

Revolutionieren Neuronale Netze unsere Vorhersagefähigkeiten?

Rüdiger W. Brause

FB Informatik, J.W. Goethe-Universität, Frankfurt

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 Sie als Mediziner die Verfahren auch in der Praxis einsetzen und fördern.

Eine wichtige Studie [5,12] 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 [4,7,14-18]. Beispielsweise wurden sie verwendet für die Diagnose von

- **erblichen Muskelkrankheiten** (Duchenne & Becker Dystrophie) [13]
EXPSYS: 16 Eingabevariable, 1 Ausgabevariable, 63 Beispielfälle.
100% richtige Diagnose, wobei sich nur 2 Variable als wichtig herausstellten.
- **Ohrenkrankheit** [14]
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 (Simple Low Back Pain SLBP, Root Pain RP, Spinal Pathology SP, Abnormal Illness Behavior AIB). Nach Training mit 100 Beispielfällen ergab sich bei 100 Testfällen folgende korrekte Diagnose:

Methode	SLBP %	RP %	SP %	AIB %	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

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

- **Überlebenswahrscheinlichkeit** nach schweren Verletzungen [10]

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:

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

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 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:

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

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

Eine Möglichkeit für eine schnelle und einfache Statistikanalyse ist der Einsatz „Neuronaler Netze“. Wieso? Worum geht es dabei? Die Methode der neuronalen Netze ist meist bei Medizinern noch unbekannt. Der folgende Abschnitt soll deshalb einen kurzen Überblick über das Paradigma der neuronalen Netze geben und Verständnis für die Natur des „Lernens“ in solchen

Netzen vermitteln.

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.




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

Ein Beispiel für eine Operation eines derartigen formalen Neurons ist eine gewichtete Summe der Eingaben x_i

$$y = z = \sum_i w_i x_i$$

mit den festen Gewichten w_i . Ordnen wir mehrere solcher formaler Neuronen parallel an, so können wir mit m Neuronen m Ausgabewerte y_1, \dots, y_m aus n Eingabewerten x_1, \dots, x_n 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. Die gesamte Operation des resultierenden neuronalen Netzes (visualisiert in Abbildung 2) ist damit die Funktion einer Matrixmultiplikation $\mathbf{y} = \mathbf{W}\mathbf{x}$: eine allgemeine lineare Operation.




Abbildung 2 Ein einfaches lineares Netzwerk

Ein Netzwerk, das eine solche Funktion ausführt, kann für viele Dinge eingesetzt werden.

3.1 Anwendung linearer Netze: ICA für EEG-Analyse

Eine wichtige Anwendung linearer neuronaler Netze besteht in der Aufbereitung von Daten, beispielsweise in der linearen Entmischung von Quellsignalen. Betrachten wir dazu Abbildung 3.




Abbildung 3 Mischung und Entmischung von Signalen

Angenommen, wir können nur die Überlagerungen $x_1(t), \dots, x_n(t)$ von Originalsignalen $s_1(t), \dots, s_n(t)$ (Quellsignalen) beobachten, nicht aber die Originale selber – was können wir tun, um trotzdem an die Quellen zu gelangen? Diese Situation ist beispielsweise bei EEG-Signalen gegeben, wo die beobachteten EEG-Signale eine Überlagerung der elektrischen Aktivität verschiedener Gehirnzentren auf der Kopfhaut darstellen. Könnten wir die Quellen erschließen, so könnten wir direkt die Aktivität dieser Zentren beobachten und bessere Diagnosen stellen.

Mathematisch gesehen besteht die Aufgabe darin, zu der Mischmatrix M die Inverse W zu finden, ohne die Quellen zu kennen. Für Menschen ist eine solche Unabhängigkeitsanalyse (*Independent Component Analysis*, ICA) schwer, nicht aber für lineare Neuronale Netze, die mit speziellen ICA-Lernregeln die unabhängigen Ursachen finden. Für die Anwendung der EEG-Analyse wurde dies von MAKEIG et al. [9] und KARHUNEN et al. [8] durchgeführt. Ein Diagramm der entmischten Quellen ist in Abbildung 4 gezeigt.




Abbildung 4 Unabhängige EEG-Signale (aus [8])

In Abbildung 4 ist das Diagramm in drei verschiedene Phasen, je nach mentaler Aktivität, eingeteilt. An dieser Stelle sind nun die Mediziner gefragt, um die eigentlichen physiologischen Ursachen der Quellenaktivität zu interpretieren.

3.2 Anwendung nicht-linearer Netze: Klassifikation und Diagnose

Die Funktion nicht-linearer Netze kann man besser verstehen, wenn man sich ihre Funktion vergegenwärtigt. Besteht die Funktion linearer Netze 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 5 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 Bauchspeicheldrüsenerkrankung 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 5 Klassifikation von Patientendaten

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 für Clusteranalysen bieten neuronale Netze. In Abbildung 6 ist ein Netzwerk neuerer Bauart gezeigt, das die Klassenentscheidung mit sog. RBF-Neuronen erbringt.




Abbildung 6 2-Schichten Netzwerk für Klassifikation

Die entscheidenden Elemente sind die Neuronen in der ersten Reihe (ersten Schicht), die sich jeweils wie kleine Experten verhalten: Jedes Neuron ist für einen Bereich im Eingaberaum um einen Klassenprototypen zuständig. Die Entscheidungen aller Experten werden dann in der


zweiten Schicht aus linearen Neuronen zusammengeführt und ergeben die Diagnosen f_1, f_2, \dots . Die Aktivität eines „Experten“ wird durch die Aktivitätsfunktion

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

beschrieben; sie entspricht einer Gauß'schen Glockenfunktion. Die Zusammenführung der Aktivität ist dann mit

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

gegeben. Verwenden wir direkt die Funktionen $S_k(\mathbf{c}_k, \sigma_i, \mathbf{x})$ für \tilde{S}_k , so erhalten wir als Ausgabe die einfache, gewichtete Überlagerung der Glockenfunktionen, siehe Abbildung 7a).



a) nicht normierte Aktivität

b) normierte Aktivität

Abbildung 7 Die Überlagerung für ein Netz aus drei Neuronen

Führen wir dagegen statt der absoluten die relative Aktivität zusammen, so erhalten wir deutlich scharfe Klassifikationsgrenzen, siehe Abbildung 7b). 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.

Alle Parameter (wie Klassenmittelpunkt \mathbf{c}_i , Breite σ_i , Einfluß 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 „Typische“ 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. Über die genannten Parameter hinaus kommt dann auch die Anzahl der Neuronen der ersten Schicht hinzu. Für den Arzt bedeutet dies etwas Neues: Das Netz hat ein neues Symptom entdeckt, das für eine gegebene Diagnose als Teildiagnose wichtig ist. Für eine Pauschal-diagnose „krank“ bedeutet eine solche Teildiagnose eine neue, dem Arzt unbekannt Krankheit!

3.3 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 8 ist dies als Forderung und Konzept visualisiert.

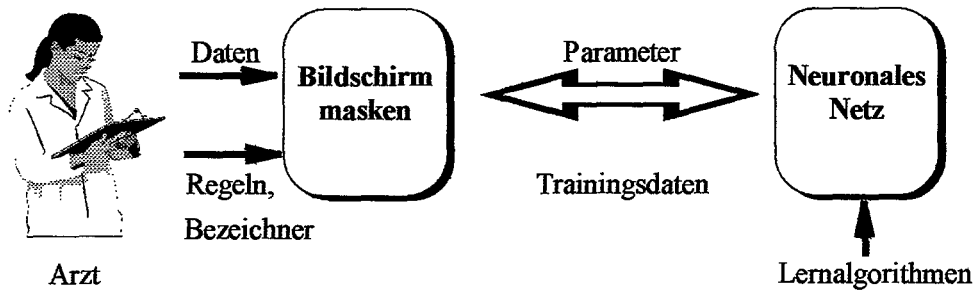


Abbildung 8 Interaktiver Transfer von vagem Wissen

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 ist dies näher erläutert. Links im Bild ist die Zuordnung der Blutzuckerwerte zu einer Insulininsuffizienz gezeigt, rechts im Bild die entsprechenden Funktionen zweier RBF-Neuronen mit trapezförmigen Aktivitäten $S_1(x)$ und $S_2(x)$.




Abbildung 9 Vage Diagnose und RBF-Initialisierung

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.

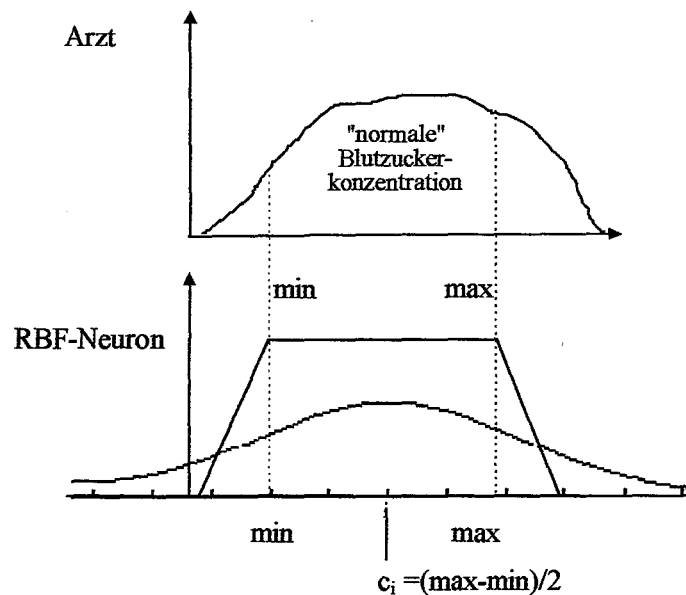


Abbildung 10 Initialisierung der RBF-Parameter mit dem Arztwissen

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 aber die meisten Mediziner, daß sie komplexe, hochdimensionale Patientendaten „per Auge“ nur durch Betrachten von wenigen Werten exakt beurteilen können. Dies ist, wie wir anfangs 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“ [11]: 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.

- **watch dog**

Spezialisierte Programme (Agentenprozesse) durchkämmen laufend die Datenbasis der Patientendaten und alarmieren den diensttuenden Arzt, wenn problematische Zusammenhänge in den Labor- und Gerätewerten 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 Mediziner 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.

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, von denen auch Mediziner in weißen Kitteln nicht frei sind, und dem gezielten Einsatz und der konsequenten Verwendung rationaler mathematisch-technischer Hilfsmittel für medizinische Zwecke.

5 Referenzen

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, San Diego 1988, Vol.II: 481-489
3. Brause R. (1995): *Neuronale Netze*; Teubner Verlag, Stuttgart, 2. Auflage, 1995
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 (1996). Auch unter http://www.kbs.uni-hannover.de/paper/96/gam96_apis.ps abrufbar.
7. 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

8. Karhunen, J., Hyvarinen, A., Vigario, R., Hurri, J, Oja, E. (1997): *Applications of Neural Blind Source Separation to Signal and Image Processing*; in Proc. IEEE 1997 Int. Conf. on Acoustics, Speech, and Signal Processing (ICASSP'97), April 21-24, 1997, Munich, Germany. Auch erhältlich über <http://nucleus.hut.fi/~juha/papers/3087KARH.ps>
9. Makeig S., Bell A.J., Jung T-P. and Sejnowski T.J. (1995): *Independent Component Analysis of Electroencephalographic Data*, in Mozer M. et al (eds) *Advances in Neural Information Processing Systems 8*, MIT press, 1995. Auch erhältlich über <ftp://ftp.cnl.salk.edu/pub/tony/nips95.ps>
10. McGonigal M. (1994): *A New Technique for Survival Prediction in Trauma Care Using a Neural Network*, Proc. World Conference on Neural Networks 1994, pp.3495-3498
11. Miller P.L.(1986): *Expert Critiquing Systems: Practice-based Medical Consultation by Computer*; Springer Verlag, New York 1986
12. http://www.klinik.uni-frankfurt.de/papers/abdom_p.htm
13. Šíma J., Neruda R. (1994): The empty expert system and its application in medicine; Proc. Europ. Meeting on Cybernetics and System research, Vienna 1994, pp.1825-1832
14. Šíma J. (1995): *Neural Expert Systems*; Neural Networks 8(2): 261-271
15. 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
16. 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
17. 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
18. 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
19. 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