

# Bildbasierte Klassifikation anatomischer Strukturen der knöchernen Wirbelsäule mit künstlichen Neuronalen Netzen

Susanne Winter, Markus Mildenstein  
Institut für Neuroinformatik, Ruhr-Universität Bochum, Deutschland

## Kurzfassung

Zur Klassifikation von anatomischen Strukturen der Lendenwirbelsäule in CT-Bildern wurden verschiedene Bildmerkmale auf ihre Eignung untersucht. Die untersuchten Merkmale waren Haar-Wavelets, Gabor-Wavelets, Orientierungsumgebungen, Grauwertumgebungen und Wavelet-Bündelgraphen. Mit den Umgebungsmerkmalen und den Bündelgraphen konnten Klassifikationsraten von bis zu 98,6% erreicht werden.

## 1 Einleitung

Um anatomische Strukturen in medizinischen Bilddaten zu segmentieren werden in der Regel modellbasierte Verfahren eingesetzt. Diese Segmentierungsverfahren benötigen meist geeignete Startpositionen, die üblicherweise manuell gewählt werden. Wünschenswert ist jedoch die automatische Initialisierung solcher Startpositionen. Eine Voraussetzung hierfür ist die automatische Interpretation der Bildinhalte.

In dieser Studie wurden verschiedene Bildmerkmale auf ihre Eignung zur bildbasierten Klassifikation anatomischer Strukturen am Beispiel gesunder Lendenwirbel untersucht. Im Unterschied zu Anwendungen in denen Gewebetypen klassifiziert werden, ging es hier um die Klassifikation von Formen bzw. Strukturen. Die verwendeten Bildmerkmale wurden zum Teil bereits in unterschiedlichen Bereichen des Computersehens erfolgreich eingesetzt, z. B. in der automatischen Gesichts- und Fahrzeugerkennung [1,2]. Für die Klassifikation wurde ein künstliches neuronales Netz [3] verwendet.

## 2 Material und Methoden

Insgesamt wurden 16 Spiral-CT-Datensätze der menschlichen Lendenwirbelsäule für die Untersuchung genutzt. Die Daten wurden zur Verarbeitung in isotrope Datensätze mit Voxelkantenlängen von 0.5 mm umgewandelt.

### 2.1. Klassen

Es wurden 13 verschiedene Klassen definiert, die unterschiedlichen anatomischen Details entsprachen. Die Einteilung orientierte sich an der visuellen Prägnanz der Strukturen in den Schichtbildern und an gebräuchlichen anatomischen Einteilungen. Folgende Klassen wurden gewählt (s. Abb. 1):

- Wirbelkörper vorne (a) / hinten (b) / links (c) / rechts (d) / innen (e)
- Querfortsatz links (f) / rechts (g)
- Pedikel links (h) / rechts (i)




Abbildung 1: Klassen im CT-Schichtbild

- Zwischenwirbelgelenk links (j) / rechts (k)
- Dornfortsatz (l)
- umgebendes Gewebe (m)

In den CT-Daten wurden die Bereiche, die den einzelnen Klassen entsprachen, manuell vorklassifiziert. Es ergaben sich pro CT-Datensatz und Klasse mindestens 1400 Datenpunkte. Für das Training des Klassifikators wurden aus jedem Datensatz pro Klasse 200 Datenpunkte zufällig ausgewählt.

### 2.2. Bildmerkmale

Aus der Gruppe der Wavelets wurden Haar-Wavelets [4] mit drei verschiedenen Filtergrößen (20x20, 40x40, 80x80 Pixel) und Gabor-Wavelets [5] mit 6 Orientierungen und 3 Filtergrößen (21, 41, 81 Pixel) verwendet.

Zur Erstellung von Orientierungsumgebungsmerkmalen wurde mit Ableitungsoperatoren 1. Ordnung ein Gradientenbild berechnet und nach Schwellwertbildung in 6 Stufen diskretisiert. In einer 5x5 Fenster Umgebung (Fensterbreite: 21 Pixel) wurde für jedes Fenster ein Orientierungshistogramm [1] erstellt. In denselben Fenstern wurden zusätzlich der größte und kleinste Grauwert als Grauwertumgebungsmerkmale bestimmt.

Ähnlich den Merkmalen in den Umgebungsfenstern wurden Haar-Wavelets und Gabor-Wavelets auf ei-

nem Bündelgraph [2] berechnet. Der Bündelgraph bestand aus 5x5 Gitterpunkten mit einem Rasterabstand von 21 Pixeln. An jedem Punkt des Graphen wurde das Bild mit Haar- und Gabor-Wavelets verschiedener Filtergrößen und Orientierungen gefiltert. Zusätzlich wurden Merkmalskombinationen erstellt, bei denen Merkmale, die zu hohen Klassifikationsraten geführt hatten, kombiniert wurden.

### 2.3. Klassifikator

Es wurde ein vollständig verbundenes Feedforward-Multi-Layer-Perzeptron [3] mit 3 versteckten Neuronen verwendet. Die Gewichte wurden zu Beginn mit kleinen Werten zufällig initialisiert. Trainiert wurde mit einem gradientenbasierten Verfahren, dem Resilient Backpropagation (Rprop) [6]. Fehlermaß für das Training war der Mean squared error (MSE). Von den 16 Computertomographien wurden Datenpunkte aus 8 Datensätzen für die Trainingsmenge und jeweils aus 4 Datensätzen für die Test- und Validierungsmengen verwendet. Das Training wurde abgebrochen, wenn die Anzahl der Trainingsepochen größer als 500 war, der MSE auf der Trainingsmenge weniger als 0,1% betrug oder der Fehler auf der Validierungsmenge über mehr als 4 Epochen hintereinander anstieg (Early stopping). Für die Beurteilung der Klassifikation war der Fehler auf dem Testdatensatz relevant.

## 3 Ergebnisse

Die höchste Klassifikationsrate mit einer Kombination aus Wavelet-Merkmalen lag bei 64%, wobei Haar-Wavelets schlechter abschnitten als Gabor-Wavelets. Grauwertumgebungen, Richtungsumgebungen sowie Bündelgraphen mit Haar-Wavelets und Gabor-Wavelets ergaben Klassifikationsraten von bis zu 98,3% (siehe Tab. 1).

Die besten Merkmalskombinationen mit einer Klassifikationsrate von bis zu 98,6% waren Grauwertumgebungen in Verbindung mit einem Gabor-Wavelet Bündelgraph oder einer Orientierungsumgebung.

## 4 Diskussion

Insgesamt konnte mit den untersuchten Bildmerkmalen eine hohe Klassifikationsrate anatomischer Teilstrukturen erzielt werden.

Mit Gabor- und Haar-Wavelets allein war die Erkennung der Strukturen nicht besonders gut, was vermutlich daran lag, dass eine zu geringe Umgebung und damit nicht die gesamte Struktur erfasst wurde.

Merkmale die auf einer Gitterstruktur berechnet wurden, waren deutlich besser geeignet, einen

größeren Bereich der Daten, und damit die anatomischen Teilstrukturen zu erfassen.

Die besten Klassifikationsergebnisse wurden durch Kombination der Merkmale erzielt. Es konnten hiermit Klassifikationsraten von bis zu 98,6% erzielt werden, die es erlauben, die anatomischen Strukturen der Lendenwirbelsäule in CT-Daten zuverlässig zu erkennen und somit Startpositionen für die Segmentierung, z.B. einzelner Wirbelknochen, zu generieren. Durch eine automatische Optimierung der Merkmalskombination können die Klassifikationsraten sicherlich noch weiter verbessert werden.

Tabelle 1: Korrekte Klassifikationen mit verschiedenen Merkmalen und Merkmalskombinationen

Merkmal	Anzahl Merkmale	richtige Klassifikationen Trainingsmenge (%)	richtige Klassifikationen Validierungsmenge (%)	richtige Klassifikationen Testmenge (%)
Haar-Wavelets	9	54,7	48,7	57,0
Gabor-Wavelets	18	64,4	70,1	64,3
Grauwertumgebung	50	96,9	94,5	96,3
Orientierungsumgebung	150	94,9	92,7	95,5
Haar-Bündelgraph	225	90,8	85,6	86,4
Gabor-Bündelgraph	450	99,2	96,9	98,3
Grauwertumgebung und Orientierungsumgebung	200	99,2	97,0	98,6
Grauwertumgebung und Haar-Bündelgraph	275	98,7	94,5	97,4
Grauwertumgebung und Gabor -Bündelgraph	500	99,5	97,0	98,4

## 5 Literatur

1. Freeman W.; Roth M.: Orientation histograms for hand gesture recognition. In Proc. IEEE International Conference on Automatic Face and Gesture Recognition, 1995, pp. 296-301
2. Wiskott L. et al.: Face recognition by elastic bunch graph matching. IEEE Trans. Pattern Anal. Machine Intell. 19(7), 1997, pp. 775-9
3. Bishop, C.M.: Neural Networks for Pattern Recognition. Oxford University Press. 1995
4. Haar A.: Zur Theorie der orthogonalen Funktionensysteme. Math. Ann. 69, 1910, pp. 331-71
5. Gabor D.: Theory of communication. J. IEE (London) 93 Part 3(26), 1946, pp. 429-57
6. Riedmiller M.; Braun H.: A direct adaptive method for faster backpropagation learning: The RPROP algorithm. In Proc. IEEE Neural Networks.: IEEE Press. 1999, pp. 586-91