

# Co-Occurrence Matrizen zur Texturklassifikation in Vektorbildern

C. Palm, V. Metzler\*, B. Mohan, O. Dieker, T. Lehmann, K. Spitzer

Institut für Medizinische Informatik  
Rheinisch-Westfälische Technische Hochschule Aachen, D-52057 Aachen

\*Institut für Signalverarbeitung und Prozeßrechentchnik  
Medizinische Universität zu Lübeck, Ratzeburger Allee 160, D-23538 Lübeck

chripa@bootes.imib.rwth-aachen.de      metzler@isip.mu-luebeck.de

**Zusammenfassung.** Statistische Eigenschaften natürlicher Grauwerttexturen werden mit Co-Occurrence Matrizen, basierend auf der Grauwertstatistik zweiter Ordnung, modelliert. Die Matrix gibt dann die a-priori Wahrscheinlichkeiten aller Grauwertpaare an. Da in der medizinischen Bildverarbeitung verstärkt Multispektralbilder ausgewertet werden, wird das bekannte Konzept hier auf beliebige Vektorbilder erweitert. Dadurch kann bei der Texturklassifikation die zur Verfügung stehende Information vollständig genutzt werden. Insbesondere zur Detektion von Farbtexturen ist dieser Ansatz geeignet, da Wertepaare unterschiedlicher Spektralebenen ausgewertet werden können. Ebenso kann die Methode auch bei der Multiskalendekomposition von Intensitätsbildern zur Verbesserung der Texturerkennung beitragen. Die in den Matrizen entstehenden Muster lassen dann über die Extraktion geeigneter Texturdeskriptoren Rückschlüsse auf die Texturen des Bildes zu.

**Schlüsselwörter:** Texturerkennung, Vektorbilder, Multispektralbilder, Multiskalenbilder, Klassifikation

## 1 Einleitung

Bei der Segmentierung der in einem digitalen Bild enthaltenen morphologischen Strukturen kommt der Texturanalyse in der medizinischen Bildverarbeitung eine besondere Bedeutung zu. Zur Extraktion geeigneter Merkmale werden hierbei meist frequenzbasierte und statistische Ansätze verwendet. Eine der wichtigsten Methoden zur statistischen Texturklassifikation stellen die von HARALICK eingeführten Co-Occurrence Matrizen dar [1]. Herkömmliche Co-Occurrence Matrizen sind auf Intensitätsbildern definiert und modellieren die a-priori Wahrscheinlichkeit des paarweisen Auftretens von Grauwerten bei festem Distanzvektor  $\mathbf{d}$  mit Hilfe einer Statistik zweiter Ordnung. In der Regel bilden sich in der Matrix charakteristische Muster aus, die Rückschlüsse auf die zugrundeliegende Textur erlauben. Co-Occurrence Matrizen eignen sich aufgrund ihres Datenvolumens nicht direkt als Texturmerkmale, weshalb meist sinnvolle Teilmengen der

in [1] vorgeschlagenen 14 Texturmaße als zu klassifizierende Merkmalsvektoren verwendet werden. Zur überwachten Klassifikation werden aus diesen Merkmalen zunächst prototypische Texturklassen errechnet. Anschließend können unbekannte Texturen aufgrund von Ähnlichkeitsmaßen einer der Klassen zugeordnet werden.

In der medizinischen Diagnostik werden vermehrt Vektorbilder (z.B. Farbbilder) akquiriert. Die dargestellten Texturen können oft in der entsprechenden Intensitätsdarstellung nicht beobachtet werden, es handelt sich also um reine Farbtexturen [2]. Um in solchen Fällen alle verfügbaren Informationen zur Texturklassifikation auszunutzen, wird hier das Konzept der Co-Occurrence Matrizen auf beliebige Vektorbilder erweitert.

Weiterhin verbessert die Modellierung von Korrelationen zwischen den Bildebenen synthetisch erzeugter Multiresolutionsbilder (Skalenräume) die Texturklassifikation in Intensitätsbildern. Dieser Ansatz geht über die bekannte Methode hinaus, den variablen Distanzvektor  $\mathbf{d}$  als Skalenparameter zu verwenden [3], da hier ein "echter" Skalenraum durch sukzessives Filtern erzeugt wird.

## 2 Methode

Aufgrund der Kombinationsmöglichkeiten der Bildebenen ergeben sich für Vektorbilder eine Vielzahl verschiedener Co-Occurrence Matrizen. Anschließend werden für jede Matrix die Haralick'schen Texturmaße berechnet, welche als Trainingsdaten eines Klassifikationsprozesses dienen.

Für ein gegebenes Bild  $f(\mathbf{x} \in \mathbb{N}^2)$  beschreibt die Co-Occurrence Matrix  $\mathbf{C}_{\mathbf{d}}(i, j)$  die Wahrscheinlichkeit, daß zwei Pixel mit dem Abstand  $\mathbf{d}$  genau die Funktionswerte  $i$  und  $j$  besitzen, wobei  $\mathbf{d} \in \mathbb{N}^2$  ist. In der Regel ist die unabhängige Bearbeitung einzelner Bildebenen bei Vektorbildern  $f_z(\mathbf{x})$  nicht ausreichend, weil so keine ebenenübergreifende Korrelation von Wertepaaren modelliert werden kann. Eine Co-Occurrence Matrix, die die Bildebenen  $f_{z_1}$  und  $f_{z_2}$  bezüglich der Distanz  $\mathbf{d}$  berücksichtigt, ist gegeben durch:

$$\mathbf{C}_{\mathbf{d}}^{z_1, z_2}(i, j) = P(f_{z_1}(\mathbf{x})=i \wedge f_{z_2}(\mathbf{y})=j \mid \mathbf{x}-\mathbf{y}=\mathbf{d}) \quad (1)$$

Im einfachsten Fall wird in  $\mathbf{C}_{\mathbf{d}}^{z_1, z_2}$  das Auftreten von Werten an korrespondierenden Stellen der Ebenen  $z_1$  und  $z_2 \neq z_1$  gezählt. Da in der Regel sowohl  $\mathbf{C}^{z_1, z_2} \neq \mathbf{C}^{z_2, z_1}$ , als auch  $(\mathbf{C}^{z_1, z_2})^{\text{tr}} = \mathbf{C}^{z_2, z_1}$  gilt, können bei festem  $\mathbf{d}$  und  $N$  Ebenen  $(N^2 - N)/2$  unabhängige Co-Occurrence Matrizen berechnet werden. Wegen dieser Vielzahl von anfallenden Matrizen ist es häufig sinnvoll, Intervallmatrizen zu bilden, die über einen bestimmten Intervallbereich  $\mathbf{d} \in [\mathbf{d}_1; \mathbf{d}_2]$  die Matrizen  $\mathbf{C}$  integrieren:

$$\mathbf{I}_{\mathbf{d}_1, \mathbf{d}_2}^{z_1, z_2}(i, j) = \frac{4}{\pi(|\mathbf{d}_2|^2 - |\mathbf{d}_1|^2)} \sum_{|\mathbf{d}_1| \leq |\mathbf{d}| \leq |\mathbf{d}_2|} \mathbf{C}_{\mathbf{d}}^{z_1, z_2}(i, j) \quad (2)$$

Bei festen Bildebenen  $f_{z_1}$  und  $f_{z_2}$  werden so ganze Distanzbereiche durch eine Matrix  $\mathbf{I}$  repräsentiert.

Während bei RGB-Farbbildern die einzelnen Bildebenen gleichwertige Informationen enthalten, läßt sich z.B. bei Multiskalenbildern eine Ordnung definieren. Deshalb ist hier eine weitere Variante der Summenmatrix sinnvoll, bei der alle Co-Occurrence Matrizen bezüglich einer Referenzebene  $f_{z_0}$  aufsummiert werden:

$$\mathbf{R}_d^{z_0, z}(i, j) = \frac{1}{z - z_0} \sum_{\hat{z}=z_0+1}^z \mathbf{C}_d^{z_0, \hat{z}}(i, j) \quad (3)$$

Welche der akkumulierten Matrizen für eine Anwendung geeignet sind, hängt in erster Linie von der Art der Vektorbilder ab. Im folgenden wird kurz auf die beiden wichtigsten Typen von Vektorbildern eingegangen.

## 2.1 Farbbilder

Bei der Akquirierung eines Farbvektors  $\mathbf{c} = [c_1, \dots, c_m, \dots, c_M]$  durch einen Sensor entsteht ein Element  $c_m$  durch spektrale Integration der sensorspezifischen Spektralwertfunktion  $r_m(\lambda)$  und dem Spektrum des einfallenden Lichts  $L(\lambda)$ :


$$\int_{\lambda} L(\lambda) r_m(\lambda) d\lambda \quad (4)$$

Dabei wird mit  $\lambda$  die Wellenlänge bezeichnet. Während die Dimension  $M$  in der Spektrometrie zwischen dreißig und sechzig liegt, unterscheidet man bei der Aufnahme durch eine CCD-Farbkamera drei Spektralwertfunktionen. Da bei einigen problemangepaßten Farbräumen wie HSV oder Luv die Symmetrie der Farbbänder verloren gehen kann, wurde zur Berechnung der ebenenübergreifenden Co-Occurrence Matrizen der RGB-Farbraum verwendet.

## 2.2 Multiskalenbilder

Der Multiskalenansatz geht davon aus, daß Texturen in mehreren Auflösungsstufen (Skalen) betrachtet werden müssen, um ihre Frequenzeigenschaften analysieren zu können. Durch die Matrizen  $\mathbf{C}$  oder  $\mathbf{R}$  werden Korrelationen und statistische Abhängigkeiten in Intensitätstexturen adäquat modelliert. In der Regel werden Tiefpaß- oder Bandpaßfilter zum Aufbau des Skalenraums verwendet [4].

Der Gaußsche Skalenraum wird beispielsweise durch Variation des Skalenparameters  $\sigma$  generiert, der die Breite des Filterkerns bezeichnet. Als Distanzvektor wird hierbei in der Regel der Nullvektor  $\mathbf{0}$  verwendet. Eine Co-Occurrence Matrix  $\mathbf{C}_0^{\sigma_1, \sigma_2}$  erfaßt also die statistische Abhängigkeit zwischen einem Bildpunkt in  $f_{\sigma_1}$  und seiner Gauß-gefilterten Umgebungen.




**Abb. 1.** *Obere Zeile.* RGB-Bänder zweier Farbtexturen. *Mittlere Zeile:* klassische Co-Occurrence Matrizen  $C_1^{\text{grau}}$ ,  $C_1^G$ , Intervallmatrizen  $I_{1,1}^{GB}$ ,  $I_{1,8}^{GB}$  der linken Textur. *Untere Zeile:*  $C_1^{\text{grau}}$ ,  $C_{1,1}^R$ ,  $I_{1,1}^{RG}$ ,  $I_{1,8}^{RG}$  der rechten Textur.

### 3 Ergebnisse und Ausblick

Das vorgestellte Verfahren ist bei Farbtexturen erfolgversprechender als herkömmliche Co-Occurrence Matrizen, die nur die Intensitätsverteilungen betrachten. Beispielsweise kann eine Überbelichtung, die sich zuerst in den Farbbändern der Objektfarbe bemerkbar macht, leicht durch Deformationen der üblicherweise ellipsenförmigen Verteilungen erkannt und ggf. korrigiert werden (Abb. 1). Ebenenübergreifende Farbmatrizen verlieren zwar ihre Symmetrieeigenschaften, zeigen aber charakteristische Strukturen.

Bei der Analyse von Grauwertbildern können die Auflösungsebenen mit beliebigen Filtern erzeugt werden. Man modelliert also den Einfluß des Filters auf die Textur, da die elliptische Verteilung umso breiter wird, je größer der Effekt des Filters ist (Abb. 2). Gerade für morphologische- und Rangordnungsfiler (also nichtlineare Filter) konnte festgestellt werden, daß die Texturen unterschiedlich reagieren, was deren Klassifikation vereinfacht.

Die etablierten Haralickschen Texturmaße [1] sind bei Verwendung von Co-Occurrence Matrizen auf Vektorbildern teilweise ungeeignet, da die Verteilungen oft von der charakteristischen elliptischen Form abweichen. Deshalb werden



**Abb. 2.** *Obere Zeile:* Zwei Texturen in drei Auflösungsstufen ( $\sigma = 0$ ,  $\sigma = 1$ ,  $\sigma = 5$ ). *Mittlere Zeile:* Klassische Co-Occurrence Matrix  $\mathbf{C}_1$ , Multiskalenmatrizen  $\mathbf{C}_0^{0.1}$ ,  $\mathbf{C}_0^{0.5}$ , Summenmatrix  $\mathbf{R}_0^{0.5}$  der oberen Textur. *Untere Zeile:*  $\mathbf{C}_1$ ,  $\mathbf{C}_0^{0.1}$ ,  $\mathbf{C}_0^{0.5}$ ,  $\mathbf{R}_0^{0.5}$  der unteren Textur.

zukünftig geeignete Merkmale entwickelt, die die Diskriminanzeigenschaften der Matrizen unterstützen. Zur Klassifikation soll ein statistischer Klassifikator auf Basis einer Mischverteilung eingesetzt werden, dessen Parameter mit Hilfe eines überwachten EM-Algorithmus' trainiert werden können.

## Literatur

1. Haralick RM, Shanmugam K, Dinstein I. Textural features for image classification. *IEEE Trans. Systems, Men, and Cybernetics*, 3(6):610–621, 1973.
2. Lakmann R, Priese L. Ein Farbkovarianzmodell zur Analyse und Synthese von Farbtexturen. In Paulus, Wahl, eds., *Mustererkennung 1997*, pp. 55–62. Springer-Verlag, Berlin, 1997.
3. Walker RF, Jackway P, Longstaff ID. Recent developments in the use of the co-occurrence matrix for texture recognition. In *13th Int'l. Conf. on Digital Signal Processing*, Santorini, vol. 1, pp. 63–65, 1997.
4. Burt PJ. The pyramid as structure for efficient computation. In Rosenfeld, ed., *Multiresolution Image Processing and Analysis*, pp. 6–35. Springer-Verlag, 1984.