.; Pap, R.: Handbook of Neural Computing Applications, a. a. O., S. 223.

- *Generalisierung*
Dieser Aufgabentyp ist dadurch charakterisiert, daß anstelle von gelernten Mustern einem KNN in der Verarbeitungsphase ungelernete Muster vorlegt werden. Das KNN ordnet die Muster nach den gelernten funktionalen Zusammenhängen einem "möglichst passenden" Ausgabemuster zu. Die Definition des Zielkriteriums ist dabei abhängig von der Aufgabenstellung und deshalb nicht allgemein formulierbar.
- *Klassifikation*
Einem Eingabemuster wird eine als Ausgabemuster kodierte Klasse zugeordnet. Die Anzahl der Klassen ist gering, im einfachsten Fall existieren zwei Klassen (z. B. gut/schlecht). Das Eingabemuster ist statisch und unabhängig von anderen Eingabemustern (keine zeitliche Reihenfolge). Die Kodierung der Ausgabe erfolgt über die Aktivierung einer oder weniger Ausgabeeinheiten. Für die Klassifikation reichen bereits wenige Mustermerkmale aus; d. h., es können verauschte und unvollständige Eingabedaten vorliegen. Überwacht lernende KNN arbeiten als Klasseneinteiler, während unüberwacht lernende KNN Klassenentdecker sind. Die Klassifikation kann als Spezialfall der Generalisierung betrachtet werden, da die Zuordnung zu Klassen der Zuordnung von Eingabemustern zu Ausgabemustern entspricht.
- **Aufgabenkategorie 2: Autoassoziative Speicherung**
Ein Eingabemuster wird in der Lernphase mit sich selbst assoziiert. Das KNN soll in der Verarbeitungsphase aus ungelerten, verauschten Eingabemustern ein gelerntes Muster wiedererkennen (*Generalisierung*).
- **Aufgabenkategorie 3: Funktionsapproximation**
Liegen die Eingabedaten in einer zeitlichen Reihenfolge vor und unterliegen diese Zeitreihen einem funktionalen Zusammenhang, können KNN eingesetzt werden, um den impliziten Zusammenhang zu approximieren und zukünftige Zeitreihenwerte vorherzusagen. Dazu lernt das KNN einen Ausschnitt aus einer Zeitreihe mit einem vorgegebenen Output zu assoziieren. In der Verarbeitungsphase ergänzt das KNN Zeitreihen um einen Prognosewert.
- **Aufgabenkategorie 4: Optimierung**
Diese Aufgabenkategorie umfaßt zwei Lösungsansätze. Ein Ansatz benutzt rückgekoppelte Netzwerke, um über die Minimierung einer Energiefunktion (*Funktionsminimierung*) zu einem Optimum zu gelangen. Ein anderer Ansatz bildet das Optimierungsproblem in nachbarschafts-erhaltende Karten (*Topologieabbildung*) ab und erzielt durch Wettbewerbslernen eine Optimierung. Im Unterschied zur Kategorie der Assoziativspeicher nutzen Optimierungsaufgaben nicht die Speicherfähigkeit von KNN.³⁵

35 Vgl. Faißt, J.: Hierarchische Planung unter Einsatz Neuronaler Netze - Illustriert an Untersuchungen zum flexiblen Personalmanagement, a. a. O., S. 220.

4.3 Klassifikation von KNN aus betriebswirtschaftlicher Sicht

Die Zuordnung von vier Aufgabenkategorien für KNN aus betriebswirtschaftlicher Sicht ist Lohrbach entnommen (Abbildung 4).³⁶

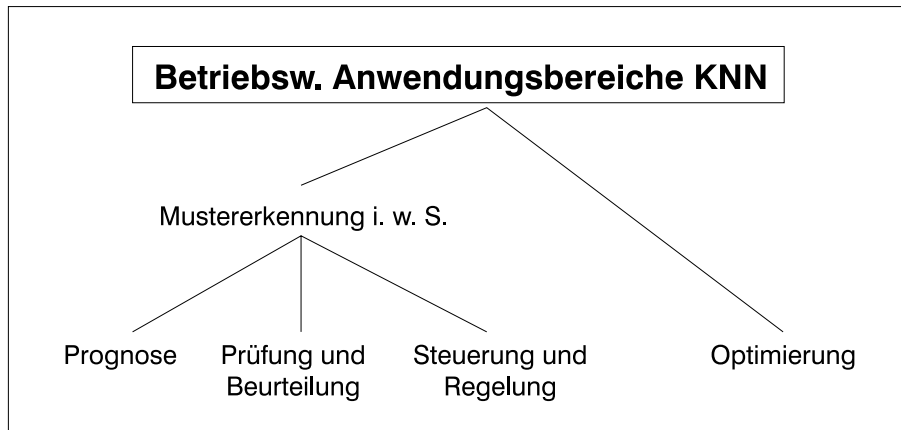


Abb. 4: Aufgabenkategorien von KNN aus betriebswirtschaftlichen Sicht

Lohrbach separiert zunächst die zwei grundlegenden betriebswirtschaftlichen Problemlösungsstrategien Mustererkennung i. w. S. und Optimierung. Bei der Mustererkennung i. w. S. erkennen KNN funktionale Zusammenhänge in den Eingabedaten und bilden das implizit zugrundeliegende Modell ab. Dagegen enthalten bei Optimierungsanwendungen die Trainingsdaten nur verschiedene Zustände des Problems (Variablen).³⁷ Die funktionalen Zusammenhänge sind in der Netzwerktopologie abgebildet, die eine Vielzahl möglicher Lösungen repräsentiert. Das Netzwerk sucht gemäß einem Optimierungsalgorithmus nach einer optimalen Lösung.³⁸ Die Mustererkennung i. w. S. wird weiter unterteilt in die Anwendungsbereiche Prognose, Prüfung und Beurteilung sowie die Steuerung und Regelung.³⁹ Tabelle 2 zeigt einen Überblick zu bekannten betriebswirtschaftliche Anwendungen in den Aufgabenkategorien Mustererkennung und Optimierung.

Optimierung

Betriebswirtschaftliche Optimierungsprobleme kombinatorischer Art werden nach der Terminologie des Operations Research unterteilt in P-harte und NP-harte (NP-

³⁶ Vgl. Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, Göttingen: unitext 1994, S. 75.

³⁷ Vgl. Schneider, B.: Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme, a. a. O., S. 32 und Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, a. a. O., S. 19.

³⁸ Vgl. Faißt, J.: Hierarchische Planung unter Einsatz Neuronaler Netze - Illustriert an Untersuchungen zum flexiblen Personalmanagement, a. a. O., S. 220.

³⁹ Vgl. Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, a. a. O., S. 75.

vollständige) Probleme.⁴⁰ NP-vollständige Probleme besitzen die Eigenschaft, daß der Rechenaufwand exponentiell statt polynomial zur Problemgröße wächst. Zur Lösung dieser Probleme stehen exakte Lösungsansätze nur für eingeschränkte Modelle zur Verfügung (z. B. der Simplex-Algorithmus). Bei umfangreicheren Problemen mit mehreren Nebenbedingungen ist man auf Näherungsverfahren (Heuristiken) angewiesen, die innerhalb eines zur Verfügung stehenden Zeitrahmens u. U. nur suboptimale Lösungen finden.⁴¹

KNN stellen im Bereich der Optimierungsprobleme eine Alternative zu den bekannten Lösungsverfahren aus dem Operations Research und der Statistik dar. Die Funktionsweise eines KNN bei Optimierungen ist vergleichbar mit Heuristiken. KNN finden daher u. U. ebenfalls nur suboptimale Lösungen. Allerdings können KNN abhängig von der fallspezifischen Aufgabenstellung z. T. schneller (bei Parallelisierung) oder sicherer eine Optimierung vornehmen. Im Gegensatz zu einigen Verfahren des Operations Research ist es in bestimmten Netzwerkmodellen möglich, ein lokales Minimum wieder zu verlassen.

Klassische Anwendungsfälle finden sich in der Tourenplanung (im einfachsten Fall das Problem des Handlungsreisenden; Travelling-Salesman-Problem, TSP). Bei der Tourenplanung sollen von einem Standort ausgehend die kürzesten Routen zwischen mehreren räumlich verteilten Kunden für eine bestimmte Anzahl von Fahrzeugen gefunden werden (Rundreisen einzelner Fahrzeuge). Dabei treten zwei Teilprobleme auf: eindeutige Zuordnung von Kunden zu einem Fahrzeug und die Ermittlung der kürzesten Strecke für eine bestimmte Rundreise. KNN lösen beide Teilprobleme simultan.⁴²

Die Ausgangsdaten (u. a. Fahrtroute, Fahrzeugkapazität, Koordinaten des Kundenstandortes und dessen Nachfrage nach zu liefernden Produkten) werden für das KNN in Prozesselementen (PE) kodiert. Beispielsweise benutzen Retzko und Schumann für den Kundenstandort jeweils ein PE für die X- und Y-Koordinate sowie ein weiteres für die Nachfrage des dortigen Kunden nach zu liefernden Produkten.⁴³ Die Trainingsdaten bestehen aus der Menge aller abzufahrenden Standorte, die in der Lernphase in zufälliger Reihenfolge an das Netz angelegt werden. Das Netz lernt verschiedene Rundreisen, bewertet diese und als Ergebnis erhält man aus einer vom Netz ermittelten Reihenfolge der PE die (nach Fahrzeit oder Fahrstrecke) optimierte Rundreise.⁴⁴

40 Vgl. Faißt, J.: Hierarchische Planung unter Einsatz Neuronaler Netze - Illustriert an Untersuchungen zum flexiblen Personalmanagement, a. a. O., S. 219.

41 Vgl. Müller, B.; Reinhardt, J.; Strickland M. T.: Neural networks: an introduction, 2. überarb. und korr. Aufl., Berlin et al.: Springer 1995, S. 126f.

42 Vgl. Retzko, R.; Schumann, M.: Lösungsmöglichkeiten von Tourenplanungsproblemen mit Selbstorganisierenden Neuronalen Netzen, Georg-August-Universität Göttingen, Abtlg. Wirtschaftsinformatik II, Arbeitspapier Nr. 11, Hrsg.: Schumann, M., Dezember 1994, S. 10.

43 Vgl. Retzko, R.; Schumann, M.: Lösungsmöglichkeiten von Tourenplanungsproblemen mit Selbstorganisierenden Neuronalen Netzen, a. a. O., S. 11f.

44 Vgl. Retzko, R.; Schumann, M.: Lösungsmöglichkeiten von Tourenplanungsproblemen mit Selbstorganisierenden Neuronalen Netzen, a. a. O., S. 8.

Ein weiteres Beispiel für Optimierungsanwendungen besteht in der Maschinenbelegungsplanung. Lohrbachs Optimierungsansatz dazu basiert auf einer zu minimierenden Kostenfunktion. Die PE des KNN spiegeln dabei unzulässige und zulässige Lösungen des Problems wieder. Das Netz lernt die optimale Lösung durch Minimierung einer Funktion, die die Zielfunktion und Restriktionen repräsentiert. Ein weiterer Optimierungsansatz Lohrbachs für die Maschinenbelegungsplanung zählt zum Aufgabengebiet der Prüfung und Beurteilung (s. u.); hier wird erkennbar, daß sich betriebliche Anwendungen nicht eindeutig auf Aufgabenkategorien künstlicher neuronaler Netze abbilden lassen.⁴⁵

Prognose

Prognoseanwendungen von KNN basieren typischerweise auf Zeitreihenanalysen; d. h., einer Zahlenfolge liegt ein funktionaler Zusammenhang zugrunde, der in einem mathematischen Modell abgebildet wird. Für nicht-deterministische Zeitreihen existieren allerdings keine exakten Modelle, mit denen eine sichere Vorhersage zukünftiger Werte möglich ist. Aus diesem Grund setzt man für Prognosen u. a. statistische Verfahren (Glättung, Extrapolation) ein. Einige dieser Verfahren unterstellen restriktive Annahmen über die zugrundeliegende Funktion (z. B. Linearität). KNN weisen gegenüber diesen Verfahren den Vorteil auf, keine expliziten Annahmen über die Zusammenhänge in den Eingabedaten zu machen. Allerdings beeinflußt die Wahl der Netzwerkkonfiguration implizit die Fähigkeit eines KNN, z. B. nicht-lineare Zusammenhänge abbilden zu können.

Eine typische Prognose-Anwendung ist die Aktienkursprognose. Als Informationsquellen stehen technische Daten (Kursdaten der betroffenen Aktie) und fundamentalanalytische Daten (Kurse anderer Aktien, volkswirtschaftliche Kenngrößen wie z. B. Arbeitslosenquote, Bruttoinlandsprodukt usw.) zur Verfügung.⁴⁶ Wichtiges Kennzeichen der Kurse als Eingabedaten ist der Zeitraumbezug; d. h., die Daten liegen in zeitlicher Reihenfolge (z. B. tageweise) vor.

In der Lernphase wird jedem technisch-fundamentalanalytischen Aktien-Datensatz der zeitpunktbezogene Preis (Kurs) oder die Richtung der Kursänderung (steigt/fällt) der zu prognostizierenden Aktie als vorgegebener Output gegenübergestellt. Das Netz approximiert das in den vergangenheitsbezogenen Eingabedaten enthaltene Modell und kann in der Verarbeitungsphase zu ungelerten Eingabedaten Folgewerte berechnen.⁴⁷

Prüfung und Beurteilung

Zu diesem Aufgabentyp zählen alle klassifikatorischen Anwendungen. Die Klassifikation ist eng mit der Prognose verknüpft. Das Ziel einer Klassifikation ist letztend-

45 Vgl. Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, a. a. O., S. 241ff.

46 Vgl. Rehkugler, H.; Poddig, T.: Neuronale Netze im Bankbetrieb, in: Die Bank, 7/1992, S. 416.

47 Vgl. Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, a. a. O., S. 151.

lich ebenfalls eine Prognose (Beispiel Insolvenzprognosen). Der wesentliche Unterschied liegt in der Art der Eingabe- und Ausgabedaten. Im Gegensatz zu Prognosen bestehen die Eingabedatensätze bei Klassifikationen aus statischen, zeitpunktbezogenen Daten (z. B. abgeschlossenen Kreditfällen). Der Prognosewert einer Klassifikation entspricht daher auch nicht einer Zeitreihenfortsetzung. Prognosen durch Klassifikation beruhen auf der Annahme, daß die vergangenheitsbezogenen Daten typische Muster enthalten, die erstens eine Klassifizierung mittels einer Trennfunktion erlauben und zweitens, daß gefundene Trennfunktionen auch für zukünftige, unbekannte Muster gültig sind.

Typische betriebswirtschaftliche Anwendungen sind in der Finanzwirtschaft (z. B. Risikomanagement) und in der Produktionswirtschaft (Qualitätskontrolle und -sicherung) zu finden. Einsatzgebiete im Risikomanagement sind u. a. Insolvenzprognosen, Kreditwürdigkeitsprüfungen von Konsumentenkrediten und die Bewilligung von Kreditkarten. In der produktionswirtschaftlichen Qualitätskontrolle existieren sehr spezielle Anwendungen. Ein Beispiel für die akustische Qualitätskontrolle stellen die Überprüfungen von (Verbrennungs- bzw. Elektro-) Motoren dar. Erfahrene Ingenieure erkennen Fehlfunktionen an Geräuschabweichungen vom Normalfall und sortieren auf diese Art Motoren geringer Qualität aus. Ein KNN für diesen Zweck konnte innerhalb kurzer Zeit zuverlässigere Diagnoseleistungen als menschliche Experten erbringen. In der optischen Qualitätskontrolle werden KNN z. B. zur Überprüfung von Verschlußkappen auf Flaschen oder in der Stahlindustrie zur Überprüfung von Schweißnähten verwendet.⁴⁸

Steuerung und Regelung

Betriebswirtschaftliche Anwendungen dieses Aufgabentyps befinden sich im Grenzbereich zu ingenieurwissenschaftlichen Einsatzgebieten. Steuerungs- und Regelungsaufgaben liegen vor allem in der Fertigung vor.⁴⁹ Dort dienen KNN zur Prozeßkontrolle und -steuerung von Fertigungsanlagen, Transportsystemen und Industrierobotern. Hierbei treten Überschneidungen mit anderen Aufgabentypen auf. Beispielsweise läßt sich die Beschickungsoptimierung von Hochregallagern mit KNN als Voraussetzung für die Steuerung von Fertigungsprozessen betrachten. Gleichfalls werden Angaben über den Prozeßzustand benötigt, wobei sich die Kombination der Prozeßsteuerung mit Diagnoseverfahren (z. B. Qualitätskontrolle) anbietet.⁵⁰ Grundlage dieser produktionswirtschaftlichen Aufgaben ist die Verarbeitung sensorischer (akustischer, optischer) Eingabedaten zur visuellen und auditiven Mustererkennung (Mustererkennung i. e. S.) in der Robotik, Steuerungs- und Regelungstechnik.⁵¹

48 Vgl. Maren, A. J.; Harston, C.; Pap, R.: Handbook of Neural Computing Applications, a.a.O., S. 310.

49 Vgl. Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, a. a. O., S. 75.

50 Vgl. Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, a. a. O., S. 84.

51 Vgl. Schneider, B.: Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme, a. a. O., S. 23 ff.

Aufgaben- kategorie	Funktions- bereich	Beispiel- anwendung	Beispiel- quelle	Netzwerk- modell
Optimierung	Produktionswirt- schaft	Maschinenbelegungs- planung	Lohrbach, 1994, S. 241	SOM, CPG, LVQ, BAM, HOP
	Absatzwirtschaft	Tourenplanung	Retzko; Schumann, 1994	HOP, SOM
Steuerung und Regelung	Produktionswirt- schaft	Autonome Roboter- steuerung	Ritter, 1991, S. 175	SOM
		Simulation einer Ro- botersteuerung	Schöneburg, 1993, S.207	MLP
Prognose	Finanzwirtschaft	Kurzfristige Aktien- kursprognose	Steiner; Wittkem- per, 1994, S. 307	MLP, Rückgeko- pelte Jordan-Netze
		Wechselkursprognose	Poddig sowie Pod- dig; Wallem ⁵²	SLP, MLP, RP
	Kurzfristige Aktien- kursprognose	Schöneburg et al., 1990, S. 151	Adaline, Madaline, MLP	
	Mittelfristige Zinspro- gnose	Rehkugler; Poddig, 1994 sowie Matthes, 1994 ⁵³	GRNN, SLP, MLP	
	Devisenhandel	Mechler, 1995, S. 133	MLP	
	Makroökonomie	Makroökonomische Modellierung	Allen, 1995, S.289 ⁵⁴	SOM
	Absatzwirtschaft	Umsatzprognosen	Schöneburg, 1993, S. 249	MLP
	Prüfung und Beurteilung	Finanzwirtschaft	Kreditwürdigkeitsprü- fung	
Hypothekenkreditver- gabe			Collins; Ghosh; Scofield, 1988	RCE
		Kennzahlenanalyse, Insolvenzprognose	u. a. Erxleben, Bischoff, Krause, Rehkugler ⁵⁵	MLP, CPG, LVQ
		Bewilligung von Kre- ditkarten	Didner, 1995, S. 31	MLP
		Entdeckung von Kre- ditkartenmißbrauch	Didner, 1995, S. 31	MLP
Absatzwirtschaft		Marketingforschung	Rittinghaus-Mayer, 1994, S. 109	MLP
Personalwirtschaft		Hierarchische Perso- nalplanung	Faißt, 1993, S. 161	MLP modifiziert um Functional Link Layer
Produktionswirt- schaft		Diagnose von Ver- brennungsmotoren	Schöneburg, 1993, S. 39	MLP

Tabelle 2: Betriebswirtschaftliche Anwendungen von KNN

52 Vgl. Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, a. a. O., S. 319

53 Vgl. Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, a. a. O., S. 319

54 Vgl. Allen, P.: Intelligent, Self-organizing Models in Economics and Finance, in: Intelligent Systems für Finance and Business, Hrsg.: Goontilake, S.; Treleaven, P., Chichster et al.: John Wiley & Sons 1995, S. 298.

55 Vgl. Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, a. a. O., S. 316.

5 Abgrenzung KNN zu anderen intelligenten Verfahren

5.1 Expertensysteme (XPS)

„XPS befassen sich mit der Erfassung und Speicherung des Wissens von Experten und darauf aufbauend Mechanismen zur automatischen Lösung von Problemen.“⁵⁶ Expertensysteme zählen zu den regelbasierten Systemen der symbolischen Künstlichen Intelligenz. Typischerweise besitzt ein Expertensystem fünf Komponenten: Wissensbasis, Problemlösungskomponente sowie Dialog-, Erklärungs- und Wissenserwerbskomponente. Hinzu kommt in der Anwendungsphase das fallbezogene Wissen in Form von Benutzereingaben.

Zentrale Bausteine sind die Problemlösungskomponente und die Wissensbasis. In der Wissensbasis ist das problembezogene Wissen (Problemdomäne) gespeichert, das damit immer wieder zur Problemlösung bereitsteht (Wissensmultiplikation). Die Wissensakquisition erfolgt dabei manuell; d. h., ein menschlicher Experte bereitet sein intuitiv vorhandenes Wissen entsprechend auf. Die Wissensdarstellung (Wissensrepräsentation) erfolgt dabei häufig in Form von Wenn-Dann-Beziehungen (Produktionsregeln) durch Fakten und Regeln, wobei Fakten konkrete Aussagen (Werte von Variablen) darstellen und Regeln einzelne Fakten verknüpfen. Regeln besitzen einen Bedingungs- und einen Aktionsteil. Im Bedingungssteil verknüpfen XPS Fakten mit binären, logischen Operationen (*und*, *oder*, *nicht*).

Beispiel einer Produktionsregel in einem Kreditvergabe-XPS:

IF age < 20 AND income < 20000 THEN credit = 0

Regeln können miteinander verknüpft sein, indem eine Regel als Aktionsteil einer anderen Regel benutzt wird. Als Resultat ergibt sich ein baumstrukturiertes Regelwerk. Dieser Regelbaum wird bei der Lösungssuche (Inferenz) durchlaufen, bis eine Problemlösung (Konklusion) gefunden ist (bzw. keine passenden Regeln gefunden wurden und das XPS keine Lösung angibt). Für die Inferenz in XPS sind zwei grundlegende Prinzipien bekannt: Bei der Vorwärtsverkettung werden zu Inputdaten (fallbasiertes Wissen) anwendbare Regeln und Fakten (problemdomänenbezogenes Wissen aus der Wissensbasis) gesucht und ausgeführt bis eine Problemlösung erstellt ist. Die Rückwärtsverkettung sucht zu einem gegebenen Problem die entsprechenden Regeln und Fakten, eventuell unter Zuhilfenahme benutzerabgefragter Fakten.

Die Dialogkomponente dient der Kommunikation mit dem Anwender. Über die Wissenserwerbskomponente wird das bereichsbezogene, fallübergreifende Wissen durch einen menschlichen Experten ergänzt. Mit Hilfe der Erklärungskomponente kann nachvollzogen werden, wie das XPS zu einer bestimmten Problemlösung gelangt ist.

⁵⁶ Stahlknecht, P.: Einführung in die Wirtschaftsinformatik, 6., völlig überarb. und erw. Aufl., Berlin et al.: Springer 1993, S. 413.

Generell dient ein XPS der DV-gestützten Entscheidungsunterstützung und Problemlösung. Die Entscheidungsqualität von XPS als regelbasierte Systeme stützt sich auf die Vollständigkeit und Exaktheit der fallspezifischen Fakten. Die Einsatzgebiete der XPS liegen insbesondere in Bereichen, in denen komplexe, schlecht oder unstrukturierbare Probleme vorliegen. Die XPS-Unterstützung hilft vor allem in den Anwendungen Konfiguration, Diagnose, Beratung und Expertise, wobei sich zahlreiche konkrete betriebswirtschaftliche Einsatzgebiete finden (eine Übersicht geben Mertens et al.).⁵⁷ XPS ersetzen hierbei den menschlichen Experten nicht, sondern kommen bei eng abgegrenzten Spezialgebieten und Routineaufgaben zum Einsatz, deren Lösungen bereits bekannt, aber sehr zeit- oder personalintensiv und daher kostenintensiv sind. XPS sollen diese Aufgaben schneller, billiger oder zuverlässiger als menschliche Experten ausführen.⁵⁸

Wesentliche Unterschiede zu KNN stellen die Art des Wissenserwerbs und der Entscheidungsfindung dar. XPS finden Lösungen anhand von Wissen, das vorher durch menschliche Experten explizit festgelegt ist. Dagegen erwerben KNN ihr Wissen implizit durch Lernen aus Beispielen. Expertensysteme besitzen keine automatische Wissenserwerbsmöglichkeit und können deshalb neue Regeln nicht selbst entdecken.⁵⁹ Die Wissensbasis ist starr festgelegt und kann nur durch einen menschlichen Experten erweitert und verändert werden. Der hohe Entwicklungsaufwand eines XPS wird daher in der unbedingten Verfügbarkeit eines oder mehrerer, teurer menschlicher Experten gesehen. Hinzu kommt die Schwierigkeit, Probleme, die sich ausschließlich intuitiv erfassen und erklären lassen, in einem exakten Regelwerk zu formulieren.

Weiterhin erlauben die binär-logischen Operationen im Gegensatz zu KNN keine Verarbeitung von unsicherem, unvollständigem und unscharfem Wissen. Die Entscheidungsfindung in XPS basiert daher auf exaktem Schließen gegenüber evidentiellm Schließen in KNN (exact match vs. best match).⁶⁰ XPS weisen jedoch den entscheidenden praktischen Vorteil auf, ihre Entscheidungen mittels der Erklärungskomponente transparent und nachvollziehbar darlegen zu können.

Vorteile von XPS:⁶¹

1. Nachvollziehbarkeit der Systementscheidungen
2. Einfache Änderung des Wissens durch Modifikation der Regeln
3. Hohe Verarbeitungsgeschwindigkeit

57 Vgl. Mertens, P.; Borkowski, V.; Geis, W.: Betriebliche Expertensystem-Anwendungen, 2., völlig neu bearbeitete und erweiterte Aufl., Heidelberg et al.: Springer 1990, S. 9.

58 Vgl. Peter, E. T.: Artificial Intelligence und Expertensysteme, Vaterstetten: IWT 1990, S. 54 und Turban, E.: Decision support and expert systems: management support systems, 2. Aufl., New York: Macmillan 1991, S. 14.

59 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 19.

60 Vgl. Wilbert, R.: Kreditwürdigkeitsanalyse im Konsumentenkreditgeschäft auf der Basis Neuronaler Netze, in ZfB, 61. Jg, H. 12, 1991, S. 1383 und Kemke, C.: Der neuere Konnektionismus, a. a. O., S. 146.

61 Vgl. Medsker, L. R.: Hybrid Intelligent Systems, a. a. O., S 3f. und Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 19.

Nachteile von XPS:

1. Hoher Entwicklungsaufwand
2. Keine automatische Anpassung des Wissens an veränderte Entscheidungssituationen

5.2 Fuzzy Logic

Die Fuzzy Logic basiert auf der Theorie unscharfer Mengen (Fuzzy Set Theory) von Lotfi Zadeh.⁶² Hintergrund bildet die Erkenntnis, daß sich komplexe Systeme häufig nicht exakt beschreiben lassen und zur Modellierung derartiger Wissensbereiche unscharfe, vage Informationen berücksichtigt werden müssen. Mit der Theorie unscharfer Mengen kann z. B. Unschärfe der natürlichen Sprache durch Begriffe wie „stark“, „schwach“ oder „hoch“, „niedrig“ in Sprachverarbeitungssysteme Eingang finden. Die Fuzzy Logic repräsentiert vages, unscharfes Wissen, in dem fehlende Präzision sowie Vagheit und Unsicherheit beim Modellierungsprozeß toleriert werden. Der Einsatz von Fuzzy Logic erfolgt deshalb dort, wo exakte Modelle schwierig zu erstellen oder nicht vorhanden, inexakte Aussagen jedoch möglich sind.⁶³

Zentraler Baustein der Theorie unscharfer Mengen ist die Fuzzy-Menge (fuzzy set), die die klassische Mengenlehre erweitert. Dort sind Mengen durch scharfe Grenzen (clear-cut) voneinander unterschieden. Ein Beispiel aus Goontilake verdeutlicht dies am Preis für ein Paar Schuhe.⁶⁴ Die linguistischen Konzepte „teuer“ und „billig“ lassen sich in der konventionellen Mengenlehre zum Beispiel durch $teuer \geq 50$ und $billig < 50$ definieren. Ein Paar Schuhe ist billig, wenn es weniger als 50 Geldeinheiten (GE) kostet und teuer, wenn es 50 GE oder mehr kostet. Ein Preis von 50,50 GE wäre dementsprechend „teuer“ und ein Preis von 49,50 GE „billig“, dabei liegt der Preisunterschied nur bei 1 GE. Im alltäglichen Sprachgebrauch umschreiben die Begriffe „teuer“ und „billig“ nicht exakten Grenzen, sondern bestimmte Grade von „teuer“ und „billig“. So entspricht 49,50 GE gegenüber 50,50 GE einem höheren Grad von „billig“ oder einem niedrigeren Grad von „teuer“. Wie an dem Beispiel zu erkennen ist, sind für die Modellierung sprachlicher Konstrukte graduelle Zugehörigkeitsmaße realistischer, hier also ein gradueller Anstieg („teuer“) bzw. Abfall („billig“) je nach Preis. Fuzzy Mengen sind daher durch Zugehörigkeitsgrade definiert, für die die Theorie unscharfer Mengen die mathematischen Grundlagen beschreibt; auf dieser Basis kann mit Fuzzy-Mengen vergleichbar mit der klassischen Mengenlehre gerechnet werden kann.

Über die Festlegung der Zugehörigkeitsgrade wird die Wissensrepräsentation in Fuzzy-Systemen gesteuert. Das heißt, ein menschlicher Experte modelliert sein Wissen durch die Festlegung von Zugehörigkeitsgraden. Gegenüber Verfahren, die auf exakte Werte

62 Vgl. Zadeh, L.: Fuzzy Sets, in: Information and Control, 8/1965, S. 338-353.

63 Vgl. Kruse, R.: Fuzzy-Systeme - Positive Aspekte der Unvollkommenheit, in: Informatik Spektrum, 19/1996, S. 5 und Nauck, D.; Klawonn, F.; Kruse, R.: Neuronale Netze und Fuzzy-Systeme, 2., überarb. und erw. Aufl., Braunschweig/Wiesbaden: Vieweg 1996, S. 4.

64 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 16.

angewiesen sind, erzielt die Fuzzy Logic bei der Modellierung vager Zusammenhänge eine höhere Flexibilität unter Beibehaltung mathematisch exakter Berechnungen.

Zwei wichtige Anwendungen von Fuzzy Logic sind Fuzzy-Expertensysteme (Fuzzy XPS) und Fuzzy-Regelung (Fuzzy Control).

a) Fuzzy XPS

Die Fuzzy Logic wird in Expertensystemen (siehe dort) zur Repräsentation unscharfen Expertenwissens eingesetzt. Die Regelbasis wird durch Fuzzy Regeln (fuzzy inference rules) ergänzt oder ersetzt.⁶⁵ (Beispiel: IF prices are high AND production is low THEN low market share.) Das Problemlösen (Fuzzy Reasoning) unterscheidet sich hier von üblichen XPS dadurch, daß alle Fuzzy Regeln in die Entscheidung einbezogen werden und jede passende Folgerung mit ihrem jeweiligen Zugehörigkeitsgrad in die Entscheidung einfließt. Darin liegt letztendlich die Flexibilität der Fuzzy XPS begründet.⁶⁶ Betriebswirtschaftliche Anwendung findet die Fuzzy Logic u. a. im Short-Term Bond Rating bei der Fuji Bank in Tokio, in Datenbanksystemen oder im Devisenhandel.⁶⁷

b) Fuzzy-Regelung (Fuzzy Control)

Bei der Fuzzy-Regelung handelt es sich um regelungs- und steuerungstechnische Anwendungen im ingenieurs- und naturwissenschaftlichen Bereich. Im Gegensatz zu Fuzzy XPS liegen hier die Ein- (Sensordaten etc.) und Ausgabedaten (Steuerungsdaten) des System immer in scharfer Form vor. Die Systeme steuern physikalische Vorgänge und verwenden Fuzzy Logic nur zur internen Berechnung (Beispiel: Wenn Drehzahl zu hoch, dann senke Stromzufuhr geringfügig).⁶⁸ Oft genannte Beispiele aus der Praxis sind die U-Bahn im japanischen Sendai und diverse Haushaltsgeräte wie Waschmaschinen und Fotoapparate.

Vorteile von Fuzzy-Systemen:⁶⁹

1. Regelbasis einfach zu verstehen und zu interpretieren
2. Nachvollziehbarkeit der Ergebnisse
3. Verarbeitung von unscharfen Daten
4. Natürlicher Umgang mit qualitativen Werten

65 Vgl. Kantrowitz, M.; Horstkotte, E.; Joslyn, C.: "Answers to Frequently Asked Questions about Fuzzy Logic and Fuzzy Expert Systems", comp.ai.fuzzy, February 1997, ftp.cs.cmu.edu:/user/ai/pubs/faqs/fuzzy/fuzzy.faq, mkant+fuzzy-faq@cs.cmu.edu.

66 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 17.

67 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 18 und Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, a. a. O., S. 133.

68 Vgl. Kruse, R.: Fuzzy-Systeme - Positive Aspekte der Unvollkommenheit, a. a. O., S. 8.

69 Vgl. Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, a. a. O., S. 19 und Korus, D.: „Fuzzy und Neuronale Methoden der Künstlichen Intelligenz“, Vorlesung an der Universität Marburg, URL: <http://www.Mathematik.Uni-Marburg.de/~korus/FuzzyNN/VLFuzzyNN.html>.

Nachteile von Fuzzy-Systemen:

1. Teure und fehleranfällige Wissensakquisition; Regeln und Zugehörigkeitsfunktionen müssen in einem zeitintensiven Trial-and-Error-Prozeß manuell spezifiziert werden; hoher Entwicklungsaufwand.
2. Keine automatische Anpassung an Umweltveränderungen; neue Regeln müssen manuell eingegeben werden; fehlende Lernfähigkeit.
3. Unklarheit bei der Wahl problemangemessener Fuzzy Mengen (bzw. Zugehörigkeitsfunktionen), Fuzzy Regeln, Fuzzy Operatoren und Fuzzy Inferenz.

5.3 Evolutionäre Algorithmen (EA)

EA sind naturanaloge Optimierungsverfahren, die sich am Vorbild des natürlichen Evolutionsprozesses orientieren. Die Evolution wird dabei als langfristiger Optimierungsvorgang aufgefaßt. Verfahren aus diesem Bereich zeichnen sich dadurch aus, „daß sie während des Optimierungsprozesses vorübergehend Lösungsverschlechterung tolerieren und somit Suboptima wieder verlassen können.“⁷⁰ Zu den Hauptausprägungen der EA zählen die Genetischen Algorithmen, Evolutionäre Strategien sowie Evolutionäre und Genetische Programmierung.

Die Verfahren greifen auf die Darwinistische Idee des „survival of the fittest“ zurück und benutzen bekannte Mechanismen der Evolution: Sie verknüpfen Individuen (Lösungen eines Optimierungsproblems) durch die evolutionären Operatoren Reproduktion, Variation und Selektion. In einem iterativen Prozeß entstehen dabei neue Lösungen (Kinder), deren Erfüllungsgrad des Optimums (Fitness) mit anderen Individuen verglichen wird. Nur diejenigen Individuen „überleben“, deren Fitness hoch ist, so daß im Laufe der Iterationen (Generationen) immer bessere Lösungen entstehen. EA konvergieren deshalb mit jedem Iterationsschritt gegen das Optimum. Da Konvergenzbeweise nur eingeschränkt vorliegen, sind EA als Heuristiken anzusehen, die bei gegebenen Ressourcen (Zeitrestriktion u. ä.) ggfs. nur suboptimale Lösungen finden.

Betriebswirtschaftliche Anwendungen Evolutionärer Algorithmen finden sich in der Produktionsprogrammplanung (Losgrößen- und Auftragsreihenfolgenplanung), dem Vertrieb (Tourenplanung, Travelling-Salesman-Problem usw.) und der Finanzwirtschaft (Portfolio-Optimierung, Kreditwürdigkeitsprüfung).⁷¹ Weitere Anwendungsbereiche sind die Bildverarbeitung und das Maschinenlernen.

70 Vgl. Nissen, V.: Evolutionäre Algorithmen - Eine kurze Einführung, in: Softcomputing-Anwendungen im Dienstleistungsbereich - Schwerpunkt Finanzdienstleistungen, Hrsg.: Biethahn, J.; Kuhl, J.; Leisewitz, M.-C.; Nissen, V.; Tietze, M., Tagungsband zum 3. Göttinger Symposium Softcomputing am 27. Feb. 1997 an der Universität Göttingen, S. 1 (geringfügig überarb. Fassung des in der Zeitschrift Wirtschaftsinformatik, 37. Jg, 4/1995, S. 393-397 erschienenen Aufsatzes „Evolutionäre Algorithmen“).

71 Vgl. Goontilake, S.: Intelligent Systems for Finance and Business: An Overview, a. a. O., S. 15 und Nissen, V.: Evolutionäre Algorithmen - Eine kurze Einführung, a. a. O., S. 6 und Beasley, D.; Bull, D.; Martin, R. R.: An Overview of Genetic Algorithms: Part 1, Fundamentals, URL: http://ralph.cs.cf.ac.uk/pub/papers/ga_overview1.ps, S. 13 (auch in: University Computing, 15. Jg., 2/1993, S. 58-69) und Medsker, L. R.: Hybrid Intelligent Systems, a. a. O., S. 9.

EA ergänzen andere Verfahren des Soft Computing, in dem sie Vor- oder Nachoptimierungen vornehmen. In Verbindung mit KNN dienen EA der Initialisierung des Netzes mit voroptimierten Werten (Typologie, Gewichtsmatrix). Zugehörigkeitsfunktionen und Fuzzy Regeln lassen sich gleichfalls mit EA vorab optimieren. Darüber hinaus kooperieren EA mit anderen Optimierungsverfahren aus dem mathematisch-statistischen Bereich (z. B. Hillclimbing-Verfahren).

Vorteile der Evolutionären Algorithmen:⁷²

1. Es lassen sich parallele Hardware-Architekturen nutzen, da auf jedem Individuum separat operiert wird. EA erzielen daher hohe Verarbeitungsgeschwindigkeiten.
2. EA sind einfach mit anderen Verfahren kombinierbar.
3. EA sind insbesondere für hochkomplexe Problemstellungen geeignet.

Nachteile von Evolutionären Algorithmen:

1. Die problemspezifische Algorithmus-Entwicklung erweist sich durch einen Trial-and-Error-Prozeß bei der Wahl der Strategieparameter als kompliziert.
2. Heuristischer Charakter; fehlende Optimalitätsgarantie bei beschränkter Zeit

6 Entwicklungstendenzen Intelligenter Informationssysteme

Künstliche Neuronale Netze sind im Begriff, sich einen festen Platz unter den betriebswirtschaftlichen Problemlösungsverfahren zu verschaffen. Im Zuge steigenden Wettbewerbsdrucks sind Unternehmen immer stärker an neuen Verfahren zur Entscheidungsunterstützung interessiert und nehmen auch fehlende theoretisch fundierte Vorgehensmodelle und heuristische Eigenschaften in Kauf. Gleiches gilt auch für Evolutionäre Algorithmen und Fuzzy Logic, die bereits heute in Nischenanwendungen einen hohen Praxiseinsatz erfahren.

Die einzelnen intelligenten Problemlösungsverfahren gelten als größtenteils theoretisch erforscht und zum Teil bereits praxiserprobt. Bisher fehlt es jedoch an integrativen Ansätzen, die die jeweiligen Nachteile der einzelnen Verfahren kompensieren und Synergien ausnutzen. Intelligente hybride Informationssysteme versprechen eine effektivere Entscheidungsunterstützung und eine höhere Effizienz von Entscheidungsunterstützungssystemen. Seit Mitte der 80er Jahre wird verstärkt nach Integrationsmöglichkeiten einzelner intelligenter Verfahren in hybriden Systeme geforscht, ohne jedoch zu einem einheitlichen Ansatz oder gar einem generischem Vorgehensmodell zu gelangen. Die Integration erfolgt zur Zeit immer noch unter starken anwendungsspezifischen Restriktionen problemgezielt und nicht problemübergreifend. Es ist zu erwarten, daß sich durch zunehmende Erfahrung Vorgehensweisen zur Entwicklung von integrierten hybriden Ansätzen herausbilden werden, die auf mehrere Problemtypen angewendet werden können.

⁷² Vgl. Nissen, V.: Evolutionäre Algorithmen - Eine kurze Einführung, a. a. O., S. 394 und Goontilake, S.: Intelligent Systems for Finance and Business: An Overview, a. a. O., S. 9.

Literaturverzeichnis

- Allen, P.: Intelligent, Self-organizing Models in Economics and Finance, in: Intelligent Systems für Finance and Business, Hrsg.: Goontilake, S.; Treleaven, P., Chichster et al.: John Wiley & Sons 1995, S. 298-311.
- Arbeitskreis „Softcomputing in der Betriebswirtschaft“, in: Tagungsband zum 3. Göttinger Symposium Softcomputing am 27. Feb. 1997 an der Universität Göttingen, Hrsg.: Biethahn, J.; Kuhl, J.; Leisewitz, M.-C.; Nissen, V.; Tietze, M.
- Beasley, D.; Bull, D.; Martin, R.R.: An Overview of Genetic Algorithms: Part 1, Fundamentals, URL: http://ralph.cs.cf.ac.uk/pub/papers/ga_overview1.ps, S. 13. Auch in: University Computing, 15. Jg., 2/1993, S. 58-69.
- Becker, J.; Prischmann, M.: Konnektionistische Modelle - Grundlagen und Anwendungen, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 5, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., September 1991.
- Caudill, M.; Butler, C.: Naturally Intelligent Systems, Cambridge, MA: MIT Press 1990.
- Faißt, J.: Hierarchische Planung unter Einsatz Neuronaler Netze - Illustriert an Untersuchungen zum flexiblen Personalmanagement, Heidelberg: Physica 1993.
- Goontilake, S.: Intelligent Systems in Finance and Business: An Overview, in: Intelligent Systems in Finance and Business, Hrsg.: Goontilake, S.; Treleaven, P., Chichester et al.: John Wiley & Sons 1995.
- Graszynski, R.: Betriebswirtschaftliche Anwendungen Neuronaler Netze, Diplomarbeit, Johann Wolfgang Goethe-Universität, Frankfurt am Main: Fachbereich Wirtschaftswissenschaften 1993
- Hecht-Nielson, R.: Neurocomputing, Reading, MA et al.: Addison-Wesley 1990.
- Horster, B.; Schneider, B.; Siedentopf, J.: Kriterien zur Auswahl konnektionistischer Verfahren für betriebliche Probleme, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 15, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., März 1993.
- Kantrowitz, M.; Horstkotte, E.; Joslyn, C.: "Answers to Frequently Asked Questions about Fuzzy Logic and Fuzzy Expert Systems", comp.ai.fuzzy, Feb., 1997, <ftp.cs.cmu.edu:/user/ai/pubs/faqs/fuzzy/fuzzy.faq>, mkant+fuzzy-faq@cs.cmu.edu.
- Kemke, C.: Der neuere Konnektionismus, in: Informatik Spektrum, 11/1988, S. 143-162.
- Korus, D.: „Fuzzy und Neuronale Methoden der Künstlichen Intelligenz“, Vorlesung an der Universität Marburg, URL: <http://www.Mathematik.Uni-Marburg.de/~korus/FuzzyNN/VLFuzzyNN.html>
- Kratzer, K.-P.: Neuronale Netze - Grundlagen und Anwendungen, 2., durchges. Aufl., München et al.: Hanser 1993.
- Krause, C.: Kreditwürdigkeitsprüfung mit Neuronalen Netzen, Düsseldorf: IDW 1993.
- Kruse, R.: Fuzzy-Systeme - Positive Aspekte der Unvollkommenheit, in: Informatik Spektrum, 19/1996, S. 5 ff.
- Lohrbach, T.: Einsatz von Künstlichen Neuronalen Netzen für ausgewählte betriebswirtschaftliche Aufgabenstellungen und Vergleich mit konventionellen Lösungsverfahren, Göttingen: unitext 1994.
- Maren, A. J.; Harston, C.; Pap, R.: Handbook of Neural Computing Applications, San Diego: Acad. Press 1990.
- Mechler, B.: Intelligente Informationssysteme - Fuzzy Logic und Neuronale Systeme zur Unterstützung von Managemententscheidungen, Reading, MA et al.: Addison-Wesley 1995.
- Medsker, L. R.: Hybrid Intelligent Systems, Boston: Kluwer 1995.

- Mertens, P.: Die Theorie der Mustererkennung in den Wirtschaftswissenschaften, in: Schmalenbachs Zeitschrift für Betriebswirtschaftliche Forschung, 29/1977, S. 777-794.
- Mertens, P.; Borkowski, V.; Geis, W.: Betriebliche Expertensystem-Anwendungen, 2., völlig neu bearbeitete und erweiterte Aufl., Heidelberg et al.: Springer 1990.
- Müller, B.; Reinhardt, J.; Strickland M. T.: Neural networks: an introduction, 2. überarb. und korr. Aufl., Berlin et al.: Springer 1995.
- Nauck, D.; Klawonn, F.; Kruse, R.: Neuronale Netze und Fuzzy-Systeme, 2., überarb. und erw. Aufl., Braunschweig/Wiesbaden: Vieweg 1996.
- Niedereichholz, J.; Kruse, H.; Mechler, B.: Kombination symbolischer und subsymbolischer Systeme in Entscheidungsunterstützungssystemen, in: Wirtschaftsinformatik: Beiträge zur modernen Unternehmensführung; Festschrift zum 60. Geburtstag von Franz Steffens, Hrsg: Niedereichholz, J.; Schumann, W., Frankfurt am Main et al.: Campus 1993.
- Nissen, V.: Evolutionäre Algorithmen - Eine kurze Einführung, in: Softcomputing-Anwendungen im Dienstleistungsbereich - Schwerpunkt Finanzdienstleistungen, Hrsg.: Biethahn, J.; Kuhl, J.; Leisewitz, M.-C.; Nissen, V.; Tietze, M., Tagungsband zum 3. Göttinger Symposium Softcomputing am 27. Feb. 1997 an der Universität Göttingen, S. 1 (geringfügig überarb. Fassung des in der Zeitschrift „Wirtschaftsinformatik“, 37. Jg, 4/1995, S. 393-397 erschienenen Aufsatzes „Evolutionäre Algorithmen“).
- Pao, Y.-H.: Adaptive pattern recognition and neural networks, Reading, MA et al.: Addison-Wesley 1989.
- Peter, E. T.: Artificial Intelligence und Expertensysteme, Vaterstetten: IWT 1990.
- Rehkugler, H.; Poddig, T.: Anwendungsperspektiven und Anwendungsprobleme von Künstlichen Neuronalen Netzwerken, in: Information Management, 2/1992, S. 50-58.
- Rehkugler, H.; Poddig, T.: Neuronale Netze im Bankbetrieb, in: Die Bank, 7/1992, S. 413-419.
- Rehkugler, H.; Kerling, M.: Einsatz Neuronaler Netze für Analyse- und Prognosezwecke, in: Betriebswirtschaftliche Forschung und Praxis, 3/1995, S. 306-324.
- Retzko, R.; Schumann, M.: Lösungsmöglichkeiten von Tourenplanungsproblemen mit Selbstorganisierenden Neuronalen Netzen, Georg-August-Universität Göttingen, Abtlg. Wirtschaftsinformatik II, Arbeitspapier Nr. 11, Hrsg.: Schumann, M., Dezember 1994.
- Rumelhart, D. E.; McClelland, J. L., et al.: Parallel Distributed Processing. Volume 1: Foundations, Cambridge, MA et al.: MIT Press 1986.
- Rumelhart, D. E.; McClelland, J. L., et al.: Parallel Distributed Processing. Volume 2: Psychological and Biological Models, Cambridge, MA et al.: MIT Press 1986.
- Schneider, B.: Neuronale Netze für betriebliche Anwendungen: Anwendungspotentiale und existierende Systeme, Westfälische Wilhelms-Universität Münster, Institut für Wirtschaftsinformatik, Arbeitsbericht Nr. 22, Hrsg.: Becker, J.; Grob, H.-L.; Kurbel, K.; Müller-Funk, U., November 1993.
- Schöneburg, E.; Hansen, N.; Gawelczyk, A.: Neuronale Netze, Haar bei München: Markt & Technik 1990.
- Stahlknecht, P.: Einführung in die Wirtschaftsinformatik, 6., völlig überarb. und erw. Aufl., Berlin et al.: Springer 1993.
- Turban, E.: Decision support and expert systems: management support systems, 2. Aufl., New York: Macmillan 1991
- Wilbert, R.: Kreditwürdigkeitsanalyse im Konsumentenkreditgeschäft auf der Basis Neuronaler Netze, in ZfB, 61. Jg, 12/1991, S. 1383 ff.
- Wilbert, R.: Interpretation und Anwendung neuronaler Netze in den Wirtschaftswissenschaften, Frankfurt a. M. et al.: Peter Lang 1996.

Bisher erschienen

Stand: Dezember 2000 – Den aktuellen Stand der Reihe erfahren
Sie über unsere Web Site unter <http://wi.uni-giessen.de>

Nr. 1/1996	Grundlagen des Client/Server-Konzepts.....	Schwicker/Grimbs
Nr. 2/1996	Wettbewerbs- und Organisationsrelevanz des Client/Server-Konzepts.....	Schwicker/Grimbs
Nr. 3/1996	Realisierungsaspekte des Client/Server-Konzepts	Schwicker/Grimbs
Nr. 4/1996	Der Geschäftsprozeß als formaler Prozeß - Definition, Eigenschaften, Arten	Schwicker/Fischer
Nr. 5/1996	Manuelle und elektronische Vorgangsteuerung.....	Schwicker/Rey
Nr. 6/1996	Das Internet im Unternehmen - Neue Chancen und Risiken	Schwicker/Ramp
Nr. 7/1996	HTML und Java im World Wide Web.....	Gröning/Schwicker
Nr. 8/1996	Electronic-Payment-Systeme im Internet.....	Schwicker/Franke
Nr. 9/1996	Von der Prozeßorientierung zum Workflow-Management - Teil 1: Grundgedanken, Kernelemente, Kritik	Maurer
Nr. 10/1996	Von der Prozeßorientierung zum Workflow- Management - Teil 2: Prozeßmanagement und Workflow	Maurer
Nr. 11/1996	Informationelle Unhygiene im Internet.....	Schwicker/Dietrich/Klein
Nr. 12/1996	Towards the theory of Virtual Organisations: A description of their formation and figure.....	Appel/Behr
Nr. 1/1997	Der Wandel von der DV-Abteilung zum IT-Profitcenter: Mehr als eine Umorganisation.....	Kargl
Nr. 2/1997	Der Online-Markt - Abgrenzung, Bestandteile, Kenngrößen	Schwicker/Pörtner
Nr. 3/1997	Netzwerkmanagement, OSI Framework und Internet SNMP	Klein/Schwicker
Nr. 4/1997	Künstliche Neuronale Netze - Einordnung, Klassifikation und Abgrenzung aus betriebswirtschaftlicher Sicht	Strecker/Schwicker
Nr. 5/1997	Sachzielintegration bei Prozeßgestaltungsmaßnahmen.....	Delnef
Nr. 6/1997	HTML, Java, ActiveX - Strukturen und Zusammenhänge.....	Schwicker/Dandl
Nr. 7/1997	Lotus Notes als Plattform für die Informationsversorgung von Beratungsunternehmen.....	Appel/Schwaab
Nr. 8/1997	Web Site Engineering - Modelltheoretische und methodische Erfahrungen aus der Praxis	Schwicker
Nr. 9/1997	Kritische Anmerkungen zur Prozeßorientierung	Maurer/Schwicker
Nr. 10/1997	Künstliche Neuronale Netze - Aufbau und Funktionsweise	Strecker
Nr. 11/1997	Workflow-Management-Systeme in virtuellen Unternehmen	Maurer/Schramke
Nr. 12/1997	CORBA-basierte Workflow-Architekturen - Die objektorientierte Kernanwendung der Bausparkasse Mainz AG	Maurer
Nr. 1/1998	Ökonomische Analyse Elektronischer Märkte.....	Steyer
Nr. 2/1998	Demokratiopolitische Potentiale des Internet in Deutschland	Muzic/Schwicker
Nr. 3/1998	Geschäftsprozeß- und Funktionsorientierung - Ein Vergleich (Teil 1)	Delnef
Nr. 4/1998	Geschäftsprozeß- und Funktionsorientierung - Ein Vergleich (Teil 2)	Delnef
Nr. 5/1998	Betriebswirtschaftlich-organisatorische Aspekte der Telearbeit	Polak
Nr. 6/1998	Das Controlling des Outsourcings von IV-Leistungen	Jäger-Goy
Nr. 7/1998	Eine kritische Beurteilung des Outsourcings von IV-Leistungen.....	Jäger-Goy
Nr. 8/1998	Online-Monitoring - Gewinnung und Verwertung von Online-Daten.....	Guba/Gebert
Nr. 9/1998	GUI - Graphical User Interface.....	Maul
Nr. 10/1998	Institutionenökonomische Grundlagen und Implikationen für Electronic Business.....	Schwicker
Nr. 11/1998	Zur Charakterisierung des Konstrukts "Web Site".....	Schwicker
Nr. 12/1998	Web Site Engineering - Ein Komponentenmodell.....	Schwicker
Nr. 1/1999	Requirements Engineering im Web Site Engineering – Einordnung und Grundlagen.....	Schwicker/Wild
Nr. 2/1999	Electronic Commerce auf lokalen Märkten	Schwicker/Lüders
Nr. 3/1999	Intranet-basiertes Workgroup Computing	Kunow/Schwicker
Nr. 4/1999	Web-Portale: Stand und Entwicklungstendenzen.....	Schumacher/Schwicker
Nr. 5/1999	Web Site Security.....	Schwicker/Häusler
Nr. 6/1999	Wissensmanagement - Grundlagen und IT-Instrumentarium.....	Gaßen
Nr. 7/1999	Web Site Controlling.....	Schwicker/Beiser
Nr. 8/1999	Web Site Promotion	Schwicker/Arnold
Nr. 9/1999	Dokumenten-Management-Systeme – Eine Einführung	Dandl
Nr. 10/1999	Sicherheit von eBusiness-Anwendungen – Eine Fallstudie	Harper/Schwicker
Nr. 11/1999	Innovative Führungsinstrumente für die Informationsverarbeitung	Jäger-Goy
Nr. 12/1999	Objektorientierte Prozeßmodellierung mit der UML und EPK	Dandl
Nr. 1/2000	Total Cost of Ownership (TCO) – Ein Überblick.....	Wild/Herges
Nr. 2/2000	Implikationen des Einsatzes der eXtensible Markup Language – Teil 1: XML-Grundlagen.....	Franke/Sulzbach
Nr. 3/2000	Implikationen des Einsatzes der eXtensible Markup Language – Teil 2: Der Einsatz im Unternehmen	Franke/Sulzbach
Nr. 4/2000	Web-Site-spezifisches Requirements Engineering – Ein Formalisierungsansatz	Wild/Schwicker
Nr. 5/2000	Elektronische Marktplätze – Formen, Beteiligte, Zutrittsbarrieren	Schwicker/Pfeiffer
Nr. 6/2000	Web Site Monitoring – Teil 1: Einordnung, Handlungsebenen, Adressaten.....	Schwicker/Wendt
Nr. 7/2000	Web Site Monitoring – Teil 2: Datenquellen, Web-Logfile-Analyse, Logfile-Analyzer	Schwicker/Wendt
Nr. 8/2000	Controlling-Kennzahlen für Web Sites.....	Schwicker/Wendt
Nr. 9/2000	eUniversity – Web-Site-Generierung und Content Management für Hochschuleinrichtungen.....	Schwicker/Ostheimer/Franke

Bestellung (bitte kopieren, ausfüllen, zusenden/zufaxen)

Adressat: Professur für BWL und Wirtschaftsinformatik
 Fachbereich Wirtschaftswissenschaften
 Licher Straße 70
 D – 35394 Gießen
 Telefax: (0 641) 99-22619

Hiermit bestelle ich gegen Rechnung die angegebenen Arbeitspapiere zu einem Kostenbeitrag von DM 10,- pro Exemplar (MwSt. entfällt) zzgl. DM 5,- Versandkosten pro Sendung.

Nr.	An
1/1996	
2/1996	
3/1996	
4/1996	
5/1996	
6/1996	
7/1996	
8/1996	
9/1996	
10/1996	
11/1996	
12/1996	

Nr.	An
1/1997	
2/1997	
3/1997	
4/1997	
5/1997	
6/1997	
7/1997	
8/1997	
9/1997	
10/1997	
11/1997	
12/1997	

Nr.	Anz
1/1998	
2/1998	
3/1998	
4/1998	
5/1998	
6/1998	
7/1998	
8/1998	
9/1998	
10/1998	
11/1998	
12/1998	

Nr.	Anz
1/1999	
2/1999	
3/1999	
4/1999	
5/1999	
6/1999	
7/1999	
8/1999	
9/1999	
10/1999	
11/1999	
12/1999	

Nr.	Anz
1/2000	
2/2000	
3/2000	
4/2000	
5/2000	
6/2000	
7/2000	
8/2000	
9/2000	

Absender:

Organisation _____

Abteilung _____

Nachname, Vorname _____

Straße _____

Plz/Ort _____

Telefon _____ Telefax _____ eMail _____

Ort, Datum _____ Unterschrift _____