

I. EINFÜHRUNG UND ÜBERSICHT

I.1 Das menschliche Gehirn

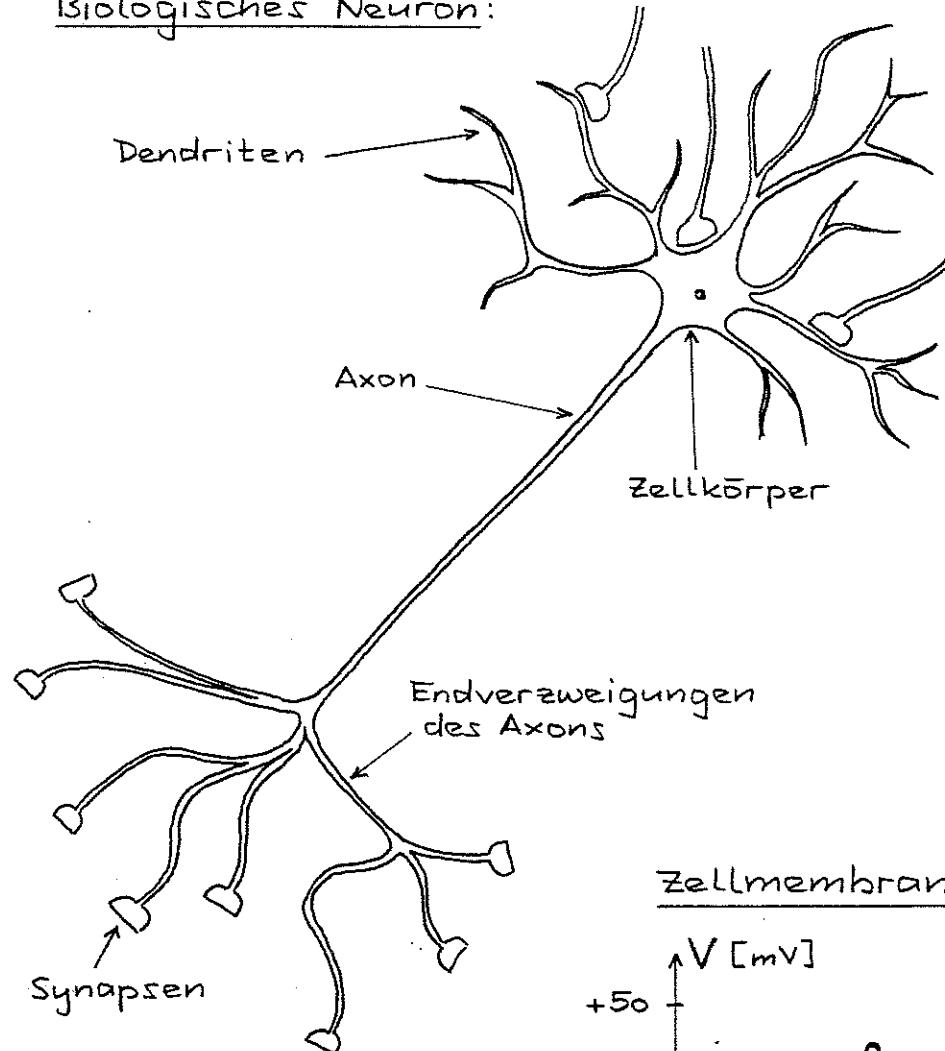
- Ein menschliches Gehirn besteht aus ca. 10^{10} Nervenzellen (Neuronen), die durch ca. 10^{15} synaptische Verbindungen miteinander verknüpft sind.
- Die neuronalen Response-Zeiten betragen einige Millisekunden, und die Information, die von einem Neuron zu einem anderen übertragen wird, ist sehr klein (einige Bits).

Trotzdem erkennen wir z.B. ein Gesicht in einigen Zehntelsekunden, d.h. in nur etwa 100 elementaren Zeitschritten.

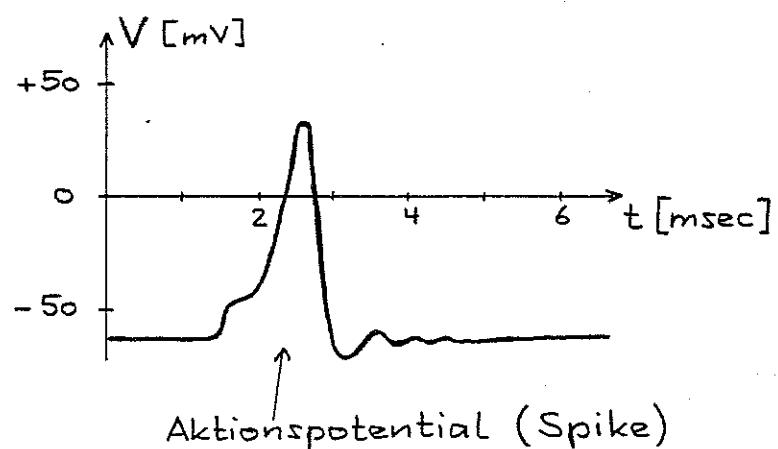
→ Parallel Informationsverarbeitung

→ Kritische Information ist im Verknüpfungsmuster gespeichert
- Das Muster der synaptischen Verbindungen und ihre Übertragungsstärken können sich verändern.
→ Lernfähigkeit
- Das Gehirn ist sehr fehlertolerant. Es funktioniert auch nach mehreren Jahrzehnten noch ohne merkliche Degradation, obwohl jede Sekunde etwa 3 Neuronen sterben (in 10 Jahren also etwa 10^9 , d.h. 1%).
- Das biologische Neuron ist eine faserig verzweigte Zelle. Diese Struktur hängt mit dem Funktionsprinzip des Gehirns (Informationsübertragung durch adressierte Mitteilungen) zusammen.

Biologisches Neuron:

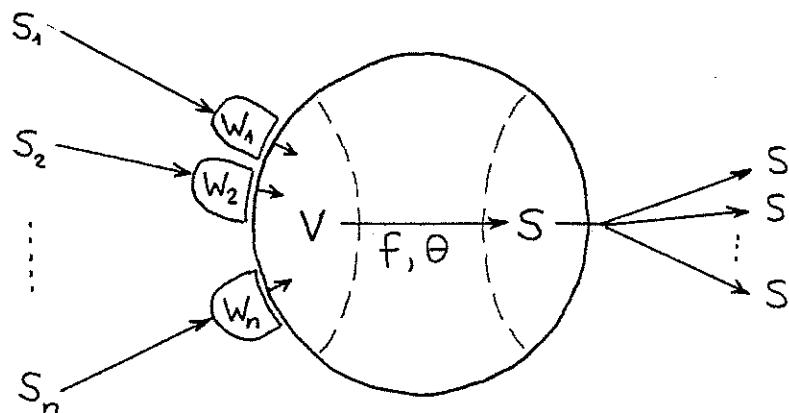


Zellmembran-Potential:

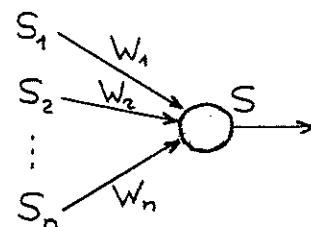


Die ankommenden Signale werden durch die Synapsen auf den Dendritenbaum übertragen. Die resultierenden Potentialstörungen werden am Fuss des Axons summiert. Wenn die totale Erregung eine bestimmte Schwelle überschreitet, wird dort ein Spike erzeugt und als elektrisches Signal vom Axon unabgeschwächt weitergeleitet. Dabei bestimmt die Höhe des durchschnittlichen Erregungsniveaus die Länge der Intervalle zwischen aufeinanderfolgenden Spikes. (Je höher das Erregungsniveau, desto kürzer die Intervalle, d.h. desto grösser die Aktivität des Neurons)

I.2 Künstliche Neuronen



Vereinfacht:



W_i : synaptische Stärken (Gewichte) $W_i \geq 0$

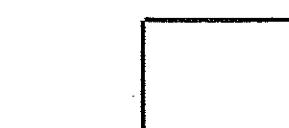
V : Erregung $V = \sum_{i=1}^n W_i S_i$

S : Aktivitätszustand $S = f(V - \theta)$

θ : Schwelle

f : Aktivierungsfunktion

z.B.

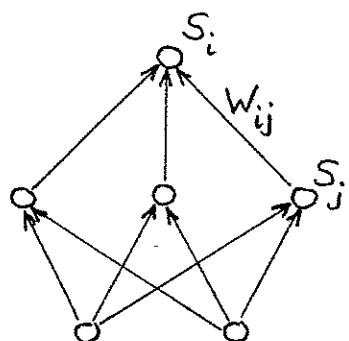


$\rightarrow S = 0, 1$ oder ± 1

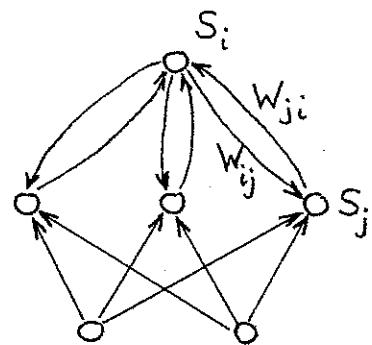


$\rightarrow 0 \leq S \leq 1$ oder $-1 \leq S \leq 1$

I.3 Neuronale Netzwerke



feedforward

recurrent
(mit Feedback)

- Dynamik:

$$S_i(t+1) = f \left(\sum_j W_{ij} S_j(t) - \theta_i \right)$$

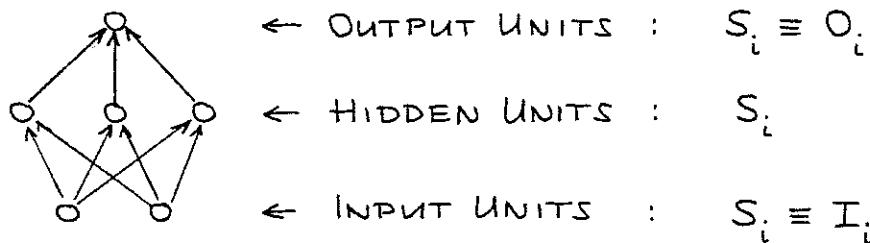
- In Feedforward-Netzwerken besteht der dynamische Prozess aus einem einzigen Durchgang.
- In Netzwerken mit Feedback wird so lange iteriert, bis ein stabiler Aktivitätszustand erreicht ist.
- Die zeitliche Änderung der Aktivitätszustände S_i kann synchron oder asynchron erfolgen.

- Vereinfachte Schreibweise durch Einführung eines zusätzlichen Neurons ($j=0$) mit konstanter Aktivität $S_0(t) \equiv 1$ und mit $W_{i0} = -\theta_i$:

$$\rightarrow S_i(t+1) = f \left(\sum_j W_{ij} S_j(t) \right)$$

- Input/Output:

Input und Output werden durch S_i -Konfigurationen dargestellt. Dabei können alle Neuronen zur Spezifikation der Input- und Output-Konfigurationen benutzt werden, oder:



- Speicherung der Information:

$\underline{O} = \underline{O}(\underline{I}, \underline{W})$: → In neuronalen Netzwerken ist die Information delokalisiert im Muster der Verbindungsgewichte W_{ij} gespeichert.

- Lernen:

Lernen = Anpassen der Gewichte W_{ij} , sodass das Netzwerk die "gewünschte" Input/Output-Abbildung ausführt.

→ Lernen aus Beispielen:

- Lernbeispiele $\underline{I}''/\underline{D}''$, \underline{D}'' = vorgegebener Output
- Netzwerk-Output: $\underline{O}'' = \underline{O}(\underline{I}'', \underline{W})$
- Bestimmung der W_{ij} , sodass Diskrepanz zwischen \underline{O}'' und \underline{D}'' , gemittelt über alle Lernbeispiele, möglichst klein wird.

- Wesentliche Eigenschaften:

- Lernfähigkeit
- langsame Degradation bei Ausfall von Teilkomponenten
- Fähigkeit, auch fehlerhafte oder unvollständige Inputs zu verarbeiten
- Massiv parallele Informationsverarbeitung

- Anwendungsgebiete:

- Mustererkennung, Klassifizierung
- Spracherkennung
- Signalverarbeitung
- Maschinelles Lernen, Expertensysteme
- Modellierung
- Diagnose
- Vorhersage
- Optimierung
- Steuerung, Regelung, Robotik
- Neurophysiologie
- Kognitive Wissenschaften
- etc.

- Forschungsthemen:

- Lernvermögen, Kapazität
- Lernverhalten, Lernverfahren
- Verallgemeinerungsfähigkeit
- Anwendungen in verschiedenen Bereichen
- Vergleich mit traditionellen Methoden
- Hardware-Realisierungen
- etc.

- Historische Entwicklung:

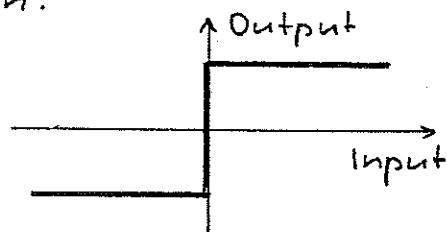
- McCulloch and Pitts (1943) formal neurons
 - Hebb (1949) "Hebb"-Synapse
 - Rosenblatt (1958) Perceptron
 - Widrow and Hoff (1960) Adaline, LMS
 - Minsky and Papert (1969) Limitations of Perceptrons
 - Kohonen (1972, 1982) linear associator, topographic maps
 - Grossberg (1976) neural feature detector
 - Barto, Sutton, Anderson (1983) neural control, reinforcement learning
 - Hopfield (1982, 1984) neural networks and statistical physics
 - Ackley, Hinton, Sejnowski (1985) Boltzmann machine
 - Rumelhart, Hinton, Williams (1986) Error Backpropagation Learning
 - Poggio & Girosi, etc. (~1990) Radial Basis Function Networks
 - Hopfield, Maass, etc. (~1995) Spiking Neurons
- ⋮

I.4 Typen von künstlichen Neuronen

Die durch biologische Nervensysteme inspirierten künstlichen neuronalen Netzwerke lassen sich in Bezug auf den Typ der verwendeten Neuronen in drei Generationen einteilen:

Erste Generation:

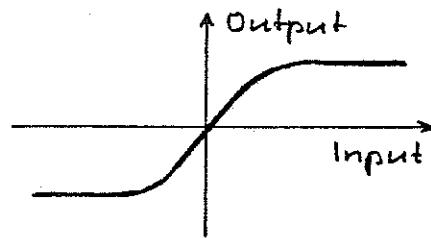
Neuronale Netze, die auf "Threshold-Neuronen" basieren, d.h. auf Neuronen mit einer stufenförmigen Aktivierungsfunktion:



Solche Netzwerke (mit einer einzigen Schicht von Hidden Units) können jede beliebige Boole'sche Funktion realisieren.

Zweite Generation:

Netzwerke aus Neuronen mit sigmoiden Aktivierungsfunktionen:



Hier können die Neuronenzustände kontinuierliche Werte annehmen (z.B. zwischen -1 und +1).

Solche Netzwerke können jede stetige Input/Output-Funktion mit kompaktem Wertebereich und Zielbereich beliebig genau approximieren.

Sie erlauben ferner Lernalgorithmen, die auf Gradienten-Verfahren beruhen (z.B. Backpropagation).

In Bezug auf ihre biologischen Vorbilder werden die Netzwerke der ersten und zweiten Generation wie folgt interpretiert:

Der Output der Neuronen wird als Rate aufgefasst, mit der das Neuron "feuert" (firing rate), d.h. sogenannte "Spikes" aussendet und an andere Neuronen weiterleitet.

Dritte Generation:

Heute weiss man, dass biologische Neuronen Information nicht nur durch ihre "firing rate" codieren, sondern auch durch das Timing und die zeitliche Form der spikes, sowie durch die Abstände zwischen den spikes.

Diese Erkenntnisse haben in den letzten Jahren zur Untersuchung einer dritten Generation von künstlichen neuronalen Netzwerken geführt, welche auf sogenannten "Spiking Neurons" (oder "Integrate-and-Fire Neurons") basieren, bei denen sowohl das Erregungspotential als auch die Schwelle zeitabhängig sind.

[W. Gerstner, Phys. Rev. E 51, 1995, pp. 738-758]

[W. Maass, Neural Networks 10, No. 9, 1997, pp. 1659-71]

"Spiking Neurons" imitieren das Verhalten von biologischen Neuronen viel genauer als die vereinfachten Modelle der ersten und zweiten Generation. Sie werden deshalb in erster Linie zur Simulation von neurophysiologischen Vorgängen verwendet.

In dieser Vorlesung beschränken wir uns aber auf Neuronen der ersten und zweiten Generation.

PROTOTYP-ANWENDUNGEN AUS DER LITERATUR

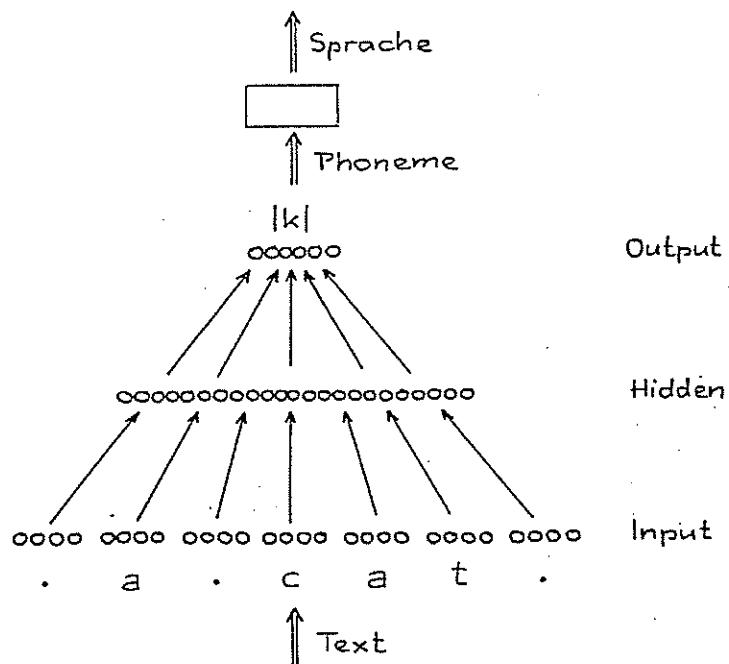
- Erkennung von handgeschriebenen Symbolen
- Spracherkennung, Sprachsynthese
- Medizinische und technische Diagnose
- Entdeckung von Sprengstoff im Flugzeuggepäck
- Risikoanalyse (Hypothesen, Versicherungen)
- Vorhersage (Devisenkurse, Wetter, Elektrizitätsbedarf, etc.)
- Steuerung von Robotern

NEURONALE NETZWERKE BEI ABB

- Modellierung und Optimierung von Materialeigenschaften
- Diagnose von Isolationsdefekten
- Vorhersage von elektrischen Lasten von Devisenkursen
- Entwicklung von selbstlernenden Regelsystemen
- Automatisches Ablesen von Wasserzählern
- Kalibrierung von Infrarot-Spektren

NETtalk

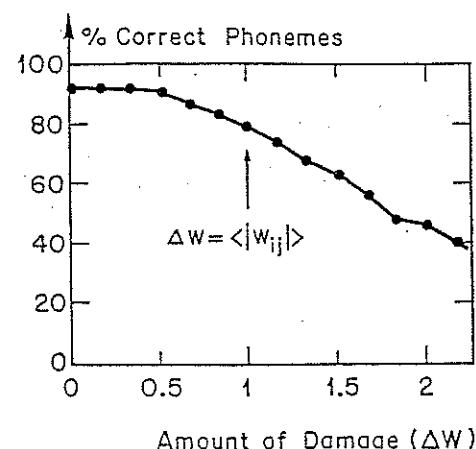
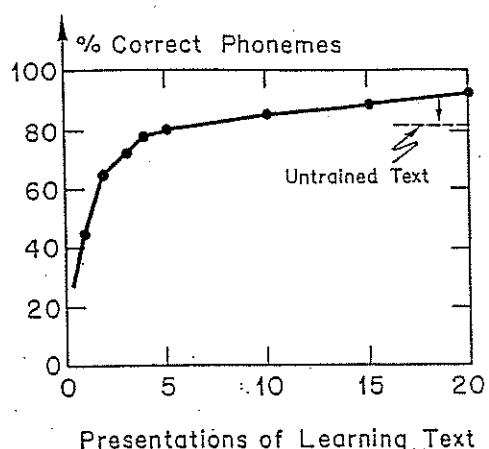
(Sejnowski & Rosenberg, 1986)



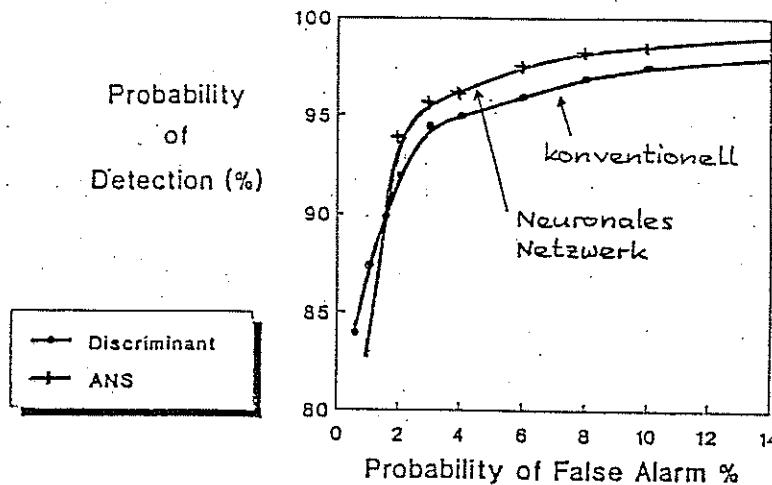
203 Input - Neuronen

80 Innere Neuronen $\sim 18'000$ Verbindungen

26 Output - Neuronen



Artificial Neural System for Explosive Detection System



(Shea & Lin, 1989)

DIAGNOSE VON RÜCKENSCHMERZEN

(Bounds et al, 1988)

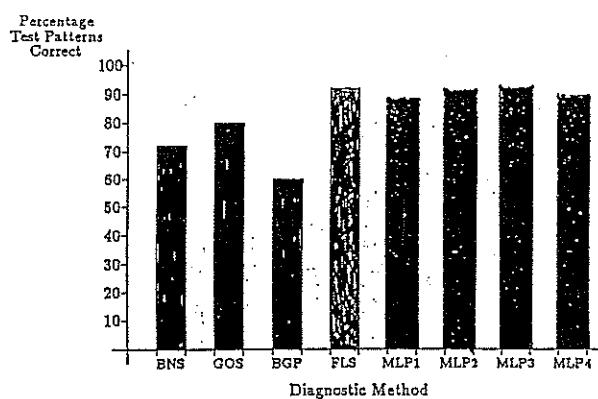


Figure 4: Results for Root Pain

Bandscheiben

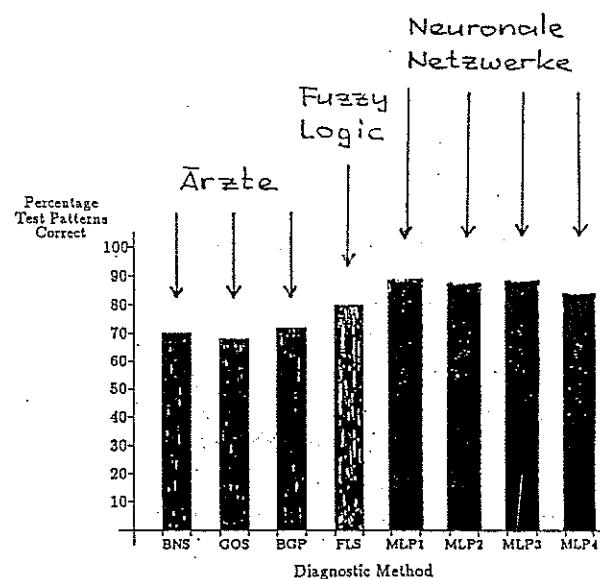
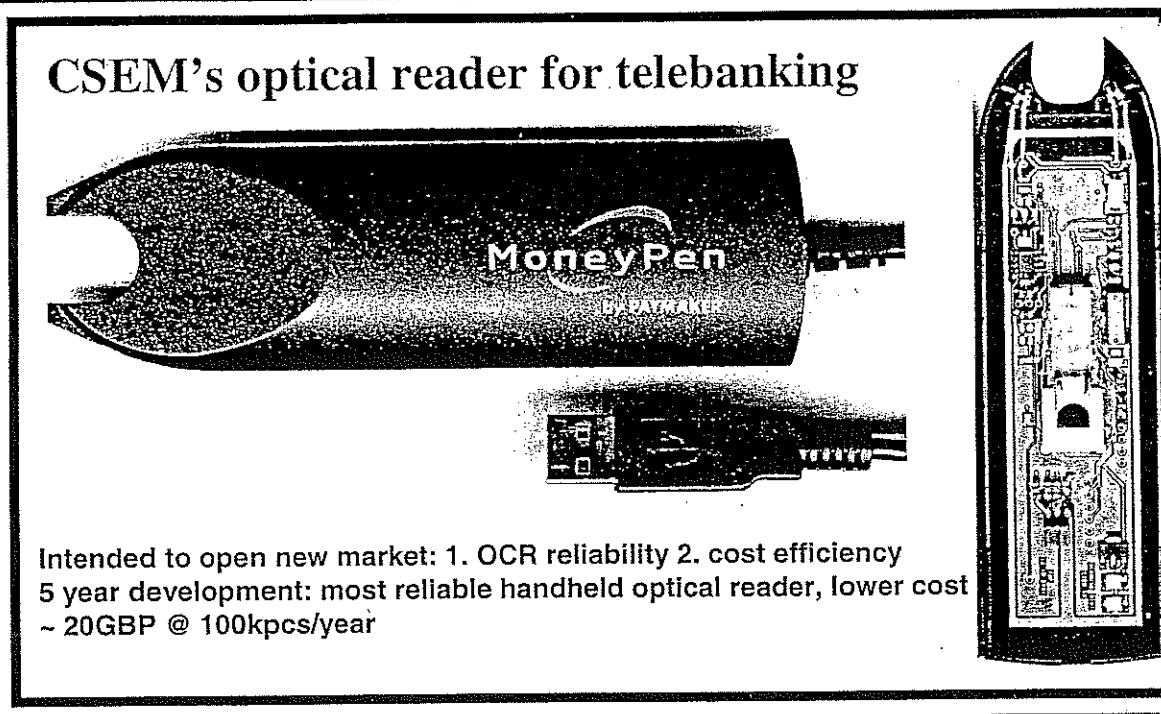


Figure 5: Results for Spinal Pathology

Tumor

CSEM's optical reader for telebanking

(künstliche Retina + Neural Network Classifier)



Telebanking application

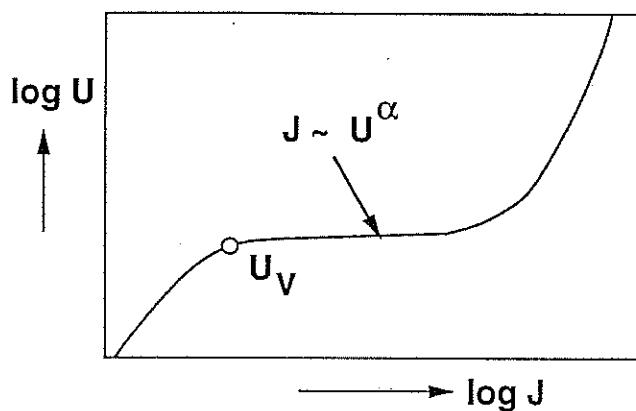
Bank paying slip	Versamento Virement PTT	Versamento Giros PTT
Execution date: 10/06/2001	Account to be debited: UBS SA	Booking Text: Giros SA
Account No: 10123456 0	Booking No: 238	
Options: <input checked="" type="checkbox"/> Update master data		
<input type="checkbox"/> Save <input type="checkbox"/> Blank template <input checked="" type="checkbox"/> Cancel <input type="checkbox"/> Help		

Payment Slip

~ 1 error in 1'000 payment slips

OPTIMIERUNG VON MATERIALEIGENSCHAFTEN

ZnO-VARISTOR:



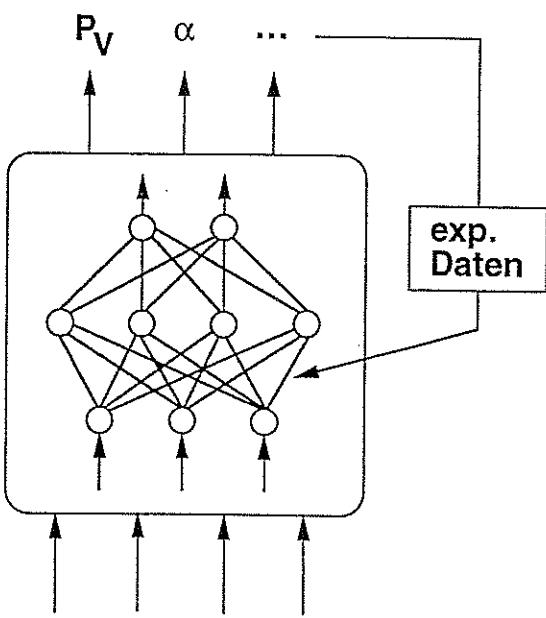
Elektrische Kenngrößen:

- P_V : Verlustleistung
- α : Nichtlinearität
- etc

Extrem nichtlinear abhängig von der Zusammensetzung (~ 10 Dotierelemente !)

MODELLIERUNG VON NICHT-LINEAREN BEZIEHUNGEN

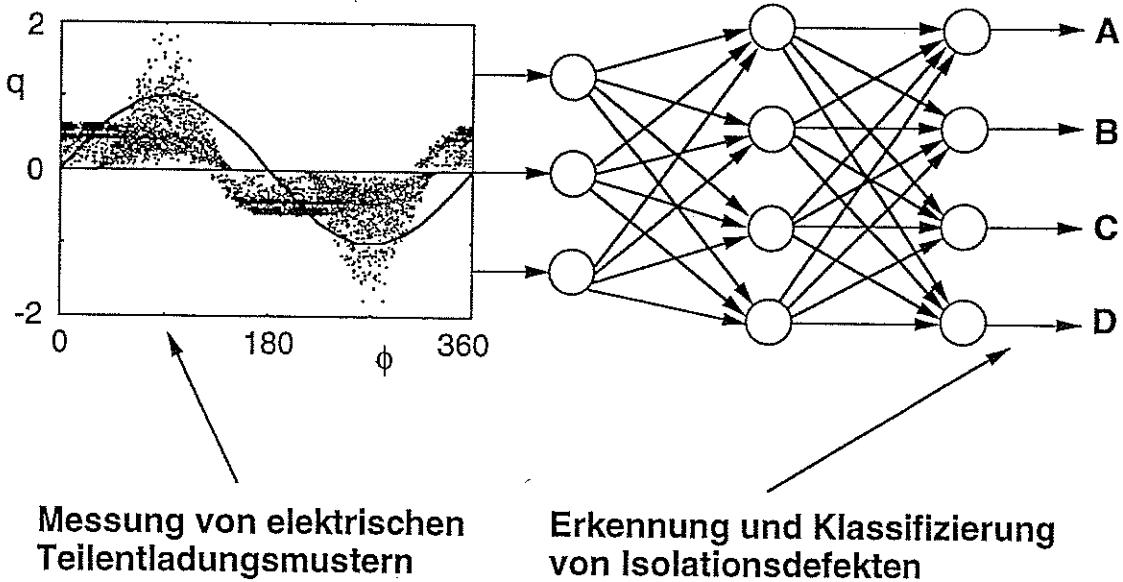
VORHERSAGE VON OPTIMALEN ZUSAMMENSETZUNGEN



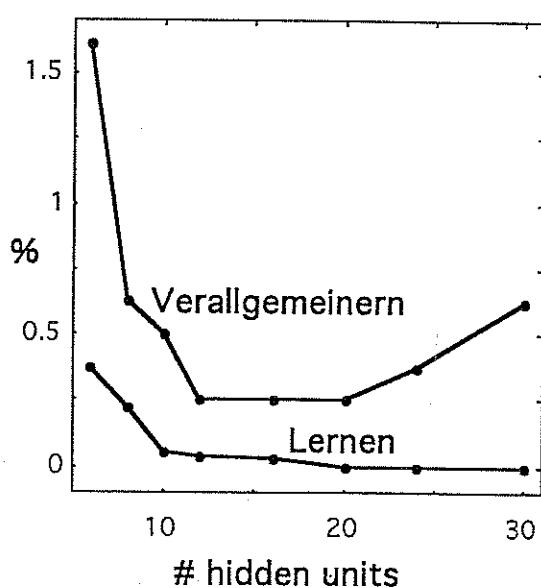
	P_V		α	
	Prog.	Exp.	Prog.	Exp.
C1	- 25 %	- 28 %	+ 48 %	+ 65 %
C2	- 15 %	- 36 %	+ 30 %	+ 78 %
C3	- 41 %	- 37 %	+ 74 %	+ 96 %

Prognostizierte und gemessene Verbesserungen

DIAGNOSE VON ISOLATIONSSYSTEMEN



Relativer Klassifizierungsfehler:



VERGLEICH:

"Training without noise":

Neural Net: 6.5 % errors

3 NN: 13.4 %

LVQ: 14.9 %

"Training with noise":

Neural Net: 0.25 % errors

3 NN: 0.62 %

LVQ: 8.83 %

Lastvorhersage mit neuronalen Netzwerken

- Projektpartner:

- ABB Network Partner
- ABB Forschungszentrum
- EPFL (ETH Lausanne)
- EOS (Energie de L'Ouest Suisse)

- Projektziele:

- Vorhersage des Elektrizitätsverbrauchs
- Realisierung eines Prototyp-Systems bei EOS
- Vergleich mit der Vorhersage von Experten

Vergleich der Vorhersagefehler

