

Neuronale Netze zur Klassifikation der SLDF-Perfusionsbilder anhand dem Erlanger Glaukomregister

István Pál

Friedrich-Alexander-Universität Erlangen-Nürnberg
Augenlinik mit Poliklinik, Labor für okuläre Perfusion
D-91054 Erlangen, Schwabachanlage 6.
Email: inpal@immd5.informatik.uni-erlangen.de

Zusammenfassung Diese Arbeit stellt die Auswertung der SLDF-Perfusionsbilder anhand dem Erlanger Glaukomregister mittels unterschiedlichen Neuronalen Netzen vor. Es wird auch die Bestimmung der optimalen Netzwerktopologie untersucht. Die Simulation der Netzwerke und die Netzwerkoptimierung werden mit Stuttgart(Tübingen) Neural Network Simulator (SNNS) durchgeführt. Neben den Ergebnissen der neuronalen Netzen werden auch die Ergebnisse der konventionellen Klassifikatoren, wie Minimum Distanz und k nächster Nachbar Klassifikator vorgestellt. Es stellte sich heraus, dass die Untersuchung der Glaukompatienten anhand den SLDF-Perfusionsbildern neben den Augeninnendruck-, morphometrischen und perimetrischen Messungen einen sehr wichtigen und guten Ersatzparameter liefert.

1 Einleitung

Die neuronalen Netze (NN) bieten eine flexible Möglichkeit zur Datenanalyse und werden immer häufiger in den medizinischen Anwendungsgebieten angewandt. Für die Klassifikation (gesund/krank Unterscheidung) der SLDF-Retinabilder (Heidelberg Retina Flowmeter /HRF/) wurden bereits in [1] unterschiedliche neuronale Netzmodelle, wie Merkmal-Input Netz, Polynomklassifikator Netz und Bild-Input Netz vorgestellt, da die Bilder anhand den aus dem Perfusionsbild herausgewonnenen Merkmalen eingestuft sind. Die Netzmodelle werden mit unterschiedlichen Netzwerkausdünnungsverfahren optimiert, wie weight decay, magnitude based pruning (MBP), optimal brain damage (OBD), optimal brain surgeon (OBS), optimal skeletonization und evolutionäre Netzwerkoptimierung (ENZO). Außerdem wird die automatische Bestimmung der optimalen Netzwerktopologie auch mit cascade correlation (CC) untersucht. Die Ausdünnungsverfahren der Netzwerktopologie können auch für die Merkmalreduktion verwendet werden. Detaillierte Beschreibung über den obigen Verfahren findet man in [2, 3, 4, 5]. Das Training der Netzwerke und die Netzwerkoptimierung wurden mit dem Stuttgart(Tübingen) Neural Network Simulator (SNNS) [6] durchgeführt.

2 Der Aufbau der neuronalen Netze

Definition 1. Ein (formales) $\Sigma\Pi$ -Neuron $u : \mathbb{R}^n \rightarrow \mathbb{R}$ ist eine Kompositfunktion von zwei Funktionen $net : \mathbb{R}^n \rightarrow \mathbb{R}$ und $f_{act} : \mathbb{R} \rightarrow \mathbb{R}$:

$$u = f_{act} \circ net = f_{act}(net(\mathbf{x})), \quad (1)$$

wobei $net(\mathbf{x}) = \sum_i w_i \prod_j x_j + \theta$ die Integrationsfunktion und f_{act} eine monoton wachsende Aktivierungs- oder Ausgangsfunktion sind.

Ein einfaches Neuron ist ein Spezialfall des $\Sigma\Pi$ -Neurons. Durch die $\Sigma\Pi$ -Neuronen lassen sich solche Netze aufbauen, mit denen z.B. der Polynomklassifikator sich modellieren läßt. Die meist verwendete Ausgangsfunktion ist die S-förmige Funktion wie die Fermi-Funktion: $f(x) = \frac{1}{1+e^{-x}}$. Durch die Ausgangsfunktion kann die Nichtlinearität des Neurons bestimmt werden.

Definition 2. Die Struktur des neuronalen Netzes (Topologie) ist durch die Funktion $W : U \times U \rightarrow \mathbb{R}$ gegeben, wobei U die Vereinigung der endlichen nichtleeren Mengen von Input-, Output- und verborgenen Neuronen ist.

Definition 3. Ein Netz heißt vorwärtsgekoppeltes bzw. rückkopplungsfreies Netz (feed forward), wenn $\neg \exists R : S_j \times S_i : i \leq j$, wobei S die Schicht der Neuronen kennzeichnet. Ein vorwärtsgekoppeltes Netz heißt ebenweises verbundenes Netz (full connected), wenn die Verbindungen von einer Schicht k nur zur nächsten Schicht $k + 1$ ($k \in \mathbb{N}$) existieren. Ein vorwärtsgekoppeltes Netz heißt allgemein vorwärtsgekoppeltes Netz (shortcut), wenn es neben den Verbindungen von aufeinanderfolgenden Schichten Verbindungen zwischen Schichten k und $k + i$ ($i > 1; k, i \in \mathbb{N}$) existieren.

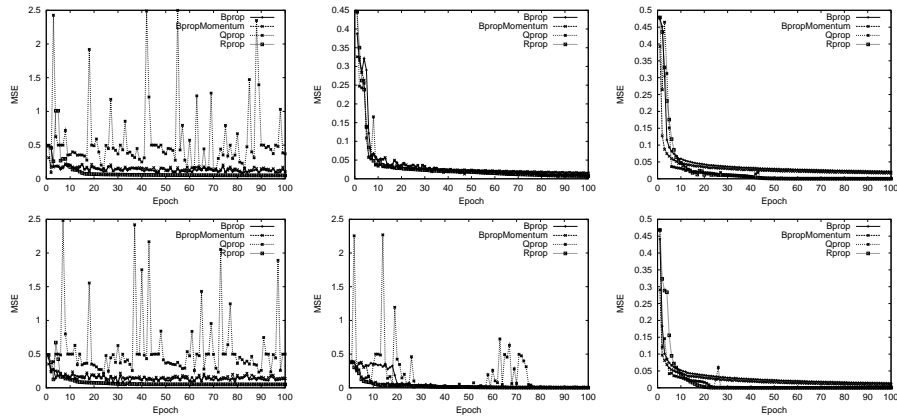
Im weiteren, wenn über die Topologie eines NNs gesprochen wird, wird ein vorwärtsgekoppeltes Netz verstanden und unter den Schichten des Netzes werden die Schichten der Neuronen verstanden, die in Form n - n -...- n [.sc] angegeben werden, wobei $n \in \mathbb{N}$ die Anzahl der Neuronen in einer Schicht bedeutet und .sc ein optionales Zeichen für shortcut Netze ist. Die erste bzw. die letzte Zahl ist die Neuronenanzahl in der Input- bzw. der Output-Schicht. Die dazwischenliegenden Zahlen bedeuten die Anzahl der Neuronen in verborgenen Schichten.

Definition 4. Ein neuronales Netz ist ein Tupel $NN = (U, W, \mathcal{L})$, wobei U eine endliche nichtleere Menge von Verarbeitungseinheiten (Neuronen) ist, W die Netzwerkstruktur (Topologie, Gewichtsmatrix) und \mathcal{L} der Trainingsalgorithmus sind.

Definition 5. Das mehrschichtige Perzeptron (MLP) ist ein vorwärtsgekoppeltes NN, das neben den Ein- und Ausgabeschichten eine oder mehrere verborgene Schichten beinhaltet.

Als Lernverfahren werden hier nur diejenigen verwendet, deren Optimierungsprinzipien auf der Delta-Regel bzw. deren Erweiterungen basieren, wie der Error Backpropagation (Bprop) bzw. Bprop mit Momentum (BpropM) [7], Quickpropagation (Qprop) und der Resilientpropagation (Rprop) Algorithmus [8], die das Training auch für mehrschichtige Netze ermöglichen.

Abbildung 1. Die Konvergenz der Bprop, Bprop mit Momentum, Qprop und Rprop Algorithmen oben bei 2-1, 2-2-1, 2-2-1.sc unten bei 4-1, 4-4-1, 4-4-1.sc Netztopologien in der Funktion von Epoch und mittlerem quadratischen Fehler



3 Ergebnisse der Retinabildauswertungen

3.1 Ergebnisse der Klassifikation

Die widerspruchsfreie Training und Test SLDF-Bilder wurden anhand den ärztlichen Diagnosen und den Bildinformationen aus dem Erlanger Glaukomregister (ErGR) und aus der HRF-Datenbank zusammengestellt, in denen die Ergebnisse mehrerer bzw. unterschiedlicher Untersuchungen (intraokuläre Druckmessung, perimetrische, morphometrische Untersuchung usw. und SLDF) über die Patienten gespeichert wurden. Anhand diesen Werten wird der Patient zu den Gruppen normal und glaukom eingestuft.

Alle verwendbare Bilder der HRF-Datenbank-0 wurden ausgewertet. Es wurden insgesamt 1716 (= 604Training + 1112Test) „kranke“ Bilder und 1289 (= 603Training + 695Test) „gesunde“ Bilder von 229 kranken und von 104 gesunden Patienten verwendet.

Die Merkmale der SLDF-Bilder wurden aus folgenden ausgewählt: die Größe des gefäßfreien Gebietes (M1), die Länge der Gefäße (M2), das Verhältnis der Kapillaren und dickeren Gefäßen (M3) und die Anzahl der Y-Verzweigungen (M4) [1]. Die Merkmale sind so skaliert, dass sie ungefähr im Intervall [0, 1] liegen. Bei 2-* Netzen wurden die Merkmalen M1, M2 verwendet und die Netzen mit vier Eingängen wurden mit den Merkmalen M3 und M4 erweitert.


Als Lernverfahren für NN wurde der Rprop Algorithmus verwendet, der eine deutlich stabilere als Qprop und deutlich schnellere Konvergenz als Bprop und dessen Varianten zeigt (siehe Abb. 1).

Die Ergebnisse der unterschiedlichen Klassifikatoren sind in der Tabelle 1 zusammengefasst.

Tabelle1. Ergebnis der Auswertung mit unterschiedlichen NN, mit minimum Distanz und k nächster Nachbar Klassifikator

Klassifikator	Erkennungsrate
4-6-2-1.sc Netz	90.81%
4-1 Netz	90.23%
Minimum Distanz	84.39%
1NN	85.22%
3NN	88.16%
5NN	88.88%

Abbildung2. Oben: Weight decay mit Erkennungsrate 68-89%, MBD 86-87%, OBD 85-89%, OBS 86-90%, Unten: Optimal skeletonization 87-91%, ENZO 82-88%, CC 87-92%



3.2 Ergebnisse der Netzwerkoptimierung

Bei der Netzwerkoptimierung /außer CC-Verfahren/ wurde aus Netztopologien 4-10-1 bzw. 4-10-10-10-1[.sc] ausgegangen. Die Netze wurden im ersten Schritt der Optimierung volltrainiert. Hier wurde ein reduziertes Bildmaterial verwendet. Die Ausdünnung wegen dem wiederholten Training ist ein zeitaufwendiges Verfahren. Die Optimierung der shortcut verbundenen Netze waren zu langsam. Durch die Ausdünnung werden häufig alle Gewichte gelöscht. Die Ergebnisse waren stark von den eingestellten Parametern abhängig. In den meisten Fällen der Optimierung wurden die Merkmale M3, M4, durch die Netzwerkoptimierung eliminiert.

Die Ergebnisse der ausgedünnten, optimierten Netze sind auf der Abb. 2 zu sehen, wo auch die Erkennungsraten der unterschiedlichen Iterationsschritten der Optimierung gegeben sind.

Das CC-Verfahren weist eine sehr hohe Stabilität und eine sehr gute Erkennungsrate auf. Im Vergleich zu anderen Pruning-Verfahren lieferte das CC-

Verfahren das beste Ergebnis vor dem optimalen Skeletonizationsverfahren.

Da bei NN die Anzahl der Gewichten, Neuronen und deren Schichten für eine gegebene Aufgabe nicht exakt bestimmbar ist, kann auch die Topologie eines überkonstruierten Netzwerkes nicht immer sicher gewählt werden. So soll das CC-Verfahren, das die optimale Topologie aus der Eingang-Ausgang-Neuron-Topologie ausgehend erreicht, plausibler als die Pruning-Verfahren sein.

4 Zusammenfassung

Anhand den vier Merkmalen konnte mit den Topologien von 4* eine Erkennungsrate von ca. 90% erreicht werden. Diese Ergebnisse entsprechen den in [9] beschriebenen multivariaten statistischen Ergebnissen des ErGRs. Durch die Netzwerkoptimierung wurden als wichtigste Merkmale die M1 und M2 erwiesen. Diese Ergebnisse konnten auch mit anderen Verfahren ([10], kNN und minimum Distanz Klassifikator für die einzelnen Merkmale mit Leave-one-out-Verfahren) bestätigt werden. Die Klassifikation der SLDF-Bilder anhand geometrischen Merkmalen mittels NN liefert eine sehr gute Diagnosemöglichkeit des Glaukoms.

Literatur

1. Pál I, Niemann H, Michelson G: Neuronale Netze zur automatischen Auswertung der Zirkulationsstörungen der Netzhaut auf den SLDF-Perfusionsbildern. Lehmann T, Metzler V, Spitzer K, Tolxdorff T (Hrsg.), Bildverarbeitung für die Medizin 1998: Algorithmen-Systeme-Anwendungen Proceedings des Aachener Workshops, Springer-Verlag, Berlin, Informatik aktuell, S. 318-322, März 1998.
2. Schreiner T. Ausdünnungsverfahren für neuronale Netze. Diplomarbeit, Fakultät Informatik Institut für Parallele und Verteilte Höchstleistungsrechner (IPVR), Universität Stuttgart, 1994. Nr. 1140.
3. Zell A: Simulation Neuronaler Netze. Addison-Wesley (Deutschland) GmbH, Bonn, 1. unv. nachdruck. Ausg., 1996.
4. Braun H: Neuronale Netze: Optimierung durch Lernen und Evolution. Springer-Verlag, Berlin, 1997.
5. Schmalzl M. Lernverfahren neuronaler Netze mit automatischer Bestimmung der Netzwerktopologie. Diplomarbeit, Fakultät Informatik Institut für Parallele und Verteilte Höchstleistungsrechner (IPVR), Universität Stuttgart, 1993. Nr. 968.
6. Zell A, et. al. : SNNs. User Manual Version 4.1, 1995.
7. Rumelhart D. E, McClelland J. L: Parallel Distributed Processing: Exploration in the Microstructure of Cognition, Bd. 1.. MIT-Press, Cambridge, Massachusetts, 1986. Foundations.
8. Riedmiller M, Braun H: A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. Proc. of IEEE Int. Conf. on Neural Networks, San Francisco, CA, 03.28-04.01 1993.
9. Martus P: Die adäquate biometrische Modellierung einer komplexen klinischen Fragestellung am Beispiel der Erlanger Glaukomstudie. Habil.-Schr., Universität Erlangen-Nürnberg, 1995.
10. Rauber T. W: Inductive Pattern Classification: Methods-Features-Sensors. Dissertation, University Nova de Lisboa, Lisboa, 1994.