

# Strukturanalyse in Epilumineszenz-Mikroskopie-Aufnahmen pigmentierter Hautmale mittels Cooccurrence-Merkmalen

Susanne Winter

Institut für Neuroinformatik, Lehrstuhl für theoretische Biologie  
Ruhr-Universität Bochum, 44870 Bochum  
Email: Susanne.Winter@neuroinformatik.ruhr-uni-bochum.de


**Zusammenfassung.** Die Analyse von Pigmentmustern, welche in pigmentierten Hautmalen durch unregelmäßige Melaninverteilung in den Hautschichten entstehen, liefert einen Beitrag zur Diagnosesicherung maligner Melanome. Um die Beurteilung dieser Pigmentmuster in technische Diagnoseunterstützungssysteme zu integrieren, ist es notwendig die Pigmentmuster durch geeignete Parameter zu beschreiben. Im Folgenden wird gezeigt, dass Texturmerkmale, welche aus Cooccurrence-Matrizen gewonnen werden, geeignet sind, die in pigmentierten Hautmalen auftretenden Netzmuster zu beschreiben.

## 1 Einleitung

Das maligne Melanom ist einer der bösartigsten Tumoren der Haut. Es entsteht durch Entartung des melaninbildenden Pigmentsystems. Aufgrund seiner steigenden Inzidenz wird eine sichere Diagnostik zunehmend wichtiger. Wird das maligne Melanom rechtzeitig erkannt, so kann durch eine frühzeitige operative Entfernung eine hohe Heilungsrate erzielt werden. Kann andererseits eine Bösartigkeit sicher ausgeschlossen werden, so können unnötige, teure und den Patienten belastende Operationen vermieden werden. Die Diagnose wird von einem Dermatologen anhand visueller Beurteilung verschiedener Kriterien, die in der ABCD-Regel zusammengefasst sind, gestellt [1]. Bei kleineren Hautmalen ist jedoch die Unterscheidung zwischen gutartigen Nävuszellnävi und bösartigen Melanomen schwierig, daher werden Melanome häufig erst in einem fortgeschritteneren Stadium, bei größerer Tumorausdehnung, diagnostiziert. Um die Diagnosesicherheit in frühem Stadium zu erhöhen, wurden Systeme zur computergesteuerten Diagnoseunterstützung entwickelt [2]. Diese Systeme berechnen und beurteilen in erster Linie Merkmale, die eine Erweiterung der visuellen Kriterien darstellen.

Die Hinzunahme von Epilumineszenz-Mikroskopie-Aufnahmen (ELM) hat zu einer Erhöhung der Diagnosesicherheit maligner Melanome durch den Dermatologen geführt [3]. Bei dieser Aufnahmetechnik ist eine Einsicht in tiefere Hautschichten möglich. Dadurch werden Pigmentmuster sichtbar, welche durch unregelmäßige Verteilung von Melanin entstehen. Der Arzt beurteilt das Auftreten bzw. die Ausprägung dieser Muster zur Sicherung seiner Diagnose. Zu den häufigsten Pigmentmustern gehören Globuli und Netzstrukturen. Sie treten sowohl in gut- als auch in bösartigen

**Abb. 1.** Beispiele für die verschiedenen Strukturtypen, (a) reguläre Netze (RN), (b) irreguläre, grobe Netze (IRNg), (c) irreguläre, feine Netze (IRNf) und (d) Globuli (Glb).



Hautmalen auf, unterscheiden sich aber in ihrem Verteilungsmuster und in ihrer Regelmäßigkeit [4]. So sind z.B. unregelmäßige Netzstrukturen häufiger in bösartigen als in gutartigen Hautmalen zu finden.

Um die Beurteilung der Pigmentmuster auch in technischen Systemen zu nutzen, müssen diese detektiert werden. Dazu ist es notwendig diese Muster durch geeignete Merkmale zu beschreiben. In dieser Arbeit wurden hierzu Cooccurrence-Merkmale verwendet und darauf basierend die Pigmentmuster mit einem künstlichen neuronalen Netz klassifiziert [5].

## 2 Methode


Aus digitalen ELM-Aufnahmen pigmentierter Hautmale, die in einer 30fachen Vergrößerung vorlagen, wurden Bildausschnitte extrahiert, welche Pigmentstrukturen vom Typ Netzstruktur oder Globuli enthalten. Diesen Bildausschnitten wurden die Strukturtypen reguläre Netze (RN), irreguläre, grobe Netze (IRNg), irreguläre, feine Netze (IRNf) und Globuli (Glb) zugeordnet. Abb. 1 zeigt ein Beispiel zu jedem Strukturtyp.

### 2.1 Vorverarbeitung und Merkmalsextraktion


Es werden eine Reihe von Vorverarbeitungsschritten durchgeführt, die der Hervorhebung der Pigmentmuster bzw. der Kantenverstärkung dienen. In Abb. 2 ist ein Schema der Verarbeitungsschritte dargestellt. Aus den so gewonnenen Bildern werden Cooccurrence-Matrizen erstellt. Um eine Rotationsinvarianz zu erreichen, werden acht Richtungen berücksichtigt.

Die Cooccurrence-Matrizen werden für die Distanzen 2, 4, 6, ..., 32 Pixel berechnet, aus diesen werden die Merkmale Energie der Homogenität (EH), Entropie (ENT), Maximale Wahrscheinlichkeit (MW), Kontrast (KON) [6] und die Diagonalsumme (DS) der Matrix berechnet. Für jeden Bildausschnitt ergeben sich somit 5 Vektoren verschiedener Merkmale aus den verstärkten Grauwertbildern und 5 Vektoren aus den Kantenbildern. Dabei besteht jeder Vektor aus den Merkmalswerten der 16 unterschiedlichen Distanzen. Abb. 3. zeigt als Beispiel den Merkmalsvektor Maximale Wahrscheinlichkeit für eine künstlich erzeugte Gitterstruktur und für einen Bildausschnitt mit einem regelmäßigen Netzmuster.

**Abb. 2.** Schematische Darstellung der Vorverarbeitungsschritte, zu jedem Schritt ist das Ergebnis der Verarbeitung anhand eines Beispiels gezeigt.



**Abb. 3.** Das Merkmal Maximale Wahrscheinlichkeit (MW) berechnet aus den Kantenbildern, für die Distanzen 2 bis 32. In (a) für eine künstlich erzeugte Gitterstruktur und (b) für einen Bildausschnitt mit einem regelmäßigen Netzmuster (RN). Abhängig von der Skalierung des Musters ergibt sich ein charakteristischer Verlauf.



## 2.2 Klassifikation

Die Beurteilung der Merkmale erfolgt durch Klassifikationsraten, die durch ein künstliches neuronales Netz vom Typ Multi Layer Perzeptron (MLP) gewonnen werden. Als Eingangsvektoren dient jeweils ein Merkmalsvektor, eines Merkmalstyps für 16 verschiedenen Distanzen. Das MLP hat eine versteckte Schicht mit 5 Neuronen und einem Ausgangsneuron. Als Lernverfahren wurde Backpropagation verwendet.

Die Klassifizierung wurde einerseits zur Unterscheidung zwischen RN und Glb durchgeführt, andererseits zwischen RN und IRNg bzw. RN und IRNf. Der Datensatz wurde für jede Trainingsphase in einen Trainings- und einen Testdatensatz unterteilt. Das Training wurde beendet, wenn der Fehler auf dem Testdatensatz zugenommen hat, d.h. wenn eine Überanpassung des MLP an die Trainingsdaten eingesetzt hat.

## 3 Ergebnisse

Die Ergebnisse wurden auf Basis der Datenbank der DANAOS-Studie [2] erstellt. Eine Klassifizierung der Strukturtypen ist bei der Unterscheidung zwischen den RN und den Glb am besten. Bei Nutzung der Energie der Homogenität kann eine Fehlerrate von 2% auf dem Testdatensatz erreicht werden. Für die anderen Merkmalstypen

**Tabelle 1.** Fehlerraten, des Trainingsdatensatzes, links für die Merkmalsvektoren der Grauwertbilder (gw), rechts für die Kantenbilder (k).

	RN-Glb	RN-IRNg	RN-IRNf		RN-Glb	RN-IRNg	RN-IRNf
EH (gw)	0,10	0,104	0,143	EH (k)	0,02	0,135	0,110
ENT (gw)	0,13	0,125	0,176	ENT (k)	0,04	0,094	0,099
MW (gw)	0,08	0,135	0,132	MW (k)	0,06	0,104	0,209
KON (gw)	0,05	0,052	0,132	KON (k)	0,04	0,156	0,099
DS (gw)	0,08	0,083	0,132	DS (k)	0,03	0,073	0,044

liegen die Fehlerraten zwischen 3% und 13%. Bei der Unterscheidung von RN und IRNgr liegen die Fehlerraten zwischen 6% und 13%. Und bei RN und IRNf zwischen 4% und 18%. Tabelle 1. zeigt die Fehlerraten des MLP beim Training mit den verschiedenen Merkmalsvektoren jeweils für die Unterscheidung RN-Glb, RN-IRNg und RN-IRNf.

Bei allen drei Klassifizierungen ist zu erkennen, dass die Merkmale, welche auf den Kantenbildern erstellt wurden, zu besseren Ergebnissen führen als die Merkmale der Grauwertbilder. Von den Merkmalen der Grauwertbilder führen Kontrast und Diagonalsumme zu den besten Resultaten.

## 4 Diskussion

Es wurde gezeigt, dass anhand von Cooccurrence-Merkmalen Pigmentstrukturen mit einem MLP klassifiziert werden können. Die Unterscheidung von Netzstrukturen und globulären Strukturen ergibt sehr gute Ergebnisse, aber auch reguläre Netze und irreguläre Netze können klassifiziert werden.

Da diese Strukturen sehr häufig in pigmentierten Hautmalen zu finden sind und die Bewertung der Pigmentstrukturen eine Verbesserung der visuellen Diagnostik erbringt, könnte eine Kombination der Cooccurrence-Merkmale mit Merkmalen aus anderen Verfahren, die z.B. Randunregelmäßigkeiten oder Symmetrieeigenschaften bewerten, die Sicherheit technischer Diagnoseunterstützungsverfahren erhöhen.

## 5 Literatur

1. Friedman RJ, et al.: Early detection of malignant melanoma. The role of physician examination and self-examination of the skin. *CA Cancer J Clin*, 35:130-151, 1985
2. Pott G, Husemann R, Eckert L, Grünendick T, Lux S, Altmeyer P. Danaos - Automated skin cancer diagnosis with neural networks. In *Proc 7th EADV*, 1998.
3. Pehamberger H, Binder M, Steiner A, Wolff K: In Vivo Epiluminescence Microscopy: Improvement of Early Diagnosis of Melanoma. *J Invest Dermatol* 100:356-362, 1993.
4. Steiner A, Binder M, et al.: Statistical evaluation of epiluminescence microscopy criteria for melanocytic pigmented skin lesions. *J Am Acad Dermatol* 29:581-8, 1993.
5. Winter S: Strukturanalyse in Epilumineszenzaufnahmen pigmentierter Hautmale. Studienarbeit, Institut für Neuroinformatik, Bochum, 2001.
6. Haralick RM, Shapiro LG: *Computer and Robot Vision*. Addison-Wesley, 1992.