

INVARIANTE MERKMALE FÜR DIE BILDERKENNUNG

Ilja Bezrukov

**Seminar Medizinische Bildverarbeitung
SS 2003**

- Bei der Bilderkennung ist es oft notwendig, Objekte unabhängig von der Aufnahmeposition zu identifizieren
- **Möglichkeit:** Extraktion von Merkmalen aus dem Bild, die invariant gegenüber Transformation des abgebildeten Objektes sind
- Projektive Transformationen werden durch mathematisch einfacher zu handhabende approximiert

- Bei der Bilderkennung ist es oft notwendig, Objekte unabhängig von der Aufnahmeposition zu identifizieren
- **Möglichkeit:** Extraktion von Merkmalen aus dem Bild, die invariant gegenüber Transformation des abgebildeten Objektes sind
- Projektive Transformationen werden durch mathematisch einfacher zu handhabende approximiert
- Mehrere Ansätze existieren, um **invariante Merkmale** zu berechnen
- Vorstellung der Methode der **integralen Invarianten** und kurzer Überblick über die anderen Methoden

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen

Beschleunigung der Berechnung

Anwendungen

- Gleichheit zwischen zwei Objekten muss formal festgelegt werden
- Zwei Objekte sind gleich, wenn eine Transformation existiert, die ein Objekt in das andere überführt:

$$X_1 \cong X_2 \Leftrightarrow \exists g \in G : X_2 = g(X_1)$$

mit G : Gruppe von Koordinatentransformationen (Affine Transformationen, **Kongruenzen**,...)

- Objektraum wird in Äquivalenzklassen unter der Gruppe G eingeteilt

- Gleichheit zwischen zwei Objekten muss formal festgelegt werden
- Zwei Objekte sind gleich, wenn eine Transformation existiert, die ein Objekt in das andere überführt:

$$X_1 \cong X_2 \Leftrightarrow \exists g \in G : X_2 = g(X_1)$$

mit G : Gruppe von Koordinatentransformationen (Affine Transformationen, **Kongruenzen**,...)

- Objektraum wird in Äquivalenzklassen unter der Gruppe G eingeteilt
- Gruppenelemente von G können durch Parametervektoren λ parametrisiert werden
- **Beispiel**: Die Gruppe der Kongruenzen kann durch drei Parameter beschrieben werden: Verschiebung in x und y-Richtung und Drehung
- Herausfinden, ob zwei Objekte äquivalent unter G sind ist möglich durch:

- Gleichheit zwischen zwei Objekten muss formal festgelegt werden
- Zwei Objekte sind gleich, wenn eine Transformation existiert, die ein Objekt in das andere überführt:

$$X_1 \cong X_2 \Leftrightarrow \exists g \in G : X_2 = g(X_1)$$

mit G : Gruppe von Koordinatentransformationen (Affine Transformationen, **Kongruenzen**,...)

- Objektraum wird in Äquivalenzklassen unter der Gruppe G eingeteilt
- Gruppenelemente von G können durch Parametervektoren λ parametrisiert werden
- **Beispiel**: Die Gruppe der Kongruenzen kann durch drei Parameter beschrieben werden: Verschiebung in x und y-Richtung und Drehung
- Herausfinden, ob zwei Objekte äquivalent unter G sind ist möglich durch:
 - Naiver Ansatz: Testen aller möglichen Transformationen
 - Finden von Merkmalen, die bei der Transformation des Objekts invariant bleiben

Wie findet man invariante Merkmale?

- **Idee:** Finden einer **Abbildung** T , die invariante Merkmale eines Objektes extrahiert
- Das heißt: Alle Objekte einer Äquivalenzklasse werden von T auf einen Punkt im Merkmalsraum abgebildet: $X_1 \cong X_2 \Rightarrow T(X_1) = T(X_2)$

Wie findet man invariante Merkmale?

- **Idee:** Finden einer **Abbildung** T , die invariante Merkmale eines Objektes extrahiert
- Das heißt: Alle Objekte einer Äquivalenzklasse werden von T auf einen Punkt im Merkmalsraum abgebildet: $X_1 \cong X_2 \Rightarrow T(X_1) = T(X_2)$

Anforderungen an diese Abbildung:

Vollständigkeit zur Vermeidung von Mehrdeutigkeiten bei der Abbildung in den Merkmalsraum

- **Projektionsmenge:** $I_T(x) := \{x_i | T(x_i) = T(x)\}$ Menge der Objekte, die auf denselben Punkt wie x abgebildet werden
- **Orbit:** $G(x) := \{x_i | x_i \cong x\}$ Menge aller Objekte, die sich aus x durch Anwendung von Transformationen aus G erzeugen lassen

Wie findet man invariante Merkmale?

- **Idee:** Finden einer **Abbildung** T , die invariante Merkmale eines Objektes extrahiert
- Das heißt: Alle Objekte einer Äquivalenzklasse werden von T auf einen Punkt im Merkmalsraum abgebildet: $X_1 \cong X_2 \Rightarrow T(X_1) = T(X_2)$

Anforderungen an diese Abbildung:

Vollständigkeit zur Vermeidung von Mehrdeutigkeiten bei der Abbildung in den Merkmalsraum

- **Projektionsmenge:** $I_T(x) := \{x_i | T(x_i) = T(x)\}$ Menge der Objekte, die auf denselben Punkt wie x abgebildet werden
- **Orbit:** $G(x) := \{x_i | x_i \cong x\}$ Menge aller Objekte, die sich aus x durch Anwendung von Transformationen aus G erzeugen lassen
- Es gilt: $G(x) \subseteq I_T(x)$
- Abbildung vollständig, wenn beide Mengen gleich: $X_1 \cong X_2 \Leftrightarrow T(X_1) = T(X_2)$
- Schwierig: Abbildungen mit hohem Vollständigkeitsgrad, d.h. $|G(x)| \approx |I_T(x)|$

Stetigkeit: Ähnliche Objekte sollen auf benachbarte Punkte im Merkmalsraum abgebildet werden

Bei geringen Unterschieden zwischen Objekten soll sich das Ergebnis der Abbildung T auch nur gering verändern

Stetigkeit: Ähnliche Objekte sollen auf benachbarte Punkte im Merkmalsraum abgebildet werden

Bei geringen Unterschieden zwischen Objekten soll sich das Ergebnis der Abbildung T auch nur gering verändern

Unterscheidungsleistung: die Abbildung soll robust gegenüber Bildstörungen sein

Komplexität: die Abbildung sollte effizient berechenbar sein

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen

Beschleunigung der Berechnung

Anwendungen

Methoden zur Erzeugung von invarianten Merkmalen können in drei Kategorien eingeteilt werden:

Normalisierung

- Idee: Finden eines Standardvertreters aus jeder Äquivalenzklasse
- Verschiedene Verfahren existieren, z.B. **affine Normalisierung**, bei welcher der minimale Umfang bei konstanter Fläche gesucht wird

Methoden zur Erzeugung von invarianten Merkmalen können in drei Kategorien eingeteilt werden:

Normalisierung

- Idee: Finden eines Standardvertreters aus jeder Äquivalenzklasse
- Verschiedene Verfahren existieren, z.B. **affine Normalisierung**, bei welcher der minimale Umfang bei konstanter Fläche gesucht wird
- Behandlung von komplexen Transformationen möglich
- Objektkontur bzw. segmentiertes Objekt erforderlich

Methoden zur Erzeugung von invarianten Merkmalen können in drei Kategorien eingeteilt werden:

Normalisierung

- Idee: Finden eines Standardvertreters aus jeder Äquivalenzklasse
- Verschiedene Verfahren existieren, z.B. **affine Normalisierung**, bei welcher der minimale Umfang bei konstanter Fläche gesucht wird
- Behandlung von komplexen Transformationen möglich
- Objektkontur bzw. segmentiertes Objekt erforderlich

Differentiale Invarianten

- Idee: Invariante Merkmale ändern sich nicht, wenn eine unendlich kleine Transformation durchgeführt wird
- In der Praxis selten angewendet, da komplizierte Differentialgleichungen entstehen

Integrale Invarianten

- Idee: Integration über die gesamte Gruppe der Transformationen
- Auswerten einer Funktion f auf allen Objekten des Orbits und anschließendes Normieren
- Dazu: Berechnung des Integrals über den gesamten Orbit:

$$T(x) = \frac{1}{|G|} \int_G f(gx) dg$$

- Das Integral ist unabhängig vom Parametervektor λ und deshalb invariant

Integrale Invarianten

- Idee: Integration über die gesamte Gruppe der Transformationen
- Auswerten einer Funktion f auf allen Objekten des Orbits und anschließendes Normieren
- Dazu: Berechnung des Integrals über den gesamten Orbit:

$$T(x) = \frac{1}{|G|} \int_G f(gx) dg$$

- Das Integral ist unabhängig vom Parametervektor λ und deshalb invariant
- Effiziente Berechenbarkeit von $T(x)$
- Keine Notwendigkeit der Segmentierung
- Behandlung von 3D-Daten möglich
- Beschränkung auf einfache Transformationen

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen

Beschleunigung der Berechnung

Anwendungen

- Beschränkung auf Grauwertbilder
- Bei Farbbildern müssen die Merkmale für jeden Farbkanal einzeln berechnet werden
- Notation für den Grauwert an einer Koordinate $n = (n_0, n_1)$:

$$X(n) \quad n \in \mathbb{R}^2 \text{ oder } n \in \mathbb{N}^2$$

- Alle Indizes periodisch fortgesetzt

- Beschränkung auf Grauwertbilder
- Bei Farbbildern müssen die Merkmale für jeden Farbkanal einzeln berechnet werden
- Notation für den Grauwert an einer Koordinate $n = (n_0, n_1)$:

$$X(n) \quad n \in \mathbb{R}^2 \text{ oder } n \in \mathbb{N}^2$$


- Alle Indizes periodisch fortgesetzt
- Als Transformationsgruppe G wird die Gruppe der Kongruenzen behandelt:

$$(gX)(n) = X(n'), \text{ mit } n' = \begin{pmatrix} \cos \phi & \sin \phi \\ -\sin \phi & \cos \phi \end{pmatrix} n + \begin{pmatrix} t_0 \\ t_1 \end{pmatrix}$$

- In der Praxis wird das Integral durch eine Summe ersetzt
- Schwieriger: Integrale Invarianten für komplizierte Transformationen, insb. Skalierung
- Aber: robust gegenüber kleineren Form- und Größenänderungen

Konstruktion einer **invarianten Abbildung** $T[f](X)$ für eine **Kernfunktion** f und ein Grauwertbild X durch die folgende Integration:

$$T[f](X) := \frac{1}{|G|} \int_G f(gX) dg$$



Für die Gruppe der Kongruenzen gilt:

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$

Für die Gruppe der Kongruenzen gilt:

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$

Dreidimensionale euklidische Transformationen parametrisierbar durch einen dreidimensionalen Translationsvektor t und drei Winkel ϕ, ψ, τ

Das Integral wird erweitert zu:

$$T[f](X) = \frac{1}{8\pi^3 N_0 N_1 N_2} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{n_2=0}^{N_2} \int_{\phi=0}^{2\pi} \int_{\psi=0}^{2\pi} \int_{\tau=0}^{2\pi} f(gX) d\tau d\psi d\phi dn_2 dn_1 dn_0$$

Für die Gruppe der Kongruenzen gilt:

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$

Dreidimensionale euklidische Transformationen parametrisierbar durch einen dreidimensionalen Translationsvektor t und drei Winkel ϕ, ψ, τ

Das Integral wird erweitert zu:

$$T[f](X) = \frac{1}{8\pi^3 N_0 N_1 N_2} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{n_2=0}^{N_2} \int_{\phi=0}^{2\pi} \int_{\psi=0}^{2\pi} \int_{\tau=0}^{2\pi} f(gX) d\tau d\psi d\phi dn_2 dn_1 dn_0$$

Diese Technik wird als “**Group Averaging**” bezeichnet, $T[f](X)$ als “Group average”, bzw. “**Gruppenmittelwert**”

Kernfunktion f besteht aus **Monomen** vom Grad $\leq |G|$

Berechnung von invarianten Merkmalen am Beispiel der Gruppe von eindimensionalen zyklischen Transformationen:

- Jedes $g \in G$ kann durch die Länge der Verschiebung parametrisiert werden
- Da Signale in der Praxis diskret, Summe anstatt Integral:

$$T[f](x) = \frac{1}{N} \sum_{n=0}^{N-1} f(g_n x) \quad \text{mit } g_n(x_0, x_1, \dots, x_{N-1}) = (x_n, x_{n+1}, \dots, x_{N-1+n})$$

wobei Indizes $\mod N$

Berechnung von invarianten Merkmalen am Beispiel der Gruppe von eindimensionalen zyklischen Transformationen:

- Jedes $g \in G$ kann durch die Länge der Verschiebung parametrisiert werden
- Da Signale in der Praxis diskret, Summe anstatt Integral:

$$T[f](x) = \frac{1}{N} \sum_{n=0}^{N-1} f(g_n x) \quad \text{mit } g_n(x_0, x_1, \dots, x_{N-1}) = (x_n, x_{n+1}, \dots, x_{N-1+n})$$

wobei Indizes $\mod N$

- Konkret: binäre Signale der Länge 4: $x = (x_0, x_1, x_2, x_3)^T$ $x_i \in \{0, 1\}$
- Berechnung des Gruppenmittelwerts aller Monome $x_0^{e_0} x_1^{e_1} x_2^{e_2} x_3^{e_3}$ mit der Eigenschaft $\sum_{i=0}^3 e_i \leq 4$ für eine vollständige Merkmalsmenge
- Keine Berücksichtigung von Monomen, die sich durch eine zyklische Verschiebung der e_i unterscheiden

Orbits der äquivalenten Signale:

Orbit	Signale			
O_0	(0,0,0,0)			
O_1	(0,0,0,1)	(0,1,0,0)	(0,0,1,0)	(0,0,0,1)
O_2	(0,0,1,1)	(0,1,1,0)	(1,1,0,0)	(1,0,0,1)
O_3	(0,1,0,1)	(1,0,1,0)		
O_4	(0,1,1,1)	(1,1,1,0)	(1,1,0,1)	(1,0,1,1)
O_5	(1,1,1,1)			

Die folgenden Monome ergeben sich für $x = (x_0, x_1, x_2, x_3)$

$$f_0(x) = x_0$$

$$f_1(x) = x_0 x_1$$

$$f_2(x) = x_0 x_2$$

$$f_3(x) = x_0 x_1 x_2$$

$$f_4(x) = x_0 x_1 x_2 x_3$$

Es ergeben sich die folgenden Gruppenmittelwerte für ein Signal x :

$$\begin{aligned}T[f_0](x) &= \frac{1}{4} \sum_{n=0}^3 f_0(g_n x) \\&= \frac{1}{4}(x_0 + x_1 + x_2 + x_3) \\T[f_1](x) &= \frac{1}{4}(x_0 x_1 + x_1 x_2 + x_2 x_3 + x_3 x_0) \\T[f_2](x) &= \frac{1}{4}(x_0 x_2 + x_1 x_3 + x_2 x_0 + x_3 x_1) \\&= \frac{1}{2}(x_0 x_2 + x_1 x_3) \\T[f_3](x) &= \frac{1}{4}(x_0 x_1 x_2 + x_1 x_2 x_3 + x_2 x_3 x_0 + x_3 x_0 x_1) \\T[f_4](x) &= (x_0 x_1 x_2 x_3)\end{aligned}$$

Und damit die folgenden Ergebnisse für die Merkmale:

Orbits	$T[f_0](x)$	$T[f_1](x)$	$T[f_2](x)$	$T[f_3](x)$	$T[f_4](x)$
O_0	0	0	0	0	0
O_1	1/4	0	0	0	0
O_2	1/2	1/4	0	0	0
O_3	1/2	0	1/2	0	0
O_4	3/4	1/2	1/2	1/4	0
O_5	1	1	1	1	1

Erinnerung: Integral über die Gruppe der Kongruenzen für eine Kernfunktion f und ein Bild mit Dimensionen N_0, N_1 :

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$

Setze $f = X(0, 0) \cdot X(0, 1) \cdot T[f](X)$ wird zu:


$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} X(n_0, n_1) \cdot X(n_0 - \sin\phi, n_1 + \cos\phi) d\phi dn_1 dn_0$$

Erinnerung: Integral über die Gruppe der Kongruenzen für eine Kernfunktion f und ein Bild mit Dimensionen N_0, N_1 :

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$


Setze $f = X(0, 0) \cdot X(0, 1) \cdot T[f](X)$ wird zu:

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} X(n_0, n_1) \cdot X(n_0 - \sin\phi, n_1 + \cos\phi) d\phi dn_1 dn_0$$




Berechnung erfolgt durch eine **Zweischritt-Strategie**:

1. Berechne das Integral über den Winkel ϕ , d.h. suche alle Pixel, die den Abstand 1 von (n_0, n_1) haben, und multipliziere ihren Grauwert mit dem Grauwert von $X(n_0, n_1)$.
2. Wiederhole diesen Prozess für alle (n_0, n_1) mit $0 \leq n_0 < N_0, 0 \leq n_1 < N_1$, addiere die Ergebnisse und normiere anschließend



- **Supportgröße:** Radius des Kreises, aus dem Werte für die Berechnung von $f(X)$ im ersten Schritt entnommen werden



- **Supportgröße:** Radius des Kreises, aus dem Werte für die Berechnung von $f(X)$ im ersten Schritt entnommen werden
- Verarbeitung von Szenen mit mehreren unabhängig transformierten Objekten möglich, wenn der Abstand der Objekte $>$ Supportgröße
- Voraussetzung: homogener Hintergrund
- **Additivität:** $T(X) = T(X_1) + T(X_2)$ wenn Hintergrund den Grauwert 0 hat
- Leichte Überlappungen werden toleriert
- Robustheit gegenüber topologischen Deformationen




Bild	$X(0, 0) \cdot X(0, 7)$
alpha	418,7
omega	210,7
alpha & omega	629,4
alpha & omega verdeckt	637,3

Durch die Überdeckung ändert sich das Ergebnis um 7.9, das sind 1.3% Abweichung

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen



Beschleunigung der Berechnung

Anwendungen

- Bedingte Einsetzbarkeit der vorgestellten Merkmale in der Praxis, da Mittelwertbildung über das gesamte Bild
- 1 Wert ist zuwenig, um ein Bild zu charakterisieren
- Möglichkeit: Verwendung von **Histogrammen** anstatt Mittelwertbildung
- Ersetzung der Summen durch Histogrammoperationen
- Invarianz bleibt erhalten

- Bedingte Einsetzbarkeit der vorgestellten Merkmale in der Praxis, da Mittelwertbildung über das gesamte Bild
- 1 Wert ist zuwenig, um ein Bild zu charakterisieren
- Möglichkeit: Verwendung von **Histogrammen** anstatt Mittelwertbildung
- Ersetzung der Summen durch Histogrammoperationen
- Invarianz bleibt erhalten
- Kombination von mehreren Merkmalen in mehrdimensionalen Histogrammen möglich
- Glättung der Diskretisierung durch stetige Korbzuweisungsfunktion(**Fuzzy-Histogramme**)
- Kombinierte Farb-Merkmalhistogramme möglich

Beispiel für ein Histogramm basierend auf der Funktion $f(X) = X(0,0) \cdot X(0,1)$



Links: Histogramm zur Abbildung in Originalgröße, rechts zur 80%-Verkleinerung.

Die innere Summe über den Winkel wurde beibehalten und beide Histogramme wurden normiert, so dass die Summe aller Körbe 1 ist. Der 0-te Korb wurde in der Grafik weggelassen.

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen

Beschleunigung der Berechnung

Anwendungen

- Laufzeit ist **linear** bezüglich Anzahl der Pixel/Voxel und der Supportgröße
- Für einen 3D-Datensatz mit 128x128x128 Voxeln und einer Supportgröße $4 \cdot 30 \cdot 10^9$ Auswertungen der Kernfunktion
- Reduzierung der Laufzeit auf $O(1)$ mit Hilfe **nichtdeterministischer Schätzung** möglich

- Laufzeit ist **linear** bezüglich Anzahl der Pixel/Voxel und der Supportgröße
- Für einen 3D-Datensatz mit 128x128x128 Voxeln und einer Supportgröße $4 \cdot 30 \cdot 10^9$ Auswertungen der Kernfunktion
- Reduzierung der Laufzeit auf $O(1)$ mit Hilfe **nichtdeterministischer Schätzung** möglich

$$T[f](X) = \frac{1}{2\pi N_0 N_1} \int_{n_0=0}^{N_0} \int_{n_1=0}^{N_1} \int_{\phi=0}^{2\pi} f(gX) d\phi dn_1 dn_0$$

wird approximiert, indem die Kernfunktion f auf einer Menge von zufällig ausgewählten Trippeln (n_0, n_1, ϕ) ausgewertet und der Mittelwert aus diesen Ergebnissen berechnet wird (**Monte-Carlo-Methode**)

$$\bar{Y} = \sum_{n=0}^{N-1} Y_n \quad \text{mit } Y_n = f(n_0, n_1, \phi) \quad V(\bar{Y}) = V(Y_n)/N$$

Bestimmung der **Sampleszahl N** , um einen Fehler ϵ mit Überschreitungswahrscheinlichkeit δ zu erhalten:

Summe vieler unabhängiger Zufallsvariablen annähernd gaussverteilt

$$\Rightarrow \Phi \left(\frac{\epsilon \sqrt{N}}{\sqrt{V(Y_n)}} \right) \geq 1 - \delta/2$$

$$\bar{Y} = \sum_{n=0}^{N-1} Y_n \quad \text{mit } Y_n = f(n_0, n_1, \phi) \quad V(\bar{Y}) = V(Y_n)/N$$

Bestimmung der **Sampleszahl N** , um einen Fehler ϵ mit Überschreitungswahrscheinlichkeit δ zu erhalten:

Summe vieler unabhängiger Zufallsvariablen annähernd gaussverteilt

$$\Rightarrow \Phi\left(\frac{\epsilon\sqrt{N}}{\sqrt{V(Y_n)}}\right) \geq 1 - \delta/2$$

Beispiel: $\epsilon = 0.01$, $\delta = 5\%$, $f(gX) \in [0, 1]$. Für die Varianz $V(Y_n)$ läßt sich die folgende grobe Abschätzung machen: $V(Y_n) = E(Y_n^2) - E(Y_n)^2 \leq 1$

Damit erhält man $\Phi(0.01\sqrt{N}) \geq 0.975$, also $N \geq 38416$

Ähnliche Abschätzung für Histogramme

Grundlagen

Methoden der Erzeugung

Integrale Invarianten

Histogramme von lokalen Merkmalen

Beschleunigung der Berechnung

Anwendungen

- Einsatz von globalen invarianten Merkmalen zum Vergleich von **CT-Volumenbildern**
- Scans, die zu verschiedenen Zeitpunkten aufgenommen wurden, sind u.U. ungleich ausgerichtet und verschoben

- Einsatz von globalen invarianten Merkmalen zum Vergleich von **CT-Volumenbildern**
- Scans, die zu verschiedenen Zeitpunkten aufgenommen wurden, sind u.U. ungleich ausgerichtet und verschoben
- Vergleich und Interpretation der Ergebnisse möglich
- Autoren meinen: Detektion von morphologischen Prozessen möglich
- Keine Segmentierung im Gegensatz zu herkömmlichen Techniken erforderlich

- Einsatz von globalen invarianten Merkmalen zum Vergleich von **CT-Volumenbildern**
- Scans, die zu verschiedenen Zeitpunkten aufgenommen wurden, sind u.U. ungleich ausgerichtet und verschoben
- Vergleich und Interpretation der Ergebnisse möglich
- Autoren meinen: Detektion von morphologischen Prozessen möglich
- Keine Segmentierung im Gegensatz zu herkömmlichen Techniken erforderlich
- Weiteres Anwendungsgebiet, in dem 3D-invariante Merkmale verwendet werden: Klassifizierung von 3D-Scans von Pollen

Verwendung der Histogramme von lokalen Merkmalen in der inhaltsbasierten Bildsuche bei:

- inhomogenem Bildmaterial, wenn Segmentierungstechniken versagen**
- grossem Datenaufkommen, wenn automatische Verarbeitung erforderlich**

Verwendung der Histogramme von lokalen Merkmalen in der inhaltsbasierten Bildsuche bei:

- inhomogenem Bildmaterial, wenn Segmentierungstechniken versagen
 - grossem Datenaufkommen, wenn automatische Verarbeitung erforderlich
-
- Histogramme von lokalen Merkmalen enthalten im gegensatz zu gewöhnlichen Histogrammen Informationen über die lokale Nachbarschaft
 - Histogramme sind robust gegenüber Objektüberschneidungen oder Verdeckungen
 - **Lokale Ähnlichkeit** bei kleinen Supportgrößen, **globale Ähnlichkeit** bei großen Supportgrößen

Verwendung der Histogramme von lokalen Merkmalen in der inhaltsbasierten Bildsuche bei:

- inhomogenem Bildmaterial, wenn Segmentierungstechniken versagen
- grossem Datenaufkommen, wenn automatische Verarbeitung erforderlich

- Histogramme von lokalen Merkmalen enthalten im gegensatz zu gewöhnlichen Histogrammen Informationen über die lokale Nachbarschaft
- Histogramme sind robust gegenüber Objektüberschneidungen oder Verdeckungen
- **Lokale Ähnlichkeit** bei kleinen Supportgrößen, **globale Ähnlichkeit** bei großen Supportgrößen
- Vergleich von Histogrammen möglich z.B. durch:
 - **χ^2 -Test**: gibt Auskunft, inwieweit sich 2 Verteilungen unterscheiden

$$\chi^2(q, h) = \sum_n \frac{(q_n - h_n)^2}{q_n + h_n}$$



332.977



2438.770



2153.461



320.663



197.527




109.492




Beispiel für die Anwendung des χ^2 -Tests

Die Histogramme basierten auf der Kernfunktion $f = X(0, 0) * X(0, 1)$



- SIMBA ist ein System zur **inhaltsbasierten Bildsuche**, entwickelt vom Institut für Mustererkennung und Bildverarbeitung an der Uni Freiburg
- SIMBA steht für Search Images By Appearance
- SIMBA verwendet die in diesem Beitrag vorgestellten **Histogramme von invarianten Merkmalen**, ergänzt um **Texturmerkmale**, die invariant gegenüber Helligkeitsveränderungen im Bild sind

- SIMBA ist ein System zur **inhaltsbasierten Bildsuche**, entwickelt vom Institut für Mustererkennung und Bildverarbeitung an der Uni Freiburg
- SIMBA steht für Search Images By Appearance
- SIMBA verwendet die in diesem Beitrag vorgestellten **Histogramme von invarianten Merkmalen**, ergänzt um **Texturmerkmale**, die invariant gegenüber Helligkeitsveränderungen im Bild sind
- SIMBA ist als ein Client-Server-System implementiert
- Der Client braucht nicht das Bild über das Internet zu senden, sondern nur die berechneten Merkmale
- Mit dem Suchmuster wird eine gewichtete “nearest neighbour”-Abfrage durchgeführt, und die Treffer mitsamt der Trefferquote zurückgeliefert
- Es ist möglich, die Gewichtung von Texturmerkmalen und den Farbmerkmalen zu variieren
- Je nach Bildwahl liefert die eine oder die andere Strategie bessere Ergebnisse



SIMBA - Search IMages By Appearance

on the MPEG-7 test set of 2343 images

Query Interface:
Please select the number of rows and columns and a subsampling rate for the presentation of the results.
Choose a weight (0 is color only, 10 is orientations only) and select ☐ whether you want to consider the spatial layout or not (neglecting 90-degree rotations).
Then provide the url of your favorite JPEG image (note: the image will be compared unscaled, the database images have size 384x256)
URL
or use to get random images from the database
or select an image from the results to look for similar ones.

Results:


Search template

 0.013021	 0.132361	 0.133601	 0.307388
 0.321934	 0.324395	 0.332793	 0.348332

Notes:
1) It might take some time before the results appear - don't panic. However, a maximum number of 5 clients is allowed to contact the database server simultaneously, so perhaps you are

- Invariante Merkmale sind eine Möglichkeit, Bilder bzw. Objekte zu klassifizieren
- Mehrere Möglichkeiten diese zu berechnen, hier wurden die integralen Invarianten vorgestellt
- Vorteile: schnelle Berechnung mittels Schätzung und die Möglichkeit der automatischen Verarbeitung, da keine Segmentierung nötig ist
- Nachteile: fehlende Berücksichtigung der Skalierung und die starke Abhängigkeit von den Grauwerten
- Große Lücke zwischen Theorie und Praxis
- Alternativ zu globalen invarianten Merkmalen können Histogramme eingesetzt werden
- Mögliche Einsatzgebiete sind z.B. inhaltsbasierte Bildsuche, Analyse von 3D-Daten
- Vorgestellten Merkmale implementiert in SIMBA, einem System zur inhaltsbasierten Bildsuche