

## 2.2.4 Neuronale Netze, Bionik und Fuzzy Logik

### - Neuronale Netze

1894 kam es durch den Wiener Psychologen Siegmund **Exner** zur ersten expliziten Formulierung der Konzeption eines "Neuronalen Netzes".<sup>1/</sup> Neuronale Netzwerke sind virtuelle Netze in Computern, die Wissen speichern und dieses durch Selbstorganisation weiterentwickeln. Neuronale Netze arbeiten nach den Prinzipien des Konnektionismus und bestehen aus Verarbeitungseinheiten, die nach Vorbild der Neuronen im menschlichen Hirn miteinander verschaltet werden. Neuronale Netze sind massiv parallel verbundene Netzwerke aus einfachen Elementen und werden auch als "Neural Nets", "Neural Computing", "Collective Models", "Subsymbolic AI", "Parallel Distributed Processing", "Neuromorphic Systems", "Artificial Neural Networks" oder "Connectionist Models" bezeichnet.<sup>2/</sup> Neuronale Netzwerke können Daten in analoger Form prozessieren, sind schneller, ausfallsicherer durch Redundanz, haben mehr Rechenpower als Turing-Maschinen und erlauben simultan Daten abzurufen und zu verarbeiten.<sup>3/</sup> Neuronale Netze können eine große Anzahl komplexer Muster speichern, die für die Visualisierung in Virtuellen Realitäten oder für Roboterbewegungen von Bedeutung sind und sie können neue Muster im Kontext zu gespeicherten Mustern klassifizieren.<sup>4/</sup>

Neuronale Netze sind durch Assoziationsfähigkeit, Fehlertoleranz, Lernfähigkeit, Ausfallsicherheit und parallele Verarbeitung geprägt.<sup>5/</sup> Insofern sind Neuronale Netze höchst wirksame Rückkopplungsnetze, die uns durch parallele Verarbeitung von Informationen völlig neue Lösungsmöglichkeiten eröffnen. Hinter diesen komplexen Vernetzungen verbergen sich unsichtbare Muster in Form von Attraktoren. Hierbei haben komplexe Systeme die Fähigkeit, Muster zu suchen und diese zu erkennen. So werden Neuronale Netze zum Beispiel bei der Mustererkennung im Zahlungsverkehr von Banken eingesetzt. Die Verknüpfung von Neuronalen Netzen in Kombination mit der Fuzzy Logik (sogenannte Neuro-Fuzzy-Systeme) verspricht deshalb äußerst interessante Entwicklungsperspektiven.

Neuronale Netze basieren auf den Gesetzen der mathematischen Logik, wobei jeder Computer durch das einfachste aller Neuronalen Netze simuliert werden kann.<sup>6/</sup> Die Fähigkeit Prozesse gleichzeitig auszuführen, macht Neuronale Netze konventionellen von Neumann- Rechnern überlegen. Dies

bedeutet, daß ein Neuronales Netz zumindest über dieselben Eigenschaften wie eine Turing-Maschine verfügt und daß komplexere Neuronale Netze durch MPP (Massive Parallel Processing) womöglich Eigenschaften zeigen, die die Fähigkeiten einer universellen Turing-Maschine deutlich übersteigen. Die Turing-Maschine arbeitet mit einer symbolischen Repräsentation der Welt, während Neuronale Netze mit komplexen Mustern arbeiten, die nicht die Frage nach der logischen Struktur sondern nach dem Interface stellen, mit dem ein bestimmtes Muster hervorgebracht werden kann./7/ Ich möchte deshalb zu Ehren von Gödel eine theoretisch keine Rechenzeit benötigende parallele Maschine definieren, die ich Gödel-Maschine nenne (siehe Kapitel 4.4.4). Da diese Maschine eine unendliche Parallelität besitzt, gibt es auch kein Halteproblem, da jedes Problem im Jetzt gelöst wird. Natürlich ist diese Maschine nur theoretisch denkbar, jedoch scheinen die Entwicklungslinien vieler Maschinen darauf zuzulaufen.

- Forschungsschwerpunkte

Da geistige Prozesse vor allem parallel ablaufen, konzentriert sich die Forschung zunehmend auf Neuronale Netze als Ansatz für den Bau intelligenter Maschinen. Der eigentliche Pionier der Netzwerktheorie ist Gustav R. **Kirchhoff**, der die bedeutenden Strom- und Spannungssätze entwickelte. Später führte **Ashby** die ersten Untersuchungen zur Dynamik großer Netze mit Zufallsverknüpfungen durch. Relevante Modelle zu Netzen wurden von **Hopfield**, **McCulloch**, **Minsky**, **Rosenblatt** und **Steinbuch** entwickelt. McCulloch und **Pitts** betonen hierbei die Analogie der Neuronenverbindungen zur zweiwertigen Aussagenlogik. Die Arbeiten von **von Neumann** zu stochastischen Zellulären Automaten haben Analogien zu stochastischen Netzwerken, die folgende Merkmale haben:/8/

**1) Die Dynamik der Zustandsänderungen ist stochastisch, nichtlinear und asynchron.**

**2) Die Zustände der Knoten sind bistabil bzw. multistabil.**

**3) Die Zahl der Zustände des Gesamtsystems wächst exponentiell mit der Knotenzahl.**

Während es Rosenblatt mit seinem Neuronenmodell der Perceptrons im Jahre 1958 um das Verständnis der Arbeitsweise des Gehirns ging, wollte Minsky nur simulieren, was das Gehirn tut./9/ Jedoch war die Kritik von Minsky und **Papert** an Rosenblatt, die diese den konnektionistischen Ansätzen in ihrem Buch "Perceptrons" entgegenbrachten, voreilig, was dadurch deutlich wird, daß der Ansatz paralleler Rechnerstrukturen (PDP -

Parallel Distributed Processing) von **Rumelhart, McClelland** und **Hinton** gegenwärtig einer der wichtigsten Ansätze für die Simulation von Intelligenz ist. Wesentliche Forschungsschwerpunkte des PDP-Ansatzes sind gegenwärtig Hopfield-Netzwerke, Boltzmann-Maschinen, Classifier Systeme und evolutionäre Modelle. Ted **Hoff** und Bernard **Widrow** entwickelten ein ähnliches Netz wie das Perceptron, das sie Adaline nannten, welches in der Praxis als selbstregulierender Filter, z.B. für den Echo-Effekt bei Ferngesprächen, eingesetzt wird./10/

Besonders hervorzuheben ist die Erforschung von Neuronennetzen durch John Hopfield, der 1982 bewies, daß Techniken der theoretischen Physik zur Analyse, Beschreibung und Konstruktion Neuronaler Netze benutzt werden können./11/ Er entwickelte ein dynamisches Prinzip zur Mustererkennung, mit dem er Netzwerkmaschinen entwarf, die die Eigenschaften von assoziativen Gedächtnissen haben./12/ In seinem Modell haben Neuronen die zwei Zustände aktiv und passiv, wobei es von den Schwellenwerten abhängt, ob diese erregt oder gedämpft werden. Diese positive und negative Rückkopplung führt zu Aktivitätsmustern, die eine holistische Speicherung von Informationen erlauben, wie dies auch in unserem Gehirn geschieht./13/ Diese verteilte Form der Speicherung ermöglicht Netzwerken, Verluste von gespeicherten Daten zu ergänzen und somit ursprüngliche Muster wieder herzustellen. Das Hopfield-Modell kann somit ein ähnliches Verhalten wie das menschliche Gedächtnis simulieren./14/

Neben den deterministischen Hopfield-Netzwerken, gibt es die nicht-deterministischen Boltzmann-Maschinen./15/ Diese lernen durch "Simulated Annealing", wobei das Ziel des Lernens nicht die Formulierung expliziter Regeln ist, sondern vielmehr das Stärken von Verbindungen in Netzwerken (siehe hierzu auch die Mustererkennung in Kapitel 1.4). Während bei Hopfield-Systemen mit einer **Hebb'schen** Lernstrategie/16/ gearbeitet wird, nutzen Boltzmann-Maschinen die "Backpropagation"-Strategie"/17/ mit verdeckten Neuronen in mehreren Ebenen. Backpropagation arbeitet hierbei mit Feed-Forward-Prinzip und einem Fehlerkorrektur-Algorithmus, der ein Lernen des Neuronalen Netzes ermöglicht./18/ Bei Boltzmann-Maschinen berechnet, anders als bei Hopfield-Netzen, jedes Neuron die Nettoerregung und verändert dann seinen Zustand stochastisch./19/ Boltzmann-Maschinen sind Netzwerkarchitekturen mit verteilter Wissensrepräsentation und können immer dort eingesetzt werden, wo die Berechnungen von Hopfield-Netzen in lokalen Minima steckenbleiben./20/ Als Charakteristika von Boltzmann-

Maschinen, die auf die Arbeiten von **Ackley**, Hinton und **Sejnowski** zurückgehen, lassen sich angeben: /[21](#)/

### Charakteristika der Boltzmann-Lernmaschine

- 1) Hierarchische Ordnung mit Eingangs- und Ausgangsebene
- 2) Stochastische Kopplung der Elemente
- 3) Flipdynamik der Zustände der Knoten
- 4) Lern-, Test- und Korrekturphase
- 5) Zielabgleich der Kopplungsmatrix
- 6) Lernen bis zum gewünschten Output

Neuronale Netze benötigen eine vernetzte Hardware und eine intelligente Software zur Steuerung der Prozesse. Hierbei wird versucht, die Eigenschaften des menschlichen Gehirns bei der Informationserzeugung zu simulieren. **Wiener** betonte, daß ein System mit vielen Neuronen nicht über längere Zeit stabil gehalten werden kann, wie es die Selbstorganisation der Neuronen im menschlichen Gehirn verdeutlicht. /[22](#)/ Ähnlich den (ununterscheidbaren) Neuronen im Gehirn besteht ein Neuronales Netzwerk aus einer Menge von meist gleichartig strukturierten Prozessorelementen, die möglichst intelligent miteinander vernetzt werden müssen. Daß schon eine vergleichsweise geringe Menge von Neuronen erstaunliche Leistungen hervorbringt, zeigte das Netzwerkmodell mit 300 Neuronen der Konnektionisten Terrence **Sejnowski** und Charles **Rosenberg**. /[23](#)/ Die Berechnung der Verbindungen von Neuronenmodellen erfolgt meist in einem Iterationsverfahren durch verschiedene Algorithmen, die oft als Lernalgorithmen bezeichnet werden. Nachfolgende Übersicht zeigt die gängigen Modelle für Neuronale Netze und der verwendeten Lernalgorithmen:

Modell	Erfinder	Schichten	Impuls- ausbreitung	Lernalgorithmus	Probleme
Perceptron	Rosenblatt	2	feed-forward	überwachtes Lernen	trivial
Backpropagation	Rumelhart	>=3	feed-forward	überwachtes Lernen	komplex
Boltzmann - Maschinen	Boltzmann	>=3 feed	forward	Boltzmann -Learning	stochastisch
Kohonen- Netzwerk	Kohonen	2	rückgekoppelt	selbstklassifizierend	unbekannte Muster
Hopfield Netzwerk	Hopfield	1	rückgekoppelt	unüberwachtes Lernen	Muster- assoziiierer

Tab. 2.10: Modelle für Neuronale Netze

Feedforward-orientierte und rückkopplungsfreie Strukturen bei Neuronalen Netzen sind z.B. das Perceptron-Modell (zwei Schichten) und das Backpropagation-Modell (drei Schichten).[/24/](#) Das Problem des ursprünglichen Perceptrons war, daß es nur zwei Ebenen hatte und somit keine interne Repräsentation ermöglichte. Rumelhart und McClelland zeigten auf, daß ein Perceptron mit 3 Ebenen nahezu alle Typen logischer Probleme eines bestimmten Anwendungsbereichs lösen konnte. Das erste Mehrebenen-Netzwerk wurde 1980 von Leon **Cooper** und Charles **Elbaum** zur Einsatzreife gebracht; es bestand aus drei Ebenen variabel gewichteter Verbindungen und lernte Muster zu klassifizieren sowie sich durch Addition neuer Neuronen der Problemstellung anzupassen.[/25/](#)

Neuronale Netze der Informatik sind nach heutigem Kenntnisstand nur in ihren weiter- entwickelten Formen für das Verständnis hochkomplexer Verschaltungen interessant. Hierzu sind leistungsfähigere Neuronenmodelle mit eigenen Algorithmen und Millionen von virtuellen, mehrschichtig angeordneten Neuronen notwendig. Das Erkennen der Leistungsfähigkeit der Parallelverarbeitung hat dazu geführt, den Von-Neumann-Engpaß konventioneller Computer[/26/](#) zu überwinden. W. Daniel **Hillis'** Connection Machine ist ein Beispiel für einen Rechner mit parallel geschalteten Prozessoren, der bereits etwa 65.000 Berechnungen gleichzeitig durchführen kann (siehe auch Vorwort des Autors). Die Herstellung von Maschinen mit millionenfachem Parallelismus, die Milliarden von gleichzeitigen Prozessen berechnen können, ist durch die Revolution im Bereich der Mikrosystemtechnik und der zukünftigen Nanotechnologien nur noch eine Frage von wenigen Jahrzehnten (siehe auch Kapitel 4.4.3). Ein "Parallel Distributed Processing"-Modell (PDP-Modell) besteht hierbei aus acht wesentlichen Komponenten:[/27/](#)

1. Ein Set von Prozessoreinheiten
2. Ein Aktivierungszustand
3. Eine Output-Funktion
4. Ein Konnektivitätsmuster
5. Eine Propagation-Regel
6. Eine Aktivierungs-Regel
7. Eine Lern-Regel
8. Eine Systemumgebung

Die Propagation-Regel (5.) verbindet den Output-Vektor mit der Konnektivitäts-Matrix, um einen neuen Input-Vektor zu erzeugen. Dagegen verbindet die Aktivierungs-Regel (6.) die Inputs miteinander und somit mit

dem gegenwärtigen Zustand, um einen neuen Aktivierungszustand zu erzeugen./[28/](#)

Mittlerweile ist bekannt, daß einzelne Neuronen sehr viel mehr als nur ein oder einige Bit speichern können. Ein typisches, computerbasiertes, semantisches Netz braucht zur Darstellung eines Begriffs nur einige tausend Bit, ein semantisches Netz im menschlichen Gehirn wegen der Redundanz dagegen sehr viel mehr./[29/](#) Mit semantischen Netzen und ähnlichen Systemen lassen sich die Merkmale und Inhalte abstrakter Konzepte und Begriffe für Wissensdatenbanken in Computern recht erfolgreich repräsentieren. Datenstrukturen in Form semantischer Netze liefern eine formale Methodik zur Repräsentation eines breiten Spektrums von Wissen. Da sie im Computer leicht gespeichert und manipuliert werden können, sind sie ein leistungsfähiges und praktisches Werkzeug, mit dem sich die Struktur von zumindest einigen Arten von Wissen erfassen und nutzbar machen läßt. Hier stellt sich die Frage, wieviel Wissen und welche Art von Wissen wir mit unseren 1011 Neuronen beherrschen können.

Laut McClelland gibt es drei Schlüsselkonzepte des Gedächtnisses: der mentale Zustand als ein aktiviertes Muster, Gedächtnisspuren in Form von Veränderungen von Gewichtungen und für Rückgewinnung durch Wiederherstellung voriger Aktivierungsmuster./[30/](#) Jedoch gilt es, für diese Modelle die Lokalität und die Linearität (siehe auch **Kohonen**/[31/](#), **Oja** und **Lehtio**) zu überwinden und nichtlokale und nichtlineare Erklärungsansätze (siehe auch Hinton) zu entwickeln./[32/](#) Nach der Pellionisz-Llinás-Hypothese findet auf jeder synaptischen Ebene eine Tensor-Transformation statt./[33/](#) Daneben werden auch Vektor-Matrix-Modelle von Hinton und Sejnowski (visuelle Wahrnehmung) sowie von McClelland und Rumelhart (Worterkennung) als nichtlineare Erklärungsansätze verwendet./[34/](#) Die Geschwindigkeit der Vektor-Matrix-Multiplikation bei Neuronalen Netzen kann insbesondere durch das in Kapitel 1.2 behandelte SIMD-Modell der Parallelverarbeitung stark erhöht werden./[35/](#)

- "Classifier"-Systeme

In nichttrivialen Spielen, wie z.B. dem Management (Wettbewerb um Marktanteile), führen Min-Max-Strategien nicht zum Erfolg, vielmehr werden dort antizipative Strategien benötigt. Diese antizipativen Strategien sind ein wesentliches Element von adaptiven Neuronalen Netzwerken (ANNs von Rumelhart und McClelland) und den "Classifier"-Systemen von

**Holland.** "Classifier"-Systeme beruhen auf dem Prinzip der Induktion, die vor allem von Carl **Hempel** und Nelson **Goodman** untersucht wurde. Induktion ist eine problemlösende Aktivität, die auf Feedback basiert, welches den Erfolg oder das Versagen der durch das System erzeugten Annahmen bewertet./36/ Der Kern der Induktion besteht in der Erzeugung und Modifikation von Wissensstrukturen, wobei die induktiven Mechanismen sicherstellen müssen, daß die Systemregeln bewertet, daß neue plausible Regeln entworfen werden und daß Assoziationen zwischen und Gruppierungen von Regeln stattfinden./37/

"Classifier"-Systeme sind regelgestützte parallel arbeitende Systeme, die adaptiv neue Regeln generieren und die Effektivität existierender Regeln testen./38/ Ein "Classifier System" besteht aus einer Liste von Klassifizierern (C1, C2,.....,Cn), einer Liste von Nachrichten, einem Input-Interface und einem Output-Interface./39/ Classifier-Systeme eignen sich dort für einen Einsatz, wo die Rechenpower begrenzt ist. Der regelerzeugende Algorithmus für "Classifier Systems" ist der genetische Algorithmus. Eine weitere Anwendung des Genetischen Algorithmus kommt aus der Spieltheorie, wobei der Politologe Robert **Axelrod** das Gefangenendilemma untersuchte und mittels der Strategie TIT FOR TAT (Wie du mir, so ich dir) die besten Ergebnisse erzielte./40/

#### - Genetischer Algorithmus

Genetische Algorithmen sind hochparallele mathematische Algorithmen, die durch individuelles Verhalten ein komplexes Verhalten von Populationen hervorbringen können, die deren Gesamtfitness erhöht./41/ Lernen in Neuronalen Netzen entspricht einem Optimierungsprozeß, bei dem die Fehlerfunktion minimiert wird, wobei beliebige Methoden für diese Optimierung verwendet werden können, wie z.B. durch genetischen Algorithmen. Bei dieser Optimierung wird im Computer ein Evolutionsprozeß simuliert, in dessen Verlauf die Parameter bestimmt werden, die ein Minimum oder ein Maximum einer Funktion produzieren./42/ Da deduktive Methoden für die Vorhersage von Preisentwicklungen an den Finanzmärkten unmöglich sind, haben **Arthur** (siehe Kapitel 4.3.4.3) und **Holland** versucht, mit induktiven Methoden (wie z.B. genetischen Algorithmen) sich solchen Problemstellungen zu nähern, um wiederhol- und kontrollierbare Experimente mit komplexen Systemen wie Aktienmärkten durchführen zu können.

Holland arbeitet vor allem an komplexen adaptiven Systemen ("Complex Adaptive Systems"), wobei es ihm vor allem um ein Verständnis der sich wandelnden Muster geht. Er hat z.B. ein Modell entworfen, das er Echo-Modell nennt und mit dem er die Emergenz von Organisation in adaptiven Systemen untersucht./43/ Die darin zentralen Akteure verfügen über die Fähigkeit zum Lernen und somit zur langfristigen Adaption an veränderte Strukturen durch ein organisiertes Set von Daten und durch induktives Finden von Gesetzen, die die Daten generieren./44/ In diesem Kontext ist die 1976 von Stephen **Grossberg** entwickelte "Adaptive Resonance Theory (ART)" interessant, nach der Neuronale Netze über eine Art Lang- und Kurzzeitgedächtnis sowie über einen Aufmerksamkeits-Mechanismus verfügen können, der das Lernen steuert./45/

Beim genetischen Algorithmus wird das Optimum der Funktion von mehreren Richtungen gleichzeitig gesucht und die Pfade zum Optimum werden simultan verarbeitet, was jedoch zu einem wesentlich höheren Rechenaufwand als bei einem einfachen "Random Search"-Verfahren führt. Da sich jedoch genetische Algorithmen gegenüber anderen stochastischen Methoden mit wenig Aufwand parallelisieren lassen und somit aus mehreren Richtungen gleichzeitig suchen, haben diese gegenüber lokalen Methoden, wie z.B. der Gradientenstrategie den Vorteil, daß lokale Minima oder Maxima verlassen werden können, wenn die Suche an anderer Stelle erfolgversprechender erscheint./46/ Zum Grundmodell des genetischen Algorithmus gehören eine Codierung des Optimierungsproblems, ein Mutationsoperator und eine Menge von Austauschoperatoren von Datenketten./47/ Genetische Algorithmen eignen sich unter anderem bei Roboterprogrammierungen, Mustererkennungsproblemen, Minimax-Strategien oder für das Training Neuronaler Netze./48/ Hybride Formen adaptiver Algorithmen durch Kombination von genetischen Algorithmen und Neuronalen Netzen können darüber hinaus die Basis für intelligente Parallelrechner bilden (siehe Kapitel 1.2)./49/

#### - Bionik und Evolutionsstrategie

Die Bionik setzt sich aus den Begriffen Biologie und Technik zusammen und nimmt die Natur als Vorbild für technische Problemlösungen. Deshalb sind nicht größere Rechner die Lösung, sondern ein Verstehen der Wechselwirkung biologischer und technischer Phänomene. Zu den Forschungsthemen der Bionik zählen unter anderem die datenverarbeitende Funktion des Neurons, die Mustererkennung in Neuronalen Netzwerken und

die Organisationsformen komplexer biologischer Regulationssysteme./50/ Die Bionik hat in den letzten Jahren zunehmende Bedeutung erlangt. Momentan werden in Japan bionische Produktionssysteme entworfen ('Bionic Manufacturing System'), die den Anforderungen an Spontaneität, Beweglichkeit und Harmonie gerecht werden sollen, wobei die Informationsanordnung der DNS sowie dynamische Strukturen biologischer Organismen berücksichtigt werden.

Während genetische Algorithmen die Ursache imitieren und primär rekombinieren, ahmen die Evolutionsstrategien/51/ die Wirkung nach und mutieren vorrangig./52/ Rechenbergs Evolutionsstrategie und Hollands genetische Algorithmen, die auf starker Kausalität beruhen, sind ähnliche Techniken, um die Evolution zu beschreiben. Hierbei gilt es, Strategien zu finden, die stabil gegenüber anderen Strategien sind, d.h. sogenannte evolutionär stabile Strategien. Während **Rechenberg** sich auf die Simulation von Mutationsereignissen konzentriert, beruhen die genetischen Algorithmen von Holland auf der Rekombination des genetischen Materials./53/ Sowohl Neuronale Netze als auch Genetische Algorithmen führen zu rechnergestützten adaptiven Systemen, die Strategien entwickeln können, die sich bisher noch kein Mensch ausgedacht hat./54/

Da es die Aufgabe der Evolutionsstrategie ist, Strukturen zu optimieren, wird diese zunehmend für die Optimierung von Interfaces Bedeutung gewinnen. Das generelle Schema einer Evolutionsstrategie beinhaltet nach Becker Genpopulationen, Fitneß, Umwelt und Selektion; genetische Operatoren wie Mutation, Rekombination und Cross-Over sowie Fortpflanzung und Iterationsprozesse./55/ Rechenberg hat die Evolutionsstrategie unter anderem zur Optimierung von Tragflächen, von Rohrkrümmern oder Düsenformen angewendet./56/ Die Evolutionsstrategie operiert in n-dimensionalen Räumen (Hyperräumen) derart, daß diese lokale Fortschritte bei der Optimierung erzielt./57/58/ Entscheidend bei mehrgliedrigen Evolutionsstrategien ist die Konvergenzrate bei einer bestimmten Mutations- und Selektionsbedingung, wobei der Prozess von der Fähigkeit des Selbst-Lernens während des Such-Verhaltens abhängt./59/ Rekombination als zusätzliches Prinzip ermöglicht eine deutliche Verbesserung des Lernprozesses, da somit die Verbesserung der eigenen Spielregeln ermöglicht wird. Durch die Anwendung evolutionärer Grundprinzipien kann ein tieferes Verständnis für die kollektiven Lernprozesse lebender Systeme gewonnen werden./60/

## Fuzzy Logik

Chaosphänomene zeigen uns, daß die hinreichenden Bedingungen von Entwicklungsprozessen nicht bestimmbar sind. Zwar können die Bedingungen der Unvorhersagbarkeit angegeben, es können jedoch keine Vorhersagen gemacht werden. Damit stellt die Chaosforschung einen Gegensatz zur positivistischen Wissenschaftsphilosophie dar, bei der Aussagen überprüfbar und beweisbar sein müssen. Die Chaostheorie hat den Weg von der Zweiwertigkeit zur Vielwertigkeit, vom seriellen zum parallelen Prozessdenken geebnet. Mit der Unbestimmtheit chaotischer Prozesse kommt die Wahrscheinlichkeit auch in die Logik zurück. Wahrscheinlichkeit als Begriff ist immer dann nützlich, wenn man eine Frage nicht mit Gewißheit beantworten kann/[61/](#), wozu **Primas** ausführt:/[62/](#)

"Vagueness is an important factor of every discourse, in fact it generates all the richness of the world."

Ein bekanntes Beispiel für das Denken in Wahrscheinlichkeiten ist das sogenannte Ziegenproblem, welches aufzeigt, daß wir einem Trugschluß unterliegen, wenn wir uns um die Vergangenheit einer Entscheidungssituation nicht kümmern und so tun, als stünden wir vor einer gänzlich neuen Entscheidung: Stehen bei einer Rateshow hinter einer Tür ein Preis und hinter den beiden anderen zwei Ziegen, so ist die Wahrscheinlichkeit nach dem 1. Falsch-Raten nicht 50:50, sondern es gibt eine Tür die eine höhere Wahrscheinlichkeit besitzt./[63/](#) Ein anderes Beispiel ist, daß die Gewißheit der Unwahrscheinlichkeiten mit der Zeit ansteigt/[64/](#), was auch als self-fulfilling prophecy bezeichnet wird. Da bei zunehmender Komplexität eines Systems unsere Fähigkeit, Aussagen über das Verhalten des Systems zu machen, abnimmt, ist das Aufkommen einer neuen Logik ein zwingender Schritt zur Bewältigung der anstehenden Phasenübergänge. Der Zweiwertigkeit von A oder Nicht-A steht die Vielwertigkeit einer neuen Logik gegenüber, die als Fuzzy Logik bezeichnet wird, wozu bereits **Russell** ausführte:/[65/](#)

"Die Welt der Existenz ist etwas Fließendes, Vages, ohne scharf umrissene Grenzen, ohne klare Planung und Anordnung."

Die Fuzzy Logik repräsentiert das verbindende Element zwischen der Mathematik und den Computern. Fuzzy Logik heißt im Grunde aus ungenauen Zahlen und unscharfen Mengen Aussagen über Entwicklungen zu treffen. Der Begründer des Begriffs Vagheit war Max **Black**/[66/](#) im Jahr

1937. Fuzzy Logik ist somit eine Art deterministisch chaotisches Interface für die Wahrnehmung komplexer Problemstellungen. Ein fuzzy-logisches System besteht aus einer Menge von unscharfen Wenn-dann-Regeln, die dem gesunden Menschenverstand entsprechen. Da die nichtlinearen Gleichungen in komplexen Situationen schwer zu erfassen sind, ist es von großem Vorteil, die Zusammenhänge durch Fuzzy Logik abzuschätzen, da sich der Anwender nicht um komplexe Gleichungssysteme kümmern muß. Hierdurch sind Steuerungssysteme mit minimalem Gedächtnis möglich, die bessere Ergebnisse erzielen, als die leistungsfähigsten kybernetischen Modelle. Die Abstimmung der fuzzy-logischen Regeln kann hierbei durch den Menschen oder mit Hilfe Neuronaler Netze erfolgen.

Technische Bedeutung gewann die Fuzzy Logik vor allem durch die Arbeiten von Lofti **Zadeh** über Fuzzy Sets im Jahr 1965. Die Fuzzy Logik wurde vor allem durch Innovationen im Bereich der Sensortechnik beschleunigt und ermöglicht es, die Problemlösungsfähigkeit von Maschinen drastisch zu verbessern. Durch fuzzy-logische Komponenten (z.B. durch Kalman-Filter) können Flugzeuge, Raumfähren oder Raketen besser auf ihren Bahnen gehalten werden. Das FAT-Theorem (Fuzzy Approximation Theorem) besagt, daß ein fuzzy-logisches System jedes System modellieren und somit näherungsweise erfassen kann./67/ Insbesondere bei allen Arten von Interfaceproblemen wie Wahrnehmung, Beobachtung oder Mustererkennung sind fuzzy-logische Systeme zukünftig nicht mehr wegzudenken. Fuzzy Logik ist deshalb ein elementarer Bestandteil für eine endoorientierte Denkweise, die den Aufbau komplexer Wissensstrukturen ermöglicht. Dies ist auch deshalb von wesentlicher Bedeutung, da Daten die Entscheidungsprozessen zugrunde liegen oftmals unscharf sind. Aufgrund der Fuzzy-Charakteristik von Daten ist es deshalb unbedingt notwendig, nur korrekte, relevante und möglichst genaue Daten/68/ zu verwenden./69/

**- Parallelverarbeitung erhöht die Machtpotentiale komplexer Netzwerke.**

**- Nichtlineare Vernetzungen führen zu unvorhersagbarem Verhalten und ermöglichen die Erzeugung neuer Bedeutungen.**

**- Mutationen im Rahmen von Evolutionsstrategien schaffen neue Freiheiten für komplexe Interfaces.**

**- Die Fuzzy Logik ermöglicht neue Freiheiten im Rahmen der Entscheidungsfindung.**

Abb. 2.23: Konsequenzen für Macht und Freiheit

**Wissenschaftliche Kontexte:** **Auswirkungen auf das Management:**

- |   |   |
|---|---|
| - Neuronale Netze und Fuzzy Logik sind aufgrund ihrer Nähe zu biologischen Vorbildern geeignete Instrumente für die Simulation von Informationserzeugung.   | - Neuronale Netze können zur Entscheidungsfindung bei komplexen Problemstellungen herangezogen werden.  |
| - Neuronale Netze arbeiten nach den Prinzipien des Konnektionismus und bestehen aus Verarbeitungseinheiten, die nach Vorbild der Neuronen im menschlichen Hirn miteinander verschaltet werden.          | - Neuronale Netze können als Vorbild für komplexe Organisationsstrukturen dienen.   |
| - Genetische Algorithmen sind hochparallele mathematische Algorithmen, die durch individuelles Verhalten ein komplexes Verhalten von Populationen hervorbringen können, die deren Gesamtfitness erhöht. | - Sollten Neuronale Netze sogar lernen, wie man lernt, eröffnet dies neuartige Möglichkeiten zur intelligenten Filterung von Daten, zur Prognose von Zeitreihen und zur Erkennung komplexer Muster. |
| - Lernen in Neuronalen Netzen entspricht einem Optimierungsprozeß, bei dem die Fehlerfunktion minimiert wird.   | - Genetische Algorithmen eignen sich als Optimierungsstrategien bei komplexen Managemententscheidungen.   |
| - Die Bionik setzt sich aus den Begriffen Biologie und Technik zusammen und nimmt die die Natur als Vorbild für technische Problemlösungen.   | - Innovations-Manager sollten sich verstärkt um die Synergien zwischen Biologie und Technik kümmern.  |
| - Fuzzy Logik heißt im Grunde aus ungenauen Zahlen und unscharfen Mengen Aussagen über Entwicklungen zu treffen.  | - Fuzzy Logik ermöglicht die Lenkung komplexer Interfaces in komplexen Problemsituationen.  |

Abb. 2.24: Konsequenzen für das Endo-Management

---

[1](#) Vgl. Maes (Software), 41.

[2](#) Vgl. Miller (Networks), 1-4.

[3](#) Vgl. Miller (Networks), 1-13.

[4](#) Vgl. Miller (Networks), 1-10.

[5](#) Vgl. Seraphin (Netze), 28f.

[6](#) Vgl. Casti (Worlds), 157.

[7](#) Die Frage nach der Konstruktion von Interfaces wird insbesondere von der Robotik, der Nanotechnologie und der Gentechnologie gestellt.

[8](#) Vgl. Ebeling (Chaos), 92.

[9](#) Vgl. Pagels (Reason), 122.

[10](#) Vgl. Schmidt (Neuronen), 66.

[11](#) Vgl. Schmidt (Neuronen), 66.

[12](#) Vgl. Ebeling (Chaos), 69f.

[13](#) Vgl. Davies (Chaos), 265.

[14](#) Das Verhalten ist jedoch nur ähnlich, da Erinnerung mit Kontexten und nicht mit gespeicherten Daten wie beim Computer arbeitet. Hopfield-Netzwerke sind jedoch neurologisch nicht korrekt, da sich Neuronen im Gehirn nicht symmetrisch verbinden. Gleiches gilt natürlich für die Verbindung von Prozessoren in der Connection Machine von Hillis (siehe nachfolgend), jedoch erleichtern symmetrische Modelle dem Menschen die Konstruktion komplexer mehrdimensionaler Netze.

[15](#) Die Boltzmann-Maschine hat keine Output-Funktion, sondern nutzt eine sehr komplexe stochastische Input-Funktion.

[16](#) Hebb-Regel: Je öfter eine Verbindung genutzt wird, desto stärker wird diese.

[17](#) Beim Training von Neuronalen Netzen hat sich insbesondere der Backpropagation-Algorithmus bewährt, bei dem Knoten so eingestellt werden, daß die Abweichungen zwischen den tatsächlichen und den gewünschten Ausgaben möglichst gering werden. Da der Algorithmus jedoch Lernen so

modelliert, daß Signale auch entgegengesetzt zur vorgegebenen Richtung verarbeitet werden können und die Geschwindigkeit des Algorithmus bei großen Netzen stark abnimmt, ist seine Anwendung umstritten.

[18](#) Vgl. Cowan (Intelligence), 112.

Bereits 1954 wurde von Dennis Gabor, dem Erfinder der Holographie, ein "Lernfilter" erfunden.

[19](#) Vgl. Rojas (Netze), 322.

[20](#) Vgl. Rojas (Netze), 332.

[21](#) Vgl. Ebeling (Chaos), 92f.

[22](#) Vgl. Wiener (Kybernetik), 211.

[23](#) Vgl. Mechsner (Chaos), 127.

[24](#) Vgl. Seraphin (Netze), 31f.

[25](#) Siehe hierzu auch Johnsons Buch Cognizers.

[26](#) Arbeiten mit nur einem Prozessor.

[27](#) Rumelhart (Processing), 46.

[28](#) Vgl. Rumelhart (Processing), 51.

[29](#) Bei einem grob geschätzten durchschnittlichen Redundanzfaktor von einigen Zehntausend schätzt man die Gesamtspeicherkapazität des Gehirns auf eine Million Begriffe.

[30](#) Vgl. McClelland (Learning), 176.

[31](#) Das bekannteste Beispiel für selbstorganisierende Netze, bei denen keine explizite Ausgabe und somit auch keine Fehlerfunktion vorgeschrieben ist, ist das von Teuvo Kohonen. Das kompetitive Lernmodell von Kohonen benötigt im Gegensatz zum Backpropagation-Modell keinen Lehrer. In diesem Modell werden nicht nur die Gewichte des erfolgreichsten Knotens modelliert, sondern auch die der nächsten Nachbarn. Beim "Competitive Learning" findet die Klassifizierung durch ein Mehrebenen-System statt. Vgl. Johnson (Cognizers), Kapitel "Learning to Learn".

Siehe dazu auch die Arbeiten von "von der Malsburg", Grossberg, Fukushima.

[32](#) Mehrdimensionale Phasenräume scheinen sich optimal für die Beschreibung neuronaler Prozesse zu eignen. Eine interessante Theorie zum Verständnis von Repräsentationen im Gehirn ist die Tensor-Netzwerk-Theorie, wobei Tensor-Transformationen die Phasenübergänge von einem Zustand zum anderen beschreiben. Vgl. Churchland (Neurophilosophy), 452.

[33](#) Vgl. Churchland (Neurophilosophy), 436.

[34](#) Vgl. Churchland (Neurophilosophy), 457.

[35](#) Vgl. Rojas (Netze), 417.

[36](#) Vgl. Holland (Induction), 9.

[37](#) Vgl. Holland (Induction), 68.

[38](#) Vgl. Holland (Induction), 3.

[39](#) Vgl. Holland (Induction), 105.

[40](#) Vgl. Levy (Leben), 226.

[41](#) Vgl. Koza (Computer), 606.

[42](#) Vgl. Rojas (Netze), 377.

[43](#) Vgl. Holland (Hidden), 144.

[44](#) Vgl. Holland (Hidden), 94.

[45](#) Vgl. Schmidt (Neuronen), 66.

[46](#) Vgl. Rojas (Netze), 378.

[47](#) Vgl. Rojas (Netze), 381.

[48](#) Vgl. Koza (Computer), 609.

[49](#) Vgl. Belew (Networks), 543.

[50](#) Vgl. Rechenberg (Evolutionsstrategie), 258.

[51](#) Das Wort Strategie weist auf eine zielorientierte Entwicklung hin.

[52](#) Vgl. Rechenberg (Evolutionsstrategie), 220.

[53](#) Vgl. Wagner (Evolutionsforschung), 227.

[54](#) Vgl. Gell-Mann (Quark), 433.

[55](#) Vgl. Becker (Evolution), 214.

[56](#) Vgl. Rechenberg (Evolutionsstrategie), 263-285.

[57](#) Bei dieser gibt es unterschiedliche Strategien: die Gradientenstrategie (folgt dem steilsten Anstieg der Funktion), die Gauß-Seidel-Strategie (eindimensionale Optimierungsabschnitte mehrdimensionaler Probleme) und die extrapolierende Gradientenstrategie (Mischform der vorigen Strategien). Vgl. Rechenberg (Evolutionsstrategie), 309ff.

[58](#) Gradienten-Strategien zählen zu den Hill-Climbing-Strategien und unterliegen einem inneren linearen Modell, woraus die Richtung des lokal steilsten Anstiegs als die beste abgeleitet wird.

Vgl. Schwefel (Lernprozesse), 18.

[59](#) Vgl. Schwefel (Lernprozesse), 23.

[60](#) Vgl. Schwefel (Lernprozesse), 17. Michael Conrad beschäftigt sich ebenfalls mit Computermodellen für evolutionäres Lernen, die eine parallele Zufallssuche starten, bei dem eine endliche Zahl von Systemen zufälligen Mutationen unterzogen wird.

[61](#) Vgl. von Randow (Ziegenproblem), 14.

[62](#) Primas (Cut), 14.

[63](#) Vgl. von Randow (Ziegenproblem), 6.

[64](#) Vgl. von Randow (Ziegenproblem), 143.

[65](#) Russell (Philosophie), 89.

[66](#) Er führte philosophische Betrachtungen zur Quantentheorie durch.

[67](#) Vgl. Kosko (Fuzzy-logisch), 192.

[68](#) Unter Abwägung von Kosten-Nutzen-Gesichtspunkten.

[69](#) Vgl. Schmid (Entscheidungen), 96.