


# INTELLIGENTE DATENANALYSE IN MATLAB

Sequenzanalyse

# Überblick

## □ Schritte der Datenanalyse:



# Überblick

- Problemstellungen.
- Eigenschaften von Sequenzen.
- Modellierung von Sequenzen.
- Sequenzvorhersage.
- Lernen aus sequenziellen Daten.


# Problemstellungen

- Eingabe: Sequenz von Datenpunkten (Beobachtungen, Messpunkte) wie bspw. Zeitreihen.
  - Tägliche Messung der Temperatur an einem Ort.
  - EKG eines Patienten.
  - Entwicklung der Einwohnerzahl eines Landes.
  - Aktienkurse an aufeinanderfolgenden Börsentagen.
- Gesucht: Modell welches Sequenz erklärt wie z.B.  $f : x_t \mapsto x_{t+1}$ .

# Problemstellungen:

## Beispiel

### □ Vorhersage der Preisentwicklung:



# Problemstellungen:

## Aufgaben der Sequenzanalyse

- Beschreibung/Eigenschaften:
  - Untersuchen der Charakteristika der Sequenz über Kennzahlen und Diagramme.
- Modellierung und Prognose:
  - Formulierung eines stochastischen Modells und Schätzung der Modellparameter.
  - Vorhersage zukünftiger Werte aufgrund des angepassten Modells.
- Kontrolle und Regelung:
  - Optimale Steuerung des datenerzeugenden Prozesses.

# Problemstellungen:

## Aufgaben der Sequenzanalyse

- **Klassifikation sequenzieller Daten:**
  - z.B. Klassifikation von EKG-Zeitreihen zur Vorhersage von Herzproblemen.
  - Kernel-Modelle benötigen Kernel (Ähnlichkeitsfunktion zwischen Zeitreihen).
- **Anomalie-Erkennung:**
  - z.B. Erdbeben-/Tsunami-Vorhersage.
- **Clustering (Gruppieren von ähnlichen Zeitreihen).**
- **Retrieval/Suche:**
  - z.B. Query-by-Humming.

# Eigenschaften von Sequenzen:

## Darstellung und Kenngrößen

- Sequenz wird durch Paare  $S = \{(x_i, t_i)\}$  definiert.
  - ▣  $t_i$  gibt Position innerhalb der Sequenz an.
  - ▣ Äquidistante Folge (gleiche Abstände  $t_{i+1} - t_i$ ):  $S = \{x_t : t = 1 \dots n\}$
  - ▣ Nicht-äquidistante Folge:  $S = \{x(t_i) : i = 1 \dots n\}$

### □ Kenngrößen:

▣ Mittelwert bis Position  $t$ :  $\mu_x(t) = \frac{1}{t} \sum_{i=1}^t x_i$   $\mu_x = \mu_x(n)$

▣ Varianz bis Position  $t$ :  $\sigma_x^2(t) = \frac{1}{t} \sum_{i=1}^t (x_i - \mu_x(t))^2$   $\sigma_x^2 = \sigma_x^2(n)$



# Eigenschaften von Sequenzen:

## Korrelation

- Korrelation = lineare Abhängigkeit zwischen verschiedenen Zeitpunkten/Zeitreihen.

- Empirische Kovarianz:

$$c_{x,y} = \frac{1}{n} \sum_{t=1}^n (x_t - \mu_x)(y_t - \mu_y)$$

- Empirischer Korrelationskoeffizient:

$$r_{x,y} = \frac{c_{x,y}}{\sigma_x \sigma_y}$$

- Autokovarianzfunktion:

$$c_x(k) = \frac{1}{n-k} \sum_{t=1}^{n-k} (x_t - \mu_x)(x_{t+k} - \mu_x)$$

- Autokorrelationsfunktion:

$$r_x(k) = \frac{c_x(k)}{\sigma_x^2}$$

# Eigenschaften von Sequenzen:

## Korrelation – Beispiel




Abb. 1.1.1 KONKURSE in den USA, (Quelle: B.Greenstein [1935])




Abb. 1.1.2 Anzahl gefangener Luchse (Quelle: M.J. Campbell and A.M. Walker [1977])

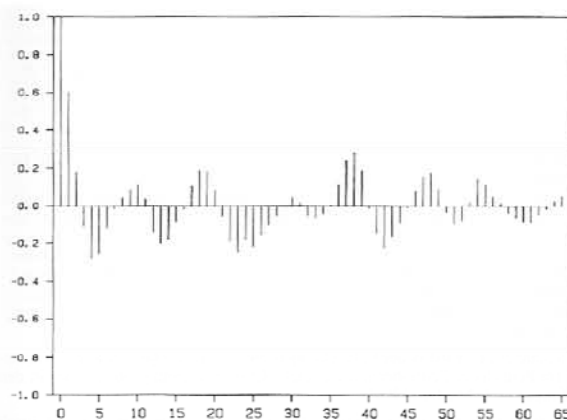


Abb. 1.2.3 Autokorrelationsfunktion der Reihe KONKURSE





Abb. 1.2.4 Autokorrelationsfunktion der Reihe LUCHS


# Modellierung von Sequenzen

Keine Abhängigkeiten:




Direkte Abhängigkeiten (Markov-Kette):


Erster Ordnung:



Zweiter Ordnung:



Indirekte Abhängigkeiten (Hidden-Markov-Modell):



# Modellierung von Sequenzen:

## Keine Abhängigkeiten

### □ Annahmen:


- Aufenthaltsort  $x$  zum Zeitpunkt  $t$  ist unabhängig vom Aufenthaltsort zu einem vorherigen Zeitpunkt.

### □ Beispiel: Rauschen (White Noise)

- Mittelwert:  $\mu_x(t) = 0$

- Varianz:  $\sigma_x^2(t) = \sigma_x^2$

- Autokovarianzfunktion:  $c_x(k) = 0$



# Modellierung von Sequenzen:

## Direkte Abhängigkeiten

### □ Annahmen:

- Aufenthaltsort  $x$  zum Zeitpunkt  $t$  hängt direkt von den  $k$  Aufenthaltsorten zu den Zeitpunkten  $t - k, \dots, t - 1$  ab.

### □ Beispiel: Random Walk

- Mittelwert:

$$\mu_x(t) = x_0$$


- Varianz:

$$\sigma_x^2(t) = t\sigma_x^2$$

- Beste Prognose:

$$E(x_{t+k} | x_t) = x_t$$

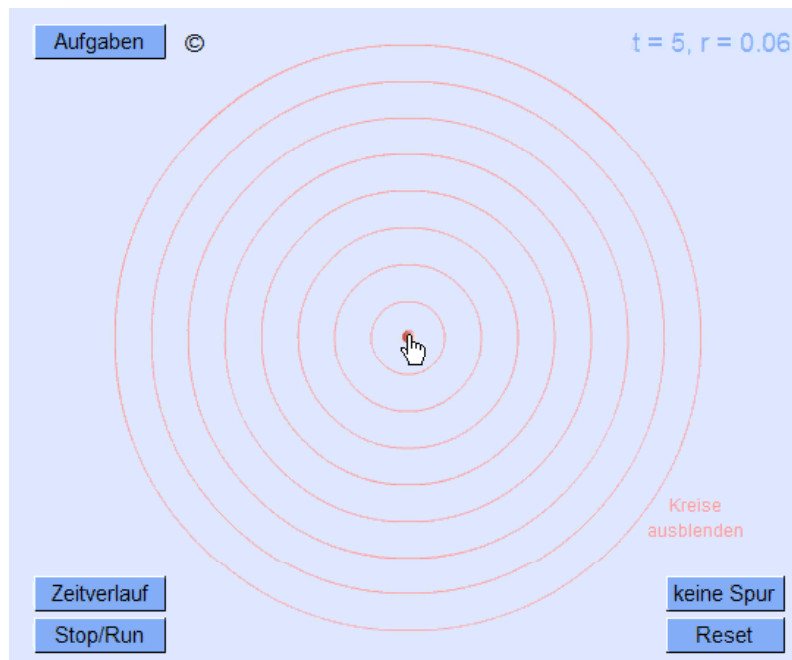
$$\text{Var}(x_{t+k} | x_t) = k\sigma_x^2$$



# Modellierung von Sequenzen:

## Direkte Abhängigkeiten

- Beispiel für Markov-Kette (1. Ordnung): Random Walk
  - ▣ Aufenthaltsort zum Zeitpunkt  $t$  = Aufenthaltsort zum Zeitpunkt  $t - 1$  zuzgl. eine zufällige Strecke.




White Noise

# Modellierung von Sequenzen:

## Indirekte Abhängigkeiten

### □ Annahmen:


- Aufenthaltsort  $x$  zum Zeitpunkt  $t$  hängt direkt vom Zustand  $z$  zum Zeitpunkt  $t$  ab.
- Zustand  $z$  zum Zeitpunkt  $t$  hängt direkt von den  $k$  Zuständen zu den Zeitpunkten  $t - k, \dots, t - 1$  ab.
- Zustände sind unbekannt/unbeobachtet.



# Modellierung von Sequenzen:

## Indirekte Abhängigkeiten

- Beispiel für HMM (1. Ordnung): Wortartenerkennung
  - ▣ Zuordnung eines Worts  $x$  zu Wortart (Zustand  $z$ ).





# Modellierung von Sequenzen:

## Indirekte Abhängigkeiten

- Einsatzmöglichkeiten von HMMs:
  - Vorhersagen zukünftiger Beobachtungen.
    - z.B. welches Wort wird als nächstes eingegeben, Autovervollständigung.
  - Vorhersagen über zukünftige/vergangene Zustände bzw. wahrscheinlichste Zustandsfolge einer Sequenz.
    - z.B. Spracherkennung (Beobachtung = Audiosignale, Zustände = Wörter).
  - Parameterschätzung/Lernen des HMMs.

# Sequenzvorhersage

- Sequenzvorhersage an den Beispielen...
  - Moving-Average-Prozess (MA).
  - Autoregressiver Prozess (AR).
  - Autoregressiver Moving-Average-Prozess (ARMA).
- Grundidee: Sequenz ist Linearkombination von Werten aus einer Sequenz von Rauschen (White Noise).
  - Sequenz von  $n$  unabhängigen Rauschwerten  $\{r_1, \dots, r_n\}$ .
- Ziel: Faktoren dieser Linearkombination aus Daten schätzen.

# Sequenzvorhersage:

## Moving-Average-Prozess

### □ Annahmen:

- Aufenthaltsort  $x$  zum Zeitpunkt  $t$  ist das gewichtete Mittel aus den  $q + 1$  Rauschwerten zu den Zeitpunkten  $t - q, \dots, t$ :

$$x_t = r_t + \sum_{j=1}^q \alpha_j r_{t-j}$$

mit Rauschwerten  $r_i$  wobei  $E(r_i) = \mu_r = 0$  und  $Var(r_i) = \sigma_r^2$ .

- Ziel: Berechnung der Gewichte  $\alpha_j$ .

# Sequenzvorhersage:

## Moving-Average-Prozess

- Beispiel: Ein Eisverkäufer möchte Verkaufszahlen von Eiscreme vorhersagen.
  - Nur bisherige Verkaufszahlen  $x_t$  gegeben.
- Annahme: Kunden essen nur Eis wenn in den letzten Tagen die Sonne oft zu sehen war.
- Modell:
  - (Unbeobachtete) Rauschwerte  $r_t$  sind die Sonnenstunden pro Tag normiert auf Mittelwert 0.
  - Beispiel für Modell mit Modellparametern:

$$x_t = r_t + 0,8 \cdot r_{t-1} + 0,5 \cdot r_{t-2} + 0,2 \cdot r_{t-3}$$

# Sequenzvorhersage:

## Moving-Average-Prozess

- Berechnung der Gewichte  $\alpha_j$  am Beispiel eines MA(1)-Prozesses:  $x_t = r_t + \alpha_1 r_{t-1}$

- Umformung des Prozesses ergibt:

$$\begin{array}{l}
 r_j = x_j - \alpha_1 r_{j-1} \\
 r_{j-1} = x_{j-1} - \alpha_1 r_{j-2} \\
 \vdots \\
 r_1 = x_1
 \end{array}
 \Rightarrow
 \begin{array}{l}
 r_j = x_j - \alpha_1 r_{j-1} \\
 r_j = x_j - \alpha_1 (x_{j-1} - \alpha_1 r_{j-2}) \\
 = x_j + (-\alpha_1)^1 x_{j-1} + (-\alpha_1)^2 r_{j-2} \\
 \vdots
 \end{array}
 \Rightarrow
 r_j(\boldsymbol{\alpha}) = \sum_{i=0}^{j-1} (-\alpha_1)^i x_{j-i}$$

- Idee: Minimieren der Varianz der Rauschfolge

$Var(r_t) = \sigma_r^2$  mit Mittelwert  $E(r_t) = \mu_t = 0$ :

$$\boldsymbol{\alpha}^* = \arg \min_{\boldsymbol{\alpha}} \frac{1}{t} \sum_{j=1}^t (r_j - \mu_r)^2 = \arg \min_{\boldsymbol{\alpha}} \sum_{j=1}^t r_j(\boldsymbol{\alpha})^2$$

Optimierungskriterium

# Sequenzvorhersage:

## Moving-Average-Prozess

- Iteratives Lösen des Minimierungsproblems mit Startlösung  $r_j^0 = 0 \quad \forall j = 1 \dots t$  und  $\alpha_j^0 = 0 \quad \forall j = 1 \dots q$ .
- Taylor-Approximation der Rauschterme  $r_j$  in der  $l$ -ten Iteration:  $r_j^{l+1}(\alpha) = r_j^l + r_j'(\alpha^l)^T (\alpha - \alpha^l)$

Gradient von  $r_j$  an der Stelle  $\alpha^l$

- Minimieren der Varianz durch Null-Setzen der Ableitung  $\min \sum_{j=1}^t r_j(\alpha)^2 \Rightarrow 0 = \sum_{j=1}^t \frac{\partial r_j^{l+1}(\alpha^l)}{\partial \alpha^l}(\alpha^{l+1})$  und Bestimmen von  $\alpha^{l+1}$ .
- Wiederholung bis  $\alpha$  konvergiert.

# Sequenzvorhersage:

## Autoregressiver Prozess

### □ Annahmen:

- Aufenthaltsort  $x$  zum Zeitpunkt  $t$  ist die Summe aus dem Rauschwert zum Zeitpunkt  $t$  und dem gewichteten Mittel der  $p$  Aufenthaltsorte zu den Zeitpunkten  $t - p, \dots, t - 1$ :

$$x_t = r_t + \sum_{j=1}^p \beta_j x_{t-j}$$

mit Rauschwerten  $r_t$  wobei  $E(r_t) = 0$  und  $Var(r_t) = \sigma_r^2$ .

- Ziel: Berechnung der Gewichte  $\beta_j$ .

# Sequenzvorhersage:

## Autoregressiver Prozess

- Beispiel: Ein Eisverkäufer möchte Verkaufszahlen von Eiscrème vorhersagen.
  - Nur bisherige Verkaufszahlen  $x_t$  gegeben.
- Annahme: Kunden essen nur Eis wenn sie in den letzten Tagen wenig Eis gegessen haben.
- Modell:
  - Verkaufszahl  $x_t$  ist nur abhängig von den vorherigen Verkaufszahlen und einem Rauschwert  $r_t$  (Laune der Kunden).
  - Beispiel für Modell mit Modellparametern:

$$x_t = r_t - 0,7 \cdot x_{t-1} - 0,6 \cdot x_{t-2} + 0,1 \cdot x_{t-3}$$



# Sequenzvorhersage:

## Autoregressiver Prozess

- Berechnung der Gewichte  $\beta_j$  eines AR-Prozesses:

$$x_t = r_t + \sum_{j=1}^p \beta_j x_{t-j}$$

- Idee: Minimieren des mittleren quadratischen Fehlers.

$$\beta^* = \arg \min_{\beta} \frac{1}{t-p-1} \sum_{i=p+1}^t \left( x_i - r_i - \sum_{j=1}^p \beta_j x_{i-j} \right)^2 = \arg \min_{\beta} \sum_{i=p+1}^t \left( x_i - \sum_{j=1}^p \beta_j x_{i-j} \right)^2$$

Erwartungswert Null & konstante Varianz

$$\beta^* = \arg \min_{\beta} \left( \begin{bmatrix} x_{p+1} \\ x_{p+2} \\ \vdots \\ x_n \end{bmatrix} - \begin{bmatrix} x_p & x_{p-1} & \cdots & x_1 \\ x_{p+1} & x_p & \cdots & x_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_{n-1} & x_{n-2} & \cdots & x_{n-p} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_p \end{bmatrix} \right)^2 \Rightarrow \beta^* = A^+ y$$

y

A

Pseudo-Inverse von A

# Sequenzvorhersage:

## Autoregressiver Moving-Average-Prozess

- Motivation:
  - Fast jeder endliche Datensatz gut an MA- oder AR-Modell mit hoher Ordnung anpassbar.
  - Je größer die Ordnung, desto mehr Parameter.
  - Ziel: Modell mit möglichst wenigen Parametern welches zudem reale Bedeutung (Interpretation) hat.
- Idee: Kombination von MA- und AR-Modellen zu ARMA( $p, q$ )-Prozess.

$$x_t = r_t + \sum_{j=1}^q \alpha_j r_{t-j} + \sum_{j=1}^p \beta_j x_{t-j}$$

# Sequenzvorhersage:

## Autoregressiver Moving-Average-Prozess

- Überlagerungssatz von ARMA-Prozessen:
  - $x_t$  und  $y_t$  seien zwei unabhängige ARMA-Prozesse der Ordnung  $(p_1, q_1)$  und  $(p_2, q_2)$ .
  - Summe  $z_t = x_t + y_t$  ist wieder ein ARMA-Prozess der Ordnung  $(p, q)$ .
  - Für AR-Ordnung gilt:  $p \leq p_1 + p_2$
  - Für MA-Ordnung gilt:  $q \leq \max(p_1 + q_2, p_2 + q_1)$
- Folgerung:
  - Summe zweier MA-Prozesse ergibt wieder MA-Prozess.
  - Summe zweier AR-Prozesse ergibt ARMA-Prozess.

# Sequenzvorhersage:

## Autoregressiver Moving-Average-Prozess

- Beispiel: Vorhersage der Werbeausgaben zweier konkurrierender Unternehmen.
  - Nur bisherige Werbeausgaben  $x_t$  und  $y_t$  gegeben.
- Modell:
  - Werbeausgabe  $x_t$  ist abhängig von der vorherigen Werbeausgabe des Konkurrenten  $y_{t-1}$  und einem Rauschwert.
  - Werbeausgabe  $y_t$  ist abhängig von der vorherigen Werbeausgabe des Konkurrenten  $x_{t-1}$  und einem Rauschwert.

$$\begin{aligned} x_t &= r_t + \beta_1 y_{t-1} \\ y_t &= r'_t + \beta'_1 x_{t-1} \end{aligned} \quad \Rightarrow \quad x_t = r_t + \beta_1 (r'_{t-1} + \beta'_1 x_{t-2}) = r_t + \alpha_1 r_{t-1} + \beta_2 x_{t-2}$$

ARMA(2,1)-Prozess

# Sequenzvorhersage:

## Autoregressiver Moving-Average-Prozess

- Berechnung der Gewichte  $\alpha_j$  und  $\beta_j$  eines ARMA-Prozesses analog zu MA-Prozessen.
- Erweiterungen von ARMA-Prozessen:
  - ARIMA: Ist  $x_t$  nach  $d$ -maligem Anwenden des Differenzfilters ein stationärer ARMA( $p, q$ )-Prozess, so bezeichnet man den Prozess  $x_t$  als ARIMA( $p, d, q$ )-Prozess.
  - ARMAX: Abhängigkeiten zwischen den Rauschwerten.
  - ...

# Sequenzvorhersage:

## Autoregressiver Moving-Average-Prozess

- Vorhersage mittels angepasstem ARMA-Prozess (Prognose für  $x_{t+h}$ ):
  - $x_t, x_{t-1}, \dots, x_1$  entsprechen den tatsächlichen Beobachtungen.
  - $x_{t+h}, \dots, x_{t+1}$  werden durch ihre Prognosen ersetzt.
  - Störterme  $r_t, r_{t-1}, \dots, r_1$  entsprechen den Prognosefehlern der 1-Schrittprognosen in der Vergangenheit.
  - Störungen  $r_{t+h}, \dots, r_{t+1}$  werden durch ihren Erwartungswert Null ersetzt.

# Lernen aus sequenziellen Daten:

## Problemstellung

- Gegeben: sequenzielle Trainingsdaten mit bekanntem Zielattributen (gelabelte Daten).
- Eingabe: Sequenz von Attribut-Belegungen  $\mathbf{x}$ .
- Ausgabe: Belegung des/der Zielattribut(e)  $y$ .
- Gesucht: Modell  $f : \mathbf{x} \mapsto y$ .
- Ansatz: Verwendung von Kernel-Modellen basierend auf Sequenz-Kernel.
  - Quadratische Euklidische Distanz (RBF-Kernel).
  - Dynamic Time Warping (DTW-Kernel).
  - Editierdistanz.


# Lernen aus sequenziellen Daten:

## Quadratische Euklidische Distanz

- Für numerische Attribute.
- Sequenzen als Vektoren auffassen und quadratischen euklidischen Abstand bestimmen:

$$D_{RBF}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^t (x_i - y_i)^2 \quad \Rightarrow \quad k_{RBF}(\mathbf{x}, \mathbf{y}) = \exp(-\lambda D_{RBF}(\mathbf{x}, \mathbf{y}))$$

- Vershobene/gedehnte Motive werden nicht berücksichtigt.






# Lernen aus sequenziellen Daten:

## Dynamic Time Warping

- Für numerische Attribute.
- Zuordnungsfunktionen  $\pi_x(i) \in [1, t_x]$  und  $\pi_y(i) \in [1, t_y]$ .
- DTW-Distanz ist Minimum des verschobenen (quadratischen euklidischen) Abstands:

$$D_{DTW}(\mathbf{x}, \mathbf{y}) = \min_{\pi_x, \pi_y} \sum_{i=1}^t (x_{\pi_x(i)} - y_{\pi_y(i)})^2 \Rightarrow k_{DTW}(\mathbf{x}, \mathbf{y}) = \exp(-\lambda D_{DTW}(\mathbf{x}, \mathbf{y}))$$



# Lernen aus sequenziellen Daten:

## Dynamic Time Warping

- Berechnung mit dynamischer Programmierung, rekursive Definition:
  - Sei  $\gamma(i, j)$  minimale (verschobene) quadrierte euklidische Distanz bis zu den Zeitpunkten  $i$  und  $j$ :

$$\gamma(i, j) = (x_i - y_j)^2 + \min(\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1))$$

- Algorithmus:

DTW(Sequenzen  $\mathbf{x}$  und  $\mathbf{y}$ )

Setze  $\gamma(0,0) = 0, \forall i, j \gamma(i,0) = \infty, \gamma(0, j) = \infty$

FOR  $i = 1 \dots t_x$

FOR  $j = 1 \dots t_y$

$$\gamma(i, j) = (x_i - y_j)^2 + \min(\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1))$$

RETURN  $\gamma(t_x, t_y)$

# Lernen aus sequenziellen Daten:

## Editierdistanz

- Für nominale und ordinale Attribute (Sonderform von Dynamic Time Warping).
- Editierdistanz ist minimale Anzahl an Operationen (Einfügen, Löschen, Ersetzen) um zwei Sequenzen ineinander zu überführen.
- Berechnung mit dynamischer Programmierung, rekursive Definition:
  - Sei  $\gamma(i, j)$  minimale Editierdistanz zu den Zeitpunkten  $i$  und  $j$ :
$$\gamma(i, j) = [x_i \neq y_j] + \min(\gamma(i-1, j-1), \gamma(i-1, j), \gamma(i, j-1))$$

# Zusammenfassung

- Zahlreiche Problemstellungen/Anwendungsgebiete
  - Charakterisierung, Visualisierung, Beschreibung.
  - Lernen von/aus sequenziellen Daten.
- Modellierung direkter Abhängigkeiten (Markov-Kette).
- Modellierung indirekter Abhängigkeiten (HMM).
- Vorhersage univariater Sequenzen durch stochastische Prozesse (z.B. MA, AR, ARMA usw.)
- Sequenz-Kernel (z.B. DTW).