

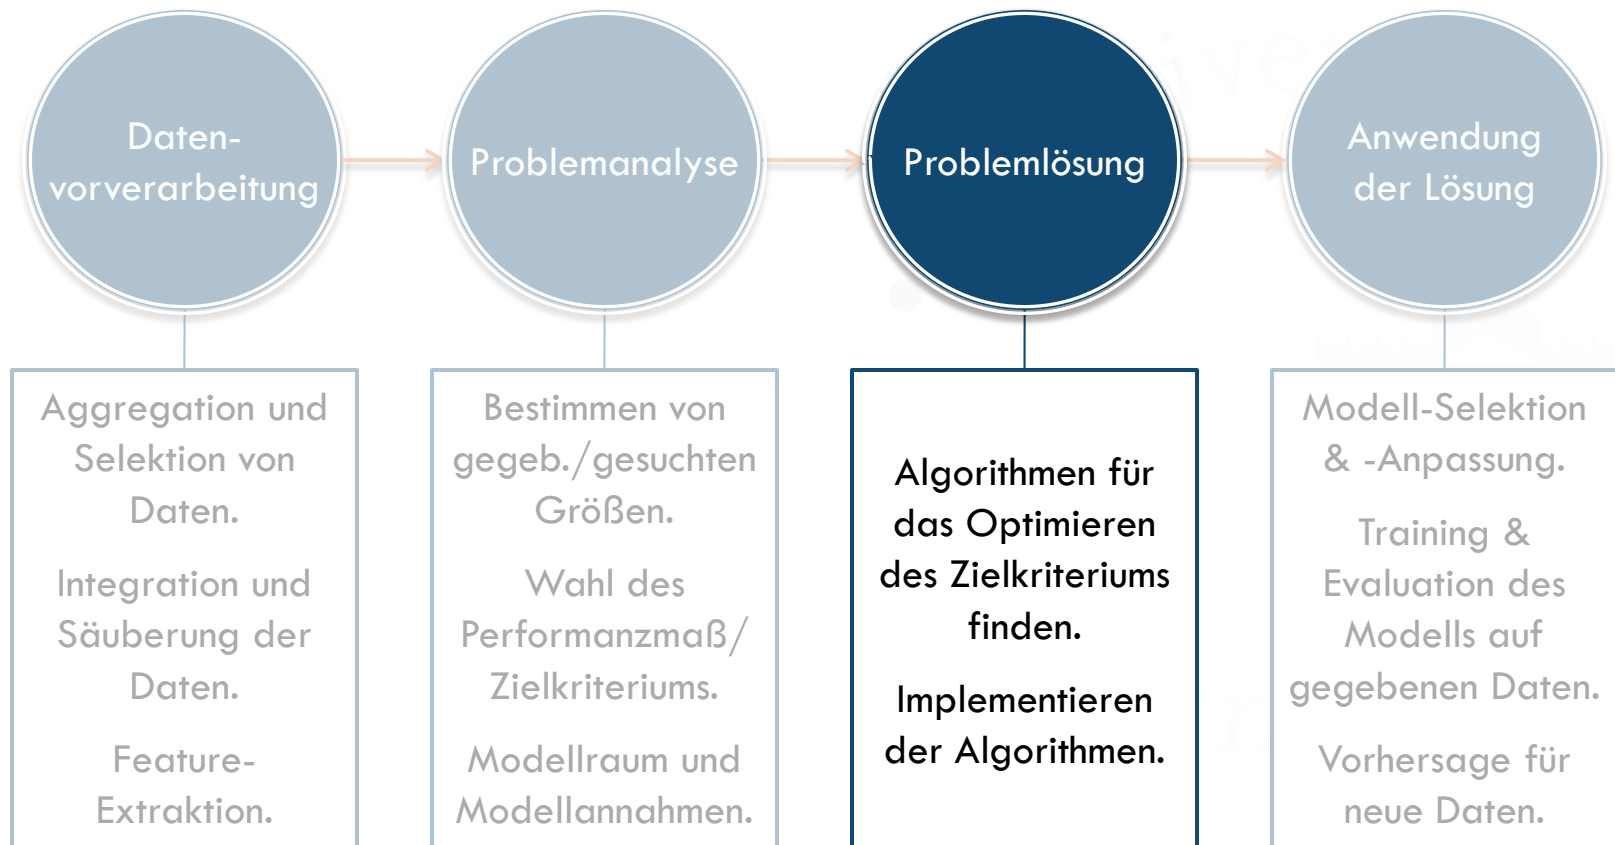


INTELLIGENTE DATENANALYSE IN MATLAB

Sequenzanalyse

Überblick

□ Schritte der Datenanalyse:



Überblick

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


Problemstellung

- 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. $f : x_t \mapsto x_{t+1}$.

Problemstellung

Beispiel

□ Vorhersage der Preisentwicklung:



Problemstellung

Aufgaben der Sequenzanalyse

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

Problemstellung

Aufgaben der Sequenzanalyse

4. **Klassifikation sequenzieller Daten:**
 - ▣ Beispiel: Klassifikation von EKG-Zeitreihen zur Vorhersage von Herzproblemen.
 - ▣ Kernel-Modelle benötigen Kernel (Ähnlichkeitsfunktion zwischen Zeitreihen).
5. **Anomalie-Erkennung:**
 - ▣ Beispiel: Erdbeben-/Tsunami-Vorhersage.
6. **Clustering (Gruppieren von ähnlichen Zeitreihen).**
7. **Retrieval/Suche:**
 - ▣ Beispiel: 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:

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

Z-Score-normalisiert

- 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.

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 α_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 α_j am Beispiel eines

MA(1)-Prozesses: $x_t = r_t + \alpha_1 r_{t-1}$

- Umformung des Prozesses ergibt:

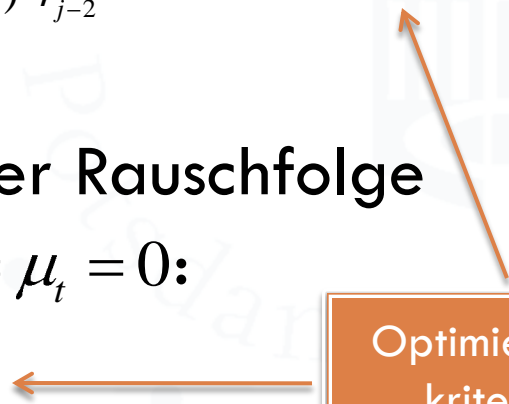
$$\begin{array}{l}
 r_j = x_j - \alpha_1 r_{j-1} \\
 r_{j-1} = x_{j-1} - \alpha_1 r_{j-2} \\
 \vdots \\
 r_1 = x_1
 \end{array}
 \implies
 \begin{array}{l}
 r_j = x_j - \alpha_1 r_{j-1} \\
 r_j = x_j - \alpha_1 (x_{j-1} - \alpha_1 r_{j-2}) \\
 = x_j + (-\alpha_1)^1 x_{j-1} + (-\alpha_1)^2 r_{j-2} \\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

- Idee: Minimieren der Varianz der Rauschfolge

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

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

Optimierungs-
kriterium



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 α^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 α^{l+1} .
- Wiederholung bis α 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 β_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 β_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.

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

ARMA(2,1)-Prozess

Sequenzvorhersage

Autoregressiver Moving-Average-Prozess

- Berechnung der Gewichte α_j und β_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:

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

- 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:

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



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).