Merkmalerkennung am Beispiel SIFT

Medieninformatik IL

Andreas Unterweger

Vertiefung Medieninformatik
Studiengang ITS
FH Salzburg

Wintersemester 2016/17

Bildmerkmale (engl. *features*) I

- Beschreiben markante Stellen eines Bildes (so genannte Schlüsselpunkte) und deren Umgebung
- Anwendungen (Auswahl):
  - Bildinhalte beschreiben
  - Objekte in Bildern (wieder-)finden
  - Bilder zusammenfügen
  - Ähnliche Bilder suchen
- Anforderungen:
  - **Robustheit** (Stabilität)
  - Kompaktheit (geringer Speicherbedarf)
  - Effizienz (geringer Zeitbedarf für Berechnung)

Bildmerkmale II

- Robustheitsgrade:
  - Invarianz
  - Quasi-Invarianz
  - Toleranz
  - Intoleranz
- Robustheitsdimensionen:
  - Translation
  - Rotation
  - Skalierung
  - Allgemeine affine Transformationen
  - Perspektivische Transformationen
  - Beleuchtung

Überblick SIFT I

- SIFT: Scale-invariant Feature Transform
- Bestandteile
  - Merkmalerkennung
  - Merkmalvergleich
- Quasi-invariant gegenüber
  - Translation
  - Rotation
  - Isotroper Skalierung
- Tolerant gegenüber
  - Perspektivischen Transformationen
  - Beleuchtung

Überblick SIFT II

- Ablauf Merkmalerkennung
  - Schlüsselpunktkandidatensuche
  - Schlüsselpunktkandidatenfilterung
  - Schlüsselpunktorientierungszuordnung
  - Schlüsselpunktdeskriptorerstellung
- Ablauf Merkmalvergleich (von erkannten Merkmalen zweier Bilder)
  - Merkmalübereinstimmungen finden
  - Falschzuordnungen erkennen und entfernen
  - Verifikation und Korrektur der Zuordnung (iterativ)
- Begriffsdefinitionen
  - Orientierung: Ausrichtung des Schlüsselpunktes (ermöglicht Neuanordnung zur Erreichung von Quasi-Rotationsinvarianz)
  - Deskriptor: Merkmalvektor mit Informationen zum Schlüsselpunkt

Einschub: Scale Space I

- Motivation: Skalierungsinvarianz durch Modellierung des Scale (zu deutsch etwa Maßstab) erreichen
- Idee: Ein Bild $L(x, y)$ in einem Scale σ entspricht einem weichgezeichneten (mit G gefalteten) Ausgangsbild $I(x, y)$ mit Weichzeichnungsstärke σ

$$L(x, y, \sigma) = I(x, y) * G(x, y, \sigma)$$

- G ist zweidimensionales Gauß-Filter mit variablem σ

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Einschub: Scale Space II

$\sigma = 0$

$\sigma = 1$

$\sigma = 4$

$\sigma = 16$

Quelle: Wikipedia contributors: Scale space. *Wikipedia, The Free Encyclopedia* `http://en.wikipedia.org/wiki/Scale_space` (18.7.2014), 2014

Schlüsselpunktkandidatensuche I

- Idee: Menschliche Wahrnehmung nachahmen
- Überlegung: Details/hochfrequente Anteile enthalten viel Information
- Umsetzung: Difference of Gaussians (DoG) D mit $k \in \mathbb{R}$:

$$D(x, y, k) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma)$$

Quellen: `http://en.wikipedia.org/wiki/File:Flowers_before_difference_of_gaussians.jpg`; `http://commons.wikimedia.org/wiki/File:Flowers_after_difference_of_gaussians_grayscale.jpg`

Schlüsselpunktkandidatensuche II

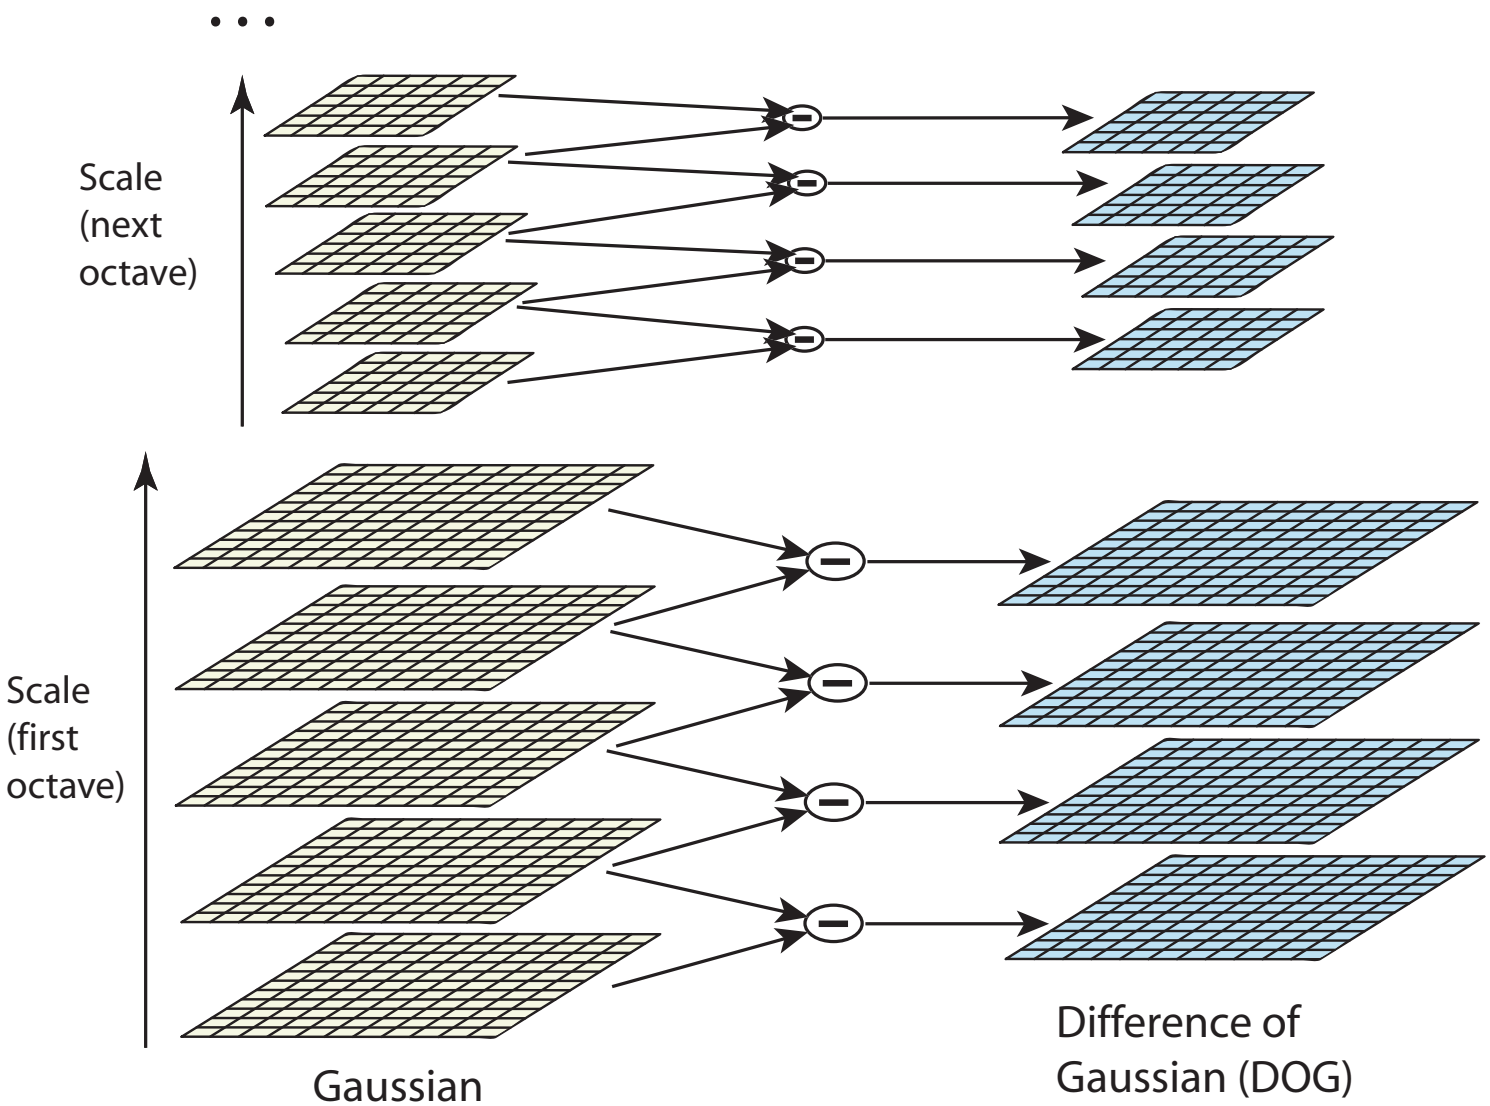

Quelle: Lowe, D. G.: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.

Schlüsselpunktkandidatensuche III

- Ohne Beweis: Scale-Invarianz durch Laplacian of Gaussians (LoG) $\nabla^2 G$ mit zusätzlichem Faktor σ^2 möglich:

$$\nabla^2 G = \frac{\partial^2 G}{\partial x^2} + \frac{\partial^2 G}{\partial y^2}$$

$\rightarrow$ Approximation von LoG durch DoG

- Scale Space erfüllt Diffusionsgleichung:

$$\sigma \nabla^2 G = \frac{\partial G}{\partial \sigma}$$

- Diskretisierung erlaubt vereinfachte numerische Ableitung:

$$\rightarrow \sigma \nabla^2 G \approx \frac{G(x, y, k\sigma) - G(x, y, \sigma)}{k\sigma - \sigma} \rightarrow D(x, y, k) \approx (k-1)\sigma^2 \nabla^2 G * I(x, y)$$

Schlüsselpunktkandidatensuche IV

- Ohne Beweis: Scale-Space-Extrema (Minima und Maxima von D) sind gute Kandidaten für Schlüsselpunkte
- Scale-Invarianz als Nebeneffekt von LoG-Approximation
- Diskreter Suchraum erlaubt Extremafindung durch Vergleich eines Pixels von D mit dessen direkten Nachbarn in allen drei Dimensionen

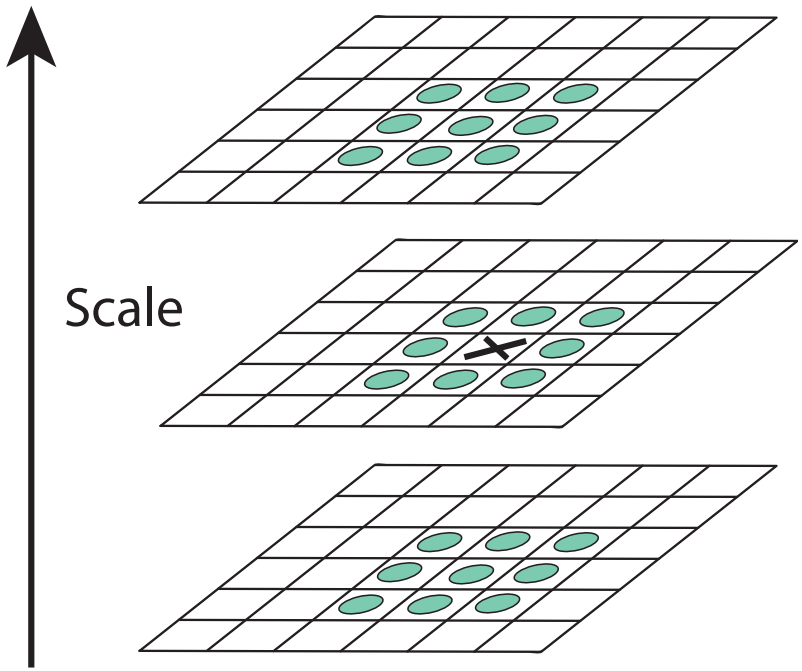

Quelle: Lowe, D. G.: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.

Schlüsselpunktkandidatenfilterung

- Kandidatenfilterungsprozess (ohne Details):
  - Kandidaten mit niedrigem Kontrast entfernen (anfällig für Rauschen)
  - Kandidaten entlang von Kanten entfernen (Lokalisation schwierig)
  - Interpolation rund um Extremum erlaubt exaktere Positionsermittlung

Adaptiert von `http://commons.wikimedia.org/wiki/File:Sift_keypoints_filtering.jpg`

Schlüsselpunktorientierungszuordnung I

- Beträge A und Winkel φ von Gradienten in Region um Schlüsselpunkt werden durch numerische Ableitung genähert
- Verwendung von $L'(x, y) = L(x, y, \sigma_P)$ zur Beibehaltung von Scale-Invarianz (σ_P ist Scale von Schlüsselpunkt P)

$$A(x, y) \approx \sqrt{(L'(x+1, y) - L'(x-1, y))^2 + (L'(x, y+1) - L'(x, y-1))^2}$$

$$\varphi(x, y) \approx \arctan\left(\frac{L'(x, y+1) - L'(x, y-1)}{L'(x+1, y) - L'(x-1, y)}\right)$$

- Winkel-Histogramm mit 10-Grad-Unterteilung wird erstellt
- Gradientenbeträge fließen entfernungsgewichtet ein (ohne Details)
- Maximum ist dominante Orientierung $\rightarrow$ Rotations(-quasi-)invarianz
- Für Werte bis 80% des Maximums: Zusätzliche Schlüsselpunkte

Schlüsselpunktorientierungszuordnung II

- Bisher bestimmte Schlüsselpunkteigenschaften:
  - Position (für Translationsinvarianz)
  - Scale (für Scale-Invarianz)
  - Orientierung (für Rotationsinvarianz)

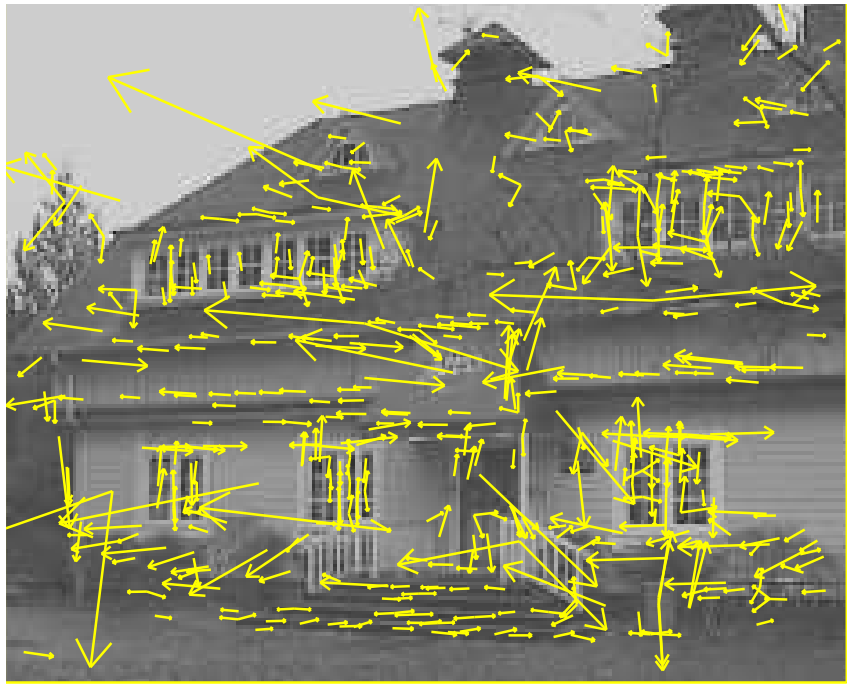

Quelle: Lowe, D. G.: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.

Schlüsselpunktdeskriptorerstellung

- $4 \cdot 4$ Orientierungshistogramme mit 45-Grad-Unterteilung aus Gradienten in $16 \cdot 16$-Region berechnen (vereinfachte Skizze)
- Vektor aus Histrogrammwerten erstellen und (vereinfacht) Vektor normalisieren (für Beleuchtungsinvarianz)

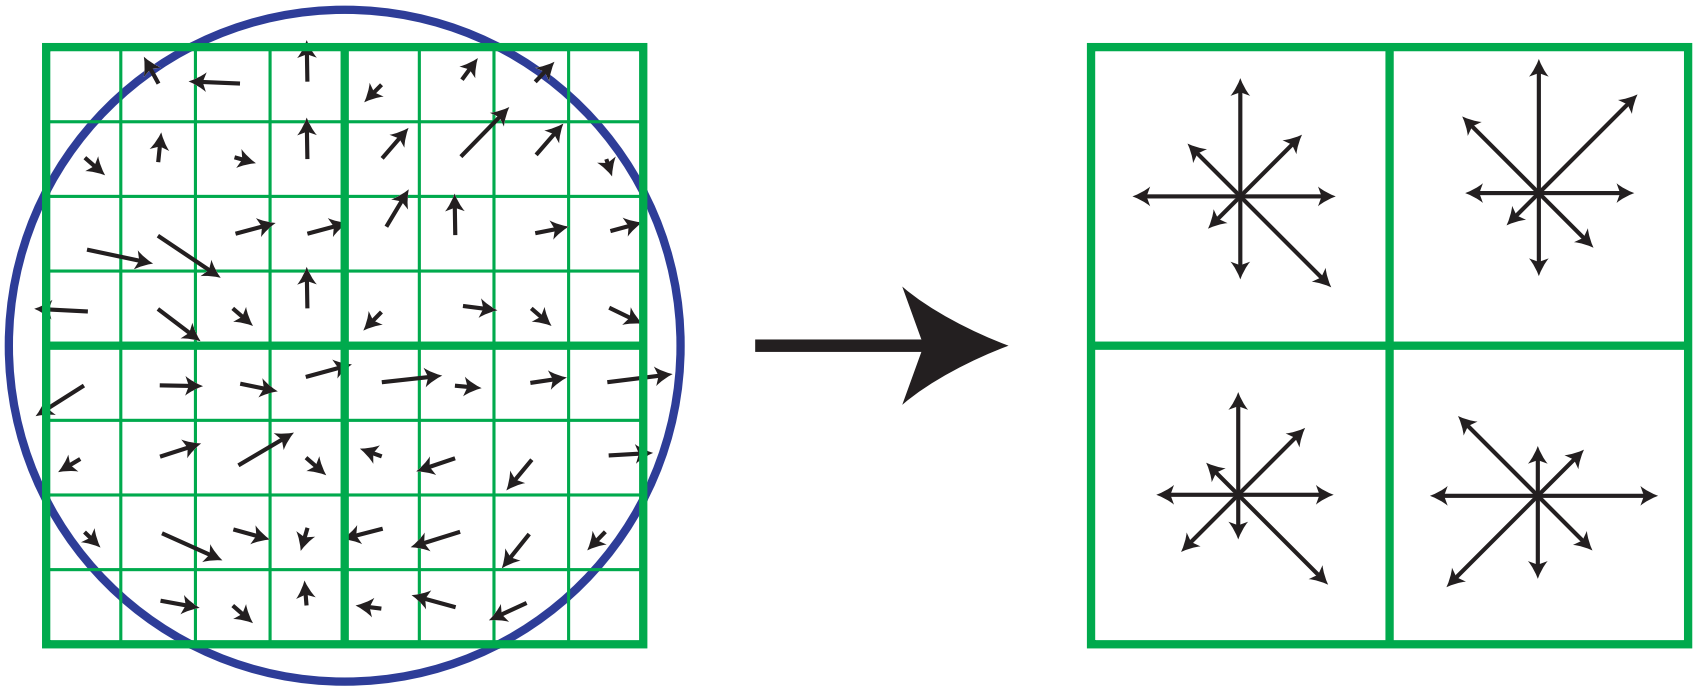

Quelle: Lowe, D. G.: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.

Merkmalvergleich I

- Schlüsselpunkte und -deskriptoren in beiden Bildern berechnen
- Schlüsselpunktdeskriptoren vergleichen: Merkmalvektoren mit jeweils kleinsten euklidischen Abständen einander zuordnen (Ausnahme: Der zweitkleinste Abstand ist sehr nahe am kleinsten)

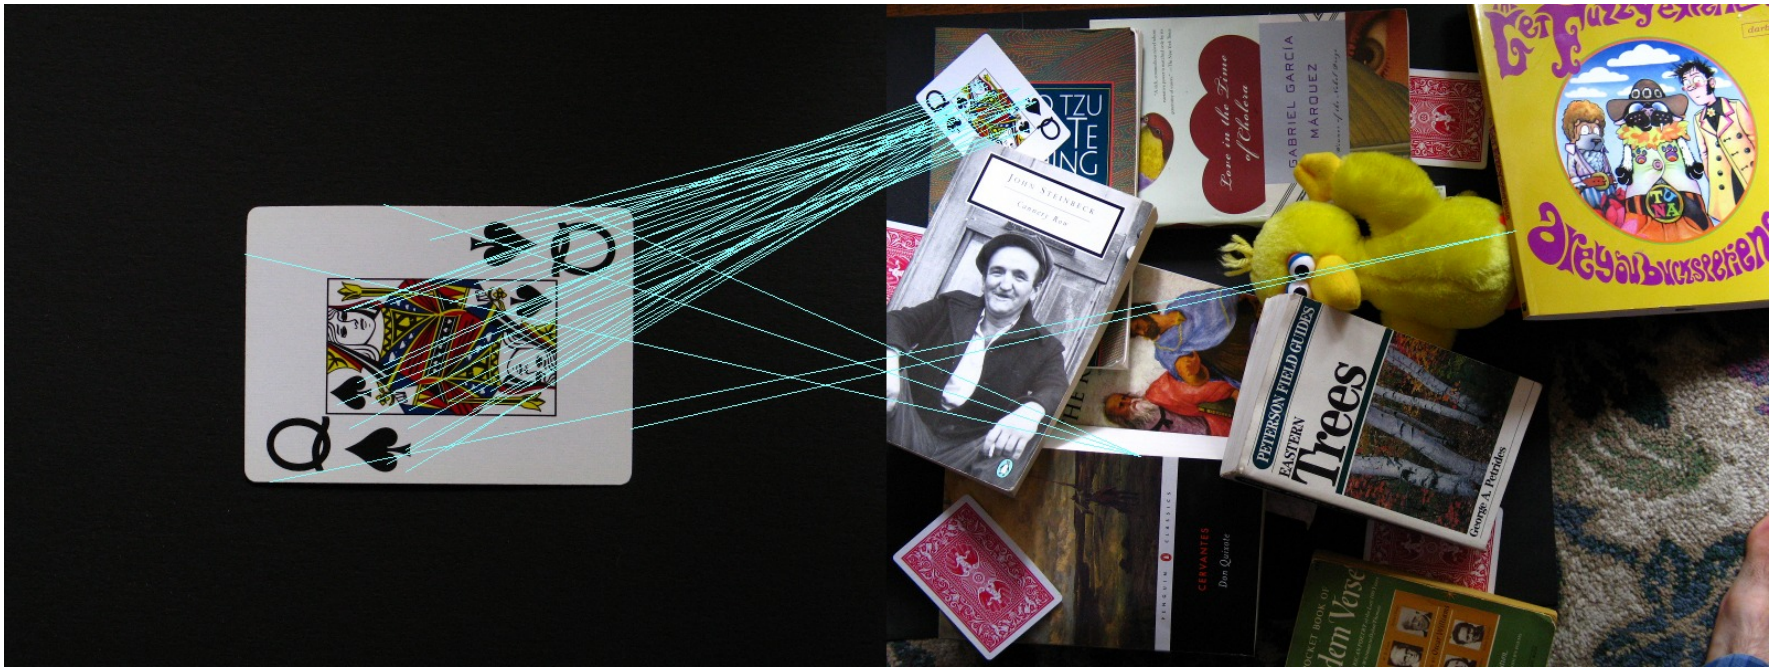

Quelle: Hess, R.: OpenSIFT – An Open-Source SIFT Library. `http://robwhess.github.io/opensift/` (15.7.2014), 2014.

Merkmalvergleich II

- Ausschluss von unpassenden Zuordnungen
  - Bestimmung der Pose (relative Position, Scale und Orientierung) jedes zugeordneten Schlüsselpunktes (mit Fehlertoleranz)
  - Gruppierung von Schlüsselpunkten, die in ihrer Pose übereinstimmen $\rightarrow$ Höhere Wahrscheinlichkeit für korrekte Zuordnung (ohne Details)
  - Verwerfen von Zuordnungsgruppen mit weniger als drei Zuordnungen

  $\rightarrow$ Menge von Zuordnungsgruppen
- Geometrische Verifikation (für jede Zuordnungsgruppe)
  - Vereinfachte Annahme: Zuordnungen werden durch affine Transformation (mit Fehlertoleranz) hinreichend genau beschrieben
  - Unbekannte affine Transformationsmatrix aus linearem Gleichungssystem (mit Fehlertoleranz) bestimmen (ohne Details)
  - Zuordnungen mit zu großem Fehler verwerfen und Zuordnungsgruppe bei weniger als drei übrigen Zuordnungen verwerfen
  - Schritte bei Bedarf wiederholen (bis nichts mehr verworfen wird)

Merkmalvergleich III

- Abschließende Zuordnung: Aus verbleibenden Gruppen anhand der Anzahl der verbleibenden Zuordnungen pro Gruppe und der Größe des Fehlers die wahrscheinlichste Zuordnung auswählen (ohne Details)

Quelle: Lowe, D. G.: Distinctive Image Features from Scale-Invariant Keypoints. International Journal of Computer Vision, vol. 60, no. 2, pp. 91–110, 2004.

Alternativen

- Nachteile von SIFT
  - Nicht robust gegenüber einigen Verzerrungsarten
  - Relativ langsam (trotz vieler Optimierungen)
  - Patentrechtlich geschützt
- Alternative Verfahren (Auswahl):
  - SURF (Speeded Up Robust Features) – ebenfalls geschützt
  - ORB (Oriented FAST[1] and Rotated BRIEF[2])
  - BRISK (Binary Robust Invariant Scalable Keypoints)
  - FREAK (Fast Retina Keypoint)
  - HOG (Histogram of Oriented Gradients)
  - Diverse Eckendetektoren (z.B. FAST und Harris)

[1] Features from Accelerated Segment Test

[2] Binary Robust Independent Elementary Features

Danke für die Aufmerksamkeit!

Fragen?