Automatische Erkennung von Bildinhalten bei Standardröntgenaufnahmen

F. Weiler, F. Vogelsang

Lehrstuhl für Angewandte Mathematik insbesondere Informatik
RWTH Aachen, Ahornstr.55, D-52074 Aachen
email: weiler@informatik.rwth-aachen.de

Klinik für Radiologische Diagnostik
RWTH Aachen, Pauwelstr.30, D-52074 Aachen
email: vogel@rad.rwth-aachen.de

Der Beitrag beschreibt ein Verfahren, das automatisch erkennt, um welche Art Röntgenaufnahme es sich bei einem gegebenen Standardröntgenbild handelt. Basierend auf einem Merkmalsraum, der anhand der Statistik 2. Ordnung die Texturinformation des Bildes repräsentiert, wird ein synergetischer Klassifikator verwendet, der sich speziell für die automatische Parametrisierung in einem hochdimensionalen Merkmalsraum eignet. Anhand einer umfangreichen Testreihe wird die Tauglichkeit des Verfahrens demonstriert.

Keywords: Klassifikation, Textur, Synergetik, PACS

1 Einleitung

In vielen Bereichen der Bildverarbeitung hat man das Problem der Klassifikation ganzer Bilder. Das heißt, man möchte automatisch feststellen, welche Inhalte auf einem digital vorliegenden Bild dargestellt sind. Diese für einen Menschen sehr einfach zu bewältigende Aufgabenstellung ist für einen Algorithmus nicht trivial. Man benötigt diese Information jedoch für weitere Verarbeitungsschritte auf dem Bildmaterial. Denkbar ist hier z.B. die Auswahl eines geeigneten Modelles für einen modellbasierten Segmentierungsalgorithmus, wie er in [7] dargestellt ist, die Suche nach Bildinhalten in einer Datenbank oder die Klassifikation von Standardröntgenaufnahmen.

In der klinischen Routine erfolgt die Bilderzeugung zunehmend mit digitalen Röntgengeräten, deren Bilder dann zur weiteren Verwendung in einem PACS (Pictures Archiving and Communication System) gespeichert werden. Zur Zeit existiert kein System, das alle Patientendaten integriert. So ist zu einem gespeicherten Bild nicht unbedingt vermerkt, um welche Art Aufnahme es sich handelt. Diese Information ist aber die Grundlage für die weitere Verteilung der Bilder auf die einzelnen Befundungsarbeitsplätze. Eine automatische Sortierung der Bilder nach den dargestellten Bildinhalten (Hand, Fuß, Thorax, etc.) innerhalb des PACS ist also wünschenswert.

Um dieses Problem der Einordnung von Röntgenbildern in eine von mehreren Klassen zu lösen, wird ein Standardansatz der Bildverarbeitung gewählt. Zuerst wird ein zu klassifizierendes Bild in einen geeigneten Merkmalsraum transformiert und dann mittels eines Klassifikators einer Bildklasse zugeordnet.

Betrachtet man die gebräuchlichen Aufnahmeeinstellungen für Standardröntgenbilder, ergeben sich, wie in [5] dargestellt, 90 verschiedene Aufnahmetypen, die sich in 15 Oberklassen gliedern lassen. Selbst innerhalb dieser Klassen unterscheiden sich die Bilder, neben der anatomischen Variabilität der abgebildeten Objekte , in Größe, Belichtung und

Aufnahmewinkel. Man benötigt also eine Menge von Invarianzen, die eine Differenzierung der einzelnen Klassen ermöglicht.

In [6] wurde gezeigt, daß sich unterschiedliche morphologische Strukturen in einem Röntgenbild durch ihre Texturen voneinander unterscheiden lassen. Die vorliegenden Röntgenaufnahmen haben je nach Bildinhalt unterschiedliche Anteile typischer Gewebetexturen. Diese Texturinformation der Bilder kann jetzt dazu verwendet werden die Zuweisung der Klassenlabels durchzuführen. In dem von uns entwickelten Algorithmus erfolgt die Modellierung der Texturinformation durch einen statistischen Ansatz mittels Co-Occurence Matrizen.

Man erhält damit einen Merkmalsvektor, der als Eingabe für einen synergetischen Klassifikationsalgorithmus verwendet wird. Durch die Deutung der Klassifikation als dynamischen Prozeß läßt sich ein Klassifikator konstruieren, der speziell für hochdimensionale Merkmalsräume geeignet ist.

Im folgenden werden die beiden Teilaspekte des Algorithmus, Merkmalsgenerierung und Klassifikation, beschrieben und die Ergebnisse einer umfangreichen Testreihe präsentiert.

2 Der Merkmalsraum

Um die unterschiedlichen Klassen von Röntgenbildern differenzieren zu können, muß ein Satz von Merkmalen generiert werden, für den die Varianz der Merkmalsvektoren innerhalb einer Bildklasse minimal und die Varianz der Merkmalsvektoren verschiedener Klassen maximal ist. Die reine Grauwertinformation der Bilder kann dazu sicherlich nicht verwendet werden, sondern es soll, wie eingangs erwähnt, die Texturinformation der im Bild dargestellten Gewebe quantifiziert werden.

In der Literatur werden strukturelle und statistische Texturmodelle diskutiert, wovon für den vorliegenden Anwendungskontext nur das statistische Modell relevant ist. Hierbei wird ein gegebenes Textursignal als Musterfunktion eines zweidimensionalen stochastischen Prozesses aufgefaßt. Bestimmt man die Verteilungsparameter des stochastischen Prozesses erhält man statistische Maßzahlen, die die Textur charakterisieren.

Eine statistische Beschreibung eines Textursignals kann dabei immer nur unvollständig sein. Für die Unterscheidung verschiedener morphologischer Strukturen in Röntgenbildern ist diese Vorgehensweise aber vielfach ausreichend [6].

Es soll eine statistische Texturbeschreibung gewählt werden, die räumliche Konzepte berücksichtigt und als Statistik 2. Ordnung bezeichnet wird. Dazu betrachtet man die Wahrscheinlichkeit $p_{\vec{d}}(i,j)$, daß zwei Bildpunkte mit Abstand $\vec{d}$ die Grauwerte i und j haben (für alle Werte i, j und $\vec{d}$). Den Vektor $\vec{d}$ bezeichnet man als Displacement. Für die $p_{\vec{d}}(i,j)$ gilt bei festem $\vec{d}$ und $(N+1)$ möglichen Grauwerten:

$$0 \leq p_{\vec{d}}(i,j) \leq 1 \quad \forall \quad i,j \qquad \text{und} \qquad \sum_{i=0}^{N} \sum_{j=0}^{N} p_{\vec{d}}(i,j) = 1 \tag{1}$$

Für jedes Displacement $\vec{d}$ können diese Auftrittswahrscheinlichkeiten in einer sogenannten Co-Occurence Matrix $M_{\vec{d}}(i,j)$ zusammengefaßt werden:

$$M_{\vec{d}}(i,j) = \begin{pmatrix} p_{\vec{d}}(0,0) & p_{\vec{d}}(1,0) & \cdots & p_{\vec{d}}(N,0) \\ p_{\vec{d}}(0,1) & p_{\vec{d}}(1,1) & \cdots & p_{\vec{d}}(N,1) \\ \vdots & \vdots & \ddots & \vdots \\ p_{\vec{d}}(0,N) & p_{\vec{d}}(1,N) & \cdots & p_{\vec{d}}(N,N) \end{pmatrix} \tag{2}$$

Da diese Texturbeschreibung über die Statistik zweiter Ordnung nicht rotationsinvariant ist, benutzt man als Co-Occurence Matrix die Summe der Matrizen für die vier möglichen Richtungen $\{0, \frac{\pi}{4}, \frac{\pi}{2}, \frac{3\pi}{4}\}$ der Achter-Nachbarschaft eines Bildpunktes, wie es Gotlieb et. al. in [1] vorschlagen. Das Displacement $\vec{d}$ kann dabei auch über den Winkel θ und die Distanz δ angegeben werden, d.h. es gilt $M_{\vec{d}}(i,j) = M_{\delta,\theta}(i,j)$. Dadurch ergibt sich die richtungsunabhängige Co-Occurence Matrix $M_\delta(i,j)$ als:

$$M_\delta(i,j) = \sum_{\theta=0,\frac{\pi}{4},\frac{\pi}{2},\frac{3\pi}{4}} M_{\delta,\theta}(i,j) \tag{3}$$

Im allgemeinen werden nun aus dieser Co-Occurence Matrix Merkmale abgeleitet, die die Textur beschreiben sollen. Haralick definiert dazu in [3] vierzehn Maße, die in der Literatur vielfach Verwendung gefunden haben und dazu dienen die Dimension des Merkmalsraums klein zu halten. Allerdings geht natürlich jede Dimensionsreduktion des Merkmalsraums mit einem Informationsverlust einher. Aus diesem Grunde verwenden wir die ganze Co-Occurence Matrix der Eingangsbilder als Merkmalsvektor und verlagern das Problem der Dimensionsreduktion auf den Klassifikationsprozeß.

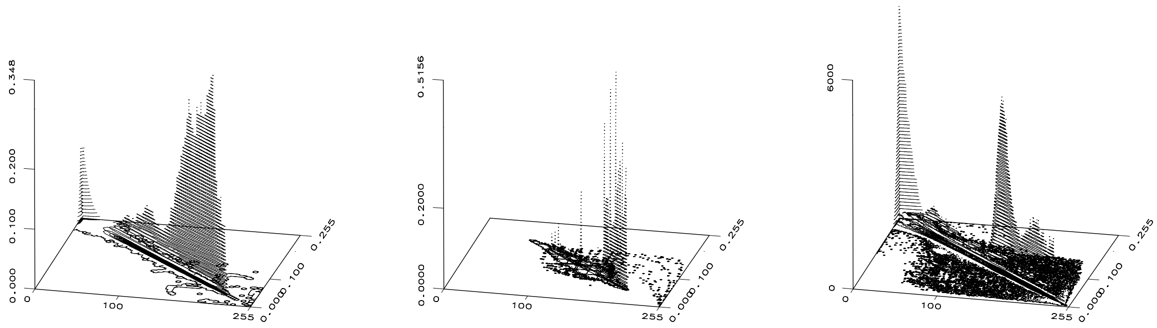

Abbildung 1: 3D Visualisierungen von drei Co-Occurence Matrizen (Oberklasse: Becken, Thorax und Mamma)

Zur Berechnung der Co-Occurence Matrizen werden die Bilder auf eine Farbtiefe von acht Bit normiert. Als Displacement wird $\delta = 1$ gewählt, was bei Röntgenbildern mit mehreren, überlagerten Texturen, die sich in Periodizität und Struktur unterscheiden, ein geeigneter Wert ist [6]. Die so erhaltene Co-Occurence Matrix wird nun als 65536 dimensionaler Merkmalsvektor für den Klassifikationsprozeß verwendet. Drei Beispiele für Prototypvektoren sind in Abbildung 1 dargestellt.

3 Der synergetische Klassifikator

Das Konzept der Synergetik geht auf Haken zurück und beschäftigt sich ursprünglich mit Selbstorganisationsphänomenen in dynamischen Systemen, wie zum Beispiel im Bénard Experiment. Es läßt sich jedoch auch auf den Bereich der Bildklassifikation übertragen, wobei die grundlegende Idee in der Interpretation von Mustererkennung und Mustererzeugung als äquivalente Prozesse besteht. Das heißt, daß man die Dynamik, die bei synergetischen Prozessen zu Selbstorganisation und Musterbildung führt, als Grundlage für den Entwurf eines Klassifikators nutzt. Man kann sich solch einen Klassifikator als dynamisches System vorstellen, das einen Assoziativspeicher realisiert.

Im folgenden werden kurz die Grundlagen des synergetischen Klassifikationsalgorithmus skizziert. Für eine ausführliche Darstellung sei auf [2] und [4] verwiesen.

Für den Klassifikator benötigt man zum einen Prototypvektoren, die die zu erkennenden Klassen repräsentieren, und zum anderen Mustervektoren, die die zu klassifizierenden Bilder darstellen. Beide Typen sind Vektoren innerhalb des N dimensionalen Merkmalsraums, der durch die Co-Occurence Matrizen der Bilder aufgespannt wird.
Die Prototypvektoren werden mit

$$\vec{v}_k = \begin{pmatrix} v_{k_1} \\ \vdots \\ v_{k_N} \end{pmatrix} \qquad k = 1, \ldots, M \tag{4}$$

bezeichnet. Hierbei ist M die Anzahl der verwendeten Prototypvektoren (Klassen). Für den vorliegenden Fall ist also $M = 15$. Die Prototypvektoren seien mittelwertfrei und normiert, d.h.

$$\sum_{i=1}^{N} v_{k_i} = 0 \quad \text{und} \quad \sum_{i=1}^{N} v_{k_i}^2 = 1 \qquad \forall\, \vec{v}_k \quad k = 1, \ldots, M \tag{5}$$

Man generiert nun einen Satz von adjungierten Prototypvektoren $\vec{v}_k^{\,+}$, die einer Orthonormalitätsrelation genügen:

$$(\vec{v}_k^{\,+}, \vec{v}_l) = \delta_{kl} \tag{6}$$

Die adjungierten Prototypvektoren sind Linearkombinationen der Prototypvektoren und lassen sich durch lösen eines einfachen Gleichungssystems bestimmen.

$$\vec{v}_k^{\,+} = \sum_{i=1}^{M} a_{ik} \vec{v}_i \tag{7}$$

Durch die Bildung des Skalarproduktes mit den adjungierten Vektoren wird eine neue Metrik für den von den Prototypvektoren aufgespannten Unterraum eingeführt. Bei einem Prototypvektor pro Klasse liefert die Skalarproduktbildung damit die Darstellung eines Mustervektors mit den Prototypvektoren als Basisvektoren, wobei die Werte des Skalarproduktes den Anteil an dieser Klasse bestimmen.

Die Klassifikation erfolgt, analog zu physikalischen synergetischen Systemen, anhand einer Gradientendynamik. Hierzu interpretiert man einen zu klassifizierenden Mustervektor $\vec{q}$ als Massepunkt in einem Potentialgebirge V. Das Potential V ist per Konstruktion derart, daß die einzigen stabilen Fixpunkte (Minima) den Prototypvektoren und damit den einzelnen Klassen zuzuordnen sind. Das Potential ergibt sich als:

$$V = -\frac{1}{2} \sum_{k=1}^{M} \lambda_k (\vec{v}_k^{\,+}, \vec{q})^2 + \frac{1}{4} B \sum_{k \neq l} (\vec{v}_k^{\,+}, \vec{q})^2 (\vec{v}_l^{\,+}, \vec{q}) + \frac{1}{4} C (\vec{q}^{\,+}, \vec{q})^2 \tag{8}$$

Über die Parameter B, C und λ_k läßt sich das Potential noch modifizieren und für die vollständige Beschreibung des Klassifikationsprozesses müssen jetzt nur noch die Bewegungsgleichungen angegeben werden:

$$\begin{aligned} \dot{\vec{q}} &= -\frac{\partial V}{\partial \vec{q}^{\,+}} \\ \dot{\vec{q}}^{\,+} &= -\frac{\partial V}{\partial \vec{q}} \end{aligned} \tag{9}$$

Die Integration der Bewegungsgleichungen ist für die Klassifikation jedoch nicht direkt notwendig, da das Potential V die Eigenschaft aufweist, daß der Mustervektor $\vec{q}$ immer der Prototypklasse i zugeordnet wird, für die gilt:

$$|(\vec{v}_i^+, \vec{q})| = max\left\{|(\vec{v}_j^+, \vec{q})|\right\} \qquad j = 1, \ldots, M \tag{10}$$

Der synergetische Klassifikator ist damit einem Minimum Distance Klassifikator mit linear transformiertem Merkmalsraum sehr ähnlich. Allerdings ist für die Klassifikation nur der Teil des Mustervektors relevant, der innerhalb des durch die Prototypvektoren aufgespannten Unterraums liegt. Dadurch ereicht man gerade für hochdimensionale Merkmalsräume eine Dimensionsreduktion. Dies geschieht dadurch, daß für die Differenzierung der einzelnen Klassen die Komponenten der Prototypvektoren herangezogen werden, die maximale Varianz haben.

Durch die Bildung der Skalarprodukte erhält man für jede der Klassen ein Ähnlichkeitsmaß, das es ermöglicht, zum einen Mischklassen zu detektieren und zum anderen als Signifikanzmaß für die Klassifikation benutzt werden kann. Eine Zuordnung zu einer bestimmten Klasse wird damit als unsicher zurückgewiesen, falls auch für die anderen Prototypvektoren hohe Skalarprodukte berechnet worden sind.

Es bleibt das Problem typische Prototypvektoren für die Klassen zu generieren. Die einfachste Möglichkeit ist die Verwendung des Mittelwertvektors einer als repräsentativ anzusehenden Menge von Bildern einer Klasse. Es können auch mehrere Prototypvektoren für jede Klasse verwendet werden oder man benutzt Lernalgorithmen, die anhand einer Trainingsmenge die Prototypvektoren geeignet bestimmen. Eine Zahl von Lernalgorithmen, die speziell für den Anwendungskontext der synergetischen Klassifikatoren entwickelt wurde, findet sich in [4].

4 Experimente

Der Algorithmus wurde auf 138 Röntgenbildern, oder vielmehr deren Co-Occurence Matrizen, angewendet. Die Prototypvektoren wurden für diesen Testlauf durch Mittelwertbildung der Co-Occurence Matrizen der jeweiligen Bilder einer Klasse bestimmt. Die Bilder stammen zu gleichen Teilen entweder von einem digitalen Röntgengerät oder wurden nachträglich mittels eines Scanners digitalisiert. Die dargestellten Bildinhalte bzw. deren Befunde sind zumeist pathologisch. Die Klassifikationsergebnisse ergaben sich damit wie folgt:

Klasse	Anzahl	richtig klass.	Klasse	Anzahl	richtig klass.
Arm	2	2	Knie	10	3
Becken	14	9	Mamma	23	19
Finger	3	2	Schädel	2	2
Fuß	2	1	Schulter	1	1
Hals	3	3	Thorax	44	30
Hand	3	2	Thorax seitl.	11	7
Hüfte	14	11	Wirbelsäule	6	5
Summe:	138	97			

Obwohl der Gesamtanteil der korrekt klassifizierten Bilder nur etwas über 70 % liegt, sind die erzielten Resultate durchaus zufriedenstellend. Bei den Fehlklassifikationen war das Signifikanzniveau sehr niedrig. Das heißt, daß der Wert des Skalarproduktes für die zugeordnete Klasse klein war und der Wert mindestens einer weiteren Klasse in der gleichen

Größenordnung lag. Damit ist eine Zurückweisung der Zuordnung über einen Threshold einfach möglich. Weiterhin sind die Fehlzuweisungen in vielen Fällen plausibel. So wurden z.B. alle fehlklassifizierten Bilder der Klasse *Becken* als *Hüfte* erkannt und umgekehrt, oder die Bilder der Klasse *Thorax seitl.* als *Thorax* oder *Schulter*. Neben diesen Klassenüberlagerungen war die Klassifikation für die anderen Klassen stabil.

5 Diskussion

Obwohl der verwendete Ansatz der Bildklassifikation über die Statistik 2. Ordnung nicht natürlich ist, d.h. er orientiert sich nicht an der Methodik eines menschlichen Betrachters, sind die Ergebnisse vielversprechend. Die Co-Occurence Matrizen liefern eine adäquate Modellierung der Texturinformation und durch die Verwendung eines synergetischen Klassifikators lassen sie sich auch effektiv für die Klassifikation verwenden.

Die Versuche sind ein Indiz, daß die Differenzierung der unterschiedlichen Gewebetypen in Röntgenaufnahmen durch die Verwendung der Co-Occurence Matrizen möglich und als Ausgangspunkt für die automatische Erkennung von Bildinhalten sinnvoll ist. Es müssen jedoch weitere, umfangreichere Versuche durchgeführt werden, die das Problem der Klassenüberlagerung z.B. durch den Einsatz eines mehrstufigen Klassifikationsprozesses lösen. Eine weitere Steigerung der Klassifikationsleistung ist zudem durch die Verwendung gelernter Prototypen zu erwarten.

Danksagung

Wir danken Thomas Lesch für die Implementierung großer Teile der Klassifikationsalgorithmen.

Literatur

[1] C.C. Gotlieb, H.E. Kreyszig: Texture Descriptors Based on Co-occurence Matrices. CVGIP 51, 70, 1990

[2] H. Haken: Synergetic Computers and Cognition. Springer Verlag, Heidelberg, 1991

[3] R.M. Haralick: Statistical and Structural Approaches to Texture. Proc. 4th ICPR, Kyoto, 45, 1978

[4] Th. Lesch: Untersuchung der Segmentierungsproblematik für diagnostische Fragestellungen bei Röntgenthoraxaufnahmen. Diplomarbeit, RWTH Aachen, Fachgruppe Informatik, 1996

[5] SIEMENS: Aufnahmehelfer für die Röntgendiagnostik. Siemens AG, Best.-Nr A19100-M1000-A508-06

[6] F. Weiler: Merkmalsextraktion aus Filmröntgenbildern zur Abschätzung der Dignität fokaler Knochenläsionen. Diplomarbeit, RWTH Aachen, Fachgruppe Informatik, 1993

[7] F. Weiler, J. Dettmann: Bildsegmentierung mit modellbasierten, aktiven Konturmodellen. Proc. Aachener Workshop 'Bildverarbeitung für die Medizin', Aachen, 1996