

11. Segmentierung

Ziel:

- Zerlegung eines Bildes $g(\mathbf{x})$ in getrennte bedeutungsvolle Bereiche

Definition: Vollständige Segmentierung

- Unterteilung der Menge Ω_g aller Bildpunkte von $g(\mathbf{x})$, $\mathbf{x} \in \Omega_g$, in I disjunkte, nichtleere Teilmengen $\omega_1, \dots, \omega_I$ so, dass mit einem gewissen Einheitlichkeitskriterium \mathcal{E} gilt:
 - $\bigcup_{i=1}^I \omega_i = \Omega_g$
 - $\forall i: \omega_i$ ist zusammenhängend
 - $\forall i: \mathcal{E}(\omega_i)$ ist erfüllt
 - für jede Vereinigungsmenge benachbarter ω_i, ω_j ist $\mathcal{E}(\omega_i \cup \omega_j)$ nicht erfüllt
- Man unterscheidet zwischen **bereichsorientierten** und **kantenorientierten** Verfahren


11.1 Bereichsorientierte Segmentierung

11.1.1 Segmentierung durch merkmalsbasierte Klassifikation

- Jedem Pixel \mathbf{x} wird ein Merkmalsvektor $\mathbf{m}(\mathbf{x}) \in \mathcal{M} \subseteq \mathbb{R}^K$ zugeordnet
- Merkmalsraum \mathcal{M} wird (z. B. mittels Ballungsanalyse) in I disjunkte Entscheidungsgebiete \mathcal{R}_i partitioniert:

$$\bigcup_{i=1}^I \mathcal{R}_i = \mathcal{M}, \quad \mathcal{R}_i \cap \mathcal{R}_j = \emptyset \quad \text{für } i \neq j$$

- **Segmentierung:** $\mathbf{m}(\mathbf{x}) \in \mathcal{R}_i \rightarrow \mathbf{x}$ wird ω_i zugewiesen

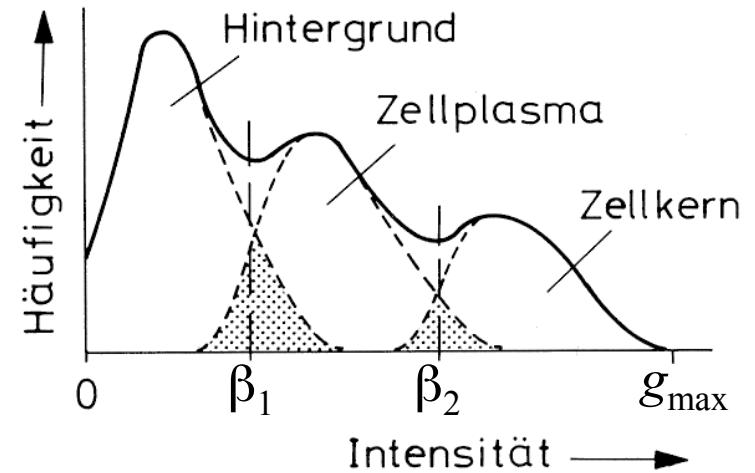
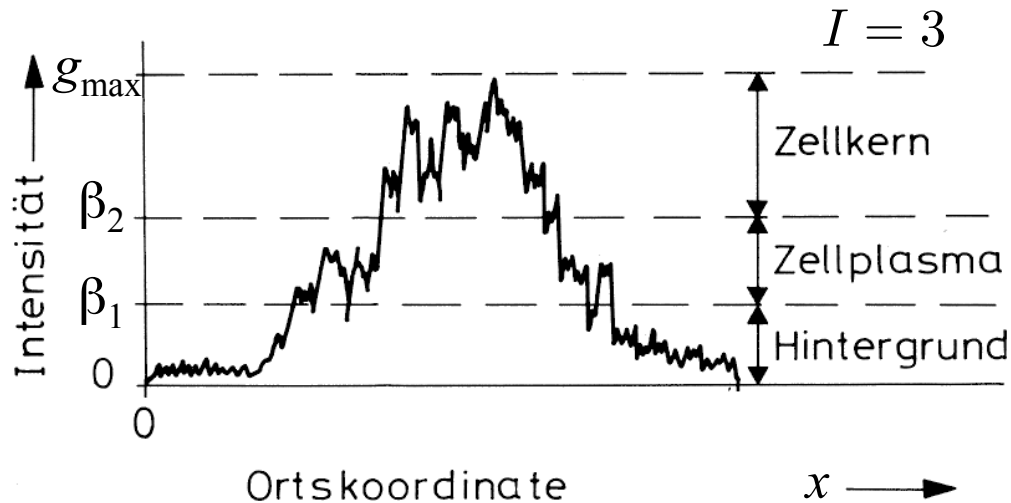


Beispiel 11.1: Bildwert als Merkmal

- Einfachster Merkmalsraum: Bildwert als Merkmal verwendet:

$$\mathbf{m}(\mathbf{x}) = g(\mathbf{x}), \quad K = 1$$


- Segmentierung erfolgt durch Festlegung von Entscheidungsgebieten (z. B. Intervalle von Grauwerten) und deren Grenzen
- Die so erzeugten Segmente ω_i müssen nicht zusammenhängen!




Quelle: F. M. Wahl, Digitale Bildsignalverarbeitung, 1989

11.1 Bereichsorientierte Segmentierung

Quelle: Wahl, 1989



Zellbild (Original)




Medianfilterung



Schwellen zu niedrig



Segmentierungsergebnis

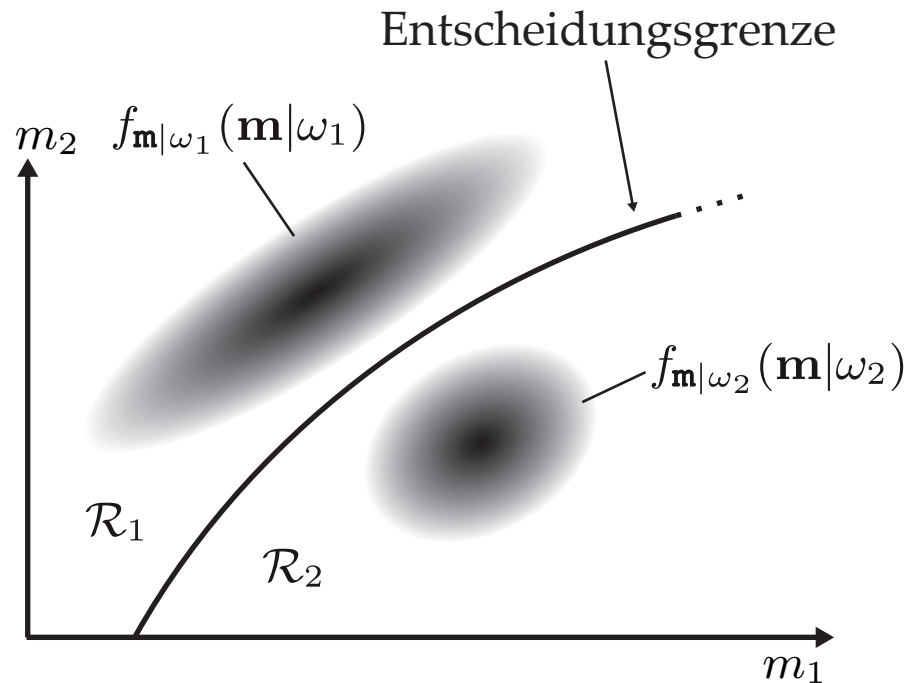


Schwellen zu hoch

Beispiel 11.3: Lokaler Mittelwert und Standardabweichung

- Statistiken über die lokale Bildwertverteilung als Merkmale geeignet, z. B.:

$$K = 2, \quad \mathbf{m}(\mathbf{x}) = \begin{pmatrix} \hat{\mu}(\mathbf{x}) \\ \hat{\sigma}(\mathbf{x}) \end{pmatrix}, \quad I = 2$$




- Klassen mit m_1 oder m_2 alleine nicht trennbar!

11.1 Bereichsorientierte Segmentierung

Beispiel: Optimale Entscheidungsgrenze, $K = 1$, $I = 2$

- Für beide Klassen werden oft Gauß-Dichten mit individuellen Parametern μ_i und σ_i angesetzt



- Entscheidungsgrenze degeneriert zu einem Schwellwert γ

11.1 Bereichsorientierte Segmentierung

Modell:

- $\mathbf{x} \in \omega_i \Rightarrow m(\mathbf{x}) = m$ mit WDF:

$$f_{m|\omega_i}(m|\omega_i) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{1}{2}\left(\frac{m-\mu_i}{\sigma_i}\right)^2}$$

Dichte des Merkmals m für den Fall, dass \mathbf{x} zur Klasse ω_i gehört

$$P_i := \Pr\{\mathbf{x} \in \omega_i\} \quad i = 1, 2$$

Wahrscheinlichkeit, dass ein \mathbf{x} zu ω_i gehört

- **Segmentierungsfehler** (Fehlerwahrscheinlichkeit):

$$\varepsilon(\gamma) = P_1 \int_{\gamma}^{\infty} f_{m|\omega_1}(m|\omega_1) dm + P_2 \int_{-\infty}^{\gamma} f_{m|\omega_2}(m|\omega_2) dm \quad \rightarrow \quad \text{Min.}$$

$$\rightarrow \gamma_{\text{opt}}(\mu_1, \sigma_1, P_1, \mu_2, \sigma_2, P_2)$$

- für $\sigma_1 = \sigma_2 = \sigma$:

$$\gamma_{\text{opt}} = \frac{\mu_1 + \mu_2}{2} - \frac{\sigma^2}{\mu_2 - \mu_1} \ln\left(\frac{P_2}{P_1}\right)$$

11.1 Bereichsorientierte Segmentierung

- μ_i, σ_i, P_i aus Histogramm $\hat{h}(m)$ schätzen durch:

$$\sum_m (f(m) - \hat{h}(m))^2 \rightarrow \text{Min.}$$

Anpassung der **Modellichte** $f(m)$ an das (empirische) Histogramm $\hat{h}(m)$ mit der Methode der kleinsten Quadrate

$$f(m) = f_m(m|\mu_1, \sigma_1, P_1, \mu_2, \sigma_2, P_2) = f_{m|\omega_1}(m) \cdot P_1 + f_{m|\omega_2}(m) \cdot P_2$$

Problem:



- Schwellwertverfahren liefern i. Allg. keine zusammenhängenden Gebiete

Andere Verfahren:

- **Bereichswachstumsverfahren:** Initialpunkte. Wachstum durch iteratives Hinzufügen von Nachbarpunkten, die mit dem Einheitlichkeitskriterium ε konform sind, bis alle Pixel $\mathbf{x} \in \Omega_g$ einer Klasse ω_i zugewiesen sind.
- **Pyramid Linking** [BPF15, Kap. 15]

Beispiel: Bereichswachstumsverfahren

- Iterative Vergrößerung von Segmenten, die Einheitlichkeitskriterium \mathcal{E} erfüllen
- Liefert zusammenhängende Segmente
- Vorgegebene Initialpunkte („Saatpunkte“, rot markiert)
- Nachteil: Abhängigkeit von der Wahl der Initialpunkte



Kantendetektion:



- Findung der Grenzen zwischen bedeutungsvollen Bildbereichen

Definition: Kante


- Grenze zwischen zwei Gebieten, die in sich bezüglich eines Einheitlichkeitskriteriums homogen sind (auch **Stufenkante** genannt)

Einteilung von Kanten

- Objektkanten (Objektgeometrie)
 - Reflektanzkanten
 - Schattenkanten
- } Scheinkanten, da keine geometrische Entsprechung



11.2 Kantenorientierte Verfahren



Extrema der
1. Ableitung
(Gradient)

Nulldurch-
gänge der
2. Ableitung

Gesucht:

- lineare diskrete Filter zur Approximation von

$$\text{grad } g(\mathbf{x}) = \left(\frac{\partial g(\mathbf{x})}{\partial x}, \frac{\partial g(\mathbf{x})}{\partial y} \right)^T$$

$\|\text{grad } g(\mathbf{x})\|$: Maß für „Kantenstärke“

$\text{grad } g(\mathbf{x}) \perp$ Kante, d. h.

$\angle \text{grad } g(\mathbf{x}) = \arctan \left(\frac{\frac{\partial g(\mathbf{x})}{\partial y}}{\frac{\partial g(\mathbf{x})}{\partial x}} \right)$: Normalenrichtung der Kante

wenn am Ort \mathbf{x} eine Kante vorliegt

Diskrete Näherungen (eindimensional):

$$\left. \frac{d}{dx} g(x) \right|_{x=m\Delta x} \approx d_m * g_m$$

Approximationen:

- Unsymmetrischer Differenzenquotient:

$$\frac{g(x) - g(x - \Delta x)}{\Delta x}$$

- Symmetrischer Differenzenquotient:

$$\frac{g(x + \Delta x) - g(x - \Delta x)}{2\Delta x}$$


- Stirling'sche Approximation:

$$\frac{-g(x+2\Delta x) + 8g(x+\Delta x) - 8g(x-\Delta x) + g(x-2\Delta x)}{12\Delta x}$$

Impulsantwort d_m

m	-3	-2	-1	0	1	2	3	
...	0	0	0	1	-1	0	0	...
...	0	0	$\frac{1}{2}$	0	$-\frac{1}{2}$	0	0	...
...	0	$-\frac{1}{12}$	$\frac{2}{3}$	0	$-\frac{2}{3}$	$\frac{1}{12}$	0	...

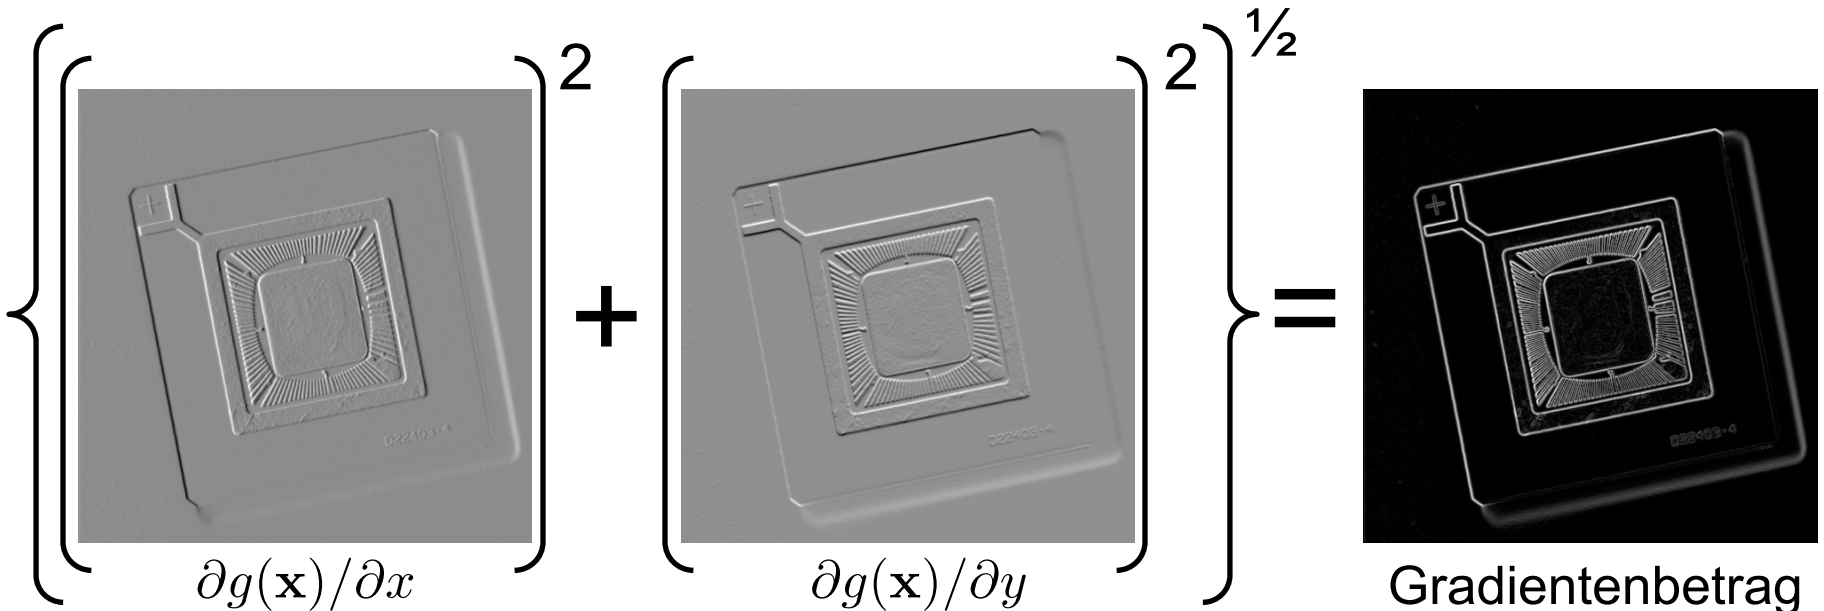
Beispiel zur Kantendetektion mit Gradientenoperatoren:



Symmetrischer Differenzenquotient ($\Delta x = \Delta y$)

$$\frac{\partial g(\mathbf{x})}{\partial x} \approx \frac{g(x + \Delta x, y) - g(x - \Delta x, y)}{2\Delta x}$$

$$\frac{\partial g(\mathbf{x})}{\partial y} \approx \frac{g(x, y + \Delta y) - g(x, y - \Delta y)}{2\Delta y}$$



Übertragungsfunktion eines Differenzierers

■ Ideal:

$$\frac{d}{dx} g(x) \quad \circ \rightarrow \bullet \quad \underbrace{j2\pi f}_{\text{ÜF}} \cdot G(f)$$

■ Symmetrischer Differenzenquotient:

$$D_k = \frac{1}{2} \left(-e^{-j2\pi \frac{k}{N}} + e^{-j2\pi \frac{k(N-1)}{N}} \right) = \frac{1}{2} \left(-e^{-j2\pi \frac{k}{N}} + e^{j2\pi \frac{k}{N}} \right)$$

$$= j \cdot \sin \left(2\pi \frac{k}{N} \right)$$

$$\stackrel{k \ll N}{\approx} j \cdot 2\pi \frac{k}{N} \quad \frac{k}{N} \hat{=} \text{ diskrete Frequenz}$$

$$D_0 = 0, \quad D_{\frac{N}{4}} = j, \quad D_{\frac{N}{2}} = 0$$

Abfall für höhere
Frequenzen

Konstruktion symmetrischer Ableitungsfiler der Länge $L = 2r + 1$

■ Ansatz:

$$r d_m = \begin{cases} 0 & \text{für } m = 0 \quad \vee \quad |m| > r \\ r d_m = -r d_{-m} & : \text{reelle, ungerade Ortsfunktion} \end{cases}$$

korrespondiert mit rein imaginärer, ungerader Fourier-Transformierten

■ DFT:

$$\begin{aligned} r D_k &= \sum_{\nu=0}^{N-1} r d_{\nu} e^{-j2\pi \frac{k\nu}{N}} = \sum_{\nu=1}^r r d_{\nu} \left(e^{-j2\pi \frac{k\nu}{N}} - e^{j2\pi \frac{k\nu}{N}} \right), \quad r < \frac{N}{2} \\ &= -2j \cdot \sum_{\nu=1}^r r d_{\nu} \sin\left(2\pi \frac{k\nu}{N}\right) \end{aligned}$$


Taylor-Entwicklung in Abhängigkeit von k/N

$\{r d_{\nu}\}$ so wählen, dass:

- lineares Glied $\stackrel{!}{=} j2\pi k/N$
- $r-1$ folgende Glieder $\stackrel{!}{=} 0$

11.2.1 Gradientenfilter

Übertragungsfunktionen
symmetrischer linearer
Ableitungsfilter der
Länge $L = 2r + 1$



Differentiation mittels der DFT (eindimensional)

$$\frac{dg(x)}{dx} \approx \text{DFT}^{-1} \{ G_k \cdot D_k \}$$

$$D_k := \begin{cases} j 2\pi \frac{k}{N} & \text{für } k < \frac{N}{2} \\ 0 & \text{für } k = \frac{N}{2} \\ j 2\pi \left(\frac{k-N}{N} \right) & \text{für } k > \frac{N}{2} \end{cases} \quad k = 0, \dots, N-1$$

problematisch
bei stark
ausgeprägtem
Leckeffekt

Probleme der Gradientenfilter:

- Differentiation verstärkt Rauschen!

→ Lösung: Unterdrückung hoher Ortsfrequenzen durch TP-Filterung

→ Brauchbare lineare Kantendetektionsfilter haben BP-Charakter

- Filterergebnis zeigt breite Konturen
- unterbrochene Konturen
- falsche Konturen, Artefakte

Nachbearbeitung nötig:

- Kantenverdünnung
- Kantenverfolgung
- Unterdrückung falscher Kanten

Differenzierter Gauß-TP

- gebräuchliche, **störungsunempfindliche** Gradientenapproximation zur Kantendetektion

$$\begin{aligned}\frac{\partial g(\mathbf{x})}{\partial x} &\approx \frac{\partial}{\partial x} (h(\mathbf{x}) ** g(\mathbf{x})) = \frac{\partial}{\partial x} \iint_{-\infty}^{\infty} g(\boldsymbol{\alpha}) h(\mathbf{x} - \boldsymbol{\alpha}) d\boldsymbol{\alpha} \\ &= \iint_{-\infty}^{\infty} g(\boldsymbol{\alpha}) \frac{\partial h}{\partial x}(\mathbf{x} - \boldsymbol{\alpha}) d\boldsymbol{\alpha} = \underbrace{\left(\frac{\partial}{\partial x} h(\mathbf{x}) \right)}_{d^x(\mathbf{x})} ** g(\mathbf{x})\end{aligned}$$

$$h(\mathbf{x}) := \frac{1}{2\pi\sigma^2} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma^2}}$$

$$\text{grad } g(\mathbf{x}) \approx (\text{grad } h(\mathbf{x})) ** g(\mathbf{x})$$

$$\text{grad } h(\mathbf{x}) = -\frac{\mathbf{x}}{\sigma^2} h(\mathbf{x}) = \begin{pmatrix} d^x(\mathbf{x}) \\ d^y(\mathbf{x}) \end{pmatrix}$$

■ Übertragungsfunktion:

$$d^x(\mathbf{x}) = -\frac{x}{2\pi\sigma^4} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma^2}} = -j2\pi x \frac{-j}{4\pi^2\sigma^4} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma^2}}$$



$$D^x(\mathbf{f}) = \frac{\partial}{\partial f_x} \left(\frac{-j}{2\sigma^2\pi} e^{-2\pi^2\sigma^2\|\mathbf{f}\|^2} \right)$$

$$D^x(\mathbf{f}) = j2\pi f_x e^{-2\pi^2\sigma^2\|\mathbf{f}\|^2} \approx j2\pi f_x$$

↑
kleine $\|\mathbf{f}\|$



Diskrete Approximation:

■ Abtastung von $d^x(\mathbf{x})$ und $d^y(\mathbf{x})$ im Ortsbereich $\rightarrow d_{mn}^x, d_{mn}^y$

■ Abtastung von $D^x(\mathbf{f})$ und $D^y(\mathbf{f})$ im Ortsfrequenzbereich $\rightarrow D_{kl}^x, D_{kl}^y$

11.2.1.3 Differenzierter Gauß-Tiefpass

Impulsantworten des differenzierten Gauß-Tiefpasses



11.2.1.4 Einfache Kantenoperatoren

Sobel-Operator

- gebräuchlicher Kantendetektor
- **Sobel-Filter** approximieren grob die differenzierten Gauß-Tiefpässe:

$s_{mn}^x :$

1	0	-1
2	0	-2
1	0	-1

$s_{mn}^y :$

-1	-2	-1
0	0	0
1	2	1

11.2.1.4 Einfache Kantenoperatoren

Sobel-Operator:

$$\left(|s_{mn}^x ** g_{mn}|^q + |s_{mn}^y ** g_{mn}|^q \right)^{\frac{1}{q}}$$

literaturüblich:
 $q = 1, 2, \infty$

Mit dieser q -Norm lassen sich für Kantendetektionszwecke auch die Komponenten anderweitig berechneter Gradientenapproximationen verarbeiten

$s_{mn}^x =$

1
2
1

**

1	0	-1
---	---	----

DFT

Binomial-TP
bzgl. y

Symm. Differenzen-
quotient bzgl. x

$S_{kl}^x =$

$2 \underbrace{\left(1 + \cos \left(2\pi \frac{l}{N} \right) \right)}_{\text{TP}} \cdot j \sin \left(2\pi \frac{k}{N} \right)$

für eine $N \times N$ -DFT

Roberts-Operator


- nutzt die kleinstmöglichen Filtermasken (Größe 2×2) zur Kantendetektion

$$k_{mn} = (|g_{m,n} - g_{m-1,n-1}|^q + |g_{m-1,n} - g_{m,n-1}|^q)^{\frac{1}{q}}$$


Eigenschaften:

- im Vergleich zum Sobel-Operator viel rauschempfindlicher
- dünnere Kanten als Sobel
- unsymmetrisch → Verschiebung der Kanten


11.2.1 Gradientenfilter






Original



Roberts-Operator




Sobel-Operator




Differenzierter Gauß-Tiefpass: $L=5$ ($\sigma = 0,8$), $L=9$ ($\sigma = 1,5$), $L=13$ ($\sigma = 2,2$)


11.2.1 Gradientenfilter






Original



Roberts-Operator






Sobel-Operator



Differenzierter Gauß-Tiefpass: $L=5$ ($\sigma = 0,8$), $L=9$ ($\sigma = 1,5$), $L=13$ ($\sigma = 2,2$)

Zweifache Differentiation sehr störanfällig!



Laplacian-of-Gaussian-Operator (LoG)

(Marr & Hildreth 1980)

$$-\Delta(h(\mathbf{x}) ** g(\mathbf{x})) = \underbrace{(-\Delta h(\mathbf{x}))}_{=: l(\mathbf{x})} ** g(\mathbf{x})$$


Gauß-TP zur Störungsunterdrückung

$$l(\mathbf{x}) = -\frac{\partial^2 h(\mathbf{x})}{\partial x^2} - \frac{\partial^2 h(\mathbf{x})}{\partial y^2}$$

$$= \frac{2\sigma^2 - \|\mathbf{x}\|^2}{2\pi\sigma^6} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma^2}}$$



$$L(\mathbf{f}) = 4\pi^2 \|\mathbf{f}\|^2 e^{-2\pi^2 \sigma^2 \|\mathbf{f}\|^2}$$



„Mexikanerhut“

$L(\mathbf{0}) = 0$, $L(\infty) = 0$: BP-Charakter

Diskrete Realisierungsmöglichkeiten:

- Abtastung von $l(\mathbf{x}) \rightarrow l_{mn}$ Maske großzügig wählen: Kantenlänge $> 7\sigma$ (kleinste von Marr/Hildreth verwendete Maske war: $\sigma = 5 \Delta x \rightarrow$ Kantenlänge $35 \Delta x$)
- Abtastung von $L(\mathbf{f}) \rightarrow L_{kl}$
- Approximation durch **Difference-of-Gaussians-Filter** (DoG)


$$l(\mathbf{x}) \approx \frac{1}{2\pi\sigma_1^2} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma_1^2}} - \frac{1}{2\pi\sigma_2^2} e^{-\frac{\|\mathbf{x}\|^2}{2\sigma_2^2}} \quad \text{mit} \quad \frac{\sigma_2}{\sigma_1} \approx 1,6$$

durch Binomialfilter realisieren!

Betragsmaximum der DoG-Übertragungsfunktion:

$$\|\mathbf{f}\|_{\max} = \frac{1}{\pi} \sqrt{\frac{\ln\left(\frac{\sigma_2}{\sigma_1}\right)}{\sigma_2^2 - \sigma_1^2}}$$

Difference of Gaussians






Vorteile:




- 1 Pixel breite Kanten
→ keine Kantenverdünnung notwendig
- angelehnt an menschliches visuelles System
(an dessen Datenverarbeitung zur Kantenextraktion)

Nachteile:

- Scheinkanten, da $\Delta g(\mathbf{x}) = 0$ nur notwendig für Kanten
- Kantenverschiebung wegen ausgedehnter Impulsantwort des LoG- bzw. DoG-Filters
→ Nachverarbeitung notwendig
(z. B. Verifikation von Kanten anhand des Gradientenbetrags)



LoG-Filterung ($\sigma = 2,5$); Steigung der Nulldurchgänge; Binarisierung.



LoG-Filterung ($\sigma = 7,5$); Steigung der Nulldurchgänge; Binarisierung.