

## Histogramm

$$\text{Histogramm-Funktion: } H(x) = \sum_{i=1}^{k-1} \left( \frac{n_i}{n} \cdot \frac{1}{t_{i+1} - t_i} \right) I_{[t_i, t_{i+1})}(x)$$

k... Klassenanzahl, t ... Intervallgrenzen | ... Indikatorfunktion, n... Umfang Stichprobe,  $n_i$ ... # im Intervall

$$\text{Intervalllänge nach Sturges: } h_n = t_{i+1} - t_i = \lceil \log_2(n) + 1 \rceil$$

$$\text{Intervalllänge nach Scott: } h_n = \frac{3.5s}{\sqrt[3]{n}} \quad s \dots \text{empirische Standardabweichung}$$

$$\text{Intervalllänge nach Freedman: } h_n = \frac{(2IQR)}{\sqrt[3]{n}}$$

## Verteilungsfunktion

von 0 bis 1, monoton wachsend,  $\lim_{x \rightarrow \infty} F(x) = 1$ ,  $\lim_{x \rightarrow -\infty} F(x) = 0$

$$\text{theoretische Verteilungsfunktion: } F(x) = \int_{-\infty}^x f(t) dt$$

$$\text{empirische Verteilungsfunktion: } F_n(x) = \frac{1}{n} \sum_{i=1}^n I_{[x_i, \infty)}(x)$$

# Dichteschätzung/Kernschätzung

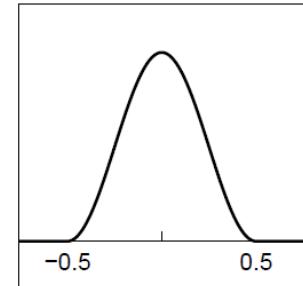
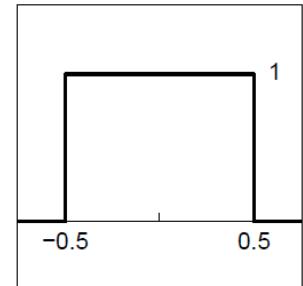
$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h} W\left(\frac{x - x_i}{h}\right)$$

$W(t)$  ... Gewichtsfunktion  $\int_{-\infty}^{\infty} W(t) = 1$ ,

$\left[x - \frac{h}{2}, x + \frac{h}{2}\right]$  ... Fenster ( $h$  = Intervalllänge)

Rechtecks Gewichtsfunktion:  $W(t) = \begin{cases} 1 & |t| \leq \frac{1}{2} \\ 0 & \text{sonst} \end{cases}$

Cosinus Gewichtsfunktion:  $W(t) = \begin{cases} 1 + \cos 2\pi t & |t| < \frac{1}{2} \\ 0 & \text{sonst} \end{cases}$



## Wahrscheinlichkeitsnetz

=Verteilungsfunktion mit verzerrter vertikaler Achse → zb.: Abstände proportional zur Inversen der Verteilungsfunktion von  $N(0,1) = \Phi$ . y-Achse =  $\Phi^{-1}(F_n(x))$  x-Achse =  $x$ .

Bei ungefähr Normalverteilung gilt:  $\Phi^{-1}(F_n(x)) \sim \Phi^{-1}\left(\Phi\left(\frac{x-\mu}{\sigma}\right)\right) = \frac{x-\mu}{\sigma} \rightarrow$  auf einer Geraden.

bei Wahrscheinlichkeit 50% Schätzung für  $\mu$  bei 84% Schätzung für  $\mu + \sigma$

# Quantile-Quantile Plots

$$F_x(t) = P(X \leq t), q_x(p) = F_x^{-1}(p)$$

$F_x = F_y \leftrightarrow (q_x(p_i), q_y(p_i))$  liegen auf der Geraden  $y = x$

## univariate Schätzer

arithmetisches Mittel:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  empirische Standardabweichung  $s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$

gestutztes Mittel:  $m(\alpha) = \frac{1}{n-2g} (x_{(g+1)} + \dots + x_{(n-g)})$   $\alpha \dots 0 \leq \alpha \leq 0.5$   $g = \lfloor n\alpha \rfloor$  (auf

Ganzzahl abgerundet)

gestutzte Streuung  $S(\alpha) = \sqrt{\frac{1}{n-2g-1} \sum_{i=g+1}^{n-g} (x_{(i)} - m(\alpha))^2}$

gestutzte SD =  $\frac{s(\alpha)}{c_\alpha}$   $c_\alpha \dots$  abhängig von  $\alpha$

$$\text{Median } \mathbf{median}(x_1, \dots, x_n) = \begin{cases} x_{\left(\frac{n+1}{2}\right)} & n \text{ ungerade} \\ \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2} & n \text{ gerade} \end{cases}$$

$$\text{MAD (Median Absolute Deviation)} = \mathbf{median}_{1 \leq i \leq n}(|x_i - \mathbf{median}_{1 \leq j \leq n}(x_j)|)$$

$$s_{MAD} = \frac{MAD}{0.675} = 1.483 \cdot MAD$$

$$25 \text{ Quartil } Q_{0.25} = \mathbf{median} \left( x_{(1)}, \dots, x_{\left(\left[\frac{n+1}{2}\right]\right)} \right)$$

$$75 \text{ Quartil } Q_{0.75} = \mathbf{median} \left( x_{\left(\left[\frac{n}{2}+1\right]\right)}, \dots, x_{(n)} \right)$$

$$\text{Interquartilabstand } \mathbf{IQR} = Q_{0.75} - Q_{0.25} \quad s_{IQR} = \frac{IQR}{1.35}$$

$$Q_n \text{ Streuungssch\"atzer } Q_n = \left\{ |x_i - x_j|; i < j \right\}_k \quad s_{Q_n} = 2.219 \cdot Q_n$$

## Dichteschätzung in zwei Dimensionen

Boxcar Funktion  $W(u, v) = \begin{cases} \frac{1}{\pi} u^2 + v^2 \leq 1 \\ 0 \text{ sonst} \end{cases}$

Cosinus Gewichtsfunktion  $W(u, v) = \begin{cases} \frac{1+\cos(\pi\sqrt{u^2+v^2})}{\pi} & \text{wenn } u^2 + v^2 \leq 1 \\ 0 \text{ sonst} \end{cases}$

Dichtefunktion  $\hat{f}(x, y) = \frac{1}{h^2 n} \sum_{i=1}^n W\left(\frac{x-x_i}{h}, \frac{y-y_i}{h}\right)$   $h \dots$  Fensterbreite

## Robuste Schätzung linearer Trends

$$y = \alpha + \beta x + \varepsilon \quad \alpha \dots \text{Abszissenabstand} \quad \beta \dots \text{Steigung} \quad \varepsilon \dots \text{Fehler}$$

$$r_i = y_i - \hat{y}_i = y_i - \hat{\alpha} - \hat{\beta} x_i \quad i = 1, \dots, n$$

Least Squares

$$(\hat{\alpha}_{LS}, \hat{\beta}_{LS}) = \operatorname{argmin}_{\alpha, \beta} \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 = \operatorname{argmin}_{\alpha, \beta} \sum_{i=1}^n r_i^2$$

$$\hat{\beta}_{LS} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} \quad \hat{\alpha}_{LS} = \bar{y} - \hat{\beta}_{LS} \bar{x}$$

Bruchpunkt:  $\frac{k}{n}$  n ... Stichprobenumfang, k ... maximale Anzahl von Ausreißern

### Tukey

Datenpaare in 3 Gruppen nach x-Werte:  $n_L + n_M + n_R = n$

Median pro Gruppe  $x_L = \text{median}_{(x_i, y_i) \in L} x_i$   $y_L = \text{median}_{(x_i, y_i) \in L} y_i$

Schätzwerte  $\hat{\beta}_0 = \frac{y_R - y_L}{x_R - x_L}$ , Residuen  $r_i^0 = y_i - (\hat{\alpha}_0^{(*)} + \hat{\beta}_0(x_i - x_M))$  Bruchpunkt =  $\frac{1}{6}$  (Median eines  $\frac{1}{3}$ )

### Theil

$\hat{\beta}_{ij} = \frac{y_j - y_i}{x_j - x_i} \quad 1 \leq i < j \leq n \quad \hat{\beta}_T = \text{median}_{1 \leq i < j \leq n}(\hat{\beta}_{ij})$  Bruchpunkt = 0.29

Siegel (Repeated Median Line) (Bruchpunkt 0.5)

$\hat{\beta}_{RM} = \text{median}_{1 \leq i \leq n}(\text{median}_{1 \leq j \leq n}(\hat{\beta}_{ij}))$   $\hat{\alpha}_{RM} = \text{median}_{1 \leq i \leq n}(y_i - \hat{\beta}_{RM} x_i)$

LMS (Least Median of Squares) Regression (Bruchpunkt 0.5)

$(\hat{\alpha}_{LMS}, \hat{\beta}_{LMS}) = \text{argmin}_{\alpha, \beta} \text{median}_i r_i^2$

LTS (Least Trimmed Squares) Regression

$(\hat{\alpha}_{LTS}, \hat{\beta}_{LTS}) = \text{argmin}_{\alpha, \beta} \sum_{i=1}^h r_{(i)}^2 \quad \frac{n}{2} < h < n$

Stichprobe:  $x_1, \dots, x_n$

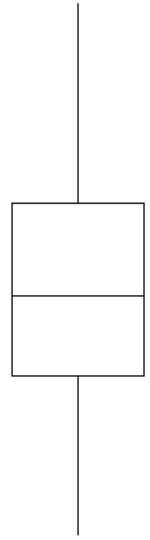
$x_M := \text{median}(x_1, \dots, x_n)$

$Q_{0.25}$  und  $Q_{0.75}$  sind die Quantile 0.25 bzw. 0.75

$\text{IQR} = Q_{0.75} - Q_{0.25}$  ist der Interquartil-Abstand

\*  $x_j > Q_{0.75} + 1.5 \text{ IQR}$  möglicher Ausreißer

größtes  $x_j$  mit  $x_j \leq Q_{0.75} + 1.5 \text{ IQR}$



$Q_{0.75}$   
 $x_M$   
 $Q_{0.25}$

kleinstes  $x_j$  mit  $x_j \geq Q_{0.25} - 1.5 \text{ IQR}$

\*  $x_j < Q_{0.25} - 1.5 \text{ IQR}$  möglicher Ausreißer

# Nichtlineare Glättung

Lineare Filter  $\mathbf{z}_t = \sum_{i=-l_1}^{l_2} \alpha_i x_{t+i}$  gewichtete Summe der  $x_i$  in einer Umgebung von t

Mediangularmässig  $Gx_t = median(x_{t-s}, x_{t-s+1}, \dots)$  Wert an Stelle t ist Median aus einer  $2s + 1$  Umgebung

Repeated Median

lokale lineare Approximation  $\mu_{t+1} \approx \mu_t + \beta_t \cdot i$   $\mu_t \dots Level$   $\beta_t \dots Steigung, i = -s \text{ bis } s$

$$r_t(t+i) = x_{t+i} - \hat{\mu}_t - \hat{\beta}_t \cdot i$$

$$\hat{\beta}_t = median_{-s \leq i \leq s} \left( median_{-s \leq j \leq s} \left( \frac{x_{t+i} - x_{t+j}}{i-j} \right) \right) \hat{\mu}_t = median_{-s \leq i \leq s} (x_{t+i} - \hat{\beta}_t \cdot i)$$

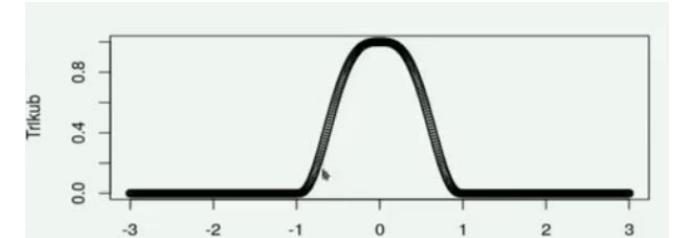
Ausreißer  $|\hat{r}_t| > 2 \cdot \hat{\sigma}_t$   $\hat{r}_t = x_t - \hat{\mu}_t$

# LOWESS (Locally WEighted regression Scatter plot Smoothing)

$q = \lfloor nf + 0.5 \rfloor$  ... Anzahl der Punkte die zur Glättung verwendet werden

$$d_{ik} = |x_i - x_k| \quad d_i = |x_i - x_{i_{max}}| \quad i_{max} \text{ ... Index des am weitesten entfernen Punkt aus q}$$

Trikubische Gewichtsfunktion  $T(t) = \begin{cases} (1 - |t|^3)^3 & |t| < 1 \\ 0 & sonst \end{cases}$



Gewicht von  $(x_k, y_k)$  bezüglich  $(x_i, y_i)$

$$t_i(x_k) = \begin{cases} T\left(\frac{|x_i - x_k|}{d_i}\right) = T\left(\frac{d_{ik}}{d_i}\right) & d_i \neq 0 \\ 1 & d_i = 0 \end{cases}$$

gewichtete Regression (Zeitpunkt i)  $\min \sum_{k=1}^n t_i(x_k)(y_k - a - bx_k)^2$  Residuen  $r_i = y_i - \hat{y}_i$

Biweight Gewichtsfunktion  $B(t) = \begin{cases} (1 - t^2)^2 & |t| < 1 \\ 0 & sonst \end{cases}$

$$m = median_{1 \leq k \leq n} |r_k| \rightarrow 3m \approx 2\sigma \quad \text{Gewichtete Residuen} \quad w(x_k) = B\left(\frac{r_k}{3m}\right)$$

robust gewichtete Regression  $\min \sum_{k=1}^n w(x_k) t_i(x_k)(y_k - a - bx_k)^2$

Upper and Lower Smoothing Aufteilung der Residuen in positive & negative Residuen  $r_i = y_i - \hat{y}_i$   
 $r_i^+$  für  $(x_i^+, \hat{y}_i^+)$

# Zeitreihenanalyse

$$x_t = \tau_t + \delta_t + e_t \quad \tau_t \dots \text{Trendkomponente}, \delta_t \dots \text{Saisonkomponente}, e_t \dots \text{Restkomponente}$$

Lineares Modell  $\ln(x_t) = \beta_0 + \beta_1 t + e_t$

quadratisches Modell  $\ln(x_t) = \beta_0 + \beta_1 t + \beta_2 t^2 + e_t \rightarrow \hat{x}_t = \exp(\hat{\beta}_0 + \hat{\beta}_1 t + \hat{\beta}_2 t^2)$

Fourierreihe 1. Ordnung  $f(t) = a_0 + \sum_{j=1}^J (a_j \cos(\omega_j t) + b_j \sin(\omega_j t)) \quad \omega_j = \frac{2\pi j}{P}$

$$\ln(x_t) = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 \cos\left(\frac{2\pi}{P} \cdot t\right) + \beta_4 \sin\left(\frac{2\pi}{P} \cdot t\right) + e_t$$

## Exponentielles Glätten

$$\tilde{x}_t = \alpha x_t + (1 - \alpha) \tilde{x}_{t-1} \quad \alpha \dots \text{Glättungsfaktor } 0 < \alpha < 1 \quad \text{Startwert } \tilde{x}_m = \text{mean}(x_0 \text{ bis } x_m)$$

Prognose  $\tilde{x}_{t+h|t} = \tilde{x}_t$

## Glättung noch Holt-Winters

$$\tilde{x}_t = \alpha x_t + (1 - \alpha)(\tilde{x}_{t-1} + b_{t-1}) \quad b_t = \beta(\tilde{x}_t - \tilde{x}_{t-1}) + (1 - \beta)b_{t-1}$$

Prognose  $\tilde{x}_{t+h|t} = \tilde{x}_t + h b_t$

Autokovarianz  $\text{Cov}(x_t, x_{t-k})$  Schätzer  $c_k = \frac{1}{T} \sum_{t=k+1}^T (x_t - \bar{x})(x_{t-k} - \bar{x})$   $k \dots$  lag (Abstand)

Autokorrelation der Ordnung  $k$   $\rho_k = \text{Corr}(x_t, x_{t-k}) = \frac{\text{Cov}(x_t, x_{t-k})}{\text{Var}(x_t)}$   $r_k = \frac{c_k}{c_0}$   $c_0 \dots$  Varianz von  $x_t$

## Zeitreihenmodelle

Moving Average (MA) Modell MA(1):  $x_t = a + u_t - \Theta_1 u_{t-1}$   $u_t \dots$  white noise

Autoregressives (AR) Modell AR(1):  $x_t = a + \phi x_{t-1} + u_t$   $u_t \dots$  white noise

ARMA (Autoregressive-Moving-Average) Modell:

ARMA(1,1):  $x_t = a + \phi x_{t-1} + u_t - \Theta_1 u_{t-1}$

ARIMA Modell

Differenz Operator  $\Delta x_t = x_t - x_{t-1}$

$$\Delta^2 x_t = \Delta(\Delta x_t) = \Delta(x_t - x_{t-1}) = x_t - 2x_{t-1} + x_{t-2}$$

ARIMA(1,1,1):  $x_t = x_{t-1} + a + \phi(x_{t-1} - x_{t-2}) + u_t - \Theta_1 u_{t-1}$ ,

## Kovarianz

$$\sigma_{jk} = E \left[ (x_j - E(x_j)) (x_k - E(x_k)) \right], \quad (j, k \in \{1, \dots, p\} \text{ } p \dots \# \text{Variablen})$$

$$\text{für } j = k: \sigma_{jj} = E \left[ (x_j - E(x_j))^2 \right] = \text{Varianz}$$

## Stichprobenkovarianz

$$s_{jk} = \frac{1}{n-1} \sum_{i=1}^n (x_{ij} - \bar{x}_j)(x_{ik} - \bar{x}_k)$$

## Korrelationskoeffizient

$$\rho_{jk} = \frac{\sigma_{jk}}{\sqrt{\sigma_{jj}\sigma_{kk}}} = \frac{\text{Kovarianz } jk}{\sqrt{\text{Varianz}(j) \cdot \text{Varianz}(k)}}$$

## Stichprobenkorrelation

$$r_{jk} = \frac{s_{jk}}{\sqrt{s_{jj}s_{kk}}}$$

# Distanzmaß

Euklidische Distanz  $d_E(x_A, x_B) = \left( \sum_{j=1}^p (x_{Bj} - x_{Aj})^2 \right)^{\frac{1}{2}} = ||x_B - x_A||$

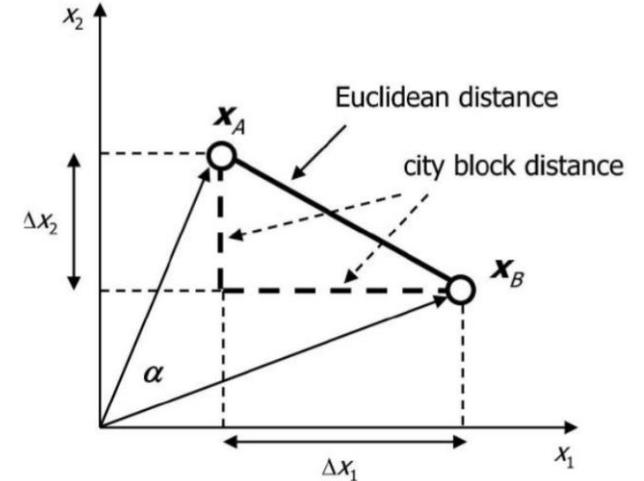
Manhattan Distanz  $d_M(x_A, x_B) = \sum_{j=1}^p |x_{Bj} - x_{Aj}|$

Minkowski Distanz  $d_{Mink}(x_A, x_B) = \left( \sum_{j=1}^p (x_{Bj} - x_{Aj})^m \right)^{\frac{1}{m}}$

Kosinus des Winkels  $\cos \alpha = \frac{x_A^T x_B}{\sqrt{(x_A^T x_A)(x_B^T x_B)}} = \frac{x_A^T x_B}{||x_A|| \cdot ||x_B||}$

Mahalanobis Distanz  $d_{Mahal}(x_A, x_B) = [(x_B - x_A)^T \Sigma^{-1} (x_B - x_A)]^{\frac{1}{2}}$   $\Sigma^{-1}$  inverse Kovarianzmatrix

$d_{Mahal}(x_i, \mu) = [(x_i - \mu)^T \Sigma^{-1} (x_i - \mu)]^{\frac{1}{2}}$  für i = 1 bis n,  $\mu$  ... Zentrum der Verteilung



# Linearkombinationen

$$u = b_1 x_1 + b_2 x_2 + \cdots + b_p x_p \quad u = x^T b$$

## Hauptkomponenten (PC)

$U = XB$   $\times \dots$  projizierte Datenwerte  $\rightarrow (n \times p) \text{ B } \dots$  (Spalten = Ladungen der PC  $\rightarrow (p \times p)$ )

$$b_j = (b_{1j}, \dots, b_{pj})^T \rightarrow \text{Max}(\text{Var}(u_j)) \quad \& \quad b_j^T b_l = 0 \quad \& \quad b_j^T b_j = 0 \quad \text{shape}(b_j) = p \times 1$$

$$\text{Var}(u_j) = \text{Var}(x_1 b_{1j} + \cdots + x_p b_{pj}) = b_j^T \text{Cov}(x_1, \dots, x_p) b_j = b_j^T \Sigma b_j$$

$\Sigma \dots$  theo. Kovarianzmatrix

Lagrange Problem  $\phi_j = b_j^T \Sigma b_j - \lambda_j (b_j^T b_j - 1)$   $j = 1 \text{ bis } p$   $\lambda_j \dots$  Langrange Parameter

$$\text{Var}(u_j) = b_j^T \Sigma b_j = b_j^T \lambda_j b_j = \lambda_j b_j^T b_j = \lambda_j$$

Anteil der ersten k PCs  $\frac{\lambda_1 + \cdots + \lambda_k}{\lambda_1 + \cdots + \lambda_p}$

# Clusteranalyse

k-means Zentroide  $\bar{x}_j = \frac{1}{n_j} \sum_{i \in I_j} x_i$  j = 1 bis k Zielfunktion:  $\sum_{j=1}^k n_j \sum_{i \in I_j} \|x_i - \bar{x}_j\|^2 \rightarrow \min$

## Hierachische Clustermethoden

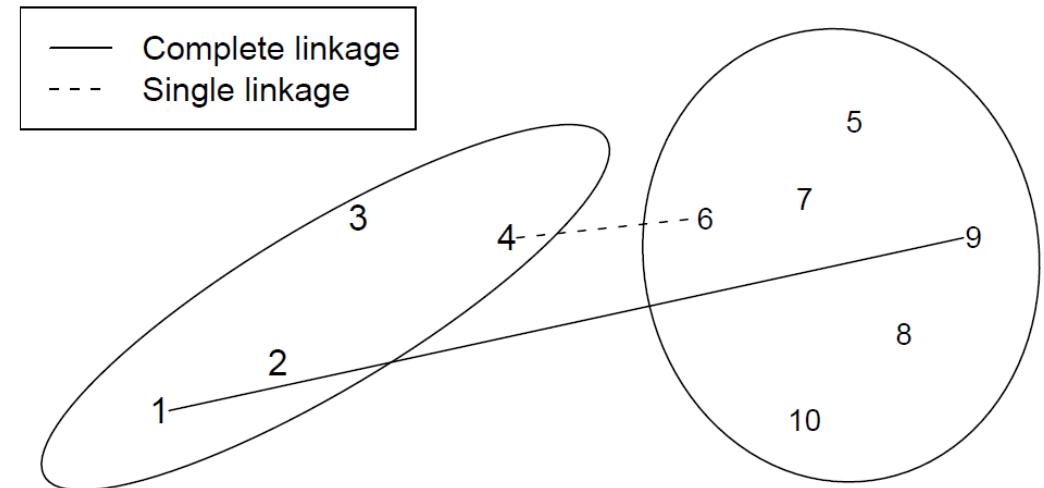
Complete linkage:  $\max_{i \in I_j, i' \in I_j} d(x_i, x_{i'})$

Single linkage:  $\min_{i \in I_j, i' \in I_j} d(x_i, x_{i'})$

Average linkage:  $\text{average } d(x_i, x_{i'})$   
 $i \in I_j, i' \in I_j$

Centroid Methode:  $d(\bar{x}_j - \bar{x}_{j'})$

Ward Methode:  $d(\bar{x}_j - \bar{x}_{j'}) \frac{\sqrt{2n_j n_{j'}}}{\sqrt{n_j + n_{j'}}$



## Fuzzy Clustering

c-means Zentroide  $\bar{x}_j = \frac{\sum_{i=1}^{n_j} u_{ij}^2 x_i}{\sum_{i=1}^{n_j} u_{ij}^2}$  Zielfunktion:  $\sum_{j=1}^k \sum_{i \in I_j} u_{ij}^2 \|x_i - \bar{x}_j\|^2 \rightarrow \min$   $u_{ij} \dots \text{Zugehörigkeit}$

# Gütemaße

Within-Cluster Sum-of-Squares (für Varianz)

$$W_k = \sum_{j=1}^k \sum_{i \in I_j} \left| |\bar{x}_j - \bar{x}| \right|^2$$

Between-Cluster Sum-of-Squares (für Heterogenität)

$$B_k \sum_{j=1}^k \left| |\bar{x}_j - \bar{x}| \right|^2 \text{ mit } \bar{x} = \frac{1}{k} \sum_{j=1}^k \bar{x}_j$$

Calinski-Harabasz-Index

$$CH_k = \frac{B_k / (k - 1)}{W_k (n - k)}$$

Hartigan-Index

$$H_k = \log \left( \frac{B_k}{W_k} \right)$$

# Diskriminanzanalyse

$$\phi_j(x) = \frac{1}{\sqrt{(2\pi)^p \det(\Sigma_j)}} \exp \left\{ -\frac{(x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j)}{2} \right\}$$

p ... Features,  $\Sigma$  ... Kovarianz, j ... Gruppe,  
 $\phi_j$  .. Dichtefunktion pro Gruppe

$$P(G = j|x) = \frac{\phi_j(x)p_j}{\sum_{l=1}^k \phi_l(x)p_l}$$

$p_j$  ... a-priori Wahrscheinlichkeit pro Gruppe. G ... Gruppenzugehörigkeit

$$x \text{ wird } j \text{ zugeteilt wenn gilt: } \log \left( \frac{P(G = j|x)}{P(G = l|x)} \right) = \log \left( \frac{\phi_j(x)p_j}{\phi_l(x)p_l} \right) = \log \left( \frac{\phi_j(x)}{\phi_l(x)} \right) + \log \left( \frac{p_j}{p_l} \right) > 0$$

## Lineare Diskriminanzanalyse (LDA)

es gilt:  $\Sigma_1 = \dots = \Sigma_k = \Sigma$

lineare Diskriminanzfunktion:

$$\delta_j(x) = x^T \Sigma^{-1} \mu_j - \frac{1}{2} \mu_j^T \Sigma^{-1} \mu_j + \log p_j$$

## Quadratische Diskriminanzanalyse (QDA)

$$\delta_j^{(q)}(x) = -\frac{1}{2} \log \left( \det(\Sigma_j) \right) - \frac{1}{2} (x - \mu_j)^T \Sigma_j^{-1} (x - \mu_j) + \log(p_j)$$