

Revolutionieren Neuronale Netze unsere Vorhersagefähigkeiten?

Rüdiger W. Brause

J.W. Goethe-Universität, Frankfurt am Main, FB Informatik,
AG Adaptive Systemarchitektur

Zusammenfassung

Diese Arbeit plädiert für eine rationale Behandlung von Patientendaten und untersucht dazu die Analyse der Daten mit Hilfe neuronale Netze etwas näher. Erfolgreiche Beispielanwendungen zeigen, daß die menschlichen Diagnosefähigkeiten deutlich schlechter sind als neuronale Diagnosesysteme. Für das Beispiel der neueren Architektur mit RBF-Netzen wird die Funktionalität näher erläutert und gezeigt, wie menschliche und neuronale Expertise miteinander gekoppelt werden kann. Der Ausblick deutet Anwendungen und Praxisproblematik derartiger Systeme an.

Do Neural Networks Revolutionize our Prediction Abilities?

Summary

This paper claims for a rational treatment of patient data. It investigates data analysis with the aid of artificial neural networks. Successful example applications show that human diagnosis abilities are significantly worse than those of neural diagnosis systems. For the example of the newer architecture using RBF nets the basic functionality is explained and it is shown how human and neural expertise can be coupled. Finally, the applications and problems of this kind of systems are discussed.

Keywords

Statistical Classification, Automatic Prediction, Neural Networks, Neurofuzzy Medical Systems

1 Einleitung

Fast alle Mediziner sind während ihrer Ausbildung vor das Problem gestellt, Diagnosen zu erlernen. Dabei müssen sie die Aufgabe lösen, anhand von mehr oder weniger genau spezifizierten Beobachtungen, gepaart mit Vorwissen, auf eine bestimmte Krankheit schließen oder eine Krankheit behandeln zu müssen. Es gibt zwar Standardwissen aus Vorlesungen und Büchern, aber dieses veraltet zum einen sehr schnell und ersetzt zum anderen nicht die eigene Anschauung.

Bei dieser Lernaufgabe sind einige grundsätzliche Schwierigkeiten zu beachten:

- Die Erfahrungsbasis für eine solide Diagnose, eine hinreichende Anzahl von Fällen, wird erst im Laufe eines Medizinerlebens erreicht und ist in der Ausbildung nicht vorhanden.
- Dies gilt besonders für seltene oder neu erkannte Krankheiten; hier sind auch erfahrene Ärzte in der gleichen Lage.
- Grundsätzlich haben Menschen nicht die Fähigkeiten von Statistikcomputern, sondern

von Mustererkennungssystemen. Menschen können Muster und Gegenstände gut wiedererkennen, aber versagen, wenn es darum geht, ihnen Wahrscheinlichkeiten zuzuordnen. Dies äußert sich nicht nur bei Optimisten, die grundsätzlich die Probleme und ihren Arbeitsaufwand unterschätzen, sondern ist eine experimentell belegbare psychologische Erkenntnis. Alle Lotto- und Toto-Gesellschaften leben von der Unfähigkeit der Menschen, Wahrscheinlichkeiten richtig abschätzen zu können.

Diesen grundsätzlichen Schwierigkeiten sind sich nur wenige Ärzte bewußt. Auch Untersuchungen, die von über 50% Fehldiagnosen sprechen, haben bisher nichts an dem Selbstbewußtsein mancher Standesvertreter ändern können. Es ist kein Zufall, daß die Krankheit AIDS erst aufgrund unwahrscheinlicher statistischer Häufungen von Karzinomen aufgefallen ist; durch das Fehlen spezieller Symptome wurde die Virusinfektion von den behandelnden Ärzten nicht erkannt.

Eine wichtige Lösung der obigen Problematik liegt in der systematischen Anwendung statistischer Instrumente. Die heutige leichte Verfügbarkeit von Rechnern macht es auch statistikunerfahrenen Medizinern möglich, die Vorteile einer solchen Diagnoseart zu nutzen:

- Auch Mediziner in der Ausbildung mit wenig Erfahrung können zu einer zuverlässigen Diagnose kommen, wenn sie die gesammelten Daten erfahrener Kollegen nutzen.
- Auch bei sehr seltenen Krankheiten ist es mit Hilfe der gesammelten Erfahrungen anderer, weltweit agierender Kollegen möglich, eine korrekte Diagnose zu erzielen.
- Neue, unbekannte Krankheitsbilder können systematisch erschlossen werden, auch wenn dies komplexe Rechenoperationen erfordert, die ein Mediziner in seiner Ausbildung nicht erlernt.
- Auch bei der Behandlung von Krankheiten hilft eine kritische statistische Betrachtung, rational mit Operationsmethoden oder Medikationstherapien umzugehen und auch seine eigene, geliebte Methode in Frage zu stellen.

Dieser Beitrag ist also ein Plädoyer für eine rationale Medizin. Dabei geht es gar nicht darum, statistische Methoden in der Medizin einzuführen; sie existieren bereits. Vielmehr sollten Mediziner die Verfahren auch in der Praxis einsetzen und fördern.

Eine wichtige Studie [5,7] zeigte schon sehr früh diesen Sachverhalt auf medizinischem Gebiet. An der Universitätsklinik von Leeds wurden 1971 für 472 Patienten mit akuten Bauchschmerzen die Daten untersucht und beurteilt. Damals gab es zwar noch keine neuronalen Netze, aber einfache, wahrscheinlichkeitsbasierte Verfahren (Bayes-Klassifikation). Für eine Datenbank von 600 Patienten wurden die Entscheidungswahrscheinlichkeiten errechnet, ebenso für eine synthetische Datenbank, die durch Befragung von Experten mittels umfangreicher Fragebögen konstruiert wurde. Dann wurden die 472 Datensätze sowohl einem Gremium von 6 Experten (3 junge und 3 erfahrene Mediziner) vorgelegt und ihre Entscheidung erfragt. Die Diagnosen waren wie folgt korrekt:

Dienstältester Mediziner	79,7 %
Computer mit Experten-Datenbank	82,2 %
Computer mit 600 Patientendaten	91,1 %

Das Ergebnis ist eindeutig: Menschen können komplexe, vernetzte Daten nicht fehlerfrei auswerten.

2 Die Prognoseleistung Neuronaler Systeme

Betrachten wir im Vergleich dazu die Prognoseleistung von lernenden Diagnosesystemen, wie sie mit künstlichen neuronalen Netzen möglich ist. Es gibt eine lange Reihe von erfolgreichen Anwendungen neuronaler Netze [4,7,12-17]. Beispielsweise wurden neuronale Systeme verwendet für die Diagnose von

- **erblichen Muskelkrankheiten** (Duchenne & Becker Dystrophie) [11]
16 Eingabevariable, 1 Ausgabevariable, 63 Beispielfälle.
100% richtige Diagnose, wobei sich nur 2 Variable als wichtig herausstellten.
- **Ohrenkrankheit** [12]
6 Eingabevariablen, 2 Ausgabevariable, 120 Beispielfälle.
95% richtige Diagnose auf einer Testmenge von weiteren 100 Beispielen.
- **Rückenschmerzen** [2]
145 (86) Antworten eines Fragebogens als Eingabevariable, 4 Ausgabevariable (LWS-Syndrom, Wurzelsymptomatik WS, Spinale Symptomatik SS, Untypische Symptomatik US). Nach Training mit 100 Beispielfällen ergab sich bei 100 Testfällen folgende korrekte Diagnose (Tabelle 1):

Methode	LWS %	WS %	SS %	US %	Mittelwert%
Netz	63	90	87	95	83
Neurochirurgen	96	92	60	80	82
Orthopäden	88	88	80	80	84
Allgemeinpraktiker	76	92	64	92	81

Tabelle 1 Diagnoseerfolg bei Rückenschmerzen

In diesem Anwendungsfall war das Netz im Mittel genauso gut wie die menschlichen, erfahrenen Experten. Allerdings war es in der entscheidenden Diagnose für spinale Symptome, bei der sofort eingegriffen werden muß, besser als alle anderen Experten.

- **Überlebenswahrscheinlichkeit** nach schweren Verletzungen [9]
Für 3 Eingabevariable (Revised Trauma Score RTS, Injury Severity Score ISS, Alter) und zwei Ausgabevariable (Leben, Tod) wurde ein Netzwerk mit 4800 Beispielfällen trainiert. Im Vergleich zu den traditionellen Score-Methoden TRISS und einer Variante ASCOT, die spezielle Risikogruppen vor der Scorebildung besonders behandelt, ergab sich folgende Diagnosewerte bei Jugendlichen (Tabelle2)

Diagnose	TRISS	ASCOT	NNetz
Sensitivität %	83,3	80,6	90,3
Spezifizität %	97,2	97,5	97,5

Tabelle 2 Diagnoseerfolg bei schweren Verletzungen von Jugendlichen

Ähnliche Werte waren bei Erwachsenen zu verzeichnen. Die deutlich erhöhte Sensitivität bei dem neuronalen Netz läßt sich auf die einfache lineare Gewichtung der Score-

basierten Systeme (wie auch z.B. APACHE-Score) zurückführen. Eine lineare Gewichtung entspricht einer Schicht linearer Neuronen; natürlich ist jedes Netz mit zwei Schichten (davon mind. eine nicht-linear) bei nicht-linearen Problemen einem Netz mit nur einer linearen Schicht überlegen.

- **Überleben nach Enddarmkrebsoperation [1]**

Für 42 klinische Variable wurde ein Netz mit 284 Patientendaten trainiert und mit weiteren 50 zufällig gewählten Patientendaten validiert. Es ergab sich eine Diagnosegenauigkeit von 82-80% für einen Zeitraum von 9-24 Monate.

Dann wurden die Daten von 100 zufällig gewählten Patienten einer anderen Klinik sowohl dem trainierten, festen Netz als auch zwei Klinikern zur Beurteilung für den Verlauf der nächsten 12 Monate vorgelegt. Es ergaben sich folgende Resultate (Tabelle 3):

Diagnose	Genauigkeit %	Sensitivität %	Spezifizität %
Kliniker 1	79	33	82
Kliniker 2	75	67	76
Neuronales Netz	90	67	92

Tabelle 3 Diagnoseerfolg bei Operationen

Interessanterweise verringerte sich die Genauigkeit des Netzes auf 75%, wenn man die zweite Schicht wegläßt – auf ungefähr die gleiche Leistung wie die der erfahrenen Kliniker.

Nach dieser einleitenden Präsentation, die den praktischen Wert von (älteren) neuronalen Diagnosesystemen zeigen sollte, stellt sich nun die Frage: Wie funktionieren neuronale Netze und warum ermöglichen sie eine bessere Diagnose?

3 Die Methode Neuronaler Netze

Ähnlich dem Vorbild aus der Natur bestehen die künstlichen neuronalen Netze aus vielen kleinen Einheiten, den formalen Neuronen, die miteinander und parallel zueinander arbeiten. Manche Informatiker sprechen deshalb auch von „massiv parallelen Rechnerarchitekturen“. Ein solches formales Neuron besteht aus mehreren Eingängen, aus deren Eingabewerte eine Funktion berechnet wird. In Abbildung 1 ist ein solches Schema gezeigt. Ein Beispiel für eine Operation eines derartigen formalen Neurons ist eine gewichtete Summe z der Eingaben x_i

$$y = S(z) \quad \text{mit} \quad z = \sum_i w_i x_i$$

mit festen Gewichten w_i . Die Aktivierung z wird schließlich von einer Ausgabefunktion $f(z)$ auf die beobachtbare Ausgabe y abgebildet.

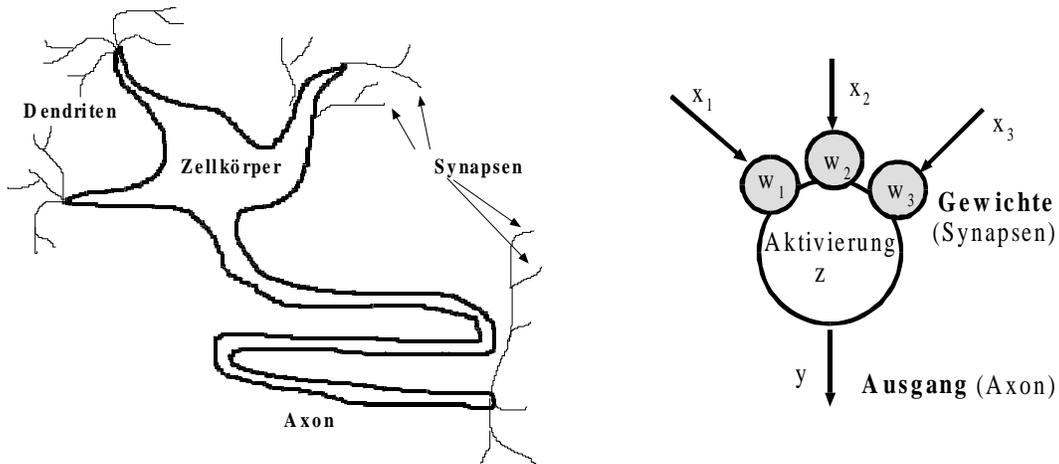


Abbildung 1 Ein biologisches Neuron und ein Modellneuron (nach [3])

Das biologische Neuron besteht im wesentlichen aus einer Nervenzelle, die über Dendriten Signale aufnimmt, diese als Zellpotential miteinander verrechnet und über eine Fortsetzung (Axon) die errechneten Impulse (Spikes) ausgibt. Dieses Verhalten modelliert ein formales Neuron dadurch, daß es Eingänge x_1, \dots, x_n besitzt, über die Aktivitäten in das Neuron eingehen. Alle dendritischen Verbindungen des einen Neurons über Synapsen zu einem anderen Neuron werden in einem einzigen Eingang, gewichtet mit einer Zahl w_j , zusammengefaßt. Die Eingabeaktivität wird üblicherweise als reelle Zahl modelliert und entspricht im positiven Bereich der Spikefrequenz.

Ordnen wir mehrere solcher formaler Neuronen parallel an, so können wir mit m Neuronen aus n Eingabewerten x_1, \dots, x_n die m Ausgabewerte y_1, \dots, y_m berechnen. Die n Eingaben und die m Ausgaben können wir zu sog. Spaltenvektoren $\mathbf{x} = (x_1, \dots, x_n)^T$ und $\mathbf{y} = (y_1, \dots, y_m)^T$ zusammenfassen, siehe Abbildung 2, so daß im einfachen linearen Fall bei $S(z) = z$ die gesamte Operation des neuronalen Netzes in einer Matrixmultiplikation $\mathbf{y} = \mathbf{W}\mathbf{x}$ besteht.

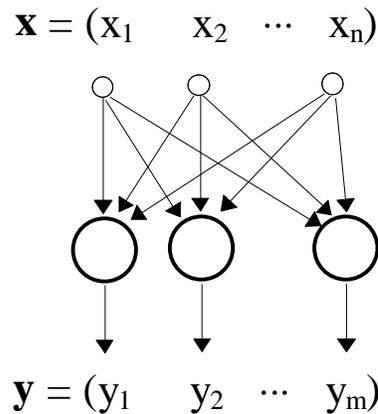


Abbildung 2 Ein einschichtiges Netzwerk

Alle Eingabeaktivitäten erreichen alle Neuronen. Die Menge aller gleichartigen Neuronen, die parallel arbeiten, wird als „Schicht“ bezeichnet. Die Ausgabe y eines Neurons ist allgemein eine nicht-lineare Funktion $y=S(x_1, \dots, x_n)$ der Eingaben.

In der Abbildung ist eine Menge parallel arbeitender, gleichartiger Neuronen (eine sog. „Schicht“) gezeigt. Ein Netzwerk aus mehreren, hinter- oder nebeneinander angeordneten Schichten kann für viele Fragestellungen eingesetzt werden. Für die Medizin sind besonders die Diagnose und Prognose wichtig.

3.1 Anwendung nicht-linearer Netze: Klassifikation und Diagnose

Besteht die Funktion linearer Netze noch darin, Eingaben (z.B. Merkmalsdaten eines Patienten) linear auf Ausgabedaten zu projizieren und damit eine lineare Abweichung vom Mittelwert zu generieren, so ist die Abweichung bei nicht-linearen Netzen nicht mehr zwangsläufig linear. Wir können sie so gestalten, daß möglichst viele ähnliche Eingaben (Patientendaten) auf einen typischen Vertreter, den Klassenprototypen, abgebildet werden: Wir benutzen das Neuronale Netz zur *Klassifikation* oder *Diagnose* der Patientendaten. In Abbildung 3 ist eine solche Diagnosesituation gezeigt. Die Patienten einer Klinik wurden mittels zweier Blutwerte auf eine 2-dim. Fläche angeordnet. Die Daten wurden für Patienten mit chronischer Bauchspeicheldrüsenentzündung mit (×) und für normale Patienten mit (●) notiert. Wie man sieht, bilden sie Haufen oder Cluster; eine Einteilung dieser Cluster in Klassen wird als *Clusteranalyse* bezeichnet.

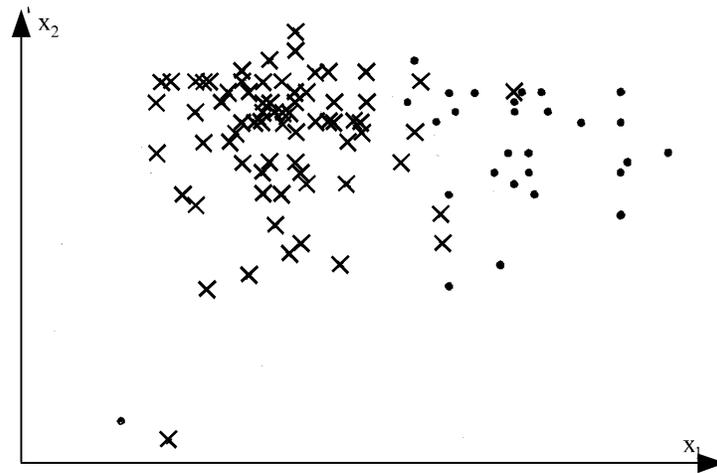


Abbildung 3 Klassifikation von Patientendaten

Aufgetragen wurden Patienten mit chronischer Bauchspeicheldrüsenentzündung (×) und normale Patienten (●), charakterisiert durch zwei Parameter x_1 und x_2 , aus den Blutwerten. Jeder Patient entspricht dabei entweder einem Punkt oder einem Kreuz. Alle gleichartigen Patienten bilden eine Klasse. Punkthaufen werden als Cluster bezeichnet, wobei eine Klasse aus mehreren Clustern bestehen kann. Die Aufgabe bei einer solchen Darstellung besteht darin, eine Linie als Grenze zwischen den Klassen derart zu ziehen, daß nicht nur alle aktuellen, bekannten Patienten richtig eingeordnet werden, sondern auch alle zukünftigen. In diesem Fall muß man sich für eine korrekte Diagnose nicht alle Referenzfälle merken, sondern nur die Lage der Klassengrenze. Man beachte, daß dies nicht einfach durch eine Gerade („lineare Klassifizierung“) bewerkstelligt werden kann, wenn „Inseln“ von Patienten anderer Diagnose bei einer Klasse existiert, s. die Daten links unten im Bild.

Aufgabe jeglicher Diagnose ist es nun, eine Trennlinie zu ziehen und zwischen den beiden Patientenklassen zu unterscheiden. Patienten mit Entzündung sollten langfristig medikamentös behandelt, normale Patienten nicht unnötig medikamentös belastet werden. Hier hilft eine

saubere, auf Statistik und vielen Erfahrungswerten basierende Entscheidung enorm, Fehldiagnosen zu verhindern.

Eine einfache Gerade ist im obigen Fall sicher nicht ausreichend, um die Gesunden von den Kranken zu trennen. Eine bessere Möglichkeit dafür („Clusteranalysen“) bieten neuronale Netze. In Abbildung 4 ist ein Netzwerk neuerer Bauart gezeigt, das die Klassenentscheidung durch spezielle Ausgabefunktionen („Radialen Basisfunktionen RBF“) bei den Neuronen der ersten Schicht erbringt.

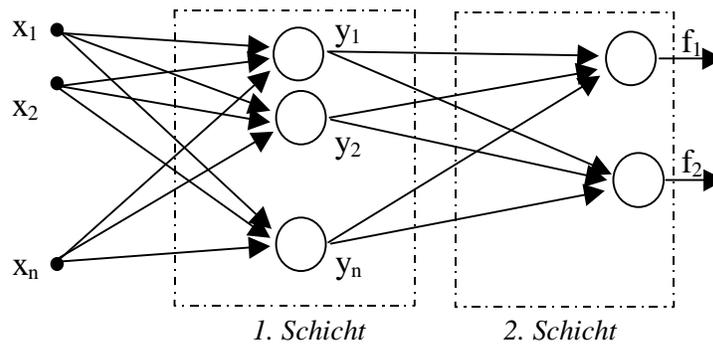


Abbildung 4 Zwei-Schichten-Netzwerk für Klassifikation

Jede der beiden durch unterbrochene Linien markierten Schichten stellt eine Menge parallel arbeitender Neuronen nach Abbildung 2 dar. Die Signale der beiden hintereinander angeordneten Schichten werden dabei pipeline-artig verarbeitet. Die Aufgabe der ersten Schicht besteht darin, das Auftreten einer ganz bestimmten Situation, charakterisiert durch die Eingabevariablen, anzuzeigen. Die zweite Schicht kombiniert mehrere solcher Elementarsituationen zu einer gemeinsamen Diagnose. Jede der Ausgaben der zweiten Schicht stellt eine Diagnose dar, die vom Netz ausgegeben wird. Ist die Ausgabefunktion eines solchen „Ausgabeneurons“ binär, so erscheinen nur zwei Werte: 0 für „Krankheit liegt nicht vor“ und 1 für „Krankheit liegt vor“. Sind mehrere Neuronen gleichzeitig aktiv, so deutet dies auf mehrere, gleichzeitig vorliegende Krankheiten beim Patienten.

Die entscheidenden Elemente in diesem Netz sind die RBF-Neuronen in der ersten Spalte (in der ersten Schicht), die sich jeweils wie kleine Experten verhalten: Jedes Neuron k ist für einen Bereich im Eingaberaum um einen Klassenprototypen \mathbf{c}_k herum zuständig. Die Aktivität eines „Experten“ wird durch die Ausgabefunktion

$$S_k(\mathbf{c}_k, \sigma_k, \mathbf{x}) = e^{-\frac{(\mathbf{c}_k - \mathbf{x})^2}{2\sigma_k^2}}$$

beschrieben; sie entspricht einer Gauß'schen Glockenfunktion. Je dichter die Patientendaten \mathbf{x} am Klassenprototypen \mathbf{c}_k liegen, desto kleiner ist die Differenz $(\mathbf{c}_k - \mathbf{x})$ und desto größer ist die Ausgabe y_k des Neurons: Der „Experte“ entscheidet für eine Krankheitsklasse. Die Entscheidungen aller Experten werden dann in der zweiten Schicht aus linearen Neuronen gewichtet zusammengeführt und ergeben die Diagnosen f_1, f_2, \dots durch

$$f_i(\mathbf{x}) = \sum_{k=1}^m w_k y_k = \sum_{k=1}^m w_k \tilde{S}_k(\mathbf{x})$$

Verwenden wir direkt die Funktionen $S_k(\mathbf{c}_k, \sigma_k, \mathbf{x})$ für \tilde{S}_k , so erhalten wir als Ausgabe die einfache, gewichtete Überlagerung der Glockenfunktionen, siehe **Fehler! Verweisquelle konnte**

nicht gefunden werden.a).

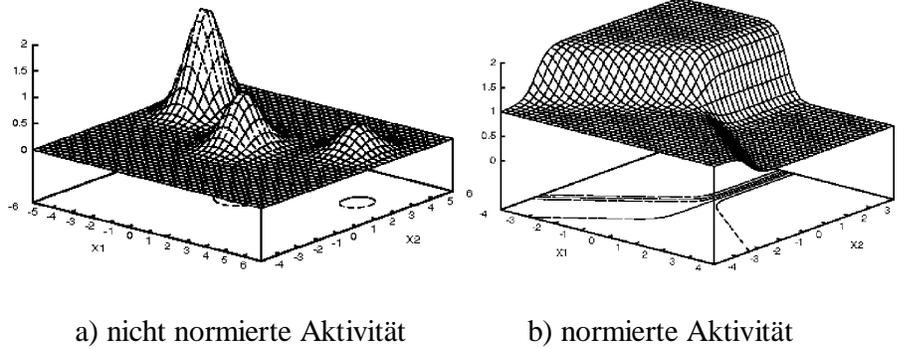


Abbildung 5 Die Überlagerung für ein RBF-Netz aus drei Neuronen

In der linken Abbildung 5a) ist nicht-normierte, lineare Überlagerung der Aktivität von drei Neuronen der ersten Schicht bei einem Ausgabeneuron für alle Werte (x_1, x_2) gezeigt. Man erkennt deutlich die Gauß'sche Glockenfunktion eines jeden Neurons. Die Höhe jeder Glockenfunktion S_i ist durch ihre Gewichtung w_i beim Ausgabeneuron in der zweiten Schicht gegeben. Die überlagerte, normierte Aktivität ist rechts in Abbildung 5b) gezeigt. Man erkennt deutlich, daß der Übergang der Aktivität einer Klasse zu einer anderen schneller stattfindet und innerhalb einer Klasse (im Unterschied zur nicht normierten Aktivität) konstant bleibt. Der Verlauf der Klassengrenzen läßt sich dabei an der Projektion der Linien gleicher Höhe am „Boden“ der Zeichnung ablesen. Daraus kann man folgern, daß Netze mit nicht-normierter Aktivität eher für Approximationsaufgaben („Lerne eine bestimmte, reelle Ausgabe bei der Eingabe eines Datensatzes“), dagegen Netze mit normierter Aktivität besser für Klassifikationsaufgaben („Gib eine bestimmte Diagnose aus solange die Eingabe nicht zu stark von einer typischen Wertekombination abweicht“) geeignet sind.

Führen wir dagegen statt der absoluten die relative Aktivität zusammen, so erhalten wir deutlich scharfe Klassifikationsgrenzen, siehe **Fehler! Verweisquelle konnte nicht gefunden werden.b).**

In diesem Fall ist

$$\tilde{S}_k = \frac{S_k(\mathbf{x})}{\sum_{j=1}^m S_j(\mathbf{x})}$$

Der Verlauf der Klassengrenzen läßt sich dabei an der Projektion der Linien gleicher Höhe am „Boden“ der Zeichnung ablesen.

Man beachte, daß die Funktion der Experten in der ersten Schicht nur darin besteht, bei einer bestimmten, ungefähr zusammenpassenden Kombination von Eingabeparametern einen hohe Aktivität („Alarm!“) auszugeben. Erst die zweite Schicht ermöglicht es, die selbe Diagnose für verschiedene Gebiete (verschiedene Prototypen) auszugeben. Ein Neuron der zweiten Schicht heftet also verschiedenen, evtl. überlappenden Gebietsteilen („Inseln“ des Eingaberaums) die gleiche Diagnose an. So ist eine sehr unregelmäßige Grenze zwischen den Patientengruppen in Abbildung 3 möglich.

Alle Parameter (wie Klassenmittelprototyp \mathbf{c}_i , Breite σ_i , Einfluß \mathbf{w}_i) eines solchen Klassifikations- oder Diagnosesystems lassen sich durch geeignete Trainingsmethoden lernen und an die Trainingsmenge anpassen. Bei einem überwachten Lernverfahren, bei dem das „Typi-

sche“ für die Diagnose einer Patientengruppe gelernt werden soll, wird zum Lernen die gewünschte und die tatsächlich vom Netz generierte Ausgabe miteinander verglichen und mit Hilfe der erhaltenen Differenz die Parameter verbessert.

Darüber hinaus gibt es auch Methoden, das Netz sequentiell für eine Trainingsmenge mit einer geeigneten Anzahl von Neuronen, also Klassen, aufzubauen. Für den Arzt bedeutet dieser Aufbau etwas Interessantes: Bei jedem neuen RBF-Neuron wurde ein neues Symptom entdeckt, das für eine gegebene Diagnose als Teildiagnose wichtig ist. Für eine Pauschal-diagnose „krank“ würde eine solche Teildiagnose eine neue, dem Arzt unbekannte Krankheit bedeuten! Es ist deshalb sehr sinnvoll, eine Wissensbrücke zwischen dem Arzt und den internen Lernvorgängen des Netzwerks zu knüpfen.

3.2 Eine Benutzerschnittstelle zu neuronalen Netzen

Trotz aller theoretischer Vorteile von neuronalen Netzen ist ein wesentliches Merkmal eines solchen neuronalen Systems, das über Gebrauch oder Ignorieren durch die Mediziner entscheidet, die Möglichkeit, die Diagnose zu erklären und/oder bestehendes Wissen zu verwenden; kurzum eine intuitive und instruktive Schnittstelle zwischen Benutzer und neuronalem Netz. In Abbildung 6 ist dies als Forderung und Konzept visualisiert.

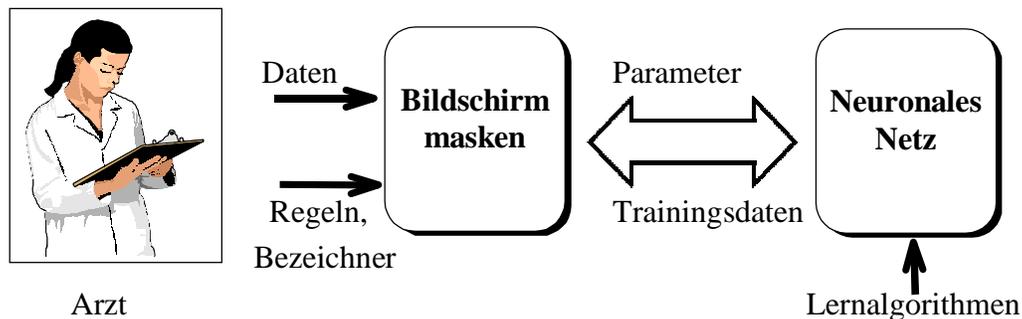


Abbildung 6 Interaktiver Transfer von vagem Wissen

Das „normale“ ärztliche Diagnosewissen kann in Form von Fakten und Schlußfolgerungen („Regeln“) in Bildschirmmasken aufgenommen und dem neuronalen Netz zur Verfügung gestellt werden. Die Patientendaten werden zum Trainieren des Netzes benötigt, die Regeln zur Initialisierung. Eine solche Initialisierung kann dazu führen, daß das Netz schneller lernt. Umgekehrt sollten die vom Netz ermittelten optimalen Parameter mit bekannten Begriffen in einer dem Arzt verständlichen Form (Fakten und Schlußfolgerungen) auf dem Bildschirm angezeigt werden.

Dabei muß die Schnittstelle (und damit auch das Netz) auf typisch menschliche Eigenschaften Rücksicht nehmen und auf einer „vagen“, inexakten Sicht der Syndrome und Diagnosen aufbauen.

In dem Fall eines RBF-Netzes zur Diagnose läßt sich dies relativ einfach bewerkstelligen. Hierbei wird das vage Wissen des Arztes dazu benutzt, das neuronale Netz zu initialisieren. In der folgenden Abbildung 7 ist dies näher erläutert.

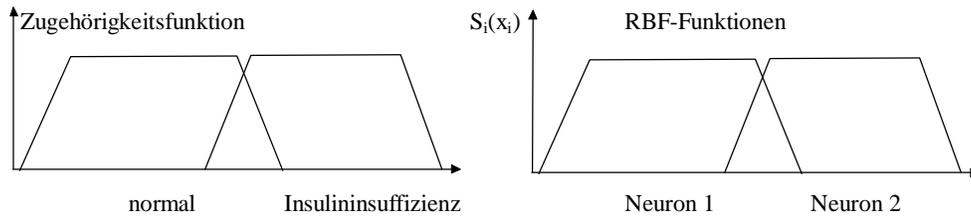


Abbildung 7 Vage Diagnose und RBF-Initialisierung

Links im Bild ist die Zuordnung der Blutzuckerwerte eines Patienten zu einer Insulininsuffizienz gezeigt. Eine sichere Diagnose (Zugehörigkeitsfunktion=1) ist nur für „typische“ Blutzuckerwerte gegeben; an den Grenzen sinkt die vermutete Zugehörigkeit langsam auf null ab. Rechts im Bild sind die entsprechenden Funktionen zweier RBF-Neuronen mit trapezförmigen Ausgabefunktionen $S_1(x)$ und $S_2(x)$ abgebildet. Es ist offensichtlich, daß jeder Teildiagnose mit ihrer Zugehörigkeitsfunktion genau ein RBF-Neuron mit seiner Ausgabefunktion zugeordnet werden kann.

Dabei bedient man sich einer vagen Notation ähnlich derjenigen, die in der mathematischen Fuzzy-Theorie benutzt wird, um mit bestehendem Wissen die RBF-Netze zu initialisieren. Der Benutzer hat immer die volle Kontrolle über die Bezeichnung und Definition der Syndrome und Diagnosen. Die als „Zugehörigkeitsfunktionen“ bezeichnete ärztliche Teildiagnose von Patientengruppen wird möglichst konsistent mit den bekannten Grenzdaten dieser Teildiagnose auf geeignete RBF-Funktionen abgebildet. In der folgenden Abbildung ist diese Zuordnung für die zwei RBF-Funktionen „Trapez“ und „Gauß-Glockenkurve“ visualisiert.

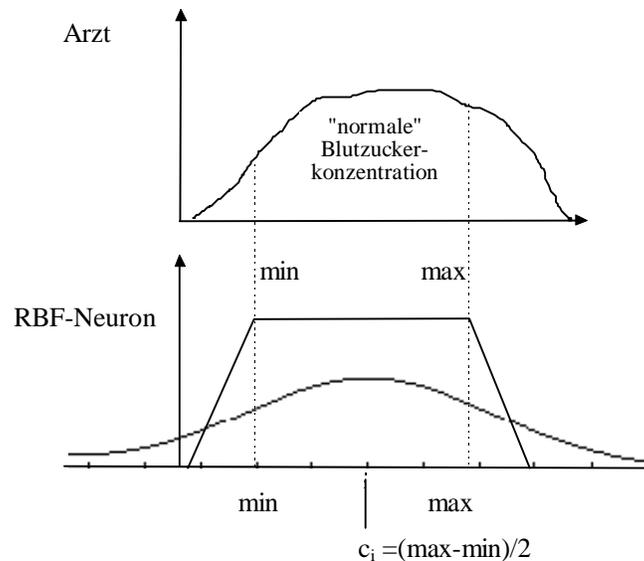


Abbildung 8 Initialisierung der RBF-Parameter mit dem Arztwissen

Die Zuordnung zwischen den medizinischen Zugehörigkeitsfunktionen und den RBF-Funktionen wird so durchgeführt, daß die Parameter wie Lage der Funktion (Mittelwert c_i) und Breite (Varianz!) übereinstimmen. Handelt es sich um sehr unterschiedliche Funktionen, so ist dies sicherlich nicht so einfach. Da die wenigsten Ärzte ein ausgeprägtes Gefühl dafür haben, welchen exakten Verlauf ihre subjektiv bekannten Zugehörigkeitsfunktionen haben, ist es sinnvoll, einheitlich nur eine Art von RBF-Funktionen vorzugeben und Mittelwert und Varianz aus den subjektiven Werten für Maximalwert und Minimalwert zu errechnen.

Die Eingabe der Zugehörigkeitswerte (min, max) zu einer Befundklasse läßt sich leicht über normale Eingabemasken vornehmen. Dies ermöglicht die direkte Initialisierung verschiedenartiger RBF-Netze, ohne exakte Aussage über die Art der Zugehörigkeitsfunktion zu benötigen. Die verbesserten Parameterwerte bedeuten für die ärztliche Praxis eine verbesserte, auf Statistik beruhende Diagnostik – auch, und gerade, wenn die gelernten Parameterwerte (diagnostischen Kategorien) von den eingegebenen Werten abweichen. Allerdings benötigen dann neue RBF-Neurone (neue Diagnosen) und stark abweichende Kategorien (stark verbesserte Diagnosekategorien) neue, synthetische Bezeichnungen.

4 Diskussion und Ausblick

Schon seit langem akzeptieren Mediziner technische Apparate, um ihnen die Diagnose zu erleichtern: Die Wichtigkeit von Laboruntersuchungen oder Röntgen- und Computertomographen ist allen bewußt. Obwohl niemand auf die Idee kommen würde, die Bilddaten eines Computertomographen per Hand auszurechnen, meinen die meisten Mediziner, daß sie komplexe, hochdimensionale Patientendaten „per Auge“ nur durch Betrachten von wenigen Werten exakt beurteilen können. Dies ist, wie wir in den Abschnitten 1 und 2 zeigten, ein fataler Fehlschluß.

Es ist deshalb sinnvoll, rechnerunterstützte Hilfsmittel in der Praxis zu verwenden. Konventionelle Expertensysteme bieten hier eine auf Expertenwissen beruhende Hilfe an. Da bei diesem System aber kein Erkenntnisgewinn zu erwarten ist, das Expertenwissen leicht veraltet und unvollständige oder inkonsistente Eingaben leicht zu Problemen führen können, wird die Hilfe von erfahrenen Ärzten nicht akzeptiert.

Im Gegensatz dazu bietet die Methode neuronaler Netze mehr an. Es lassen sich zum einen folgende konventionelle Funktionen direkt mit neuronalen Netzen verwirklichen:

- **Diagnoseassistent, Kritiker**

Für die individuelle Patientendiagnose hat das System aus der Sicht des Arztes die Funktion des „Kritikers“ [10]: Das System bekommt als Eingabe sowohl die patientenspezifischen Daten als auch die bereits getroffenen Entscheidungen (Diagnose, Therapie) des Arztes und hat als Aufgabe, Abweichungen von der eigenen Diagnose zu melden und Alternativen vorzuschlagen. Dies entspricht dem Wunsch der meisten Ärzte, nicht von einem „allmächtigen Orakel“, dem alles erst vorgetragen werden muß, in der Arbeit behindert zu werden, sondern nur anonym kritisiert und in Zweifelsfällen unterstützt zu werden.

- **Wachhund**

Spezialisierte Programme („Agenten“) durchkämmen laufend die Datenbasis der Patienten und alarmieren den diensttuenden Arzt, wenn problematische Zusammenhänge in den Labor- und Gerätwerten für einen Patienten festgestellt werden.

- **Lehrer**

Für Mediziner in der Lernphase ist es nützlich, Diagnosen ausführlich erläutert zu bekommen und alternative Vorschläge zu überdenken.

Im Unterschied zu konventionellen Expertensystemen gewinnt das System hier seine Diagnosen direkt aus den Rohdaten; eine menschliche Datenaufbereitung mit allen Irrtumsmöglichkeiten ist unerwünscht. Dies erspart den Medizinern Arbeit.

Zum anderen ermöglicht der selbstlernende Ansatz auch etwas, was herkömmliche Expertensysteme nicht bieten können: die Gewinnung neuer, den Experten unbekanntes Erkenntnisse. Sie können sowohl in der Gewinnung unabhängiger Eingangsvariablen bestehen, also in der

Angabe, welche Patientendaten für die Diagnose tatsächlich wichtig sind und welche nicht, als auch in der Gewinnung **neuer Diagnosen** auf der Basis einer geeigneten Verknüpfung sehr vieler (multivariater) Daten.

Wie läßt sich die obig skizzierte, wünschenswerte Funktionalität in die Praxis umsetzen? Der erste, wichtigste Schritt für eine rationale Behandlung der Patientendaten besteht darin, die Daten, die in Listen, Patientenakten und anderen internen Papierdokumenten niedergelegt sind, stattdessen in elektronischer Form zu erfassen und weiterzuverarbeiten. Dies ist der erste, aber auch der schwierigste Schritt in der Praxis, da er öfters eine komplette Neuorganisation der Datenverarbeitung auf den Stationen im Klinikbetrieb erfordert. Wird der Betrieb sowieso im Rahmen der notwendig gewordenen, genauen Abrechnungen für die Krankenhausträger umgestellt, so ist die medizinische Datenauswertung ein positiver Nebeneffekt der Umstellung, der den Patienten direkt zugute kommen kann.

Für eine Dateneingabe reichen einfache Eingabemasken aus, wie sie von den meisten Datenbanken auf PCs (z.B. Access, dBase etc.) angeboten werden. Neben stationären Eingabeterminals am Krankenbett haben sich dabei besonders mobile Notebooks als Eingabemedien bewährt. Mit wenig Aufwand läßt sich diese Datenbasis mit Hilfe einfacher Office-Programme (wie z.B. Excel) nach Scorewerten oder Bayeswahrscheinlichkeiten analysieren. Sogar eine Auswertung mit neuronalen Netzen läßt sich mit etwas mehr Aufwand mit fertigen Programmen (z.B. „Neural Connection“) erreichen.

Bei manchen Problemen aber, wie dies beispielsweise der septische Schock darstellt, ist auch eine solche Datenauswertung problematisch: Es fehlt die für eine zuverlässige Aussage nötige Menge an Patientendaten. Hier kann eine zuverlässige Diagnose erst durch eine Kooperation vieler Kliniken erstellt werden. Eine Auswertung derartiger Multi-Center-Studiendaten läßt alle daran Beteiligten früher oder später davon profitieren.

Für eine rationale Behandlung von Patientendaten in der Medizin auf breiter Basis müssen noch viele Hindernisse überwunden werden: angefangen von der Datenerfassung, über die notwendige Kooperation medizinischer Einrichtungen bis hin zu einer internationalen Standardisierung und Verbreitung von Diagnosedaten und der darauf arbeitenden Programme.

Erst dies, was nicht nur die Sicherheit konventioneller Diagnosen erhöht, ist eine Revolution: dann aber eine richtige. Sie besteht allerdings nicht so sehr in der unreflektierten Anwendung des mystischen Wundermittels „Neuronale Netze“, sondern in der Erkenntnis über fundamentale menschliche Schwächen und dem gezielten Einsatz und der konsequenten Verwendung rationaler mathematisch-technischer Hilfsmittel für medizinische Zwecke.

5 Literatur

1. Bottaci L., Drew P., Hartley J., Hadfield M., Farouk R., Lee P., Macintyre I., Duthie G., Monson J. (1997): *Artificial neural networks applied to outcome prediction for colorectal cancer patients in separate institutions*; Lancet, 350: 469-472
2. Bounds D., Lloyd P.J.(1988): *A Multi-layer perceptron network for the diagnosis of low back pain*; Proc. IEEE Int. Conf. on Neural Networks, Vol.II: 481-489
3. Brause R. (1995): *Neuronale Netze*; Teubner Verlag, Stuttgart, 2. Auflage
4. Cicchetti DV. (1992): *Neural networks and diagnosis in the clinical laboratory: state of the art*; Clin. Chem. 38(1): 9-10
5. de Dombal, F.T., Leaper D.J., Staniland J.R., McCann A.P., Horrocks J.C. (1972): *Acute Abdominal Pain*, Brit. Med. J. 2: 9-13

6. Gamper J., Steimann F. (1996): *Medizinische Expertensysteme – Eine kritische Betrachtung*; APIS-Zeitschrift für Politik, Ethik, Wissenschaft und Kultur im Gesundheitswesen. Auch unter http://www.kbs.uni-hannover.de/paper/96/gam96_apis.ps abrufbar.
7. http://www.klinik.uni-frankfurt.de/papers/abdom_p.htm
8. Heden B. Edenbrandt L. Haisty W.K. jr., Pahlm O. (1994): *Artificial neural networks for the electrocardiographic diagnosis of healed myocardial infarction*; Am. J. Cardiol. 74(1): 5-8
9. McGonigal M. (1994): *A New Technique for Survival Prediction in Trauma Care Using a Neural Network*, Proc. World Conference on Neural Networks, pp.3495-3498
10. Miller P.L.(1986): *Expert Critiquing Systems: Practice-based Medical Consultation by Computer*; Springer Verlag, New York
11. Šíma J., Neruda R. (1994): *The empty expert system and its application in medicine*; Proc. Europ. Meeting on Cybernetics and System research, Vienna, pp.1825-1832
12. Šíma J. (1995): *Neural Expert Systems*; Neural Networks 8(2): 261-271
13. Snow P.B. Smith D.S. (1994): *Artificial neural networks in the diagnosis and prognosis of prostate cancer: a pilot study*; J.Urology. 152(5 Pt 2): 1923-1926
14. Sharpe P.K. Solberg H.E. Rootwelt K. Yearworth M. (1993): *Artificial neural networks in diagnosis of thyroid function from in vitro laboratory tests*; Clin. Chem. 39(11 Pt 1): 2248-2253
15. Wilding P. Morgan M.A. Grygotis A.E. Shoffner M.A. Rosato E.F. (1994): *Application of backpropagation neural networks to diagnosis of breast and ovarian cancer*; Cancer Letters. 77(2-3): 145-53
16. Yang T.F. Devine B. Macfarlane P.W. (1993): *Deterministic logic versus software-based artificial neural networks in the diagnosis of atrial fibrillation*; J. Electrocardiol. 26 Suppl: 90-94
17. Yang T.F. Devine B. Macfarlane P.W. (1994): *Artificial neural networks for the diagnosis of atrial fibrillation*; Med. Biol. Eng. Comput. 32(6): 615-619

Vollständige Anschrift des Autors

PD Dr. R. Brause, J.W. Goethe-Universität, Fachbereich Informatik, D-60054 Frankfurt;
 EMAIL: brause@cs.uni-frankfurt.de; HOME: <http://www.cs.uni-frankfurt.de/~brause>