

# Computerphysik II

## Teil 2 - Signalverarbeitung

**S. Gerlach**

**WiSe 2021/22**

Universität  
Konstanz



## INHALT

1. Entwicklung von Funktionen
2. DFT und Anwendungen
3. Signalverarbeitung und -analyse
4. Bildbearbeitung
5. Bildanalyse

# Entwicklung nach Basisfunktionen

Viele Signale sind periodisch und glatt.

Idee: Entwicklung nach einfachen, bekannten Basisfunktionen.

Basis: Sinus/Cosinus bzw. kompl. Exponentialfkt.

→ Reelle **Fourier-Reihe**:

$$f_n(x) = \frac{a_0}{2} + \sum_{j=1}^n (a_j \cos(k_j x) + b_j \sin(k_j x)), \quad k_j = \frac{2\pi}{L} j$$






mit

$$\begin{aligned} a_j(x) &= \frac{2}{L} \int_a^b f(x) \cos(k_j x) dx \quad (j \geq 0), \\ b_j(x) &= \frac{2}{L} \int_a^b f(x) \sin(k_j x) dx \quad (j > 0), \end{aligned} \quad (1)$$



Komplexe Fourier-Reihe:

$$f_n(x) = \sum_{j=-n}^n c_j e^{ik_j x}, \quad c_j = \frac{1}{L} \int_a^b f(x) e^{-ik_j x} dx.$$



# Fourier-Reihe - Beispiel 1





# Fourier-Reihe - Beispiel 2



# Fourier-Reihe - Beispiel 3



# Fourier-Reihe - Beispiel 4





# Fourier-Reihe

Je höher die Ordnung ( $n$ ), desto höher die Frequenz der Basisfunktionen  
→ Schnelle Konvergenz erwünscht.


Man kann zeigen:

- ▶ Symmetrie/Antisymmetrie:  $b_i = 0/a_i = 0$
- ▶ Konvergenz der Fourierkoeff. **quadratisch wenn stetig**, sonst linear.





Zusätzliches Problem mit Sprungstellen: **Gibbs-Phänomen:**  
Überschwingen bei Sprungstellen





Zerlegung in Fourierkoeff. eindeutig.  $\rightarrow$  Transformation **Ort in Impuls** ( $k$ ) bzw. **Zeit in Frequenz**.

\* **Übung:** Entwicklung nach Legendre-Polynomen  
(s. Buch, Kap. 9.4)

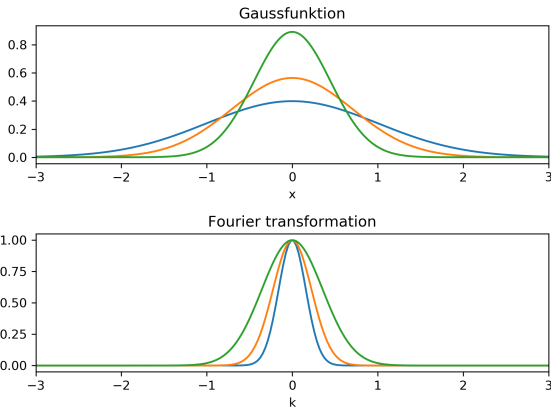
Verallgemeinerung auf nicht-period. Funktionen:  $L/T \rightarrow \infty$   
(komplexe) Fourierkoeff.:

$$c_j = \frac{1}{L} \int_{-L/2}^{L/2} f(x) e^{-ik_j x} dx \xrightarrow{L \rightarrow \infty} \int_{-\infty}^{\infty} f(x) e^{-ikx} dx = \hat{f}(k)$$

(kont.) **Fouriertransformation**



Analytische Berechnung mit SymPy:  
`sympy.fourier_transform(f(x), x, k)`



→ mehr Beispiele: Laplace, sinc, Wellenpaket, ...

Im Computer nur diskrete Werte möglich, d. h. **Diskretisierung** nötig:

$x = x_0 + k\Delta x \rightarrow$  (Herleitung im Buch)

**Diskrete Fouriertrafo** (DFT):

$$\hat{f}_j = \sum_{k=0}^{N-1} f_k e^{-i2\pi \frac{jk}{N}} \quad (j = 0, \dots, N-1)$$

$$f_k = \sum_{j=0}^{N-1} \hat{f}_j e^{i2\pi \frac{jk}{N}} \quad (k = 0, \dots, N-1)$$

**DFT-Berechnung: FFT-Algorithmen.** (Fast-Fourier-Trafo)

`numpy.fft.fft()`, `numpy.fft.ifft()`,

`scipy.fftpack.fft()`, `scipy.fftpack.ifft()`


Reelle DFT:  $N$  (reelle) Werte  $\rightarrow N/2 + 1$  komplexe Ergebnisse

Beispiel: **Frequenzanalyse**

$\Delta T$  - Abstand der Messungen (Samples)

→ **Samplefrequenz**:  $\nu = 1/\Delta T$

Maximal messbare Frequenz (3 Messpunkte):  $\nu_{Ny} = \frac{\nu}{2} = \frac{1}{2\Delta T}$   
**(Nyquist-Frequenz)**



Beispiel: **Frequenzanalyse**

$\Delta T$  - Abstand der Messungen (Samples)




→ **Samplefrequenz**:  $\nu = 1/\Delta T$

→ Je höher die Samplefrequenz, desto größer die messbaren **Frequenzen**.




**Frequenzabstand**:  $\Delta\nu = \frac{\nu}{N} = \frac{1}{N\Delta T} = \frac{1}{T}$

→ Je länger die Messzeit, desto genauer die **Frequenzauflösung**.

# DFT verstehen



# DFT verstehen







`numpy.fft.fftshift()`, `numpy.fft.fftfreq()`



# DFT verstehen

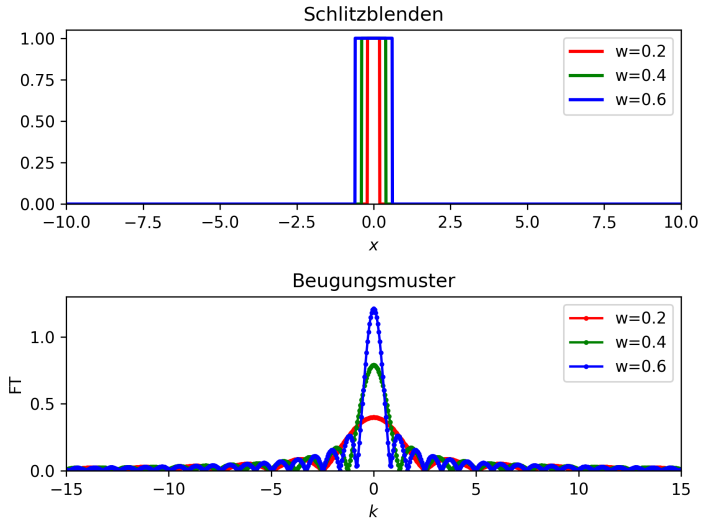
## Variation: Messzeit, Samplefrequenz



- 1  $dt = T/N$
- 2  $x = \text{fftfreq}(N, dt)$
- 3  $Y = \text{fft}(y) * 2.0/N$
- 4  $\text{pl.plot}(x, \text{abs}(Y))$



# Anwendung: Beugung

Beispiel: **Beugungsmuster eines Spaltes:**




# Anwendung: Beugung

Beispiel: **Beugungsmuster eines Doppelspalt:**





# Anwendung: Beugung

Interferenzmuster (sehr schmale Spalte):



# Anwendung: Beugung

Gitter (Kamm):  $\rightarrow$  Reziprokes Gitter




# Anwendung: 2D Beugung

2D-DFT:

$$\hat{a}_{kl} = \sum_{n=0}^{N-1} \sum_{m=0}^{M-1} a_{mn} e^{-i2\pi(\frac{mk}{M} + \frac{nl}{N})}$$


Lochblende, Poisson-Fleck, Rechteck-, Dreieckblende:




Sharp edges are represented by streaks in the FT perpendicular to the edge.

# Anwendung: 2D Beugung

Realer Spalt/Doppelspalt:



Kreis-Gitter (große - kleine Strukturen invertiert!),  $\log(|FT| + X)$ :



# Übersicht DFT berechnen

## Python:

`fft()/ifft()`, `fft2()/ifft2()`, `fftn()/ifftn()`  
`fftshift()/ifftshift()`, `fftfreq()`

Optimiert: `numpy.fft`, `scipy.fftpack`, `pyfftw`

## C:

FFTW - Fastest Fourier Trafo in the West

MKL - Math Kernel Library von Intel

@ GPU: `cufft` (CUDA)

**FFTW**






# Signalverarbeitung und -analyse: Wichtige Effekte

Realität: Signale (Messungen) immer endlich und damit z.B. im Frequenzbereich über einen weiten Bereich verteilt. entspricht Rechteckfilter in der Zeit, der zu einem schmalen Hauptmaximum, aber auch vielen Nebenmaxima im Frequenzbereich führt.

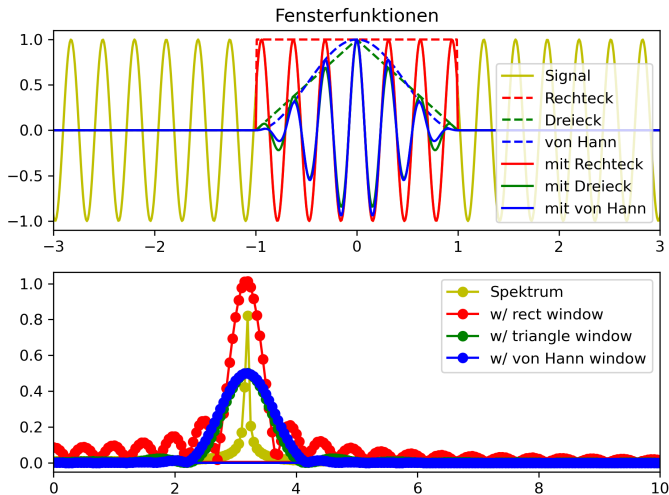
→ **Leck-Effekt** (*spectral leakage*)



# Signalverarbeitung und -analyse: Leck-Effekt






**Lösung:** Verwendung von sog. Fensterfiltern.

Beispiele: Dreieckfenster, von-Hann-Fenster, ... (WP)



# Signalverarbeitung und -analyse: Leck-Effekt

## Vergleich: Breite/Nebenmaxima/Abklingen






# Signalverarbeitung und -analyse: Wichtige Effekte

**Alias-Effekt** (Stroboskop-Effekt): Endliche Samplerate  $\rightarrow$  Abschneiden hoher Frequenzen (**Abtasttheorem**, vgl. Nyquist-Frequenz)


$\rightarrow$  **Interferenz zw. Signal und Sample-/Abtastfrequenz**

Bei Resonanz: Stroboskop-Effekt, Moire-Muster, etc. (Auch bekannt aus Filmen: *Wagon-Wheel-Effekt*)




# Signalverarbeitung und -analyse: Einfache Methoden

”**Detrend**”: Entferne konstanten Untergrund bzw. Trend in den Daten. Dafür einfach lineare Anpassung anziehen:  
`scipy.signal.detrend(data, type='constant'/'linear')`




**"Peak Find"**: Viele Signale enthalten Resonanzen (Spektren, etc.). Oft gesucht: Linienposition, -breite und -höhe  
Idee: jeweils Anpassung mit Linienform ...



... oder spezielle Transformation (CWT):


`scipy.signal.find_peaks_cwt()`




# Signalverarbeitung und -analyse: Spektren

## Mehr Beispiele: Molekülspektren




### Hydrogen chloride (HCl) spectrum



• Vibrational-rotational absorption spectrum of HCl: shows affect of two chlorine isotopes with slightly different mass





## XRD, Massenspektrometer, Sequenzanalyse





**Periodogramm:** gleitende DFT eines Zeitsignals (mit Fenster) → power-spectral-density (=  $\log |Amplitude|^2$ )  
`scipy.signal.periodogram()`





Optionen: `detrend`, `window`

Optimiertes Periodogramm: **Welch-Methode:**

`scipy.signal.welch()`

Überlappende Fensterfunktionen und Mittelung




Optionen: Segmentgröße, Overlap, Fenster (default: Hann-Fenster)

# Signalverarbeitung und -analyse: Fourier-Filter


Idee: Verwende **Filter im Fourier-Raum** (Frequenzbereich)

Anwendungen: Hochpass-, Tiefpass-, Bandpass-, Bandblock-Filter


Second-Order Low Pass Filter




Second-Order High Pass Filter



Second-Order Band Pass Filter







Second-Order Band Rejects Filter







# Signalverarbeitung und -analyse: Fourier-Filter

## Tiefpass Fourier Filter

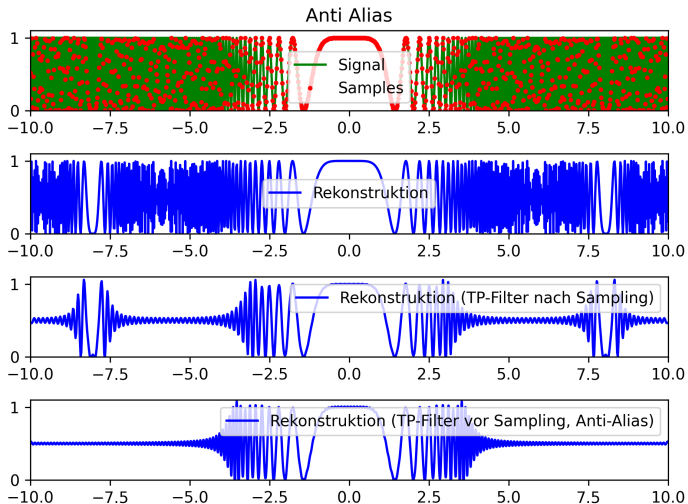


# Signalverarbeitung und -analyse: Fourier-Filter


Hochpass Fourier Filter





## Anti-Alias: Aliaseffekt durch Filter verringern




# Signalverarbeitung und -analyse: Anti-Alias



Tiefpass vor Sampling





Tiefpass nach Sampling



# Signalverarbeitung und -analyse: Anti-Alias

Auch bekannt bei Schriften (Raster) oder Monitoren (Pixel)









# Signalverarbeitung und -analyse: Bildbearbeitung

Viele Methoden, die Fourierfilter verwenden:

## Beispiel 1: **Streifenfilter**





Entferne die Anteile im Fourierbild, die zu den Streifen führen



## Beispiel 2: **Weichzeichnen**





Entferne hochfrequente Anteile (Kanten, kleine Strukturen, etc.)

Um Aliaseffekte zu vermeiden ("Ringing"): verwende "weiche"  
Filter, z.B. Gauss







## Beispiel 3: **Kantenfilter**

Verwende Hochpassfilter um Umrissse (Kanten) zu sehen



## Beispiel 4: **Schärfen**

Idee: Weichzeichnen des Bildes und Abziehen vom Originalbild



## EVALUATION:

https:

`//evasys.uni-konstanz.de/evasys/online.php?pswd=Q8S6F`

# Signalverarbeitung und -analyse: Faltung und Anwendungen

**Faltung** (*convolution*):

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau) d\tau.$$

Anschaulich: Eine (gespiegelte) Gewichtsfunktion ("Kernel")  $g$  wird über die Funktion  $f$  geschoben.

**Diskrete Berechnung** ( $\mathcal{O}(N^2)$ ):

$$(f * g)_n = \sum_k^N f_k g_{n-k}$$

**Besser:** nutze **Faltungstheorem**

$$f * g = \mathcal{F}^{-1}(k\mathcal{F}\{f\} \cdot \mathcal{F}\{g\})$$

FFT mit  $\mathcal{O}(N \log N)$  deutlich schneller als Summe (s.o.).

Ist  $g$  viel kürzer als  $f$  ( $g$  ist ein FIR - *Finite Impulse Response*):  
*Overlap-save* oder *Overlap-add* Methode.

Beispiel: Gleitender Mittelwert durch Rechteck-FIR (*boxcar*)

# Signalverarbeitung und -analyse: Faltung - Anschaulich

Faltung einer Gaussfunktion mit Gauss-Kernel:

Typische Anwendung: Glättung durch Faltung mit Gauss-Kernel






*Out-of-Focus* Fotografie (**Bokeh**)

Unschärfe des Hintergrunds durch Linsenfunktion:




# Signalverarbeitung und -analyse: Faltung Beispiel 1





`scipy.signal.convolve()`, `scipy.signal.fftconvolve()`

# Signalverarbeitung und -analyse: Faltung Beispiel 2

**Voigt-Profil:** Faltung von Dopplerverbreiterung (Gauss) mit natürlicher Linienbreite (Lorentz)




## Kernel Density Estimation:



$N$ -Datenpunkte KDE:

$$f_h(x) = \sum_i^N K_h(x - x_i)$$


Bestimmung **Bandbreite**  $h$ : *Rule of Thumb*  
oder Berechnung durch Fehlerminimierung.



# Signalverarbeitung und -analyse: Faltung und Anwendung




2D: Kernel sog. *point spread function* (**PSF**), da jeder Punkt/Pixel mit dem Kernel multipliziert wird.

2D-Gauss-Kernel: **Gauss-Glättung**





`scipy.ndimage.filters.gaussian_filter()` (nicht `scipy.signal.convolve2d()`)

Verschiedene Kernel führen zu unterschiedlichen Effekten.  
Beispiel: **Blur**




## Comet-Kernel/Belichtungskernel




# Signalverarbeitung und -analyse: Faltung und Anwendung

`scipy.ndimage.filters`

`uniform_filter()`: 2D-Mittelung mit fester Wichtung



`median_filter()`: 2D-Median mit fester Wichtung





$$(f * g)_n = \sum_k^N f_k g_{n-k}$$

Kernel  $(1; -1) \equiv (f * g)_n = f_n - f_{n-1}$ : Vorwärtsableitung

Kernel  $(\frac{1}{2}; 0; -\frac{1}{2}) \equiv (f * g)_n = \frac{1}{2}(f_{n+1} - f_{n-1})$ : Zentrale Ableitung

Kernel  $(1; -2; 1) \equiv (f * g)_n = f_{n+1} - 2f_n + f_{n-1}$ : 2. zentr. Abl.

Kernel  $(\frac{1}{3}; \frac{1}{3}; \frac{1}{3}) \equiv (f * g)_n = \frac{1}{3}(f_{n+1} + f_n + f_{n-1})$ :

Mittelung/Glättung (*boxcar*)


**Kantenerkennung** im Bild: 2D Faltung mit Kernel  $(1; -1)$  bzw.

$\begin{pmatrix} 1 \\ -1 \end{pmatrix}$  oder besser **Sobelfilter** (Ableitung + Glättung)


$$S = \sqrt{S_x^2 + S_y^2}, S_x = \begin{pmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{pmatrix}, S_y = \begin{pmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{pmatrix}$$

# Signalverarbeitung und -analyse: Faltung und Anwendung


Sobelfilter (`scipy.ndimage.sobel()`):




Sobel vertikal



Sobel horizontal



Kanten (Sobel)



$$S = B * K$$

$$\mathcal{F}\{S\} = \mathcal{F}\{B\} \cdot \mathcal{F}\{K\}$$

$$S = \mathcal{F}^{-1}(\mathcal{F}\{B\} \cdot \mathcal{F}\{K\})$$

Umkehrung:




$$\mathcal{F}\{B\} = \frac{\mathcal{F}\{S\}}{\mathcal{F}\{K\}}$$

$$B = \mathcal{F}^{-1} \left\{ \frac{\mathcal{F}\{S\}}{\mathcal{F}\{K\}} \right\}.$$

**Dekonvolution:** Zurückrechnen des Originalbildes bei bekanntem/geratenem Kernel





# Signalverarbeitung und -analyse: Rekonstruktion

Pulsrekonstruktion:




# Signalverarbeitung und -analyse: Rekonstruktion

Bildrekonstruktion (Hier: Unschärfe):




Beispiel: Bewegungskorrektur (s. Übung)


Sternspuren



Kernel



Dekonvolution




$$B = \mathcal{F}^{-1} \left\{ \frac{\mathcal{F}\{S\}}{\mathcal{F}\{K\}} \right\}.$$

Problem: Kernel  $K$  ist glatt, hat also keinen Hochfrequenzanteil.  
Damit Rauschen des Signals  $S$  wird extrem verstärkt!

Lösung: **Wiener-Filter**, Optimale Rauschunterdrückung durch Anwendung der Methode der kleinsten Quadrate auf ein Signal mit additivem Rauschen um den Kernel  $K$  zu optimieren.

## Filtervergleich:






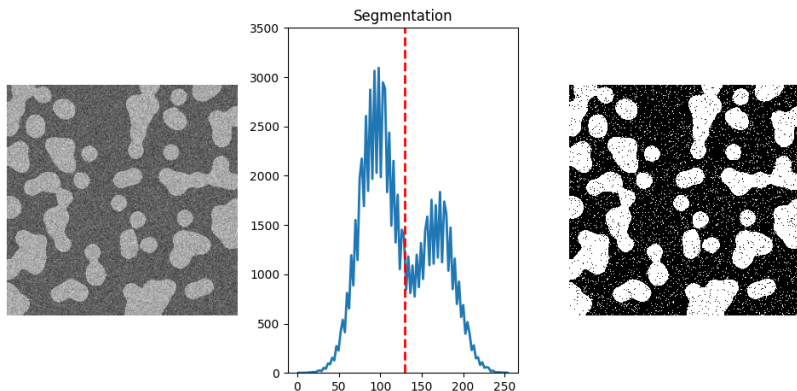
# Signalverarbeitung und -analyse: Bildanalyse

Informationen aus Bildern extrahieren. Beispiel: Segmentation, Morphologie und Granulometrie

→ s. Buch Kap. 18.3.4



## Segmentation: Trennung der Helligkeitswerte




```
S = asarray(Image.open('ising.png').convert('L'))  
BS = S > LIMIT
```

# Signalverarbeitung und -analyse: Pixeltransformationenen

→ *Morphing*

**Erosion:**  $A \ominus B$ : Alle Pixel, für die B in A passt.

**Dilation:**  $A \oplus B$ : B an jedem Pixel von A einfügen.



Binary Opening:  $A \circ B = (A \ominus B) \oplus B$


Binary Closing:  $A \bullet B = (A \oplus B) \ominus B$

# Signalverarbeitung und -analyse: Morphing

Binary Opening:  $A \circ B = (A \ominus B) \oplus B$

Binary Closing:  $A \bullet B = (A \oplus B) \ominus B$


```
scipy.ndimage.binary_opening(),  
scipy.ndimage.binary_closing()
```



# Signalverarbeitung und -analyse: Morphing

**Grayscale Morphing:** Maximum/Minimum Pixelwert in B


```
scipy.ndimage.grey_opening(),  
scipy.ndimage.grey_closing()
```




**Gradient Morphing:**  $A \oplus B - A \ominus B$

`scipy.ndimage.morphology_gradient()`

Original




morphological\_gradient(5x5)




# Signalverarbeitung und -analyse: Labeling

```
LI, nr_labels = scipy.ndimage.label(MS)  
pl.imshow(LI, interpolation='nearest')
```


Original



Segmented and spots removed





Labeled Image (Teile=29)



# Signalverarbeitung und -analyse: Granulometrie

Bestimme die Größe/Größenverteilung von Gebieten:

```
1 def granulometry(image, sizes):  
2     return [binary_opening(image,  
3         _____structure=disk_structure(n)).sum() for n in sizes]  
4  
5 GS = granulometry(BS, sizes=arange(1, 15, 1))
```







# Signalverarbeitung und -analyse: Clusteranalyse

Finden/Trennen von Gruppen

Beispiel:




Beispiel:



**k-means:** Bilde  $k$  Gruppen aus Elementen durch Minimierung der Summe der quadr. Abweichungen von den  $k$  Zentren.

# Signalverarbeitung und -analyse: Clusteranalyse


**Voronoi-Diagramm:** Zerlegung des Raumes anhand von Zentren. Region enthält alle Punkte, deren Abstand zu den anderen Zentren größer ist.



```
1 from scipy.cluster.vq import kmeans2
2 centroid, label = kmeans2(data, 4, minit='points')
3
4 print("Counts: ", np.bincount(label))
5 pl.plot(centroid[:, 0], centroid[:, 1], 'k*', label='centroids')
6
7 from scipy.spatial import Voronoi, voronoi_plot_2d
8 vor = Voronoi(centroid)
9 fig = voronoi_plot_2d(vor, label='Voronoi')
```


# Signalverarbeitung und -analyse: Clusteranalyse

Gutes Ergebnis:



# Signalverarbeitung und -analyse: Clusteranalyse

Weniger gutes Ergebnis:



## Korrelation:

$$(f \star g)(t) = \int_{-\infty}^{\infty} f^*(\tau)g(\tau + t) d\tau$$

$$(f \star g)_j = \sum_k f_k^* g_{k+j}.$$

Gleitender Mittelwert von  $f$  mit Gewichtung/Muster  $g$ . Hohe Werte bei Übereinstimmung: **Mustererkennung**


$$\mathcal{F}\{f \star g\} = k\mathcal{F}\{f^*(-t)\} \cdot \mathcal{F}\{g\} = k\mathcal{F}^*\{f\} \cdot \mathcal{F}\{g\}.$$

**Autokorrelation:** Korrelation mit sich selbst: Erkennung von periodischen Mustern

`scipy.signal.correlate()`, `scipy.signal.correlate2d()`



# Signalverarbeitung und -analyse: Autokorrelation

Übereinstimmung mit verschobener Kopie:



# Signalverarbeitung und -analyse: Kreuzkorrelation

Übereinstimmung mit Muster:






# Signalverarbeitung und -analyse: Autokorrelation

Periodische Muster im Bild: Autokorrelation

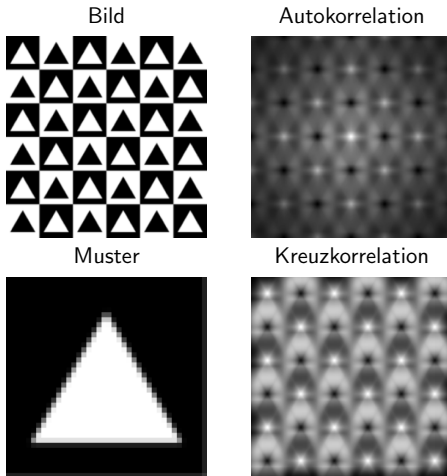
`scipy.signal.correlate(S,S)` (nicht `correlate2d()`!)



# Signalverarbeitung und -analyse: Korrelation

Mustersuche im Bild: Kreuzkorrelation

`scipy.signal.correlate(S,M)`



# Signalverarbeitung und -analyse: Bildanalyse

Anwendung: Mustererkennung durch Kreuzkorrelation

