Neuronale Netze zur automatischen Auswertung der Zirkulationsstörungen der Netzhaut auf den SLDF-Perfusionsbildern

István Pál[1], Heinrich Niemann[2] und Georg Michelson[1]

[1]Augenklinik mit Poliklinik Universität Erlangen–Nürnberg
Schwabachanlage 6. (Kopfklinikum), D–91054 Erlangen
Email: inpal@cip.informatik.uni-erlangen.de
[2] Lehrstuhl für Mustererkennung (Informatik5)
Universität Erlangen–Nürnberg, Martenstraße 3. D–91058 Erlangen

Zusammenfassung. Scanning Laser Doppler Flowmetrie (SLDF) bietet ein nicht-invasives Verfahren zur Untersuchung der Zirkulationsstörungen des Augenhintergrundes. Die mit SLDF hergestellten Perfusionsbilder können mit neuronalem Netz automatisch ausgewertet werden.

Schlüsselwörter: neuronales Netz, Laser Doppler Flowmetrie

1 Einleitung

Eine Reihe von Augenerkrankungen beruhen auf Zirkulationstörungen in der retinalen und papillären Strombahn. Neuere Untersuchungen ergaben, daß auch bei Glaukom Zirkulationstörungen betrachtet werden können, wobei die rechtzeitige Erkennung wegen der irreversibilen Veränderung und Absterben des Gefäßsystems sehr wichtig ist. Bei diesen Erkrankungen ist es notwendig, die retinalen Kapillaren und Gefäßsysteme zu untersuchen. Dazu eignet sich die "Scanning Laser Doppler Flowmetrie" (SLDF), ein nicht-invasives Verfahren, das die zweidimensionale Darstellung der retinalen Blutzirkulation und die Visualisierung des retinalen Gefäß- und Kapillarsystems ermöglicht [1]. Durch dieses Verfahren wird der Augenhintergrund sequentiell, mehrmalig mit einem Laserstrahl abgetastet. Die Wellenlänge des Laserlichtes verändert sich gemäß optischem Doppler-Effekt und wird von einer empfindlichen Photodiode empfangen. Diese Meßwerte von Photodiode werden mit Fast-Fourier Transformation (FFT) verarbeitet und schließlich normiert. Nach der Normierung können die Perfusionsbilder, d.h. das anatomische (DC), volume, (Vol), flow (Flw) und velocity (Vel) Bilder errechnet werden. Diese Bilder (64 Pixel x 256 Pixel) visualisieren das retinale Gefäß- und Kapillarsystem (siehe Abb. 1). Auf den von SLDF hergestellten Bildern können zwischen dem gesunden und kranken Auge Unterschiede beobachtet werden (verändertes und abgestorbenes Gefäßsystem). Diese Eigenschaften sind auch auf den Bildern eines glaukomatösen Auges zu sehen (siehe Abb. 1). In dieser Arbeit möchten wir die computerunterstüzte Verarbeitung und die automatische Auswertung der SLDF-Bilder mit neuronalen Netzen vorstellen.

Abb. 1. *linke Spalte*: gesundes Auge; *rechte Spalte*: glaukomatöses Auge

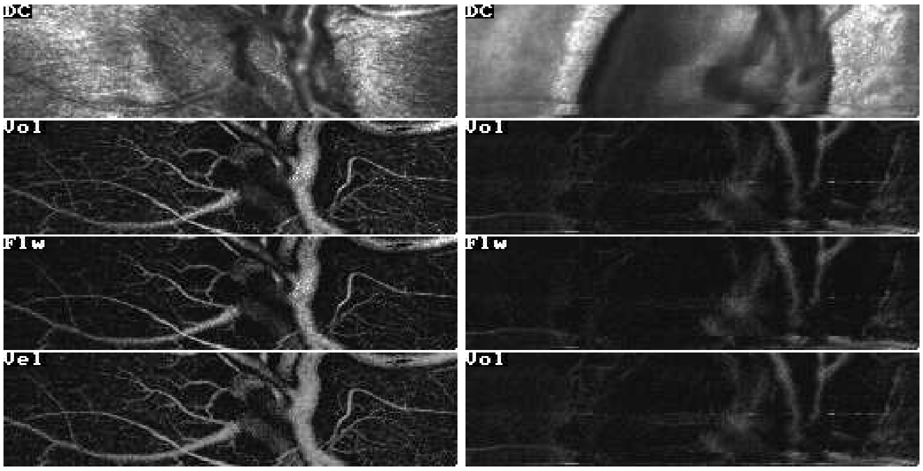

2 Vorverarbeitung und Merkmalgewinnung

2.1 Vorverarbeitung

Zu der Auswertung der Perfusionsbilder werden die volume Bilder verwendet. Es ist notwendig, die unerwünschten Linienstörungen (Sakkaden) auf den Retinabildern zu eliminieren, die bei einer Augenbewegung des Patienten auftreten. Die Sakkaden werden mit einem zeilenlangen Kantenfilter (Abb. 2) mit Hilfe eines Schwellwertverfahrens erkannt und eliminiert (Abb. 3). Das Bild wird danach mit einem Gaussian Filter gefiltert, um die Rauschen zu unterdrücken. Schließlich wird ein nichtlineares Kapillarhervorhebungsverfahren mit einer Binarisierung durchgeführt, wodurch das Kapillarsystem und die dickeren Gefäße besser visualisiert werden [2]. Dieses Bild wird zu der Merkmalextraktion verwendet.

2.2 Die Komponenten des Merkmalvektors

Infolge Makro- oder/und Mikrozirkulationserkrankungen wird das Gefäßsystem des Auges verändert bzw. es stirbt ab. Dadurch wird die Kapillardichte kleiner, nur die größeren Gefäße sind sichtbar, das interkapillare Gebiet vergrößert sich. Diese Eigenschaften der Zirkulationserkrankungen können auch bei dem sehr häufigen Glaukom auf den SLDF-Bildern beobachtet werden (siehe Abb. 1).

$$\begin{array}{cccccc} \cdots & -1 & -1 & -1 & -1 & \cdots \\ \cdots & 2 & 2 & 2 & 2 & \cdots \\ \cdots & -1 & -1 & -1 & -1 & \cdots \end{array}$$

Abb. 2. Kantenmaske

Abb. 3. Ergebnisse des Kantenfilters

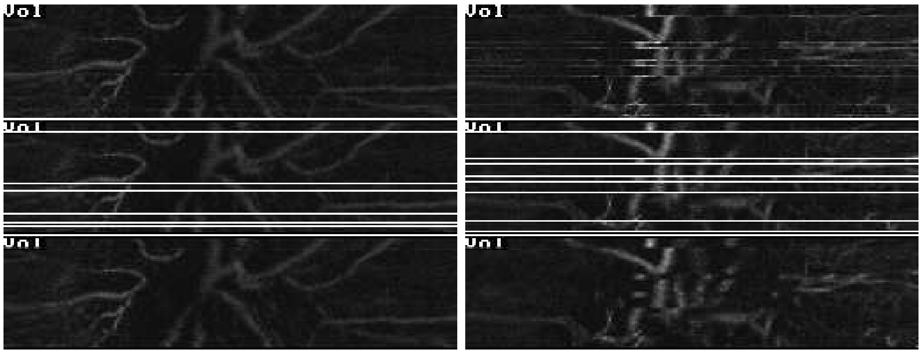

Abb. 4. *obere Reihe*: Skelettbilder der Binärbilder; *untere Reihe*: Ausfüllung der interkapillaren Bereiche mit Quadraten

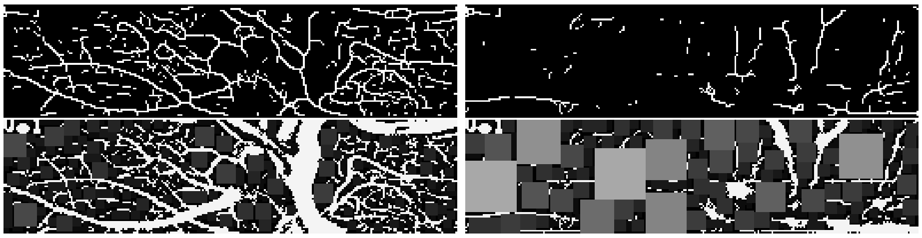

Diesen Eigenschaften entsprechend werden die Komponenten des Merkmalvektors [3] nach folgenden gewählt und errechnet:

1. Die Länge der Gefäße: aus dem Binärbild der Gefäßstruktur kann mit einem Skelettierungsverfahren [4] eine Gefäßmittellinie in der Breite von 1 Pixel hergestellt werden (Abb. 4 oben), diese Gefäßmittellinie gibt die Länge der Gefäße an
2. Die Größe des interkapillaren Gebietes: der Mittelwert der fünf größten Quadrate; das kapillarfreie Gebiet wird hierzu mit möglichst großen disjunkten Quadraten iterativ ausgefüllt [2] (Abb. 4 unten)
3. Die Kapillardichte bzw. die Proportion der Länge der dickeren Gefäße und der Kapillaren: aus dem Skelettbild und aus dem Gefäßbild kann ein Wert bestimmt werden, der mit der Kapillardichte proportional ist
4. Die Anzahl der "Y-Verzweigungen": kann aus dem Skelettbild mit der Hilfe der "connectivity number" der Gefäßmittelpunkte bestimmt werden

Diese vier Merkmale bilden die Komponenten des Merkmalvektors und die Inputs der Klassifikatoren bzw. des neuronalen Netzes.

Abb. 5. 4-Input Netz

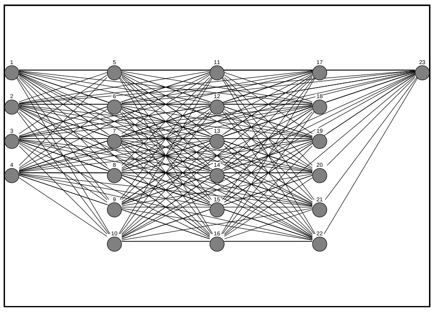

Abb. 6. Polynomklassifikator Netz

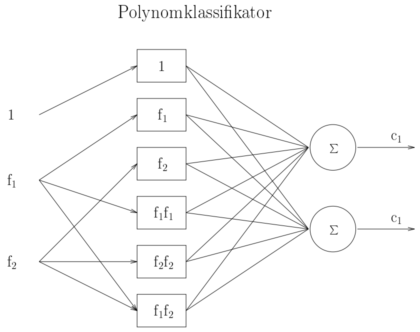

3 Neuronale Netze zur Auswertung der Retinabilder

3.1 "4-Input" Netz

Hier wurde ein feedforward, vollverbundenes (shortcut) Netz mit drei verborgenen Schichten verwendet (Abb. 5). Die Aktivationsfunktion der Neuronen ist die Sigmoide Funktion. Als Lernverfahren wird der Rprop Algorithmus [5, 6] verwendet, der schnellere Konvergenz als Backpropogation oder Quickpropogation Algorithmus zeigte. Das Netz hat vier Inputs den Komponenten des Merkmalvektors (Abschnitt 2.2) entschprechend und ein Output für das Ergebnis "krank" oder "gesund".

3.2 Polynomkassifikator Netz

Der Polynomkassifikator wird mit einem neuronalen Netz realisiert [7]. Die Abbildung 6. stellt ein Netz dar, das einen vollständig quadratischen Polynomklassifikator für zwei Merkmale und für zwei Klassen realisiert. Für vier Merkmale wird der Input des Netzes entsprechend erweitert.

3.3 "Bild-Input" Netz

Bei diesem Netz wird das Bild ohne Vorverarbeitung ausgewertet. Das Bild wird mit einem bilinearen Verkleinerungsverfahren mit einem Verkleinerungsfaktor von $0,25$ (Breite und Höche) verkleinert und zeilenweise als ein 1024-komponentiger Input Vektor verarbeitet [8]. Das Netz besteht wieder aus drei verborgenen Schichten und aus einem Ausgang, wie in dem Abschnitt 3.1.

3.4 Ergebnisse der Auswertungen

Zur Training wurden 38 "gesunde" und 82 "glaukomatöse" und zum Testen 77 "gesunde" 164 "glaukomatöse" Aufnahmen verwendet. Die Ergebnisse der verschiednen Netztypen sind in Tabelle 1 zu sehen. Hier sind zusätzlich die Ergebnisse des minimum Distanz- und des nächsten Nachbar Klassifikators [9] dargestellt.

Tabelle 1. Die Erkennungsergebnisse

Klassifikator	Glaukom	Normal	Insgesamt
4-Input Netz	90.24%	90.91%	90.57%
Polynom Klassifikator	89.61%	84.76%	87.18%
Bild-Input Netz	88.31%	71.34%	79.82%
Minimum Distanz	87.80%	88.31%	88.05%
Nächster Nachbar	82.31%	85.71%	84.01%

4 Weitere Pläne

Zur Verbesserung der Erkennungsrate des "4-Input" Netzes: weitere Merkmale als Input verwenden, die Merkmale der Temporal-, Nasalseite des Auges und des Papillenbereiches getrennt errechnen und verarbeiten, da wegen der Konfokalität des Lasergeretes der Papillenbereich "unscharf" sein kann. Die Anzahl der Training und Tesmuster muß erhöht werden.

Literatur

1. Michelson G, Groh M, Langhans MJ, Schmauß B: Zwiedimensionale Kartierung der retinalen und papillären Mikrozirkulation mittels Scanning Laser Doppler Flowmetrie. Klinische Monatsblätter für Augenheilkunde, Bd. 207, Nr. 3, 1995, S. 180–190.
2. Pál I, Michelson G, Niemann H, Welzenbach J: Erkennung von Mikrozirkulationsstörungen der Netzhaut mittels "Scanning Laser Doppler Flowmetrie". in Bildverarbeitung für Medizin Proceedings des Aachener Workshop, Bd. 1., Verlag der Augustinus Buchh., Aachen, Nov. 1996, S. 89–94.
3. Pál I, Niemann H, Michelson G: Evaluation of retina pictures using "Scanning Laser Doppler Flowmetrie" with neuronal networks. in Magyar Képfeldolgozók és Alakfelismerők Országos Konferenciája, Konferenciakiadvány, Keszthely, Okt. 1997, S. 18–24.
4. Zhou RW, Quek C, Ng GS: A novel single-pass thinning algorithm and an effective set of performance citeria. IEEE Trans. on Pattern Recognition Letters, Bd. 16, 1995, S. 1267–1275.
5. Zell A, et. all: SNNS. User Manual Version 4.1, 1995.
6. Zell A: Simulation Neuronaler Netze. Addison–Wesley (Deutschland) GmbH, Bonn, 1. unv. nachdruck. Ausg., 1996.
7. Sagerer G: Neuronal, Statistisch, Wissenbasiert: Ein Beitrag zur Paradigmendiskussion für die Mustererkennung. Mustererkennung 93, 15. DAGM-Symposium Bielefeld, Informatik aktuell, Springer-Verlag, 1993, S. 158–177.
8. Kulkarni AD: Artificial Neural Networks for Image Understanding. International Tomhomson Publishing, New York, 1994.
9. Niemann H: Klassifikation von Mustern. Springer–Verlag, Berlin, Heidelberg, New York, Tokyo, 1983.