



24.01.2019

Segmentierung



Segmentierung


24.01.2019

- Segmentierung: low-level Bilderkennung
- Aufteilung des Bildes in Regionen mit verschiedenen Eigenschaften (Nachbarregionen haben nicht die gleiche Eigenschaft)
- Pixelorientierte, bereichsorientierte und kantenorientierte Verfahren



24.01.2019

- Pixelorientierte Verfahren
 - Schwellwertverfahren, optimale Schwellwertverfahren
 - Klassifikation




Schwellwertbildung

24.01.2019

Wie wird der Schwellwert bestimmt?

Einfaches Verfahren:

Minimum zw. zwei Maxima im Histogramm.





Schwellwertbildung


24.01.2019

Verfahren, die dem Optimum näher kommen, gehen von bekannten Helligkeitsverteilungen aus und legen Schwelle auch neben Minimum.



Schwellwertbildung

24.01.2019




Schwellwertbildung

24.01.2019

Dynamisch Schwellwertbestimmung:

- Wie bei dynamischer Histogrammeinebnung, Schwelle wird f. jeden Bildpunkt aus Umgebung berechnet.



- Bimodalitätsprüfung. Falls Histogramm nicht bimodal, Schwellwert aus größerer Umgebung.



Klassifikation

24.01.2019

Klassifizierung wird einfacher, wenn wir für jeden Bildpunkt verschiedene Merkmale (Kanäle) haben, z.B.

- Farben,
- lokale Frequenzen,
- Streuung in Umgebung,
- Mittelwert in Umgebung
- ...



Klassifikation

24.01.2019

Nun müssen die Merkmalsvektoren den Objekten zugeordnet werden. Dabei liegen die Punkte (hoffentlich) in deutlich unterscheidbaren Gruppen (Clusters).


Punkte Objekten oder Clusters zuzuordnen kann auf verschiedene Weisen geschehen:

- fest dimensioniert aufgrund von Vorwissen
- mit Lernverfahren (maschinelles Lernen)



24.01.2019

Minimum Distance Klassifikator



$$d_j(x) = \|\mathbf{x} - \mathbf{m}_j\|$$



Maximum Likelihood Klassifikator

Definitionen:

- Verteilungsdichte der Musterklasse ω_i (Likelihood von $\mathbf{x}$ für die Klasse ω_i):

$$l_i(\mathbf{x}) = p(\mathbf{x} | \omega_i) \quad \text{wobei} \quad \int_{\mathbf{x}} p(\mathbf{x} | \omega_i) d\mathbf{x} = 1$$

- apriori-Wahrscheinlichkeit der Musterklasse ω_i :

$$P(\omega_i) \quad \text{wobei} \quad \sum_i P(\omega_i) = 1$$



Klassifikatoren

24.01.2019

Der Maximum Likelihood Klassifikator maximiert lediglich die Likelihood

$$l_i(\mathbf{x}) = p(\mathbf{x} | \omega_i)$$

Um die Wahrscheinlichkeit einer Falschklassifikation zu minimieren müsste eigentlich die Klasse ausgewählt werden, für die der Ausdruck

$$P(\omega_i) p(\mathbf{x} | \omega_i)$$

maximal wird.



Klassifikatoren

24.01.2019

Annahmen, wenn statistische Eigenschaften unbekannt:

- Verteilungsdichten der Musterklassen werden durch mehrdimensionale Gaußverteilungen angenähert:

$$p(\mathbf{x} | \omega_i) = \frac{1}{\sqrt{(2\pi)^N \det \mathbf{C}_i}} e^{-\frac{1}{2}(\mathbf{x}-\mathbf{z}_i)^T \mathbf{C}_i^{-1}(\mathbf{x}-\mathbf{z}_i)}$$

- apriori-Wahrscheinlichkeiten gleich groß.



Klassifikatoren

24.01.2019

Da der Logarithmus monoton ist, können wir logarithmieren und dann das Minimum suchen:

$$\begin{aligned} d_i(\mathbf{x}) &= -\ln P(\omega_i) - \ln p(\mathbf{x} | \omega_i) \\ &= -\ln P(\omega_i) + \frac{1}{2} \ln (2\pi)^N \det \mathbf{C}_i + \frac{1}{2} (\mathbf{x} - \mathbf{z}_i)^T \mathbf{C}_i^{-1} (\mathbf{x} - \mathbf{z}_i) \end{aligned}$$

Nach Weglassen von Konstanten erhalten wir:

$$d_i(\mathbf{x}) = -\ln P(\omega_i) + \frac{1}{2} \ln \det \mathbf{C}_i + \frac{1}{2} (\mathbf{x} - \mathbf{z}_i)^T \mathbf{C}_i^{-1} (\mathbf{x} - \mathbf{z}_i)$$



Klassifikatoren

24.01.2019

Der Ausdruck

$$\left(\mathbf{x} - \mathbf{z}_i \right)^T \mathbf{C}_i^{-1} \left(\mathbf{x} - \mathbf{z}_i \right)$$

heißt Mahalanobis-Abstand

Ein konstanter Mahalanobis-Abstand

$$\left(\mathbf{x} - \mathbf{z}_i \right)^T \mathbf{C}_i^{-1} \left(\mathbf{x} - \mathbf{z}_i \right) = \text{const.}$$

beschreibt ein Ellipsoid.



Klassifikatoren

24.01.2019

Dabei ist

$$\mathbf{C}_i$$

die Kovarianzmatrix.


Die Koeffizienten der Kovarianzmatrix im 2D berechnen sich als:

$$\begin{aligned} c_{i,jk} &= \frac{1}{anz_i} \sum_{\mathbf{x} \text{ aus } K_i} (x_j - m_{i,j})(x_k - m_{i,k}) \\ &= \frac{1}{anz_i} \sum_{\mathbf{x} \text{ aus } K_i} (x_j)(x_k) - m_{i,j}m_{i,k} \end{aligned}$$

Klassifikatoren

24.01.2019


Beispiel:



Klassifikatoren

24.01.2019


Minimum Distance Klassifikator



Klassifikatoren

24.01.2019


Minimum Distance Klassifikator mit festem Zurückweisungsradius



Klassifikatoren

24.01.2019

Minimum Distance Klassifikator mit an die Ausdehnung der Musterklassen angepaßten Zurückweisungsradien






Klassifikatoren

24.01.2019

Maximum Likelihood Klassifikator



Bereichsorientierte Verfahren

24.01.2019

- Homogenitätskriterium $H(R)$
- $H(R_i) = TRUE$ für alle R_i
- $H(R_i \cup R_j) = FALSE$; R_i und R_j benachbart





Bereichsorientierte Verfahren

24.01.2019

Segmentierung durch

- Region Growing
- Region Merging
- Region Splitting
- Split and Merge
- Watershed Transformation
- Edge



Bereichsorientierte Verfahren


24.01.2019

Region Growing

- Verteilung von Saatzellen über das Bild. Die Anzahl der Saatzellen bestimmt die Anzahl der Regionen.
- Bestimmung der Nachbarpixel zu jeder Basisregion, Ordnen aller Nachbarn in einer Kandidaten-Liste nach einer Bewertung (priority queue - Pixel mit großer „Ähnlichkeit“ zu einer Region zuerst).
- Pixel mit größter Ähnlichkeit (das erste der Kandidaten-Liste) mit entsprechender Region vereinigen. Update der Kandidatenliste.
- Vorigen Punkt wiederholen, bis die Kandidaten-Liste leer ist.

Region Growing

Ein Beispiel:



Saatpunkte

von diesen Saatpunkten aus soll ein Gebietswachstumsverfahren starten, das all diejenigen Punkte zum Gebiet um den entsprechenden Saatpunkt hinzufügt, deren Grauwerte um weniger als **4** (Differenz) vom Grauwert des Saatpunktes abweichen.



Region Growing

Ein Beispiel:

1	1	7	6	7
1	2	5	5	6
2	1	6	7	6
3	3	7	6	7
3	3	5	5	6

1	1	7	6	7
1	a	5	b	6
a	a	b	b	b
3	a	7	b	7
3	3	5	5	6

a	a	b	b	b
a	a	b	b	b
a	a	b	b	b
a	a	b	b	b
a	a	b	b	b

Hier ist das Ergebnis unabhängig von der Reihenfolge der Saatpunkte.



Region Growing

Andere Schwelle ($\pm < 5$): Abhängig von Reihenfolge der Abarbeitung der (Start-) Saatpunkte:

1	1	7	6	7
1	2	5	5	6
2	1	6	7	6
3	3	7	6	7
3	3	5	5	6

a	a	b	b	b
a	a	a	a	b
a	a	b	b	b
a	a	b	b	b
a	a	a	a	b

a	a	b	b	b
a	a	b	b	b
a	a	b	b	b
b	b	b	b	b
b	b	b	b	b

Startpunkt

Startpunkt



Region Growing

24.01.2019

Schwierigkeiten bei der Verwendung von
Gebietswachstumsverfahren.

- Auswahl der Saatpunkte. Z.B. Punkte mit solchen Grauwerten, die den Maxima des Histogramms entsprechen.
- Auswahl der Zugehörigkeitskriterien. Hier können neben lokalen Kriterien wie Grauwert, Farbe und Textur auch regionale Aspekte wie Größe und Form des bereits zusammengefassten Gebiets Verwendung finden.

Region Growing

24.01.2019

Beispiele aus [Köthe95]

- Region growing mit automatischer Seedpunktbestimmung



Region Growing

24.01.2019

Beispiele



Region Growing

24.01.2019



Accuracy of edge localization: Region borders overlaid over the original image



Region Merging

24.01.2019

- Region Merging
 - Zusammenfügen von verschiedenen Regionen, solange Homogenitätsbedingung erfüllt ist.
 - Resultat hängt von Reihenfolge ab!
 - Zuerst ähnlichste Regionen zusammenfügen
 - Kriterium kann auch Kantenstärke und Kantenlänge zwischen den Regionen sein.
 - Region Merging wird u.a. verwendet, um übersegmentierte Bilder weiterzubearbeiten.

Region Merging

24.01.2019




Figure 5.42 *Region merging segmentation: (a - top left) Original image, (b - top right) pseudocolor representation of the original image, (c - bottom left) recursive region merging, (d - bottom right) region merging via boundary melting. Color versions of b, c and d may be seen in the color inset. Courtesy R. Marik, Czech Technical University, Prague.*



Region Splitting

24.01.2019

- Region Splitting
 - Teilen, solange Homogenitätsbedingung nicht erfüllt ist oder/und:
 - Teilen, solange durch Teilung Homogenität besser wird
 - Andere Ergebnisse als bei Merging!
 - Problem:
 - Wo soll unterteilt werden?
 - Quadtree-Unterteilung ist dem Bild nicht angepasst, daher oft Split und Merge kombiniert




Split and Merge

24.01.2019

- Split and Merge (Horowitz, Pavlidis 1976)
 - Quadtree
 - Teilen (Elternknoten durch Kindknoten ersetzen), wenn Homogenitätsbedingung nicht erfüllt ist.
 - Normales Merging, wenn dieser Prozess beendet ist (nötig wegen Quadtreestruktur, die kein Mergen von Nicht-Geschwistern erlaubt).

Edge flow

24.01.2019



Edge flow

24.01.2019



Edge flow

24.01.2019





Literatur

24.01.2019

Wladyslaw Skarbek, Andreas Koschan: Colour Image Segmentation – A Survey, Technischer Bericht 94-32, Technische Universität Berlin Fachbereich Informatik Okt. 1994

Peter Haberäcker: Digitale Bildverarbeitung Hanser Studienbücher, 2. Aufl. 1987

U. Köthe: *"Primary Image Segmentation"*, in: Mustererkennung 1995, 17. DAGM-Symposium, Springer 1995

http://kogs-www.informatik.uni-hamburg.de/~koethe/papers/primary_segmentation.ps

S. Stoev, W. Straßer: Extracting Regions of Interest Applying a Local Watershed Transformation, Proceedings of IEEE Visualization 2000, Salt Lake City

W. Y. Ma and B. S. Manjunath: Edge Flow: A Framework of Boundary Detection and Image Segmentation, Proceedings of IEEE Int. Conf. on Computer Vision and Pattern Recognition, 1997 <http://citeseer.ch/>

Steven L. Horowitz, Theodosios Pavlidis: Picture segmentation by a tree traversal algorithm. Journal of the ACM, 23(2):368-388, April 1976

F. Meyer: Colour image segmentation, Proc. IEE Int. Conf. on Image Processing and its Applications, Maastricht, Netherlands, 7-9 April 1992, pp. 303-306.



24.01.2019

Textur



Was ist Textur

24.01.2019

Definition schwierig, aber

- Nicht homogen (Intensitätsunterschiede)
- Homogenität bezüglich Frequenzinhalt von Teilbildern
 - verschiedene Teilbilder der Textur haben ähnliches Frequenzspektrum
 - u.U. erst ab einer bestimmten Teilbildgröße homogen.
- Homogenität bezüglich statistischer Eigenschaften von Teilbildern



Wozu Texturklassifikation?

24.01.2019

- Medizinische Diagnose
- Fernerkundung
 - Terrainklassifizierung, Wolkenklassifizierung, Seismische Analysen
- Industrielle Inspektion und Kontrolle
- Segmentierung von Dokumenten
- Inhaltsbasierte Bildsuche
- Shape from Texture



Texturmerkmale

24.01.2019

- Ziel: Berechnung von Merkmalsvektoren aus lokalen Umgebungen, die die Unterscheidung von Texturen ermöglichen.
- Verschiedene Möglichkeiten sind u.a.:
 - Statistik
 - lokale Histogrammen
 - Co-occurrence Matrizen
 - Geometrie
 - Analyse der Struktur
 - Filter
 - Powerspektren
 - Richtungsabhängige Filter im Ortsraum



Statistische Texturmerkmale

24.01.2019

Statistik 1. Ordnung (ein Pixelwert geht jeweils unabhängig von anderen Pixeln in die Statistik ein) aus lokalen Histogrammen, z.B.

- Mittelwert
- Standardabweichung
- Nähe zu bekannter Verteilung

Statistik 2. Ordnung / Verbundstatistik (jeweils zwei Pixel werden im Zusammenhang betrachtet)

- Cooccurrence Matrizen
- Differenz-Histogramme



Statistische Texturmerkmale

24.01.2019

Cooccurrence Matrizen

- Die Einträge geben die Häufigkeit des Auftretens der Helligkeitspaare i, j für Pixel im Abstand δ an.

$$c_{\delta, ij} = p\left(\left(f(\mathbf{x}) = i \wedge f(\mathbf{x} + \delta) = j\right) \vee \left(f(\mathbf{x}) = j \wedge f(\mathbf{x} + \delta) = i\right)\right)$$

- Nur für kleine δ oder stark gefilterte Bilder geeignet.

Statistische Texturmerkmale

24.01.2019

13.07.2007

Cooccurrence Matrizen

Aus Cooccurrence Matrix können Haralick-Parameter berechnet werden, die typische Merkmale extrahieren.



Statistische Texturmerkmale

Beispiele f. Haralick-Parameter:

- Kontrast

$$\lambda_{1,\delta} = \sum_{i=1}^Q \sum_{j=1}^Q (i-j)^2 c_{\delta,ij}$$

- Homogenität

$$\lambda_{2,\delta} = \sum_{i=1}^Q \sum_{j=1}^Q c_{\delta,ij}^2$$

- Entropie


$$\lambda_{3,\delta} = - \sum_{i=1}^Q \sum_{j=1}^Q c_{\delta,ij} \log c_{\delta,ij}$$

Filterbasierte Texturmerkmale

24.01.2019

Filteransatz:


- Filterung mit Richtungsabhängigen Bandpaßfiltern
- Betragsbildung und Glättung
- Bilden von Featurevektoren




Aus [Randen 99]

Filterbasierte Texturmerkmale


24.01.2019



(a)




(b)



(c)



(d)



(e)



(f)

Aus [Randen 97]

Filterbasierte Texturmerkmale

Filterbank

- Berechnung von binären Vektoren:




Figure 3. Example of texture extraction using three channel filter bank, (a) the thresholded and processed images for the three channels are concatenated, which produces (b) eight binary texture images that illustrate the segmented texture regions.

Aus [Smith96]




24.01.2019


Filter

1. Laws Filter (Laws 1980)

- Separable Filter (5x5)



(a)




(b)

nach [Randen 99]

2. Ring and wedge (Keil) (Coggins et al. 1985)

- Extraktion typischer Merkmale durch Summation über Bereiche im Frequenzraum:
 - Ringförmig (Bandpaß)
 - Sektorenweise (Richtungsabhängig)




nach [Randen 99]



24.01.2019

Ring and wedge filters



nach [Randen 99]



3. Gabor-Filter

- Gaussförmige Bandpassfilter
- Zuerst von D. Gabor zur kombinierten Zeit-Frequenzanalyse eingesetzt
- Können definierte Spektralbereiche aus der Ortsfrequenzebene herausfiltern.
- Menschliche Sehzellen sind zu Gaborfiltern verschaltet.



24.01.2019

Filter


Gabor-Filter

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\left(\frac{\tilde{x}^2}{2\sigma_x^2} + \frac{\tilde{y}^2}{2\sigma_y^2}\right)} e^{i2\pi f\tilde{x}}$$


$$\tilde{x} = x \cos \theta + y \sin \theta$$

$$\tilde{y} = -x \sin \theta + y \cos \theta$$


cos(x)




Gauss



Gauss*sin



Gauss*cos





24.01.2019


Filter

Gabor-Filter


$$\operatorname{Re}(g(x, y)) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\left(\frac{\tilde{x}^2}{2\sigma_x^2} + \frac{\tilde{y}^2}{2\sigma_y^2}\right)} \cos(2\pi f\tilde{x})$$

$$\operatorname{Im}(g(x, y)) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\left(\frac{\tilde{x}^2}{2\sigma_x^2} + \frac{\tilde{y}^2}{2\sigma_y^2}\right)} \sin(2\pi f\tilde{x})$$


$\cos(x)$




Gauss



Gauss* $\sin$
 $\operatorname{Im}(g(x, y))$



Gauss* $\cos$
 $\operatorname{Re}(g(x, y))$



Fouriertransformierte des Gaborfilters:



$$G(\tilde{u}, \tilde{v}) = e^{-\left(\frac{(\tilde{u}-f)^2}{2\sigma_u^2} + \frac{\tilde{v}^2}{2\sigma_v^2}\right)} e^{i2\pi f\tilde{x}}$$
$$\sigma_u = \frac{1}{2} \pi \sigma_x$$
$$\sigma_v = \frac{1}{2} \pi \sigma_y$$
$$\tilde{u} = u \cos \theta + v \sin \theta$$
$$\tilde{v} = -u \sin \theta + v \cos \theta$$

Filter

Fouriertransformierte des Gaborfilters

Die Parameter in der Gabor-Filterfunktion haben die folgende Bedeutung:


- σ : räumliche Ausdehnung der Filterfunktion
- θ : Ausrichtung der Filterfunktion
- σ_y/σ_x : Seitenverhältnis der Filterfunktion
- u_0, v_0 : Zentrum der Filterfunktion





24.01.2019


Fouriertransformierte des Gaborfilters - Beispiele





24.01.2019

Fouriertransformierte des Gaborfilters - Beispiele



D.Jackel, Uni-Rostock






Gabor-Filter

- Oft werden Quadraturfilterpaare benutzt (90° Phasenverschiebung)
- Dann kann die Gesamtfrequenzantwort als Summe der Quadrate der Einzelantworten berechnet werden.

Filter

Gabor-Filter im Ortsraum

Die Merkmalsgewinnung lässt sich auch mit Hilfe von Faltungsoperation im Ortsraum durchführen.



Faltet man den Real- und den Imaginärteil eines Gaborfilters mit einem Bild, so unterscheiden sich die Antworten um die Phasendifferenz $\pi/2$.

D.Jackel, Uni-Rostock



24.01.2019

Filter


Dyadische Gabor-Filter-Bank [Jain et al. 1991]

- versch. Gabor-Filter mit Frequenzen jeweils im Verhältnis 1:2

- horizontal:

$$h(k, l) = e^{-\frac{1}{2} \left(\frac{k^2}{\sigma_x^2} + \frac{l^2}{\sigma_y^2} \right)} \cos(2\pi f_0 k)$$


- andere Versionen durch Drehung des Koordinatensystems.



Filter

4. Wavelet-basierte Signaturen

- Betrachtet werden Teilbilder D_n^i oder
- Teile von Teilbildern





Wavelet-basierte Signaturen (äquivalent zu Filterung)

- Energie eines Subimage D_n^i ist definiert als:

$$E_n^i = \frac{1}{N} \sum_{j,k} \left(D_n^i(b_j, b_k) \right)^2$$

- Alternativ MD-signatures (mean deviation):

$$MD_n^i = \frac{1}{N} \sum_{j,k} \left| D_n^i(b_j, b_k) \right|$$



Wavelet-basierte Signaturen

- Cooccurrence signatures:
 - Cooccurrence Matrizen für Teilbilder D_n^i oder Teile davon.
 - δ kann konstant gewählt werden, da Abtastung von scale abhängt

Powerspektrum und wavelet-basierte Signatur




Figure 1: Texture signatures. *Left:* Patches from fabric (top) and tile (bottom) textures. *Middle:* DFT magnitude. *Right:* Texture signatures.

Aus [Rubner98]

Filter

Wavelet-Filterbank





Figure 2. Extraction of textures using wavelet filter bank, (I.) H_k are orthogonal filters, (II.) $|\cdot|$ obtains s - f energy, (III.) τ_k are energy thresholds, (IV.) non-linear filtering (NL), (V.) spatial size thresholds (Σ_k), (VI.) expansion into binary space $\mathcal{B}^N$, (VII.) concatenation of channels, (VIII.) final NL filtering and (IX.) size thresholding (Σ).

Aus [Smith96]

Ergebnisse



(a)



(b)



(a) QMF wavelet image ($y'_k s$), (b) subband energy

Aus [Smith96]



24.01.2019

Ergebnisse



(c) after thresholding (b'_k s) (d) labeled textures ($t[m, n]$), (e) texture regions outlined.

Aus [Smith96]



T. Randen, J. H. Husøy : Filtering for Texture Classification: A Comparative Study, IEEE Transactions on pattern analysis and machine intelligence, vol. 21, no. 4, Apr 1999, p. 291-309.
<http://www.computer.org/portal/web/csdl/transactions/tpami#3>

Trygve Randen: Filter and Filter Bank Design for Image Texture Recognition, Dissertation, Stavanger, 1997

J. R. Smith and S.-F. Chang, "Automated binary texture feature sets for image retrieval," in Proc ICASSP-96
http://www.ece.umassd.edu/Faculty/acosta/ICASSP/ICASSP_1996/pdf/ic962241.pdf



Literatur

24.01.2019

R. Haralick, K. Shanmugam and I. Dinstein: Textural Features for Image Classification; IEEE Transactions on Systems, Man and Cybernetics, Vol.SMC-3 (1973), No.6
http://scholar.google.com/citations?view_op=view_citation&hl=en&citation_for_view=HMnF6i0AAAAJ:txeM2kYbVNMC

Y. Rubner and C. Tomasi: Texture metrics. In Proc. IEEE Intl. Conf. on Systems, Man, and Cybernetics, 1998
<http://robotics.stanford.edu/~rubner/papers/rubnerSmc98.pdf>



Literatur

24.01.2019

- D. Chetverikov, R.M. Haralick, Texture Anisotropy, Symmetry, Regularity: Recovering Structure and Orientation from Interaction Maps, Proc. 6th British Machine Vision Conference, Birmingham, BMVA, 1995
<http://citeseer.ist.psu.edu/viewdoc/download?doi=10.1.1.139.5919&rep=rep1&type=pdf>
- D. Chetverikov, "Texture Analysis Using Feature Based Pairwise Interaction Maps", Pattern Recognition 32, Special Issue on Color and Texture, S.487-502, 1998.
<http://citeseer.ist.psu.edu/viewdoc/download?doi=10.1.1.56.2543&rep=rep1&type=pdf>
- D. Gabor. "Theory of communication", Journal of the Institution of Electrical Engineers – Part III: Radio and Communication Engineering, 93(26):429–457, Nov. 1946.
<http://www.csee.wvu.edu/~xinl/library/papers/physics/gabor1946.pdf>