

# Computergrafik 2: Filtern im Ortsraum

Prof. Dr. Michael Rohs, Dipl.-Inform. Sven Kratz

[michael.rohs@ifi.lmu.de](mailto:michael.rohs@ifi.lmu.de)

MHCI Lab, LMU München

Folien teilweise von Andreas Butz, sowie von Klaus D. Tönnies  
(Grundlagen der Bildverarbeitung. Pearson Studium, 2005)

# Themen heute

- Konvolution und Korrelation
- Lineare Filterung
- Nichtlineare Filterung
- Kantenmerkmale durch lineare Filterung
- Schärfen von Bildern
- Interpolation

# Filterung im Ortsraum

- Lineare Filterung
- $m \times n$  Filtermaske
- Lokale Umgebung
- Vorgegebene Operation auf Pixeln in lokaler Umgebung
- Skalarprodukt  
 $f(x-1, y-1) * w(-1, -1) +$   
 $\dots + f(x, y) * w(0, 0) +$   
 $\dots + f(x+1, y+1) * w(1, 1)$

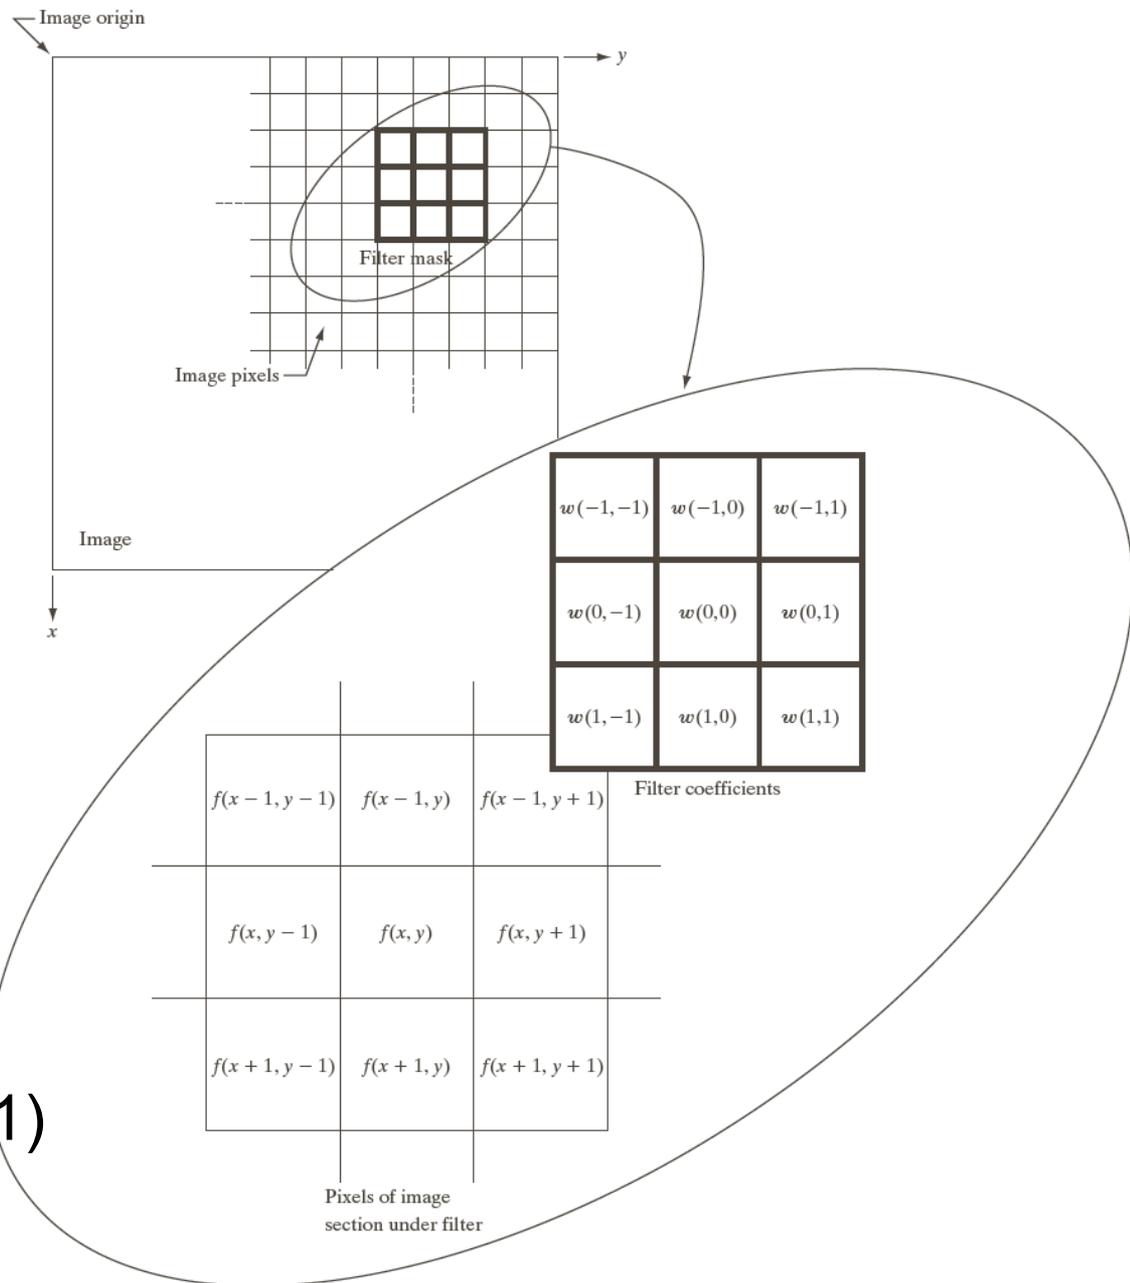


Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

# Filtern im Ortsraum

- Filterung als gewichtetes Mittel

$$g(x, y) = \frac{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t)}{\sum_{s=-a}^a \sum_{t=-b}^b w(s, t)}$$

- $m \times n$  Filtermaske mit  $m = 2a+1$ ,  $n = 2b+1$
- $M \times N$  Bild mit  $M$  Zeilen und  $N$  Spalten
- Üblicherweise
  - Filtermaske begrenzt, Gewicht normalisiert
  - Seitenlänge des Filters ungerade

# Filtergrößen

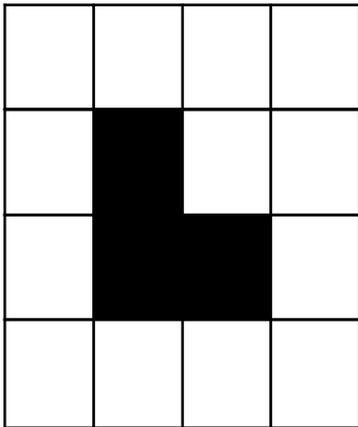
- Stärke der Glättung als Effekt der Filtergröße
  - Bild  $M \times N = 500 \times 500$
  - quadratisches Boxfilter



Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

# Hintereinanderschreiben von Pixeln

- 2-dimensionales Bild  
(M Zeilen, N Spalten)  
wird zu MN Spaltenvektor



$$f = \begin{pmatrix} f(0,0) \\ f(1,0) \\ \vdots \\ f(N-1,0) \\ f(0,1) \\ \vdots \\ f(N-1,1) \\ \vdots \\ \vdots \\ f(0,M-1) \\ \vdots \\ f(N-1,M-1) \end{pmatrix}$$

# Lineare Operatoren

- Definition eines linearen Operators  $O(\cdot)$

$$O(\alpha \vec{f} + \beta \vec{g}) = \alpha O(\vec{f}) + \beta O(\vec{g})$$

für alle Skalare  $\alpha, \beta$

- Superpositionsprinzip: komplexe Signale können in einfachere Komponenten zerlegt werden

# Linearer Operator als Matrix

Linearer operator  $O$  lässt sich auch als Matrix ausdrücken:

Seien  $x, y$  die hintereinandergeschriebenen Pixel zweier Bilder, dann ist

$$\vec{y} = A\vec{x}$$

Jeder Eintrag  $A_{i,j}$  gibt an, mit welchem Gewicht Pixel  $j$  aus  $x$  auf Pixel  $i$  in  $y$  abgebildet wird

# Verschiebungsinvariante Operatoren

- ... sind lineare Operatoren, deren Wirkung unabhängig vom Ort ist
- Beispiel: Filtermaske wirkt überall im Bild gleich
- Beispiel: gleichmäßige Unschärfe im Bild durch Bewegung der Kamera

# Konvolution (Faltung)

- Seien  $f, g$  abgetastete Bilder mit unendlicher Größe,  $m, n$ , Skalare

$$(g * f)(m, n) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} g(i, j) f(m - i, n - j)$$

Heißt Konvolution der Funktion  $f$  mit  $g$

- $g$  heißt die Konvolutionsfunktion
- Funktioniert so nur für unendlich große Bilder

# Eigenschaften der Konvolution

- Linear & verschiebungsinvariant
- Kommutativ & assoziativ

$$[g_1 * g_2](m, n) = [g_2 * g_1](m, n)$$

$$g_1 * ([g_2 * g_3](m, n)) = [g_1 * g_2](m, n) * g_3(m, n)$$

- D.h. wir können mehrere Konvolutionen vorab kombinieren und dann gemeinsam anwenden

# Konvolution vereinfacht

Hat die Konvolutionsfunktion  $g$  nur einen begrenzten Bereich, in dem  $g \neq 0$ , dann heißt dieser Bereich Kern von  $g$  (kernel)

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

# Konvolution anschaulich

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

	1	2	0	-2	-1	
	2	2	0	-2	-2	
	3	2	0	-2	-3	
	3	2	0	-2	-3	
	2	2	0	-2	-2	

Worst case Aufwand im Ortsraum:  $N^4$  für Kantenlänge  $N$  des Bildes

# Verwendung der Konvolution

- Sobel-Operator: Kanten finden



\*

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

=



# Konvolution des Dirac-Impulses

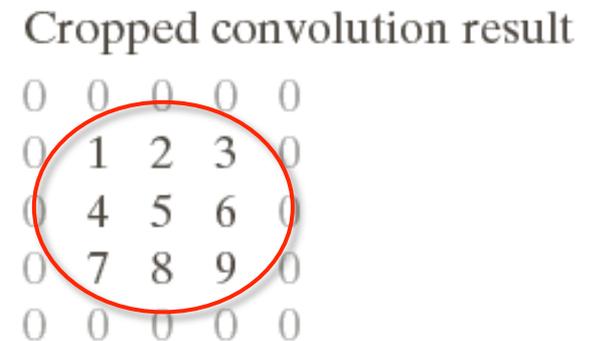
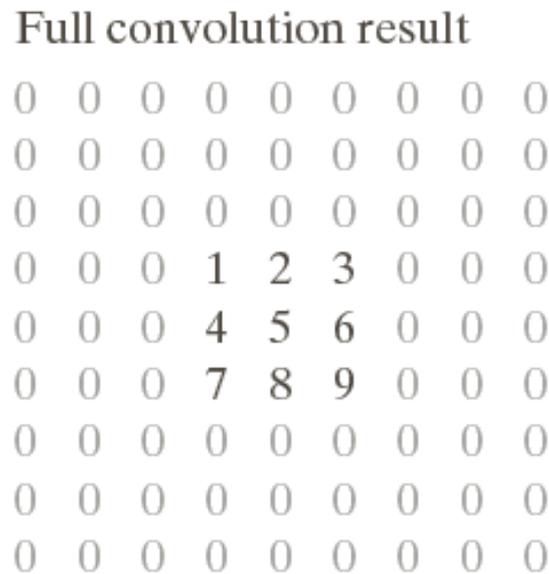
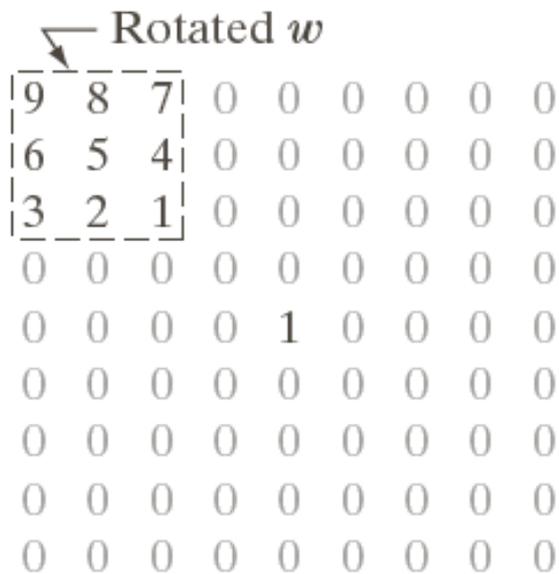
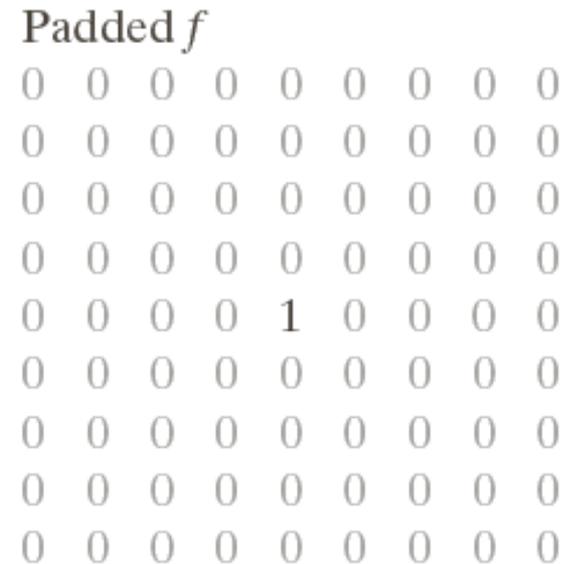
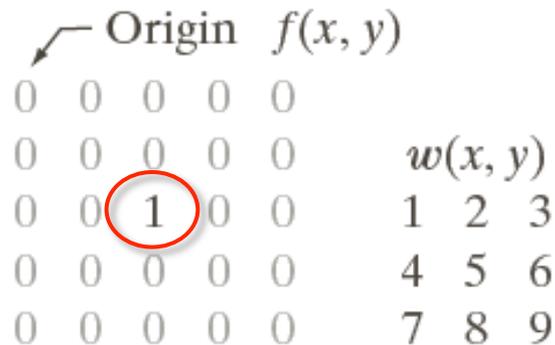
Dirac-Impuls  
= Einheitsimpuls  
= unit impulse

	Origin ↙	$f(x, y)$			
0	0	0	0	0	
0	0	0	0	0	$w(x, y)$
0	0	1	0	0	1 2 3
0	0	0	0	0	4 5 6
0	0	0	0	0	7 8 9

= Punktverteilungsfunktion  
= Point Spread Function (PSF)

# Konvolution des Dirac-Impulses

Dirac-Impuls  
= Einheitsimpuls  
= unit impulse



Punktantwort  
= Punktverteilungs-  
funktion  
= Point Spread Func-  
tion (PSF)

Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

# Punktantwort (Point Spread Function, PSF)

- Faltung eines einzelnen Dirac-Impulses
  - Bild mit einem einzigen weißen Pixel
- Abgetastetes Bild =  
Folge von Dirac-Impulsen \* Pixelhelligkeiten
- → Gesamtwirkung durch PSF vollständig beschrieben
- → falls PSF umkehrbar, kann Wirkung rückgängig gemacht werden
- PSF kann manchmal experimentell bestimmt werden

# Punktantwort (Point Spread Function, PSF)

- Alternative Repräsentation eines linearen Operators

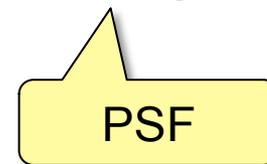
$$g(\alpha, \beta) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot h(x, \alpha, y, \beta)$$

- Einheitsimpuls an Pixel (a,b)

$$\delta(x - a, y - b) = \begin{cases} 1 & x = a \wedge y = b \\ 0 & \text{sonst} \end{cases}$$

- Punktantwort

$$g(\alpha, \beta) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \delta(x - a, y - b) \cdot h(x, \alpha, y, \beta) = h(a, \alpha, b, \beta)$$



# Dekomposition eines Bildes in Pixel

- Digitales Bild als Summe seiner Pixel

$$f(x, y) = \sum_{a=0}^{N-1} \sum_{b=0}^{M-1} f(a, b) \cdot \delta(x - a, y - b)$$

- Das Resultat einer linearen Filterung ist die Überlagerung der Punktantworten

$$g(\alpha, \beta) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot h(x, \alpha, y, \beta)$$

$$= \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} \sum_{a=0}^{N-1} \sum_{b=0}^{M-1} f(a, b) \cdot \delta(x - a, y - b) \cdot h(x, \alpha, y, \beta)$$

# Separierbarkeit linearer Filter

- Ein zweidimensionales Filter ist separierbar, falls Punktantwort durch Hintereinanderausführung zweier eindimensionaler Impulsantworten darstellbar
- Strategie: zerlege 2D Filter in einen x- und y-Kern die hintereinander angewandt werden
- Separierbarkeit in  $h_x$  und  $h_y$ :

$$g(\alpha, \beta) = \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot h(x, \alpha, y, \beta)$$

$$= \sum_{x=0}^{N-1} \sum_{y=0}^{M-1} f(x, y) \cdot h_x(x, \alpha) \cdot h_y(y, \beta)$$

# Separierbarkeit linearer Filter

- Verarbeitung zeilenweise

$$g(\alpha, \beta) = \sum_{y=0}^{M-1} h_y(y, \beta) \sum_{x=0}^{N-1} f(x, y) \cdot h_x(x, \alpha)$$

- Verarbeitung spaltenweise

$$g(\alpha, \beta) = \sum_{x=0}^{N-1} h_x(x, \alpha) \sum_{y=0}^{M-1} f(x, y) \cdot h_y(y, \beta)$$

- Reduziert Rechenaufwand von  $O(NM)$  auf  $O(N+M)$

- Beispiel:

$$h = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}, h_x = \frac{1}{3} \begin{pmatrix} 1 & 1 & 1 \end{pmatrix}, h_y = \frac{1}{3} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$$

# Korrelation

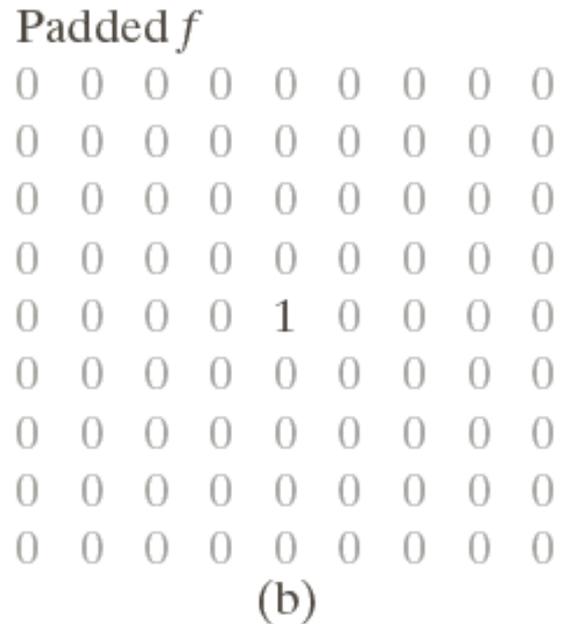
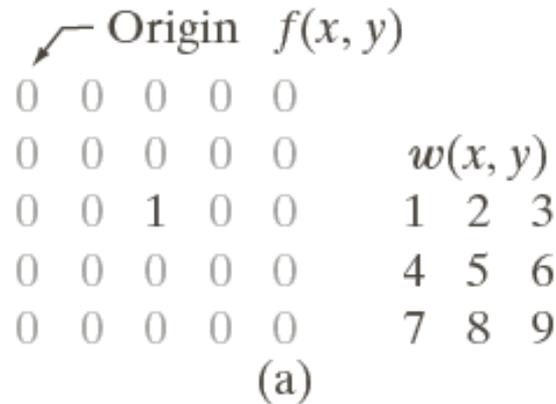
- Seien  $f, g$  abgetastete Bilder mit unendlicher Größe,  $m, n$ , Skalare

$$(g * f)(m, n) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} g(i, j) f(i - m, j - n)$$

Heißt Korrelation der Funktion  $f$  mit  $g$

- $g$  heißt die Korrelationsfunktion
- Funktioniert so nur für unendlich große Bilder → Vereinfachung siehe Konvolution

# Korrelation



Kern nicht gedreht, sonst wie bei Konvolution

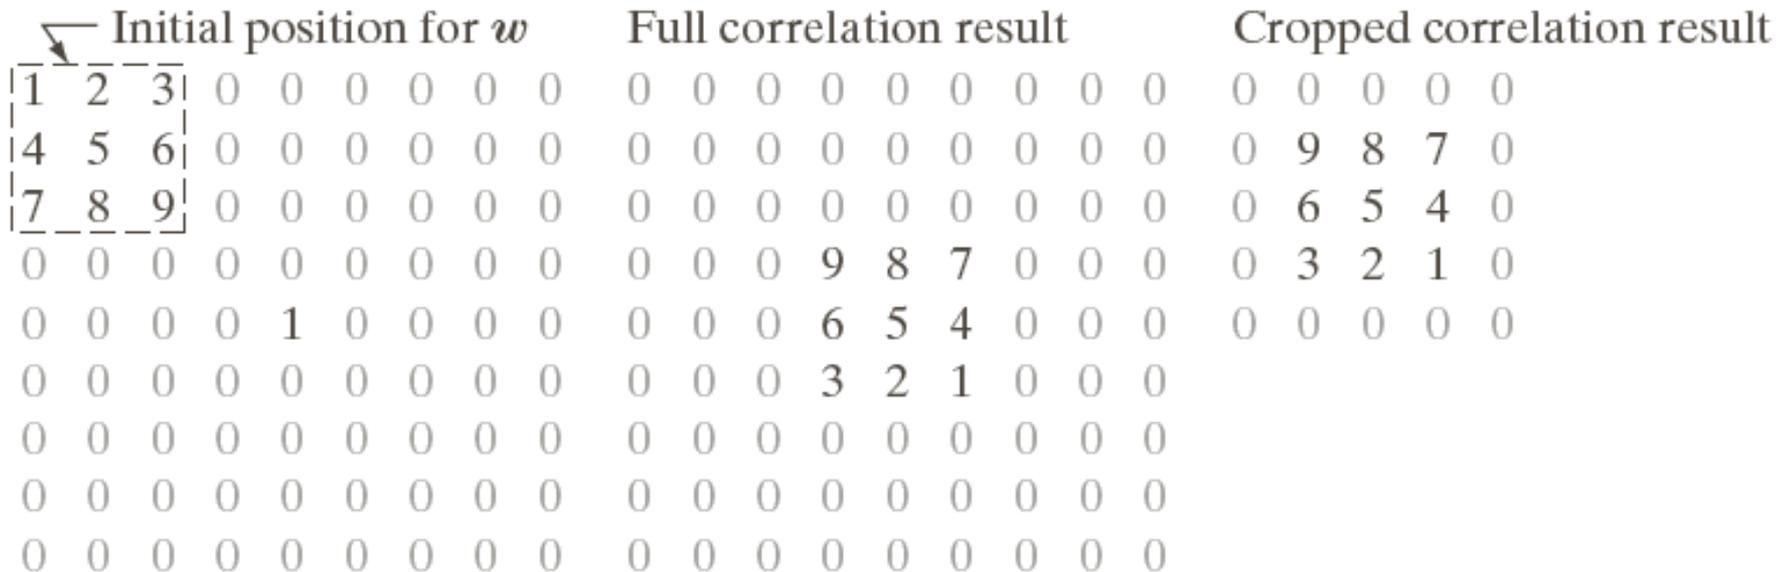
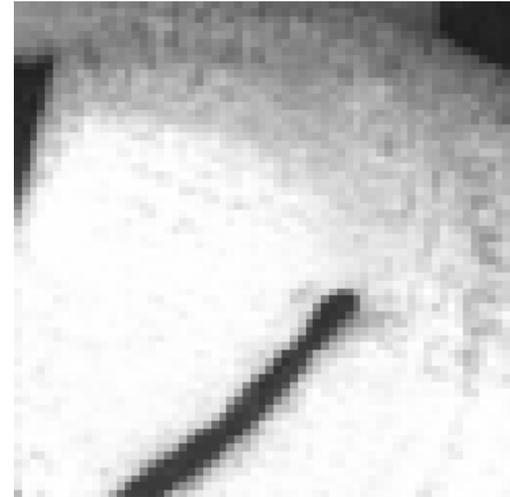


Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

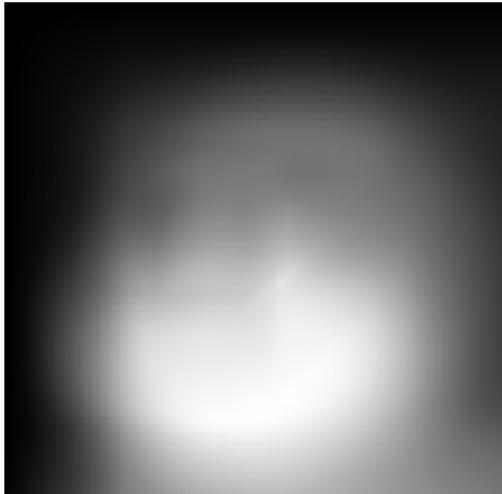
# Verwendung der Korrelation



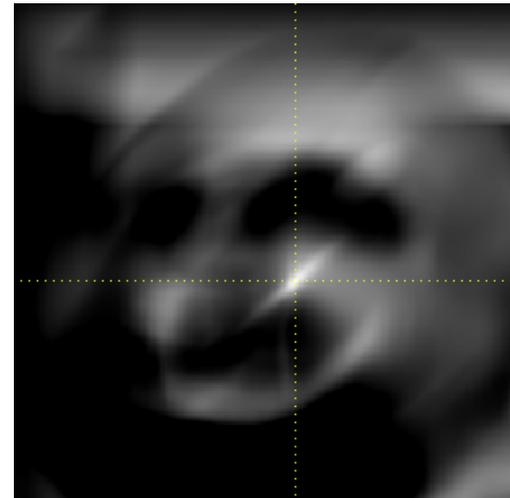
Ausgangsbild (f)



Korrelationsfunktion (g)



Ergebnis (g\*f)



...normalisiert

# Unterschiede Konvolution / Korrelation

- Konvolution und Korrelation sind zwei eng verwandte Filter-Operationen
- Gleich, falls der Kern von  $g$  symmetrisch unter  $180^\circ$  Rotation
- Beispiele:

$1/9$	$1/9$	$1/9$
$1/9$	$1/9$	$1/9$
$1/9$	$1/9$	$1/9$

Tiefpass

-1	-1	-1
-1	9	-1
-1	-1	-1

Hochpass

# Tiefpass: Wirkung



$$* \begin{array}{|c|c|c|} \hline 1/9 & 1/9 & 1/9 \\ \hline 1/9 & 1/9 & 1/9 \\ \hline 1/9 & 1/9 & 1/9 \\ \hline \end{array} =$$



Nützlich z.B. gegen Rauschen und Alias-Effekte

# Hochpass: Wirkung



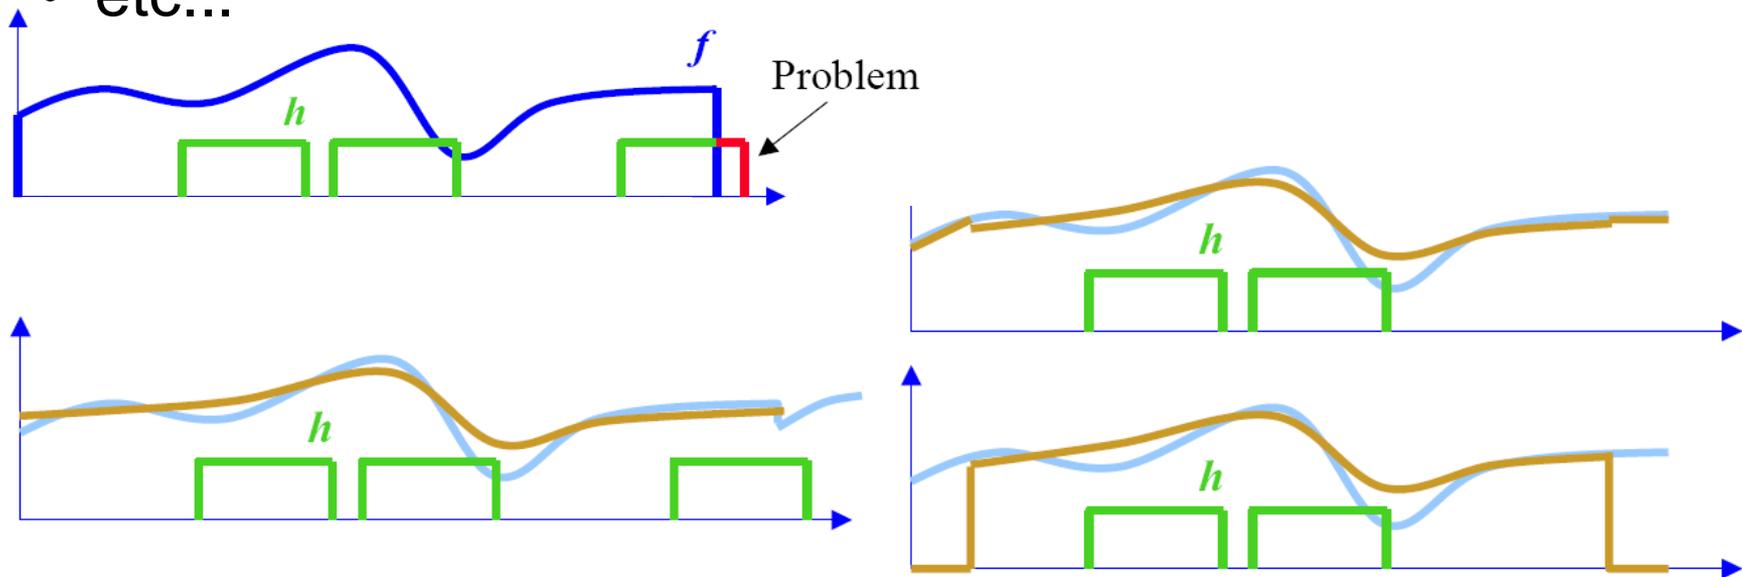
$$* \begin{array}{|c|c|c|} \hline -1 & -1 & -1 \\ \hline -1 & 9 & -1 \\ \hline -1 & -1 & -1 \\ \hline \end{array} =$$



Nützlich zum Scharfzeichnen und Kanten finden

# Konvolution am Bildrand

- Lösung 1: periodische Fortsetzung des Bildes
- Lösung 2: Spiegeln am Rand
- Lösung 3: Rand konstant fortsetzen
- Lösung 4: Werte außerhalb des Bildes auf 0 setzen
- etc...



# Konvolution am Bildrand



\*



# Flächenbasierte Bildverbesserung

- Rauschen kann durch Integration einer Signalfolge mit (nahezu) konstantem Signal reduziert werden
- Konstante Signalfolge
  - Integration über eine zeitliche Folge
  - Integration über eine homogene Fläche
- Lineare verschiebungsinvariante Operatoren
  - Konvolutionsmethoden

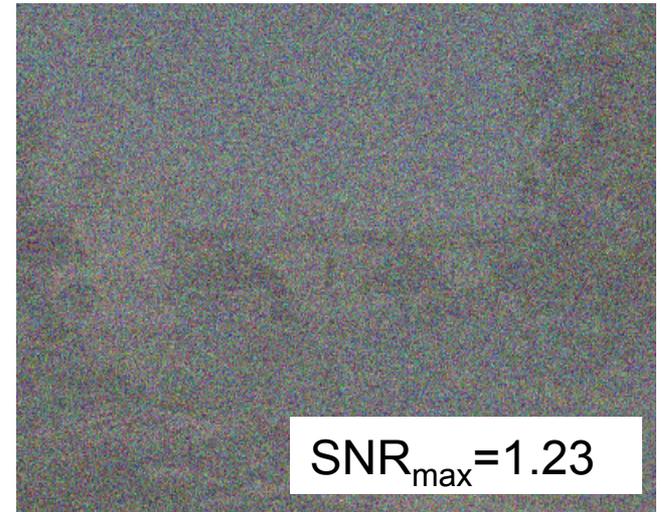
# Zeitliche Folge

- Annahmen
  - Aufnahme mehrerer Bilder  $g_i, i=1, l$  über einen gegebenen Zeitraum
  - Bild verändert sich über den Zeitraum nicht (keine Bewegung, keine Beleuchtungsänderung)
  - Erwartungswert  $E$  des Rauschens  $n$  ist 0
- Näherung an die unverrauschte Funktion  $f$ 
  - $$E\{g(m,n)\} = E\{f(m,n)\} + E\{n(m,n)\}$$
$$= E\{f(m,n)\} + 0 = f(m,n)$$
  - Abschätzung von  $E\{g(m,n)\}$  durch Integration über die Bilder



# Beispiel

- Einzelne Aufnahme mit normalverteiltem Rauschen ( $\text{SNR} \approx 1.2$ )
- $\text{SNR}_{\max} = \text{max. Signalamplitude} / \text{Standardabweichung des Rauschens}$
- Addition von 10 bzw. 50 Aufnahmen



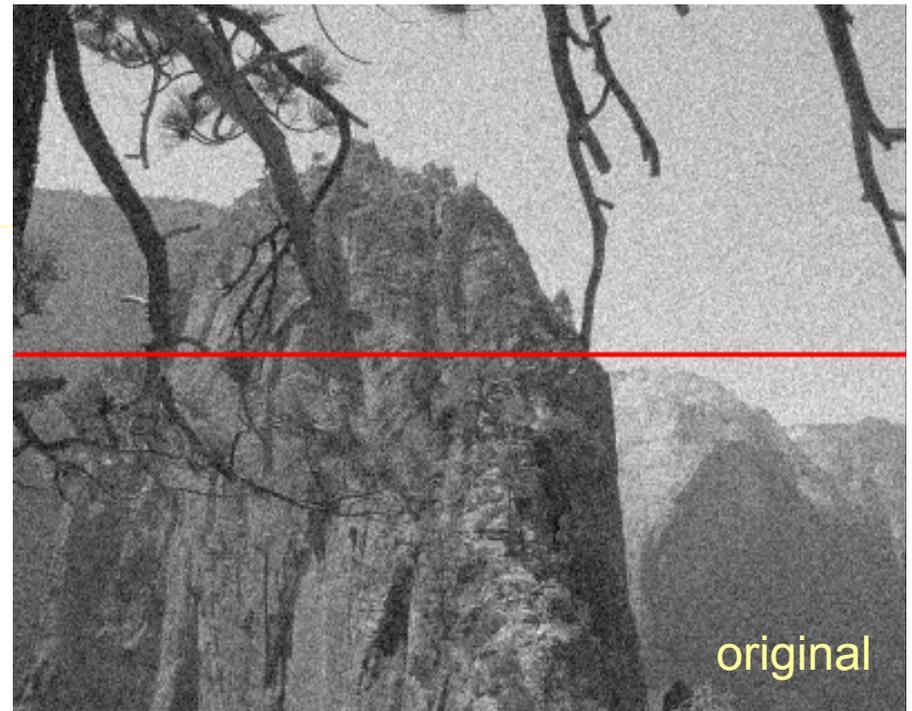
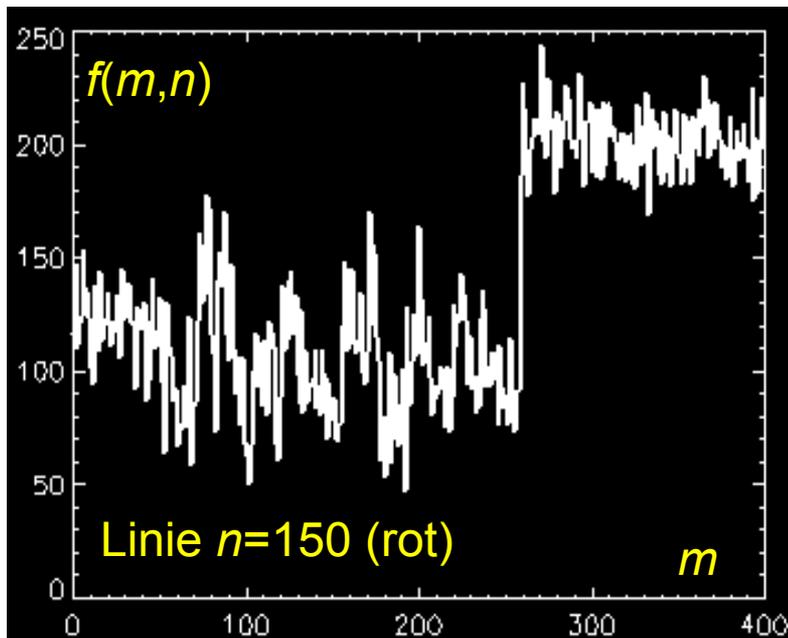
# Integration über die Fläche

- Falls für eine Reihe von Bildpunkten  $(p_0, \dots, p_n)$  gilt, dass  $f(p_i) = \text{const}$ , dann kann Rauschen  $n$  mit  $E\{n\} = 0$  durch Addition der gemessenen Funktionswerte  $g(p_i)$  reduziert werden
- Annahmen:
  - Bild besteht aus homogenen Bereichen
  - Benachbarte Punkte haben den gleichen Grauwert
- Rauschunterdrückung:
  - Mittelwertbildung über vorgegebene Nachbarschaft



# Mittelwertbildung durch Konvolution

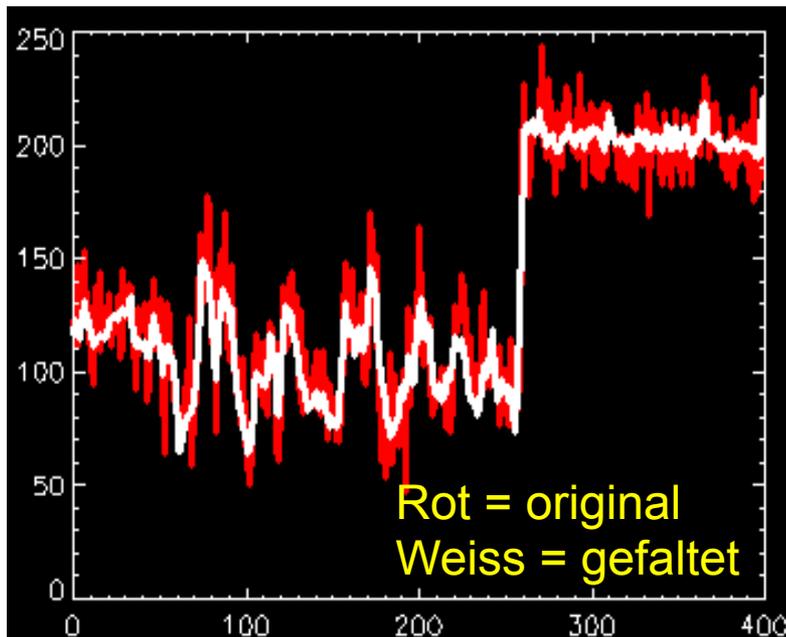
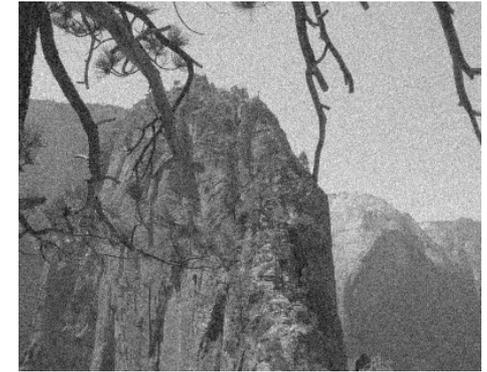
Konvolutionskern: Gleichmäßige Gewichtung der Pixel in einer gegebenen Nachbarschaft



# 3x3 Boxcar-Filter

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

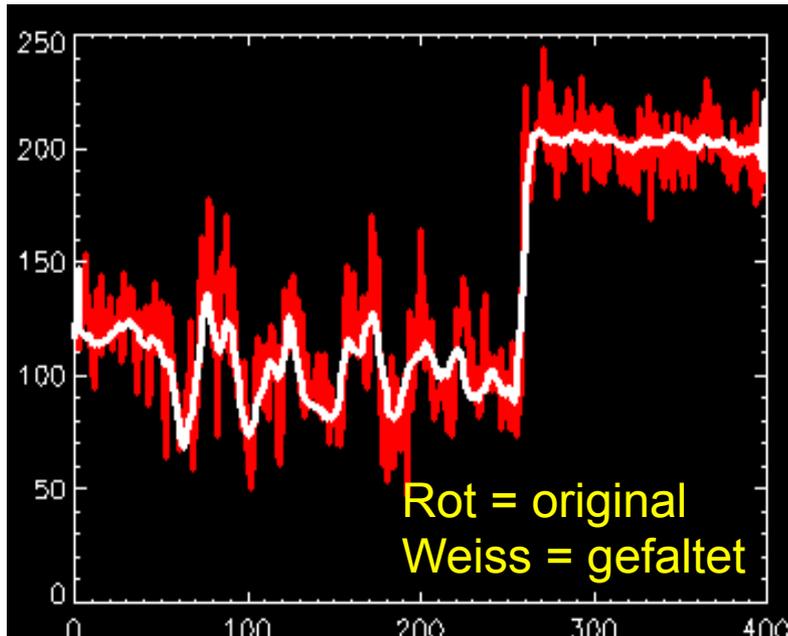
Filterkern



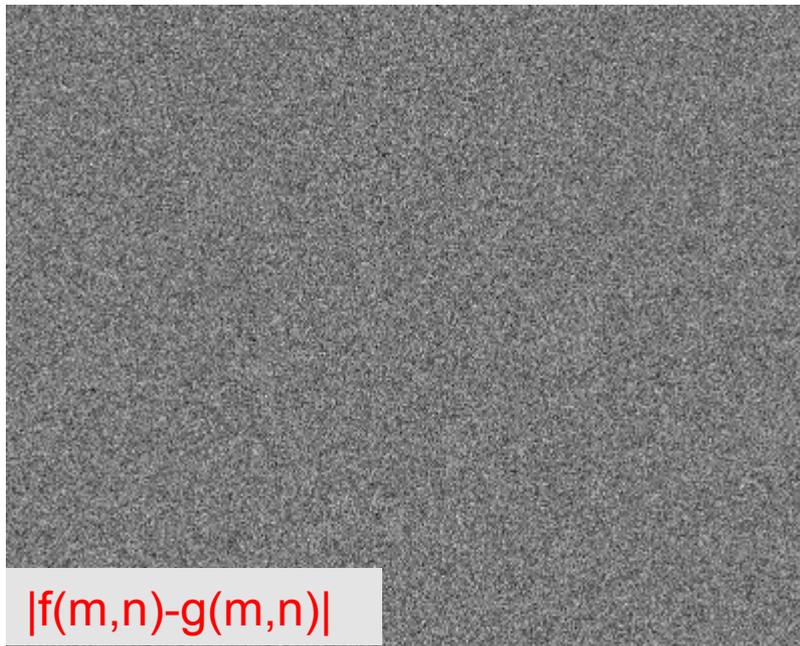
# 7x7 Boxcar-Filter

**Beobachtung:** Kanten werden degradiert

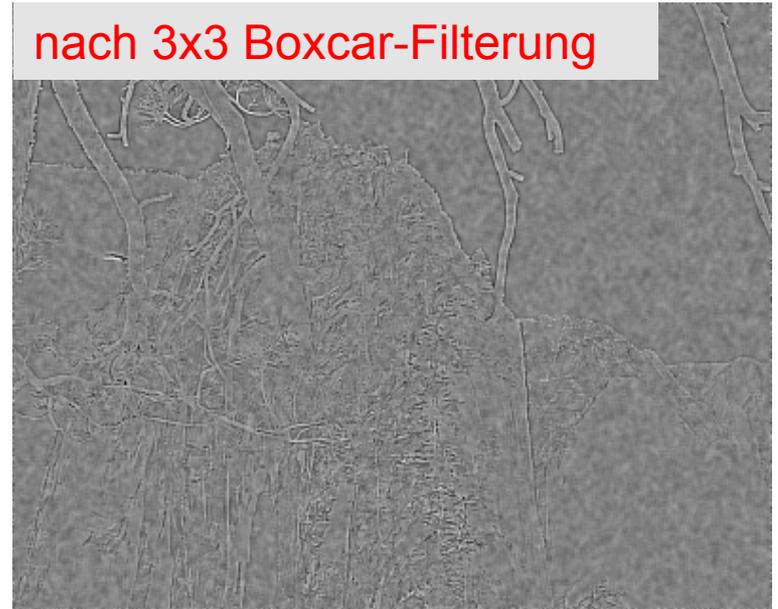
**Grund:** Annahme konstanter Funktionswerte ist nicht wahr



# Verhalten an Kanten



nach 3x3 Boxcar-Filterung



nach 7x7 Boxcar-Filterung



# Tiefpassfilter zur Rauschunterdrückung



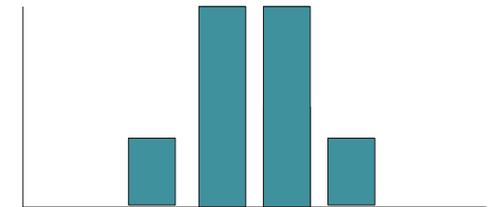
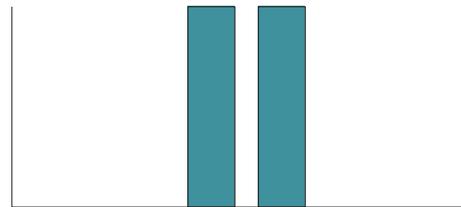
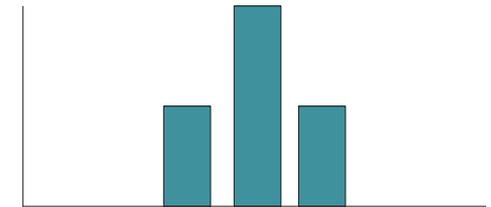
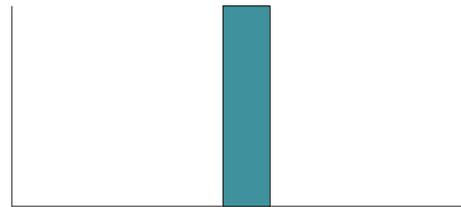
„Ringing Artefakte“



# Binomialfilter

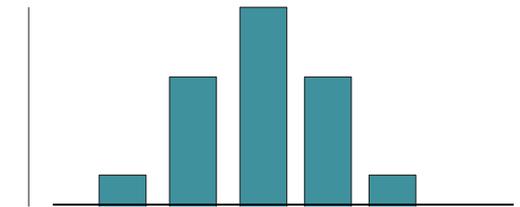
Eindimensionales Binomialfilter  $B^p = [1 \ 1] * [1 \ 1] * \dots * [1 \ 1]$  ( $p$ -mal):

$$\begin{aligned}
 B^0 &= 1^{-1} \cdot [1] \\
 B^1 &= 2^{-1} \cdot [1 \ 1] \\
 B^2 &= 4^{-1} \cdot [1 \ 2 \ 1] \\
 B^3 &= 8^{-1} \cdot [1 \ 3 \ 3 \ 1] \\
 B^4 &= 16^{-1} \cdot [1 \ 4 \ 6 \ 4 \ 1] \\
 &\dots
 \end{aligned}$$



Zweidimensionales Binomialfilter  $\mathbf{B}^p = B^p * (B^p)^T$ :

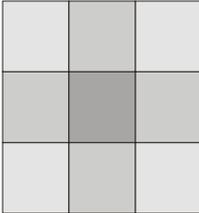
$$\mathbf{B}^2 = 4^{-1} \cdot [1 \ 2 \ 1]^T \cdot 4^{-1} \cdot [1 \ 2 \ 1] = 16^{-1} \cdot \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$



# Zweidimensionale Binomialfilter

$$\mathbf{B}^2 = 1/16 \cdot [1 \ 2 \ 1]^T \cdot [1 \ 2 \ 1] = 1/16 \cdot$$

1	2	1
2	4	2
1	2	1

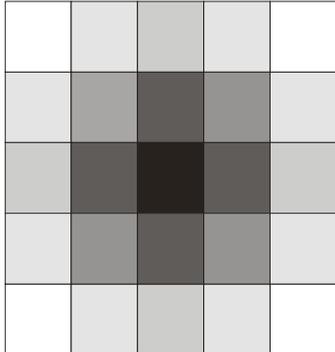


$$\mathbf{B}^3 = 1/64 \cdot [1 \ 3 \ 3 \ 1]^T \cdot [1 \ 3 \ 3 \ 1] = 1/64 \cdot$$

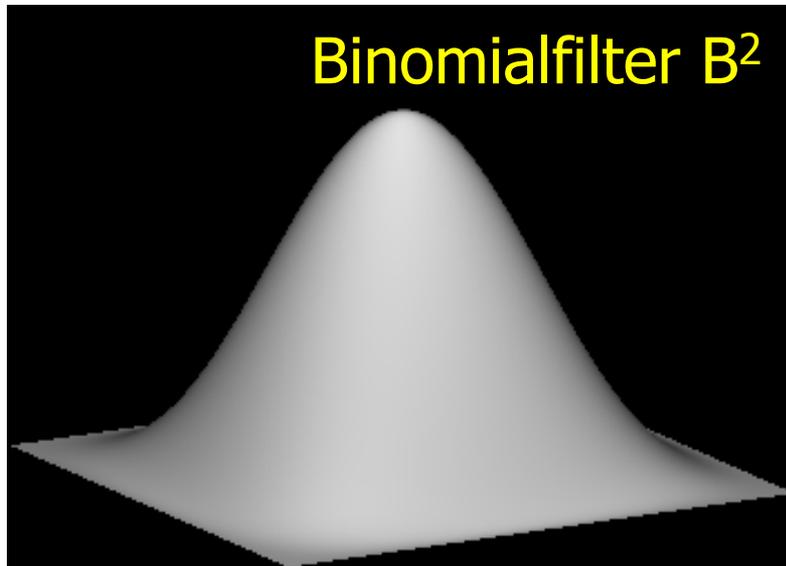
1	3	3	1
3	9	9	3
3	9	9	3
1	3	3	1

$$\mathbf{B}^4 = 1/256 \cdot$$

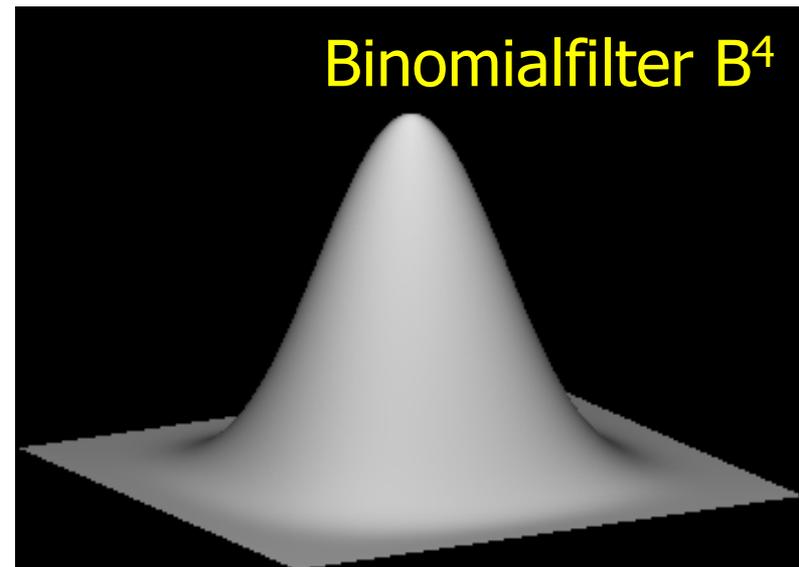
1	4	6	4	1
4	16	24	16	4
6	24	36	24	6
4	16	24	16	4
1	4	6	4	1



# Transferfunktion des Binomialfilters



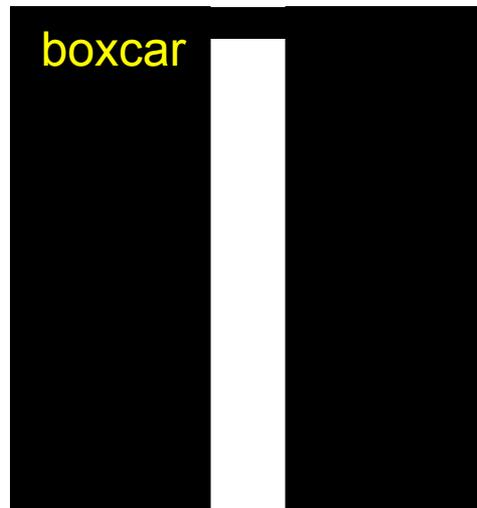
Weniger Artefakte an  
Kanten sind zu erwarten



# Binomialfilter und Gaußfunktion

- Für immer größere Filterkerne nähert sich das Binomialfilter der **Gaußschen Glockenkurve** an

$$G(x, y) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{x^2 + y^2}{2\sigma^2}\right]$$



# Filterung mit 2D Gaußfilter

Die Gaußfunktion ist separierbar, so dass die Filterung durch zwei 1D Konvolutionen erfolgen kann

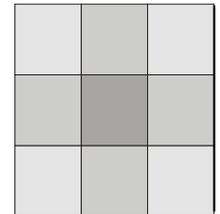


# Separierbarkeit der Gaußfunktion

$$G(x, y) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{x^2 + y^2}{2\sigma^2}\right] = a \exp[-b(x^2 + y^2)]$$

$$= a \exp[-bx^2] \exp[-by^2]$$

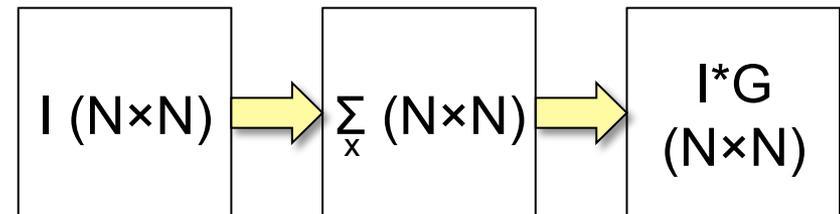
1	2	1
2	4	2
1	2	1



- Konvolution in lokaler Umgebung:

$$\sum_y \sum_x I_{xy} G(x, y) = \sum_y \sum_x I_{xy} a \exp[-bx^2] \exp[-by^2]$$

$$= a \sum_y \exp[-by^2] \sum_x I_{xy} \exp[-bx^2]$$



- Original:  $N^2K^2$  Multiplikationen
- Separiert:  $2N^2K$  Multiplikationen

# Grenzen



Impulsrauschen  
(Salt & Pepper  
Noise) kann durch  
lineare Filterung  
nicht entfernt  
werden



# Nichtlineare Filterung

- Rauschen und Kanten haben im Frequenzbereich ähnliche Attribute
- Ist ein nichtlineares Filter denkbar, das für Rauschen und Kanteneigenschaften unterschiedlich sensitiv ist?
  - Rauschen sind räumlich gleichverteilte Grauwertvariationen
  - Grauwertvariationen an Kanten sind nicht räumlich gleichverteilt
  - Filter muss diesen Unterschied berücksichtigen

# Rangordnungsfilter

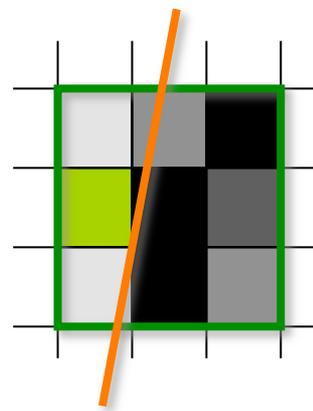
- Vorgehen
  - Sortierung der Elemente in einer Filtermaske
  - Auswahl des an einer bestimmten Stelle einsortierten Werts
  - Eintragung des ausgewählten Werts in die zentrale Position
- Eigenschaften
  - Es entstehen keine neuen Werte
  - Filter ist nichtlinear, nicht kommutativ, nicht assoziativ

Gebräuchlichstes  
Rangordnungsfilter ist das  
Medianfilter

26 3.	132 8.	112 5.
25 2.	102 4.	142 9.
17 1.	122 7.	117 6.

-  erster Rang
-  mittlerer Rang (Median)
-  letzter Rang

# Medianfilter



- Annahmen
  1. Grauwerte auf beiden Seiten der Kante jeweils (nahezu) konstant
  2. Kantensignal größer als das Rauschsignal
  3. Kante im Filterbereich (nahezu) gerade

$k_D$  ( $k_H$ ) = sortierte Folge der Pixelwerte der dunkleren/helleren Seite
- Kante verläuft durch Filterbereich
  - wegen (2) : alle  $k_D$  vor  $k_H$
  - wegen (3): mehr  $k_D$ , falls Zentrum in  $k_D$  (und umgekehrt)
  - also Median von der Seite, zu der Pixel im Zentrum gehört(kantenerhaltend), Artefakte bei Ecken
- Keine Kante im Filterbereich
  - Median nähert sich dem Erwartungswert mit Anzahl der Stichproben (rauschunterdrückend)

# Medianfilter



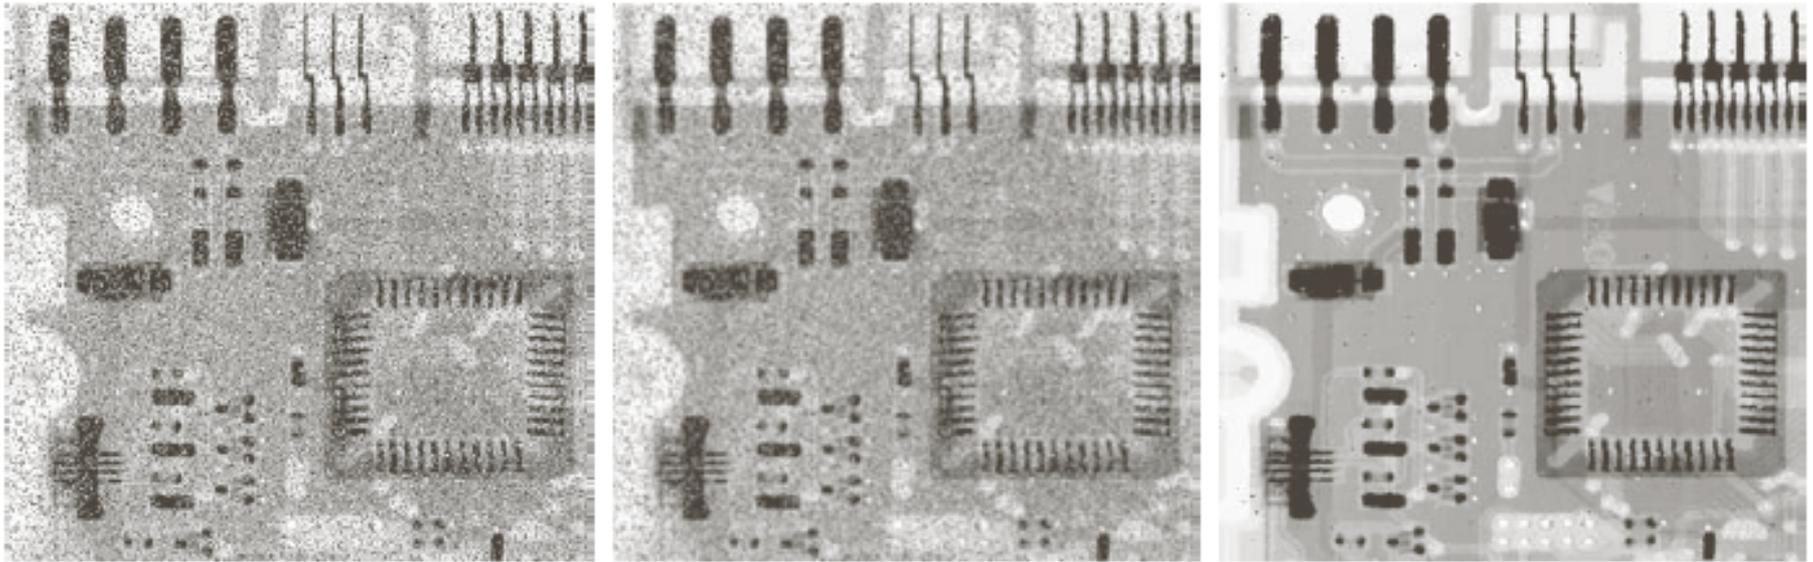
Median zur  
Entfernung von  
Pepper-Noise in  
einer 3x3  
Umgebung

# Medianfilter



- Durch Medianfilterung (rechts) kann Impulsrauschen im Gegensatz zur Mittelwertfilterung (Mitte) beseitigt werden.

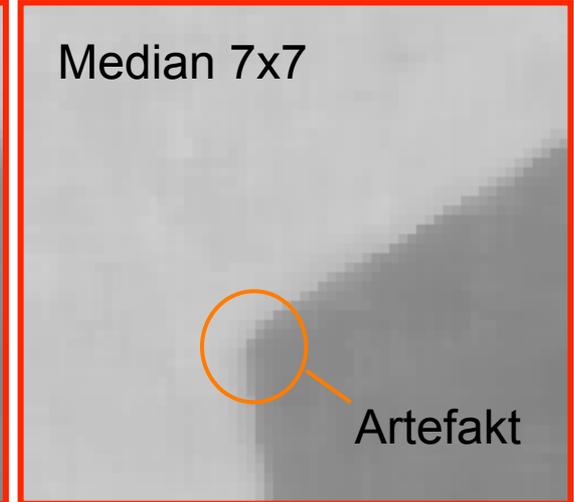
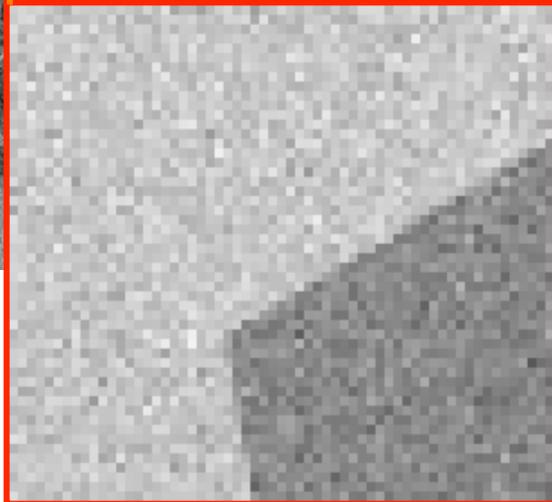
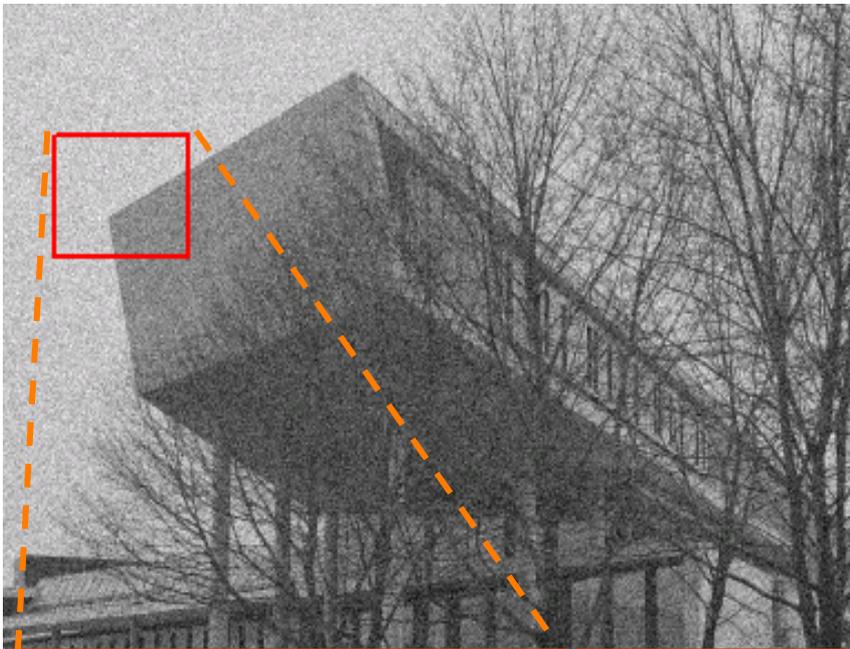
# Medianfilter



a b c

**FIGURE 3.35** (a) X-ray image of circuit board corrupted by salt-and-pepper noise. (b) Noise reduction with a  $3 \times 3$  averaging mask. (c) Noise reduction with a  $3 \times 3$  median filter. (Original image courtesy of Mr. Joseph E. Pascente, Lixi, Inc.)

# Vergleich Median vs. Mittelwert



# Adaptives Medianfilter

- Kann mit dichterem Impulsrauschen umgehen
- Verschont Zwischenpunkte
- Parameter

Variable (quadratische) Größe  $S_{xy}$

$z_{\min}$  = minimaler Grauwert in  $S_{xy}$

$z_{\max}$  = maximaler Grauwert in  $S_{xy}$

$z_{\text{med}}$  = median Grauwert in  $S_{xy}$

$z_{xy}$  = Grauwert an  $(x,y)$

$S_{\max}$  = Maximalgröße von  $S_{xy}$

$S$  = aktuelle Größe von  $S_{xy}$

$a = 0..1$ ,  $b = 0..5$

$z_{\text{med}} = 0$

**while**  $S \leq S_{\max}$ :

$z_{\min}, z_{\text{med}}, z_{\max}, z_{xy} =$

`medFilter(img, x, y, S)`

**if**  $z_{\min} + a < z_{\text{med}} < z_{\max} - a$ :

**if**  $z_{\min} + b < z_{xy} < z_{\max} - b$ :

**return**  $z_{xy}$

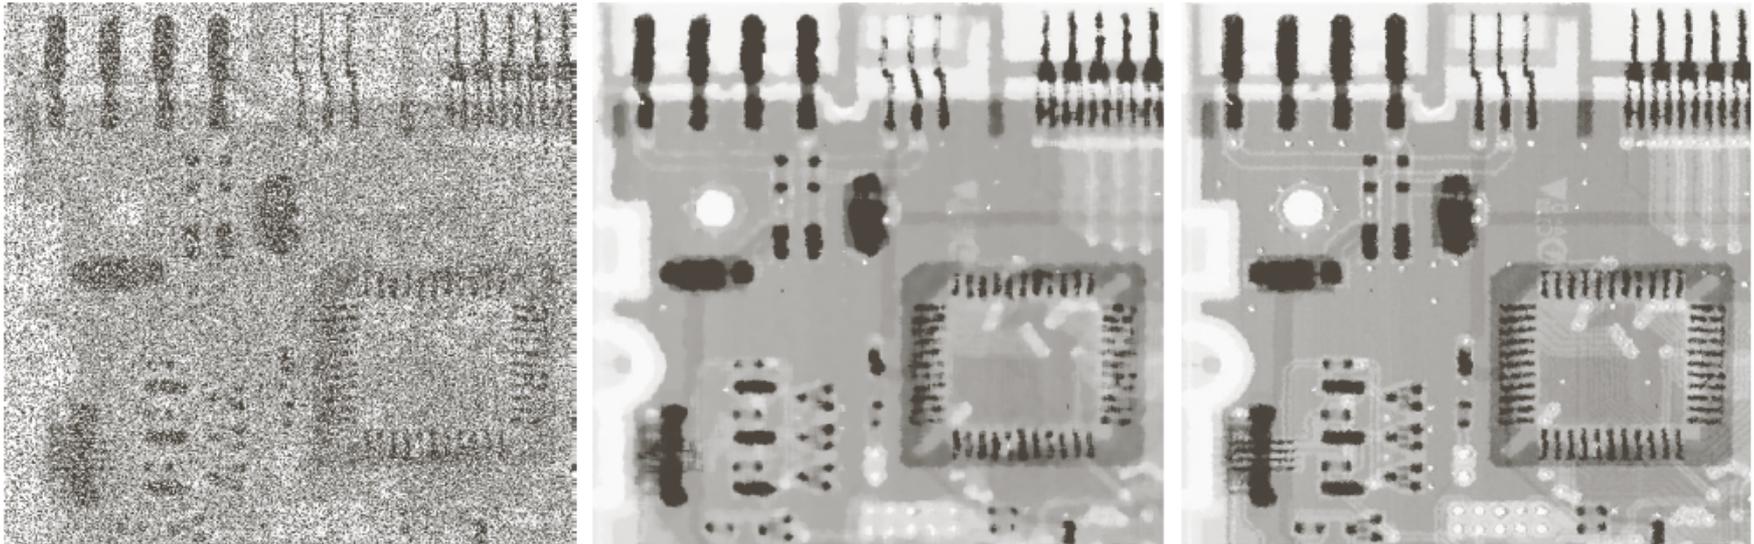
**else**:

**return**  $z_{\text{med}}$

$S = S + 1$

**return**  $z_{\text{med}}$

# Adaptives Medianfilter

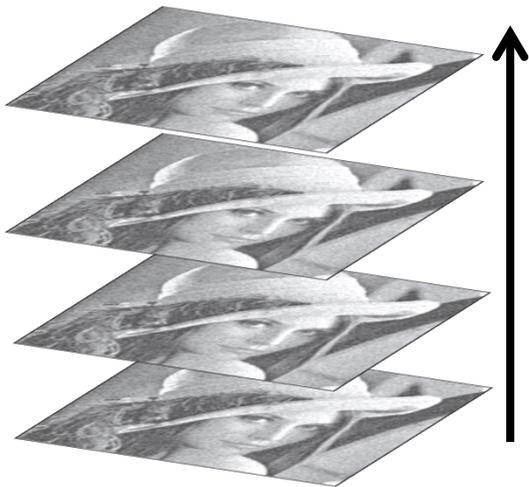


a b c

**FIGURE 5.14** (a) Image corrupted by salt-and-pepper noise with probabilities  $P_a = P_b = 0.25$ . (b) Result of filtering with a  $7 \times 7$  median filter. (c) Result of adaptive median filtering with  $S_{\max} = 7$ .

# Nicht-lokale Mittelwertbildung

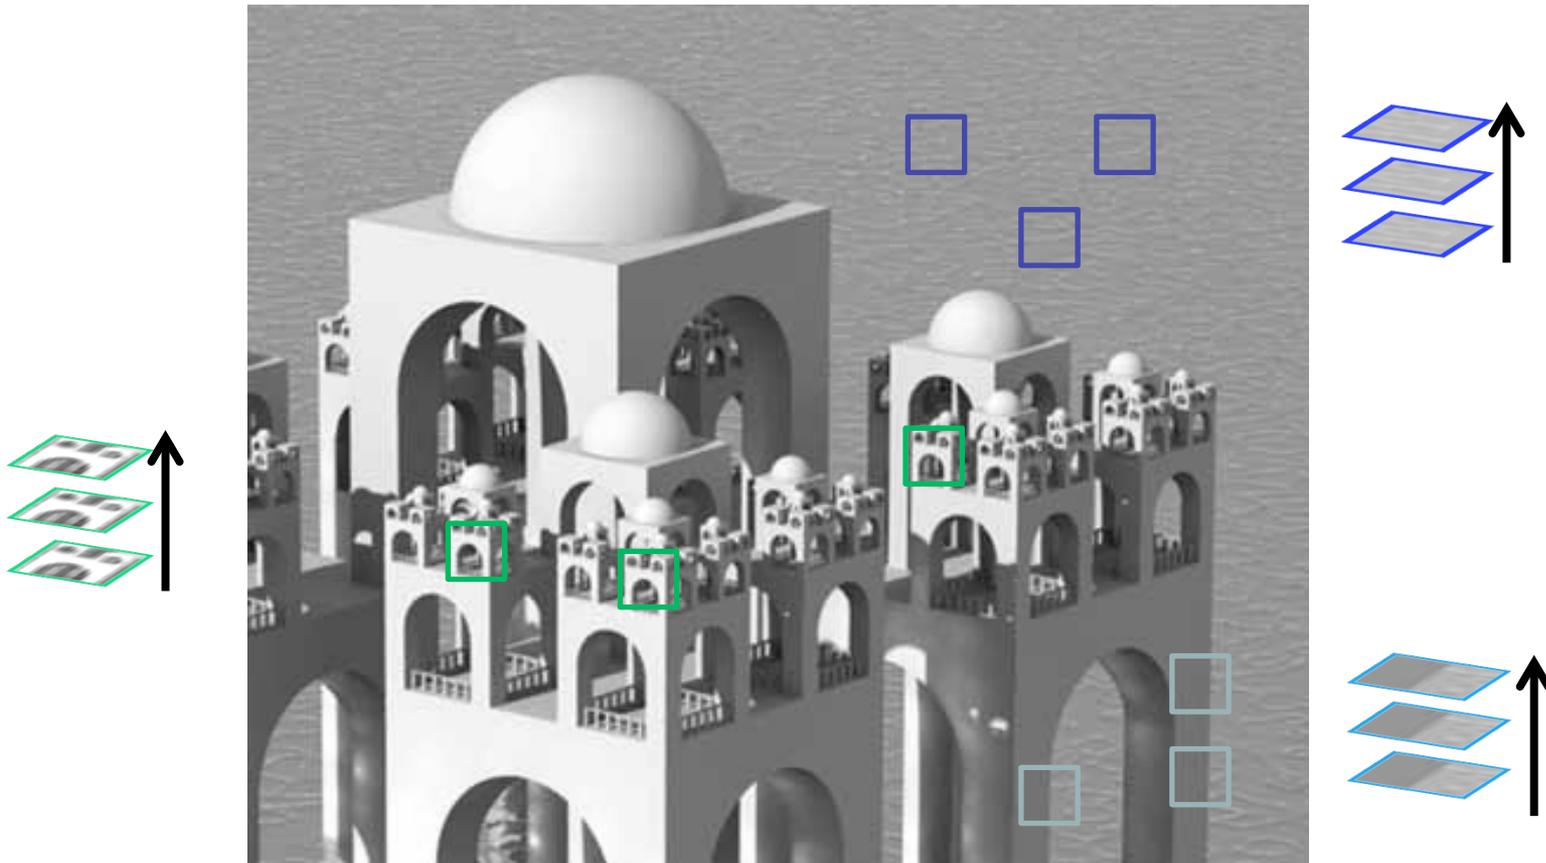
- Mehrere verrauschte Bilder einer statischen Szene
- Rauschen hat Mittelwert 0
- Mittelwert bilden



Figures from: Shahar Kovalsky, Alon Faktor: A Tour of Image Denoising, Slides

# Nicht-lokale Mittelwertbildung

- Redundanz in natürlichen Bildern ausnutzen



Figures from: Shahar Kovalsky, Alon Faktor: A Tour of Image Denoising, Slides

# Buades, Coll, Morel: Gewichteter Mittelwert durch Selbst-Ähnlichkeit

- Verrauschtes Bild:

$$v = \{v(i) \mid i \in I\}, \quad v(i) = u(i) + n(i)$$

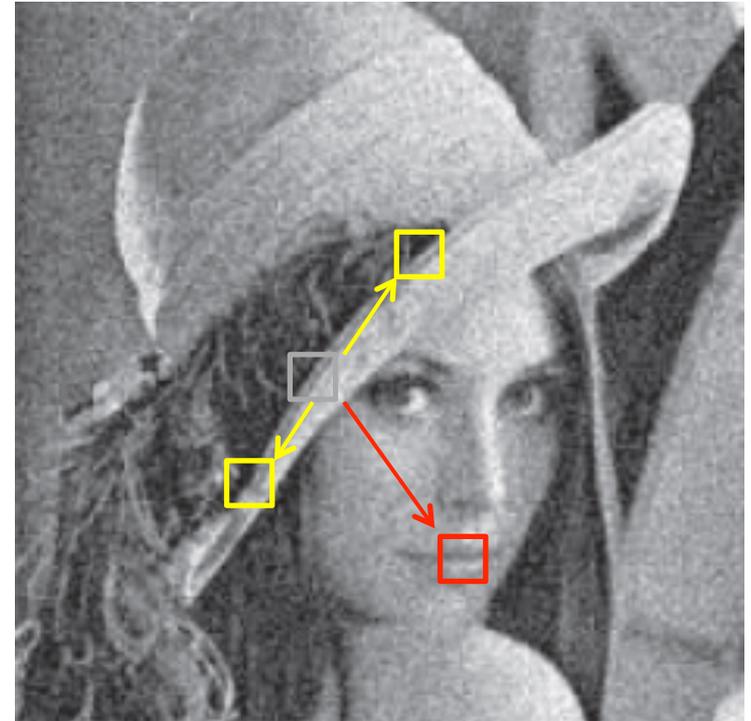
- Nicht-lokaler Mittelwert:

$$NL[v](i) = \sum_{j \in I} w(i, j) v(j)$$

- Gewichtsfunktion

$$w(i, j) = \frac{1}{Z(i)} \exp\left(-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}\right)$$

$$Z(i) = \sum_j \exp\left(-\frac{\|v(N_i) - v(N_j)\|_{2,a}^2}{h^2}\right)$$



Figures from: Shahar Kovalsky, Alon Faktor:  
A Tour of Image Denoising, Slides

# KANTENMERKMALE DURCH LINEARE FILTERUNG

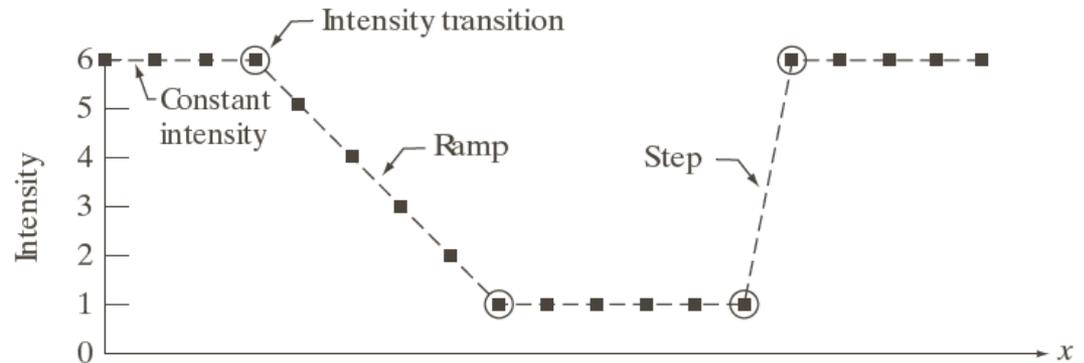
# Erste und zweite Ableitung von Bildern

- Erste Ableitung:

$$\frac{\partial f}{\partial x} = f(x+1) - f(x)$$

- Zweite Ableitung:

$$\begin{aligned} \frac{\partial^2 f}{\partial^2 x} &= (f(x+1) - f(x)) \\ &\quad - (f(x) - f(x-1)) \\ &= f(x+1) + f(x-1) - 2f(x) \end{aligned}$$



Scan line	6	6	6	6	5	4	3	2	1	1	1	1	1	1	6	6	6	6	6
1st derivative	0	0	-1	-1	-1	-1	-1	0	0	0	0	0	0	5	0	0	0	0	0
2nd derivative	0	0	-1	0	0	0	0	1	0	0	0	0	0	5	-5	0	0	0	0

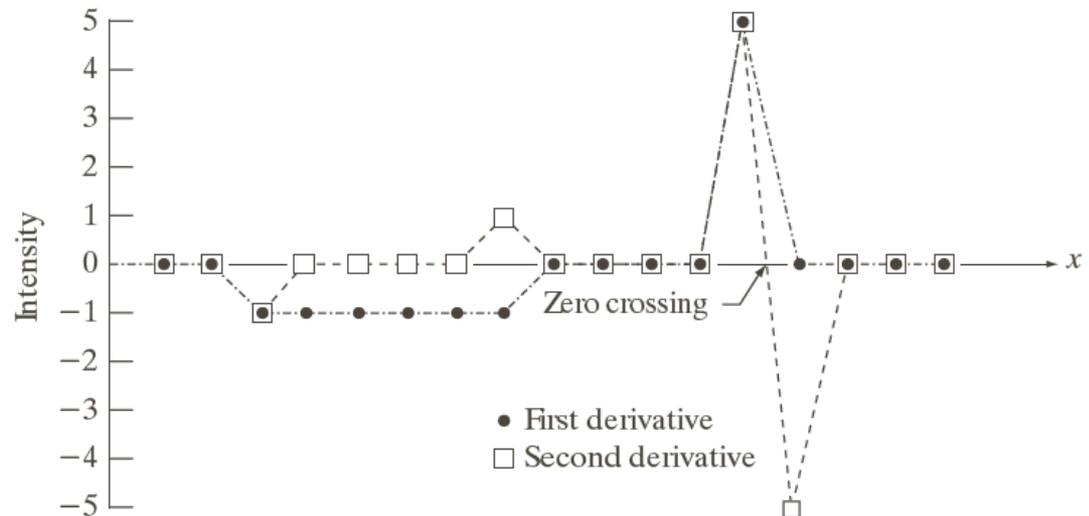
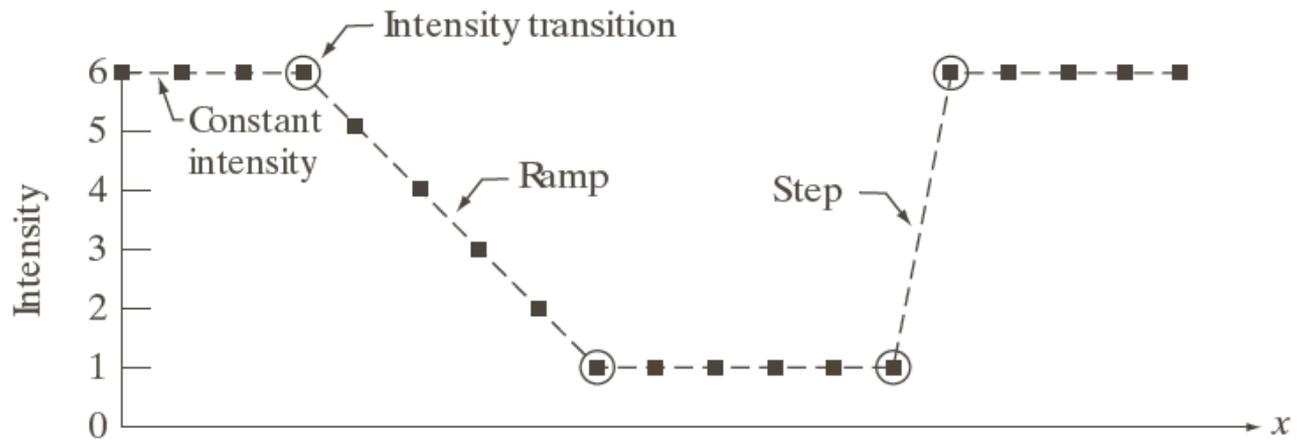


Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing



Scan line	6	6	6	6	5	4	3	2	1	1	1	1	1	1	6	6	6	6	6
1st derivative	0	0	-1	-1	-1	-1	-1	0	0	0	0	0	0	5	0	0	0	0	0
2nd derivative	0	0	-1	0	0	0	0	1	0	0	0	0	0	5	-5	0	0	0	0

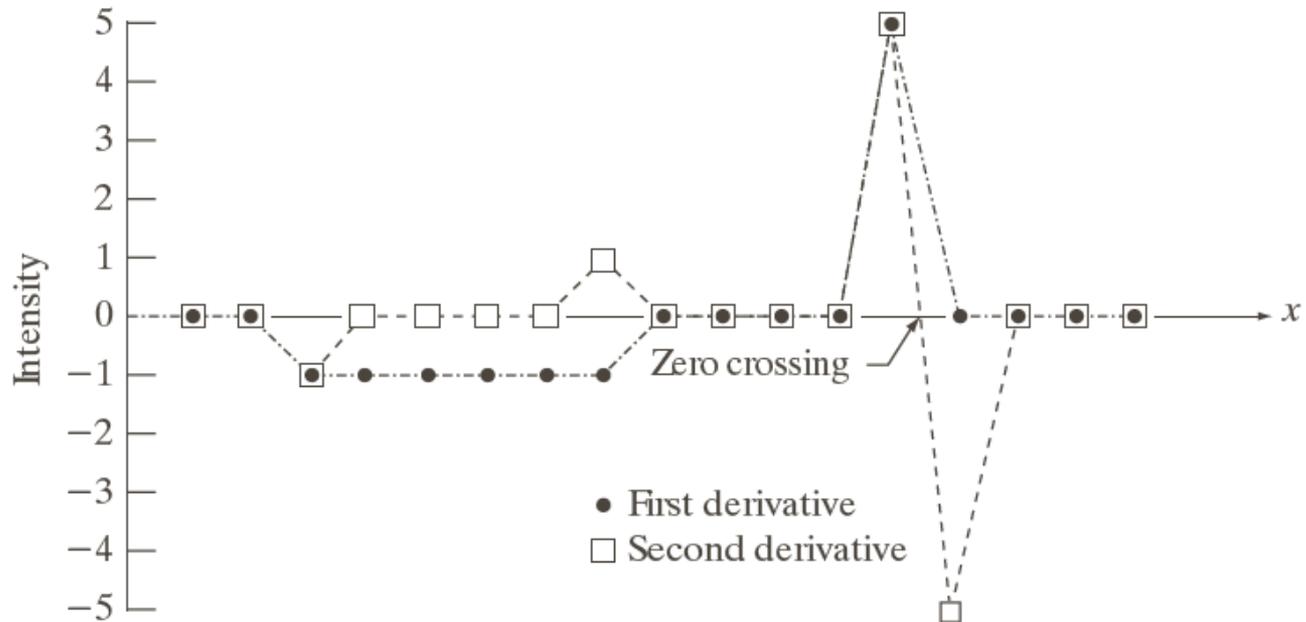


Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

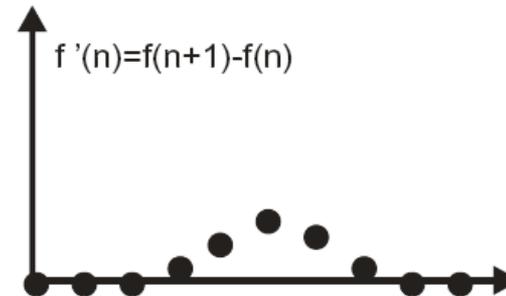
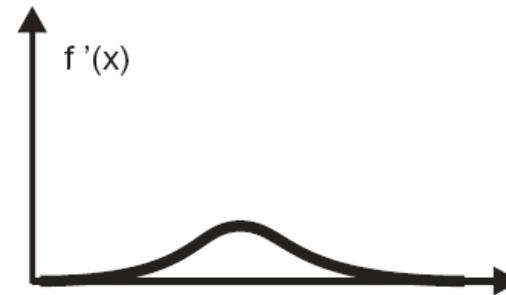
# Kanten

Die meisten Bilder weisen wenige Linien oder Punkte auf, aber Kanten können in fast jedem Bild gefunden werden.

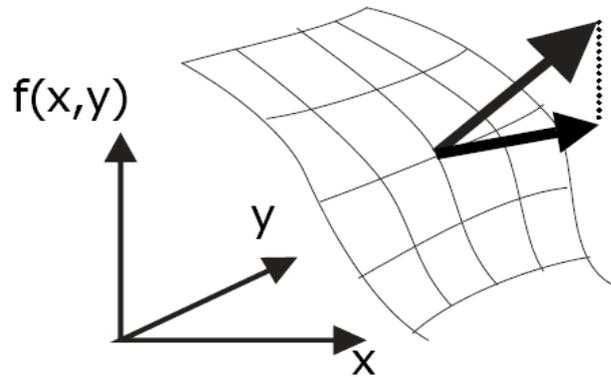


# 1D-Kanten

- Die **Stärke einer Kante** hängt von der Steigung der Funktion ab: Betrag der ersten Ableitung bestimmen
- Für **diskrete Funktionen**: Ableitung wird durch Differenz angenähert



# Kanten im 2D-Raum: Gradienten


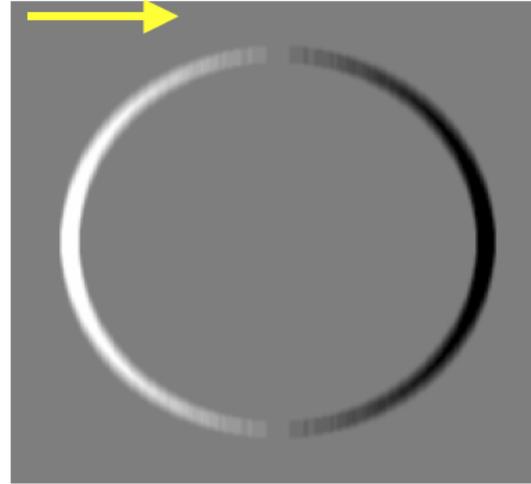


**Richtung:** Richtung der größten Steigung.

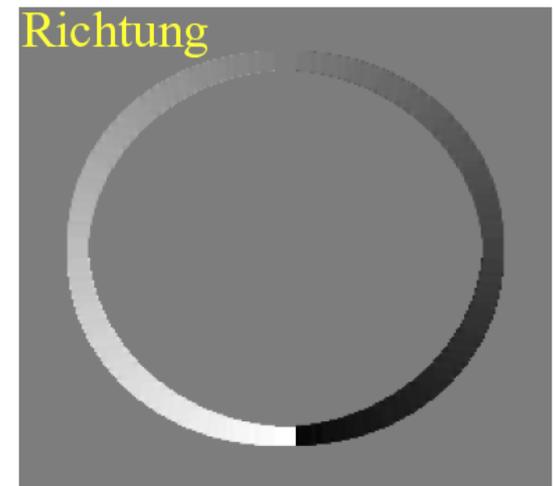
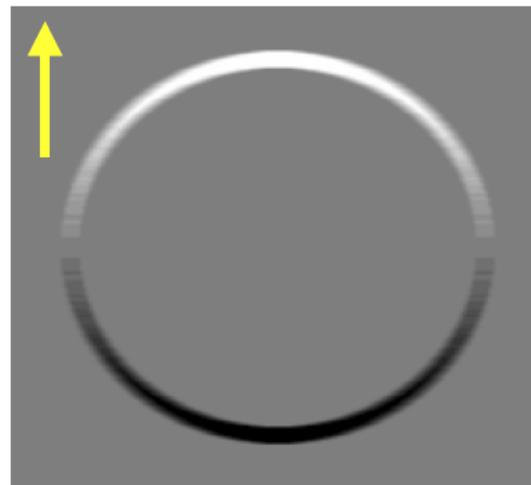
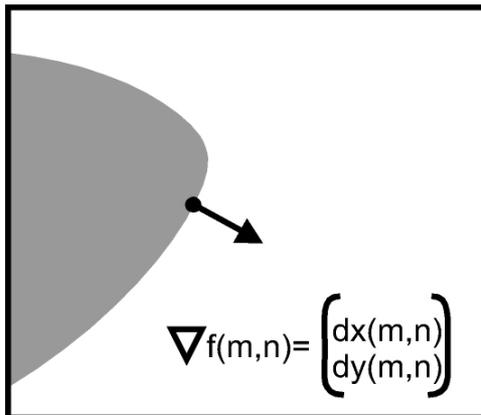
**Länge:** Stärke der stärksten Steigung.

- Gradient im kontinuierlichen Raum  $(x, y)$ : Vektor der partiellen Ableitungen der Bildfunktion in  $x$ - und  $y$ -Richtung:  
 $(f(x, y)) = (\partial f / \partial x \quad \partial f / \partial y)$
- Approximation des Gradienten: Differential wird durch Differenz approximiert:  
 $\vec{G}(f)(m, n) \approx [G_x(m, n) \quad G_y(m, n)] = [f(m, n) - f(m-1, n) \quad f(m, n) - f(m, n-1)]$
- Die Länge des Gradienten ist sein Betrag  $|G(f)|$  oder näherungsweise  $|G_x| + |G_y|$ .

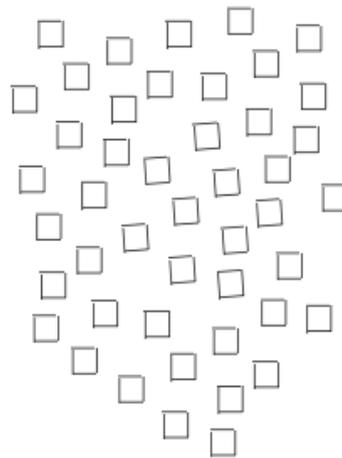
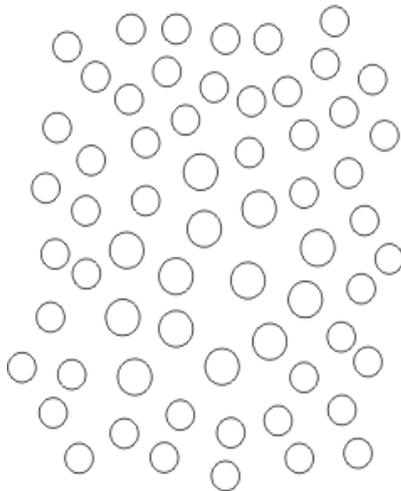
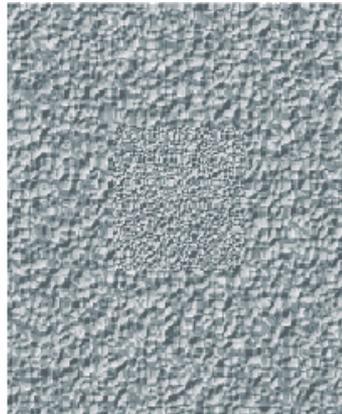
# Elemente des Gradienten



Betrag:  $\sqrt{G_x^2 + G_y^2}$   
Richtung:  $\tan^{-1}(G_y / G_x)$



# Was sind Kanten?



Diskontinuitäten zwischen Regionen.

## Problem:

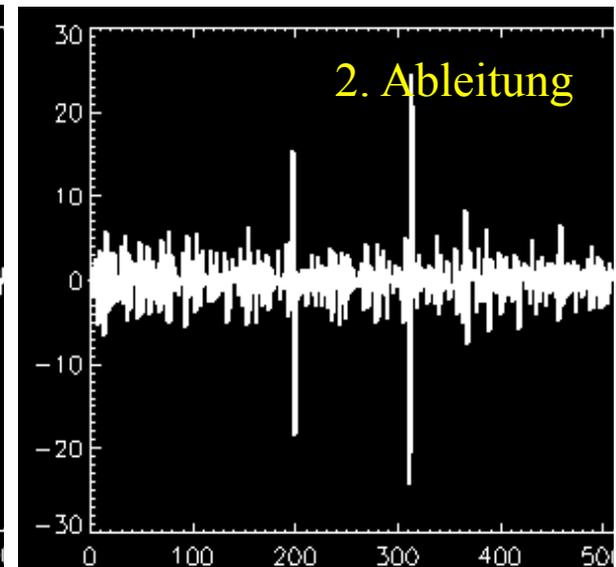
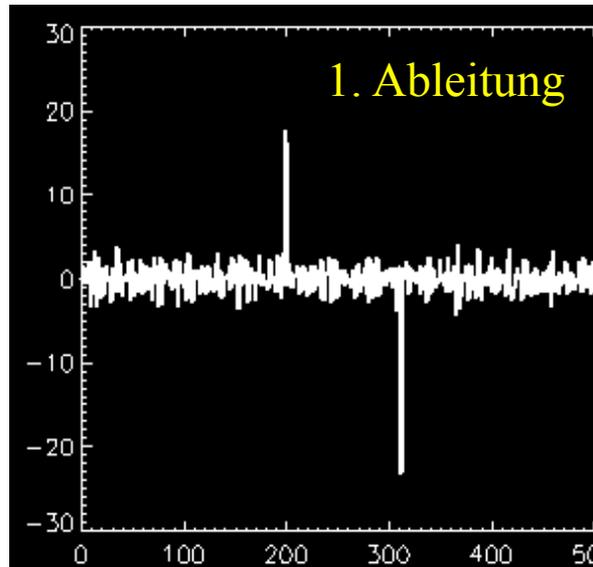
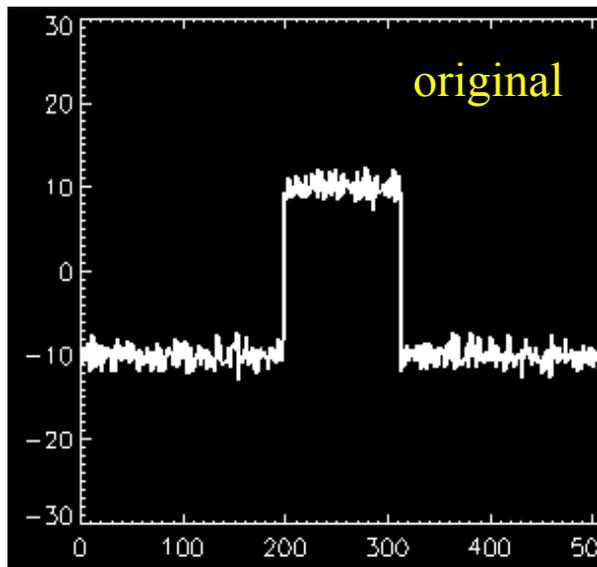
Die Region selbst und damit ihr **Homogenitätskriterium** muss bekannt sein, um Diskontinuität definieren zu können.

## Homogenität einer Funktion:

- Grauwerte
- Textur
- Form

# Kanten im Ortsraum

Kanten und Rauschen haben **ähnliche Charakteristika** im Frequenzraum → Kantendetektor verstärkt Rauschen.

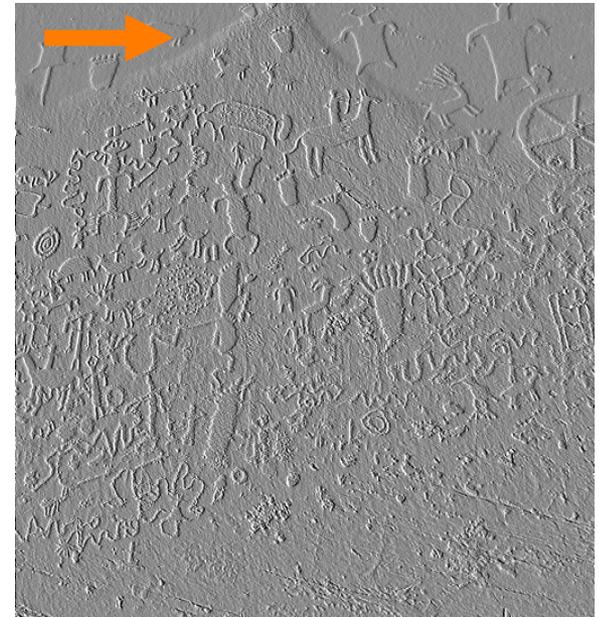
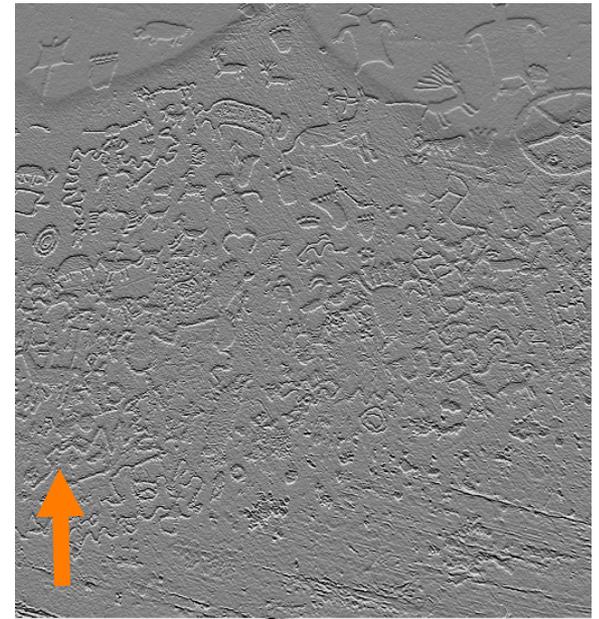


# Kanten im 2-D Raum

Differenzbildung in  $n$ -Richtung



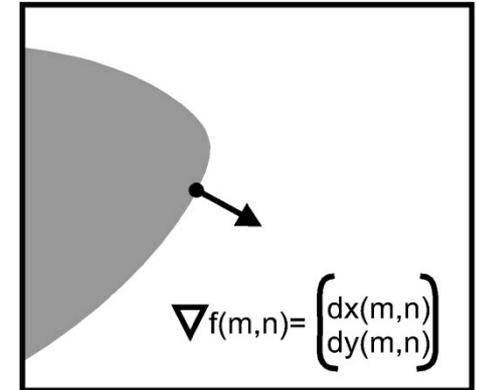
Pseudo-3D  
Eindruck:



Differenzbildung in  $m$ -Richtung

# Gradientenschätzung über Konvolution

- Gradient im  $N$ -dimensionalen Raum ist ein  $N$ -dimensionaler Vektor aus  $N$  partiellen Ableitungen.
- Jede partielle Ableitung kann durch eine Differenz abgeschätzt werden, die durch Konvolution berechnet werden kann.



- Beispiele:

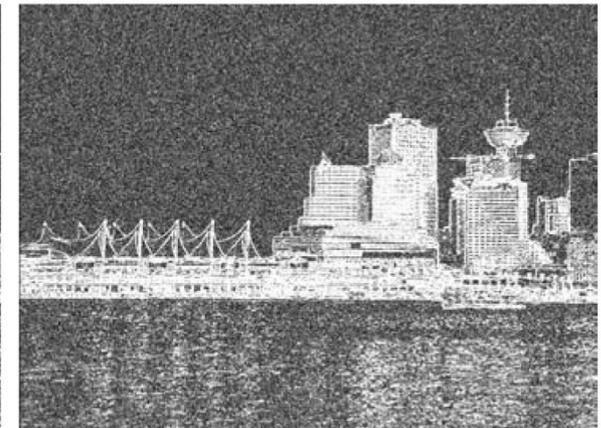

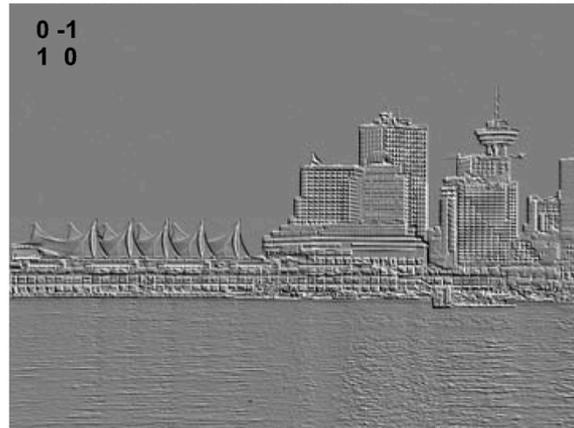
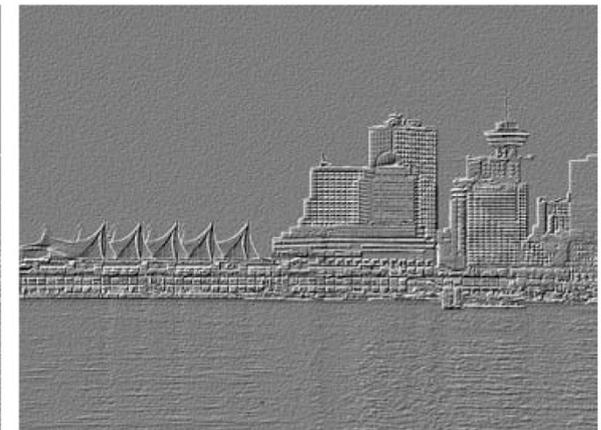
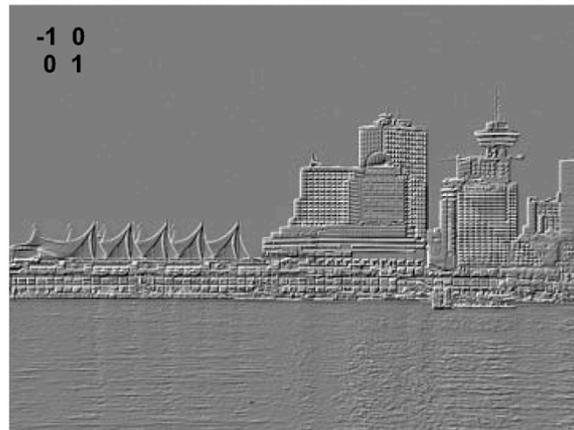
$$\vec{G}(m,n) = \begin{pmatrix} G_x(m,n) \\ G_y(m,n) \end{pmatrix}, \quad G_x(m,n) \approx [f * g_x](m,n), \quad G_y(m,n) \approx [f * g_y](m,n).$$

$$g_x = \begin{bmatrix} -1 & 1 \end{bmatrix} \quad g_y = \begin{bmatrix} -1 \\ 1 \end{bmatrix}, \quad g_{R1} = \begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \quad g_{R2} = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix} \text{ (Robert's Gradient)}$$

$$g_x = \begin{bmatrix} -1 & 0 & 1 \end{bmatrix} \quad g_y = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}$$

# Robert's Gradient

Die beiden Komponenten des Robert's Gradient sowie der Betrag des Gradienten (unten) auf einem rauscharmen (links) und einem verrauschten (rechts) Bild



# Rauschen und Kanten

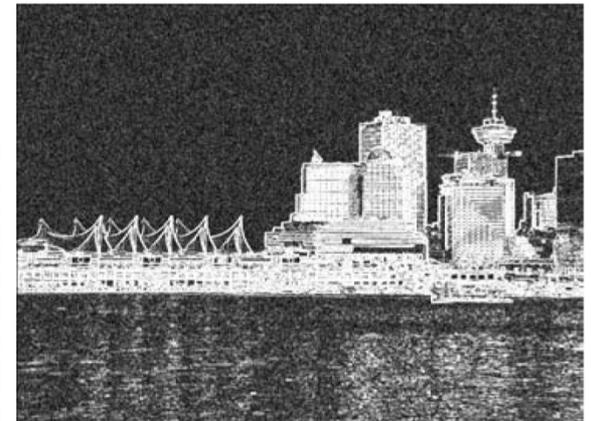
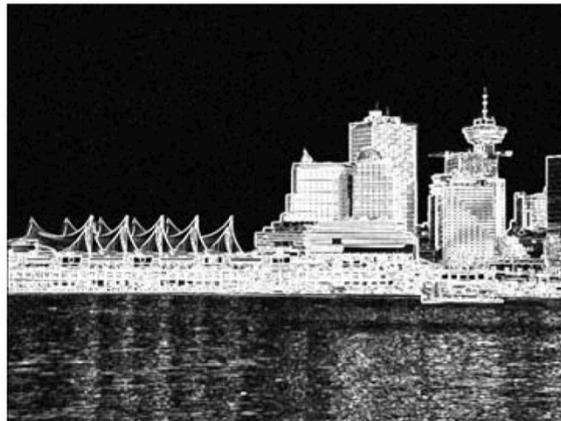
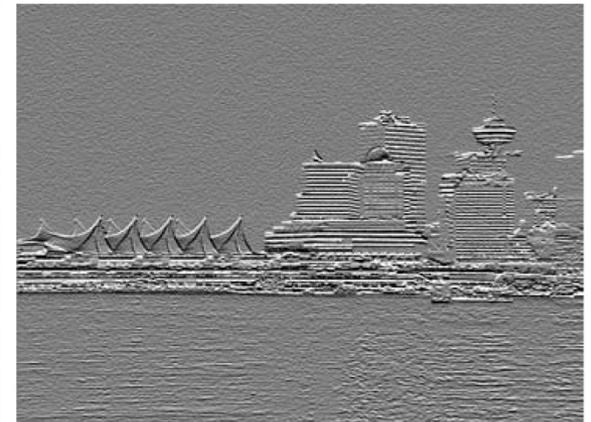
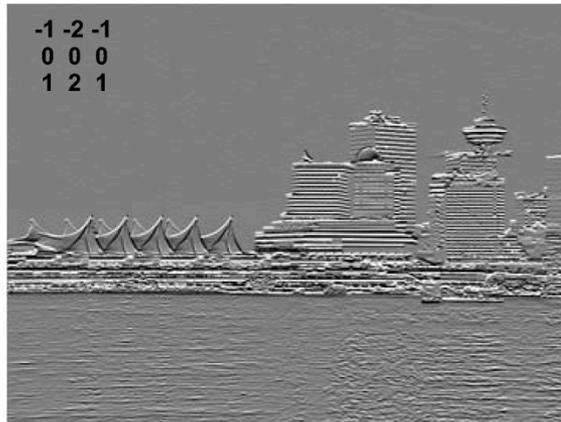
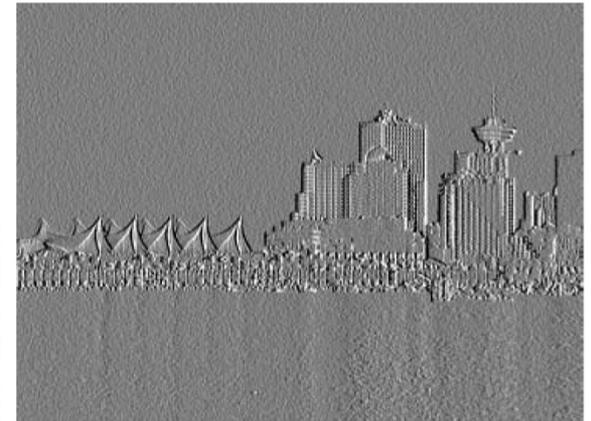
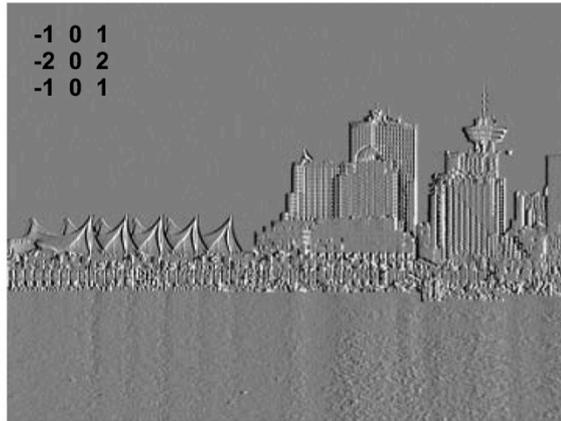


Hintergrundartefakte (Rauschen) werden verstärkt.

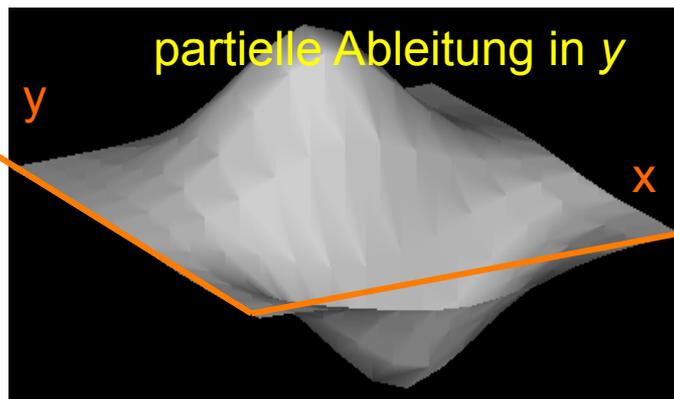
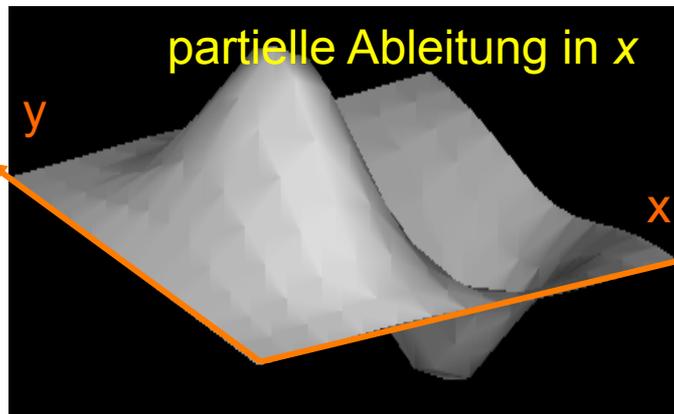
# Sobel Operator

$$\begin{matrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{matrix} \quad \text{und} \quad \begin{matrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{matrix}$$

Faltungskern  
kombiniert  
Glättung und  
Differenzierung in  
einem Operator



# Ableitungen der Gaußfunktion



# Sobel vs. Gauß



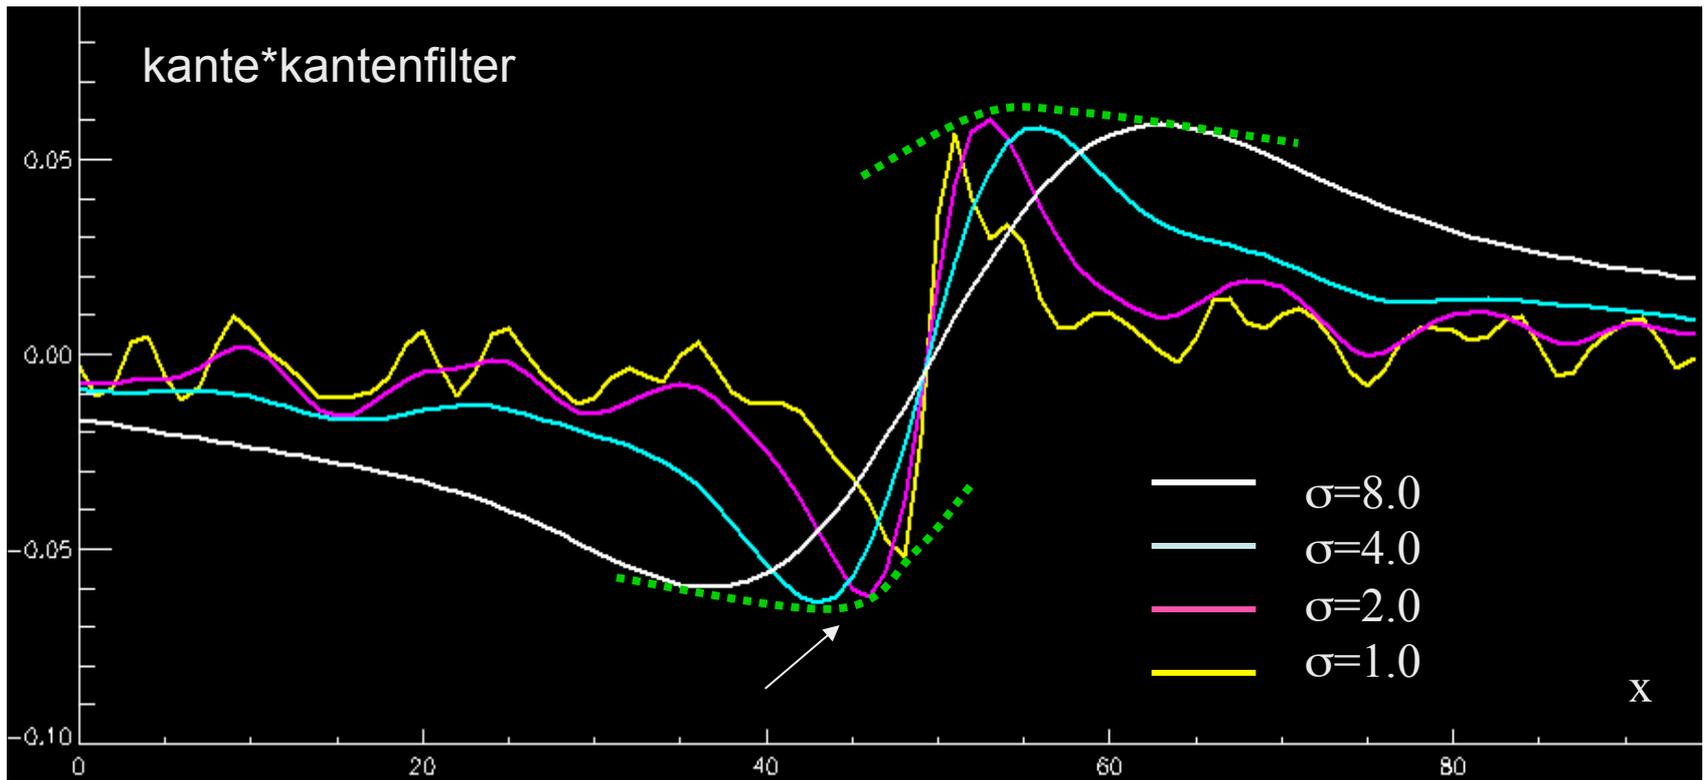
3x3 Sobel



13x13 Gauß



# Filterresultat



# Kompassfilter

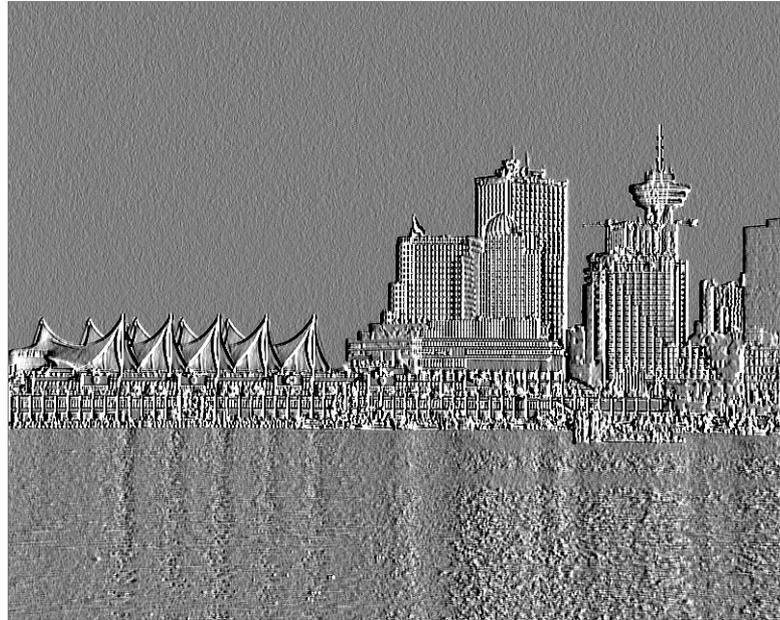
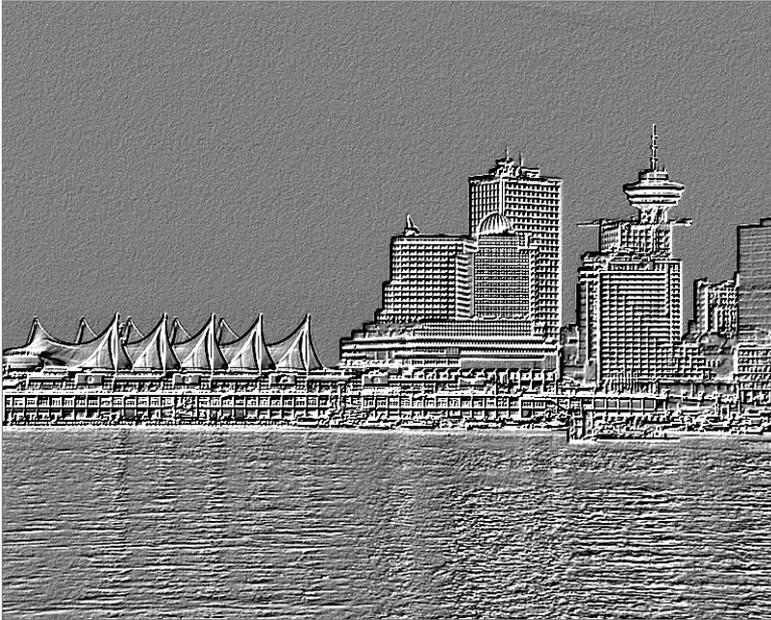
- Dienen der Hervorhebung von Kanten in einer bestimmten Richtung.
- Prewitt-Operator

$$h_1 = \begin{pmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{pmatrix}, \quad h_2 = \begin{pmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{pmatrix}, \quad h_3 = \begin{pmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix} \dots \quad h_8 = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -1 \end{pmatrix}$$

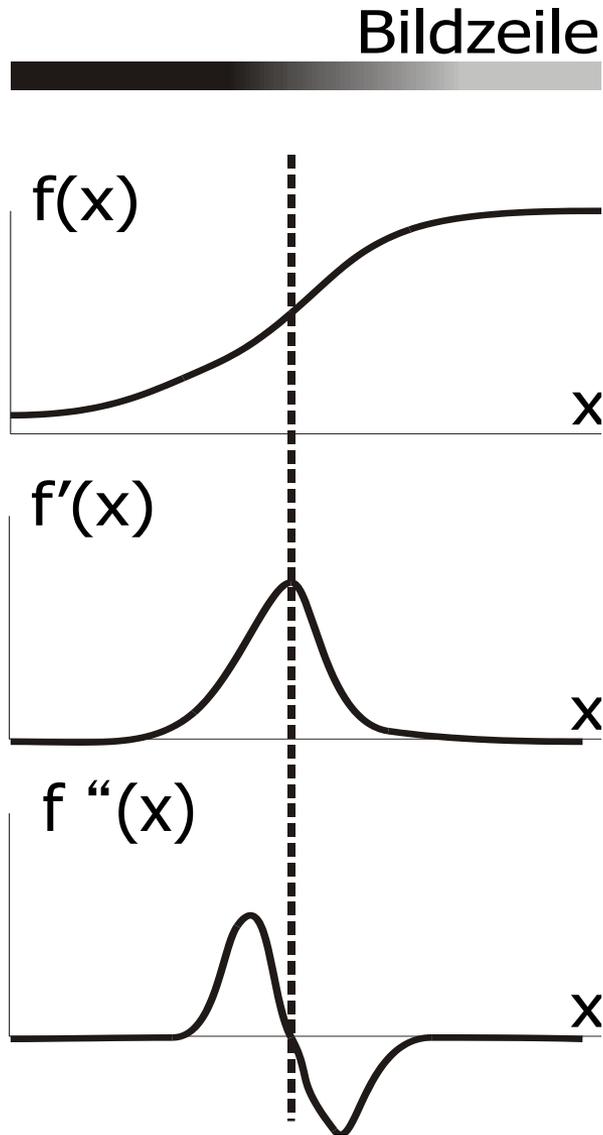
- Kirsch-Operator

$$h_1 = \begin{pmatrix} 3 & 3 & 3 \\ 3 & 0 & 3 \\ -5 & -5 & -5 \end{pmatrix}, \quad h_2 = \begin{pmatrix} 3 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & -5 & 3 \end{pmatrix}, \quad h_3 = \begin{pmatrix} -5 & 3 & 3 \\ -5 & 0 & 3 \\ -5 & 3 & 3 \end{pmatrix} \dots \quad h_8 = \begin{pmatrix} 3 & 3 & 3 \\ 3 & 0 & -5 \\ 3 & -5 & -5 \end{pmatrix}$$

# Kirschoperator



# Wo ist die Regionengrenze?



Vorzeichenwechsel ist leichter zu erkennen, als ein Minimum oder Maximum.

- Gradient (Länge) als Kennzeichen für die Wichtigkeit einer Kante
- zweite Ableitung für den Ort der Kante (Nulldurchgang)

Operatoren zur Berechnung der zweiten Ableitung:

- Laplace Filter
- Marr-Hildreth Filter (LoG Filter, Mexican Hat)
- DoG (Difference of Gaussians)

# Laplace Funktion

- Summe der partiellen zweiten Ableitungen:  $\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}$
- Nulldurchgänge der Laplacefunktion produzieren zusammenhängende Kurven entlang von Bildkanten
- Approximation durch Kombination einer doppelten Differenzbildung in x- und y-Richtung
  - z.B. Faltung eines Differenzoperators  $[-1 \ 1]$  mit sich selbst:  $[-1 \ 2 \ -1]$
  - ergibt für  $[-1 \ 1]^*[-1 \ 1] + [-1 \ 1]^T[-1 \ 1]^T$ :
 
$$\begin{bmatrix} 0 & 0 & 0 \\ -1 & 2 & -1 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 0 & -1 & 0 \\ 0 & 2 & 0 \\ 0 & -1 & 0 \end{bmatrix} = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$
  - Summe **aller** partiellen Ableitungen:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} + \frac{\partial^2 f(x, y)}{\partial x \partial y} + \frac{\partial^2 f(x, y)}{\partial y \partial x} : \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

# Laplace-Operator



- Nulldurchgänge des Laplace-Operators. Dunkle Pixel bezeichnen negative, helle Pixel bezeichnen positive Werte.

# Schärfen eines Bildes mit Laplace-Operator

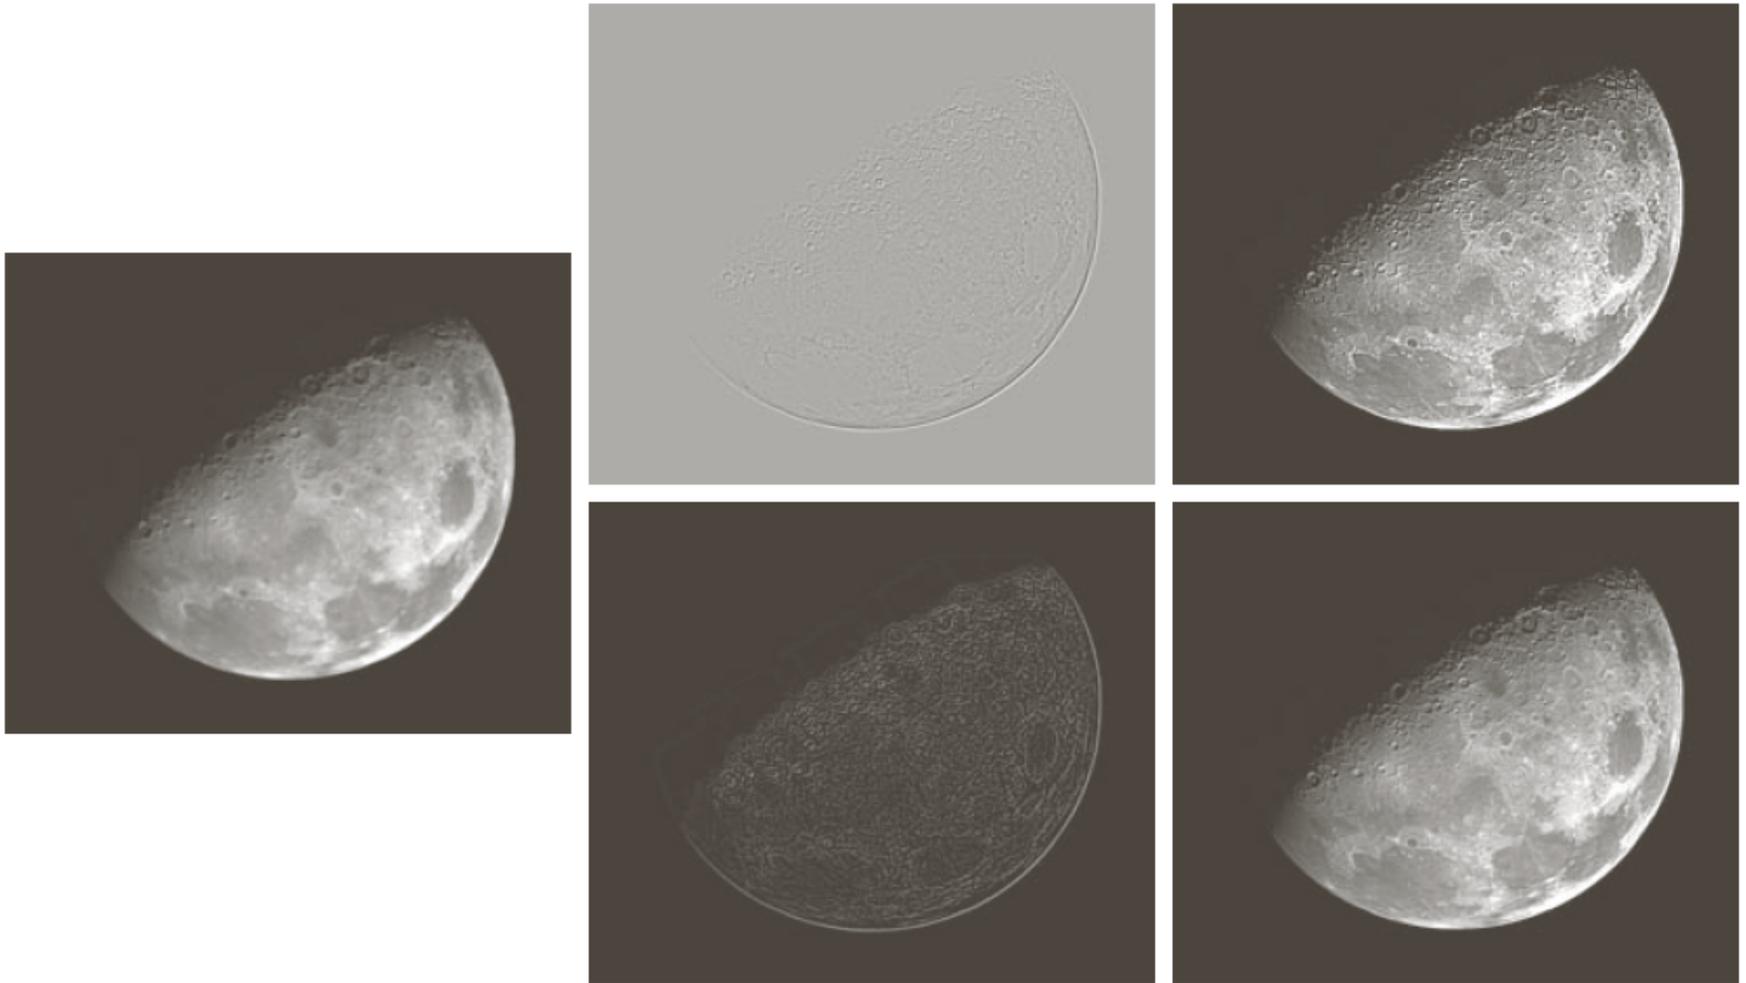
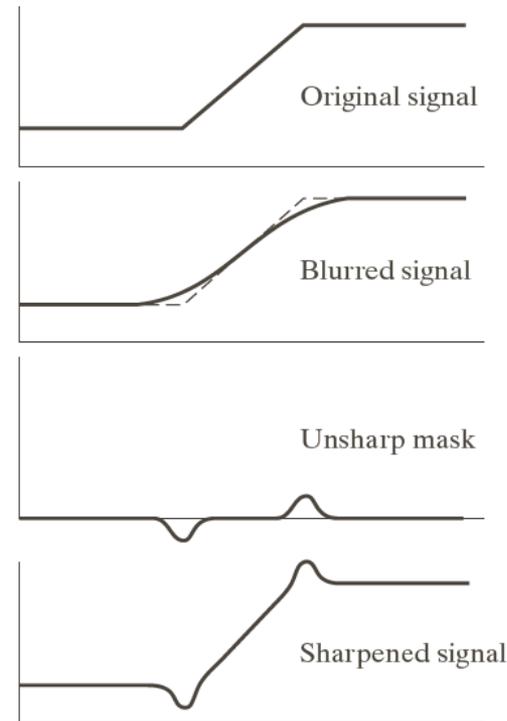


Abbildung: © R. C. Gonzalez & R. E. Woods, Digital Image Processing

# Unscharfes Maskieren

- Originalbild unschärfer machen (Tiefpass filtern)
- Unscharfes Bild vom Original subtrahieren (ergibt die unscharfe Maske)
- Maske (nach Skalierung) zum Original addieren

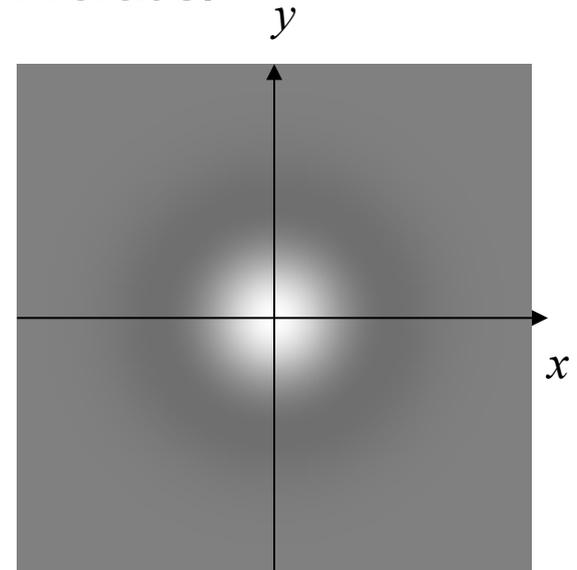
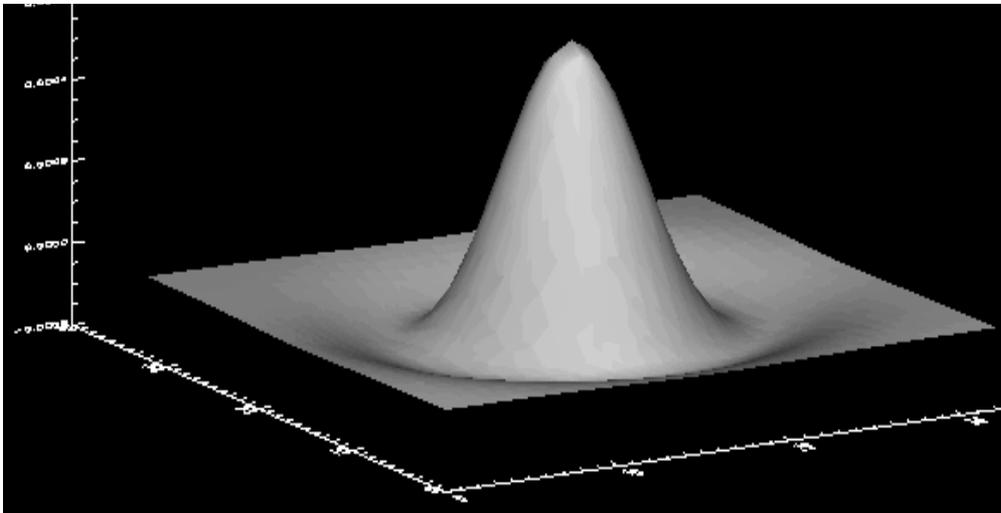


Highboost filtering

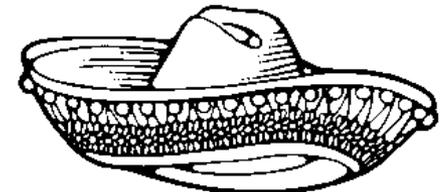


# Marr-Hildreth-Filter = LoG-Filter

LoG-Filter: Laplacian-of-Gaussian,  
d.h. der Faltung mit dem Laplacefilter geht eine  
Glättung mit einer Gaußfunktion voraus.



$$LoG(x, y) = -\frac{1}{\pi\sigma^4} \left( 1 - \frac{x^2 + y^2}{2\sigma^2} \right) \exp\left( -\frac{x^2 + y^2}{2\sigma^2} \right)$$

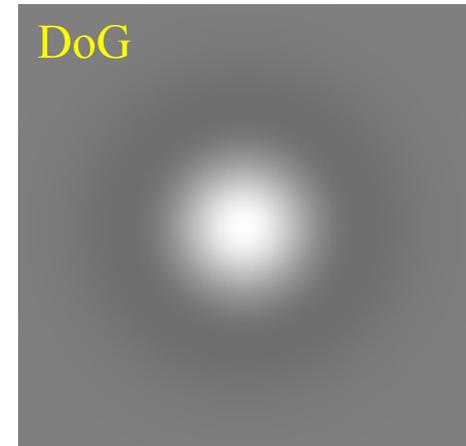
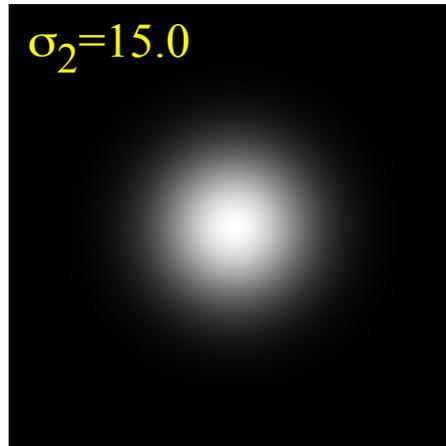
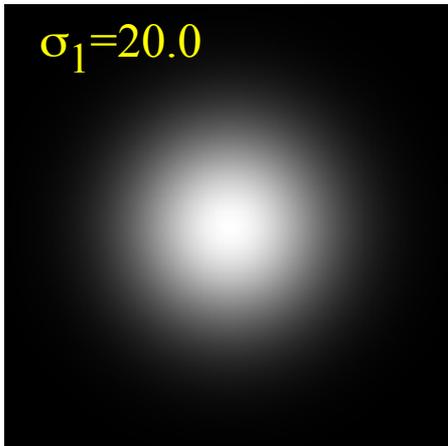


Auch genannt: „Mexican hat“ filter

# DoG (Difference of Gaussians)

Subtraktion zweier Gaußfilter mit unterschiedlicher Varianz  $\sigma^2$ :

$$\text{DoG}(x,y,\sigma_1,\sigma_2) = [\sqrt{2\pi}\cdot\sigma_1]^{-1} \cdot \exp(-(x^2+y^2)/2\sigma_1^2) \\ - [\sqrt{2\pi}\cdot\sigma_2]^{-1} \cdot \exp(-(x^2+y^2)/2\sigma_2^2)$$



DoG und LoG-Filter sind in ihrer Wirkungsweise vergleichbar.

# TRANSFORMATION UND INTERPOLATION

# Transformation und Interpolation

- Die Transformationen Translation, Rotation und Skalierung sind auf reellen Zahlen definiert:

$$Rot_{\alpha} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} \cos \alpha & \sin \alpha \\ -\sin \alpha & \cos \alpha \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix}, \quad Tr_{dx,dy} \begin{pmatrix} x \\ y \end{pmatrix} = \begin{pmatrix} x + dx \\ y + dy \end{pmatrix}, \quad Sc_s \begin{pmatrix} x \\ y \end{pmatrix} = s \begin{pmatrix} x \\ y \end{pmatrix}$$

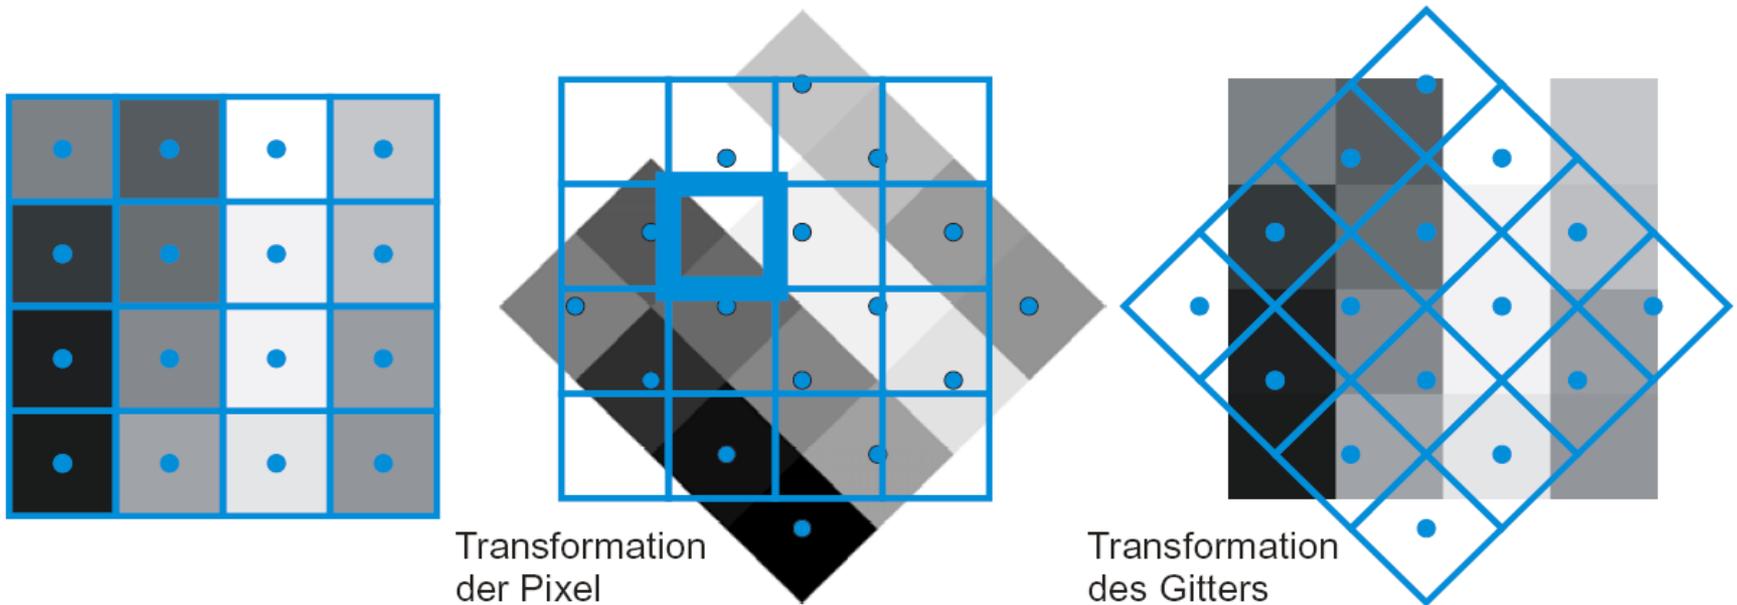
- Digitale Bilder haben einen ganzzahligen Definitionsbereich.
- Nach Transformation ist eine Interpolation notwendig.

# Interpolation

- Konstante Interpolation (Wert des nächsten Nachbarpixels)
- Lineare Interpolation
- Interpolation durch Polynome höheren Grades.
- Interpolation im Frequenzraum.



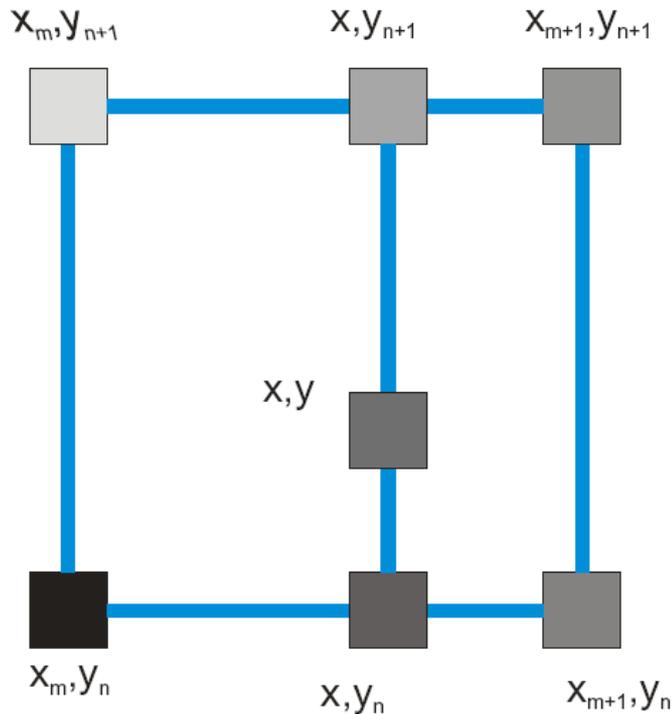
# Konstante Interpolation



Transformation  
der Pixel

Transformation  
des Gitters

# Bilineare Interpolation



Erster Schritt:

$$g_1(x_m, y) = \frac{y_{n+1} - y}{y_{n+1} - y_n} f(x_m, y_n) + \frac{y - y_n}{y_{n+1} - y_n} f(x_m, y_{n+1}),$$

$$g_1(x_{m+1}, y) = \frac{y_{n+1} - y}{y_{n+1} - y_n} f(x_{m+1}, y_n) + \frac{y - y_n}{y_{n+1} - y_n} f(x_{m+1}, y_{n+1}).$$

Zweiter Schritt:

$$g(x, y) = \frac{x_{m+1} - x}{x_{m+1} - x_m} g_1(x_m, y) + \frac{x - x_m}{x_{m+1} - x_m} g_1(x_{m+1}, y).$$

# Polynome höheren Grades

- Interpolation der Bildfunktion durch mehr als 2 Stützpunkte
  - Polynom  $n$ -ten Grades interpoliert  $n+1$  Punkte
- Die Bildfunktion wird besser angenähert, wenn mehr Terme der Taylor-Approximation berücksichtigt werden.
  - Ableitungen für Taylor-Reihe durch Differenzen angenähert
- Grad des Polynoms ist ein Kompromiss zwischen
  - steigender Anzahl berücksichtigter Terme der Taylor-Reihe
  - steigender Ungenauigkeit der geschätzten Ableitungen

