

Skript zur Vorlesung  
**Managing and Mining Multiplayer Online Games**  
im Sommersemester 2012

# Kapitel 8: Zeitliche Verhaltensmodellierung

Skript © 2012 Matthias Schubert

[http://www.dbs.informatik.uni-muenchen.de/cms/VO\\_Managing\\_Massive\\_Multiplayer\\_Online\\_Games](http://www.dbs.informatik.uni-muenchen.de/cms/VO_Managing_Massive_Multiplayer_Online_Games)

## Kapitelüberblick

---

- Verhalten und Sequenzen
- Vergleiche zwischen Sequenzen
- Finden häufiger Teilsequenzen
- Markow-Ketten
- Hidden Markow-Ketten
- Zeitreihen und Feature-Transformationen
- Vergleich zwischen Zeitreihen
- Poisson-Prozesse

# Spielerverhalten

## Beispiele für Spielerverhalten

- Abfolge der Züge im Schach
  - Folge von Bewegung, Aktionen und Interaktionen in einen MMORPG
  - Folge von Aufträgen an die eigenen Einheiten in RTS Games
- 
- Abstrakt besteht Verhalten aus einer Folge von möglichen Aktionen
  - Einfachstes Modell für Verhalten sind Strings oder Sequenzen.

**Definition:** Sei  $A = \{A_1, \dots, A_n\}$  ein endliches Alphabet von  $n$  möglichen Spieleraktionen. Dann heißt der  $l$ -Tupel  $(a_1, \dots, a_l) \in A \times \dots \times A$  Sequenz der Länge  $l$  über  $A$ .

## Bemerkung:

- Modell beschreibt erstmal nur Beobachtung und unterscheidet nicht zwischen möglichen und unmöglichen Sequenzen.
- Modell vernachlässigt die Zeit zwischen den Aktionen

3

## Beispiel: SC II Zerg Rushes

Aggressive Pool First - Liquipedia Starcraft 2 Wiki - Mozilla Firefox

http://wiki.teamliquid.net/starcraft2/Aggressive\_Pool\_First

10 pool build order

While the build is a cheese build, in that it needs to do damage or else you will be behind, it is made to transition into a standard game after the first 6 or 8 Zerglings. However it can be turned into all in simply by continuing to build Zerglings.

### Basic Build Order

All the variations of this opening are shown below:

#### 6 Pool

- 5 Spawning Pool
- 5 Drone
- 6 Drone
- @ 100% Spawning Pool, 3 pairs of Zerglings
- 10 Zergling (Extractor Trick)
- 11 Overlord

#### 7 Pool

- 7 Spawning Pool
- 6 Drone
- 7 Drone
- 8 Overlord
- @ 100% Spawning Pool, 3 pairs of Zerglings
- a 4th pair of Zerglings when the larva becomes available

#### 8 Pool

- 8 Spawning Pool
- 7 Drone
- 8 Drone
- 9 Overlord
- @ 100% Spawning Pool, 3 pairs of Zerglings
- a 4th pair of Zerglings when the larva becomes available

#### 9 Pool

- 9 Spawning Pool
- 8 Drone
- 9 Drone
- 10 Drone (Extractor Trick)
- 11 Overlord
- @ 100% Spawning Pool, 3 pairs of Zerglings
- a 4th pair of Zerglings when the larva becomes available

#### 10 Pool

- 10 Spawning Pool
- 9 Drone
- 10 Overlord
- 10 Drone (Extractor Trick)
- @ 100% Spawning Pool, 3 pairs of Zerglings
- a 4th pair of Zerglings when the larva becomes available

### Notes

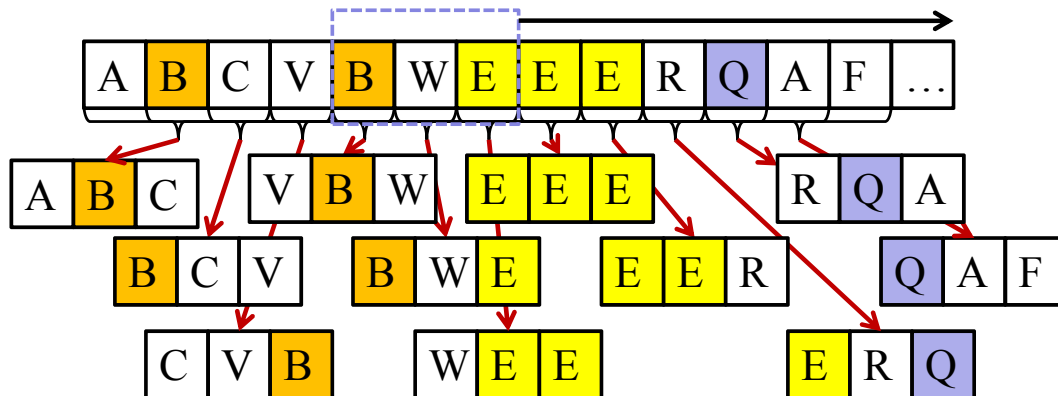
The only key difference in the variations, besides the number of drones and timing of Zerglings, is that a 6 Pool doesn't allow for an Overlord to be made before the Zerglings are ready. 10 Pool allows you to start your Queen almost immediately after your initial 6 Zerglings are made.

### Spawning Pool timings

4

## Subsequenzen und Aufteilung der Beobachtung

- Wann wird welcher Spieler wie lange beobachtet?
- Je länger ein Spieler beobachtet wird desto unwahrscheinlicher wird es das ein anderer Spieler sich sehr ähnlich verhält.
- Zum Finden typischer Verhaltensmuster wird eine Sequenz in der Regel in Subsequenzen aufgeteilt.
- Aufteilen durch Windowing  
Schiebe ein Fenster der Länge  $k$  über die Sequenz und betrachte alle Teilsequenzen: im Beispiel ist  $k = 3$



5

## Subsequenzen und Aufteilung der Beobachtung

**Problem:** Eine Sequenz der Länge  $l$  hat  $l - (k-1)$   $k$ -elementige Subsequenzen und viele davon sind irrelevant.

**Idee:** Nur Sequenzen die in einer bestimmten Häufigkeit auftreten sind interessant.

### Frequent Subsequenz Mining

Finde alle Teilsequenzen einer Sequenz-Datenbank, die häufiger als *minsup* vorkommen. (vgl. frequent Itemset Mining)

⇒ Länge der Sequenz ist beliebig

⇒ Suchraum ist größer als beim Itemset Mining  
(mehrfaches Auftreten eines Elements und Reihenfolge)

6

## Frequent Subsequence Mining

---

- Häufigkeit  $fr(S, G)$  von  $S$  in der Sequence  $G$ :  
Zähle Vorkommen von  $S$  in  $G$ .
- relative Häufigkeit von  $S$ :

$$\phi(S, G) = \frac{fr(S, G)}{|G| - |S| + 1}$$

- Sequenzbeschreibung von  $G$ :  
 $\delta(G) = \{(S, \phi(S, G)) \mid S \in G\}$
- Mining Sequential Patterns ist gut erforscht  
=> Viele Lösungsansätze und Algorithmen

7

## Suffix Bäume

---

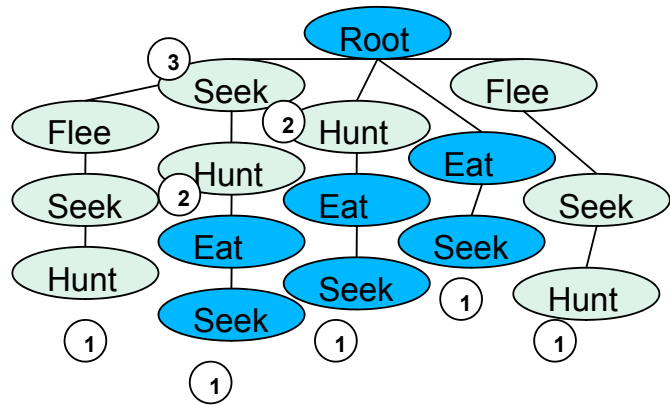

Eigenschaften eines Suffix Baumes  $ST$  über dem Alphabet  $A$  für Sequenz  $G$  mit  $|G| = n$ :

- $ST$  hat genau  $n+1$  Blattknoten, die von  $0$  bis  $n$  nummeriert werden.
- Alle inneren Knoten außer der Wurzel haben mindestens 2 Nachfolger.
- Kanten repräsentieren nicht-leere Teilsequenzen.
- Alle Kanten mit dem gleichen Startknoten beginnen mit einem anderem Element von  $A$ .
- Für jeden Blattknoten  $i$ , ist die Konkatenation der Kanten des Pfades von der Wurzel zu  $i$  die Subsequenz  $[i, \dots, n-1]$ .

8

# Suffix Trees

- Beispiel: Alphabet  $A = \{\text{eat, hunt, seek, flee}\}$ ,
- Einfügen:  
 $S_1 = (\text{seek, hunt, eat, seek})$ ,  
 $S_2 = (\text{seek, flee, seek, hunt})$



9

## Interessantheit von Teilsequenzen

- interessant  $\neq$  häufig
- Beispiel: select drones, collect crystals, train drone,..“  
Aber: Die ersten Aktionen in SC II sind fast immer identisch.
- die Anzahl häufiger Teilsequenzen kann sehr groß sein.
- die meisten davon beschreiben Standard-Game-Play.
- Interessantheit sollte immer im Bezug auf ein weiteres Merkmal untersucht werden :
  - Karte (Bezug auf eine Örtlichkeit)
  - Spieler (Bezug auf das Individuum)
  - Strategie (Bezug auf Situation)
  - Kombination mehrerer Bezüge (Karte und Strategie..)

10

## Maß für die Interessantheit

- Verwendung von Maßen für die Korrelation:
- Finde eine Zielvariable: z.B. player\_id
- Finde interessant Ereignisse: z.B. Boss-Kämpfe, Flaggenträger,...
- Finde Orte die ähnliches Verhalten auslösen: Spawn-Punkte für Monster, Flaggenabgabepunkte, Ort einer Bossbegegnung...
- Berechnung durch zum Beispiel:
  - **Mutual Information**

$$MI(S, \text{Player\_ID}) = \sum_{P \in \text{Players}} \sum_{S \in \{S_1, \bar{S}_1\}} \Pr[S, P] \cdot \log \frac{\Pr[S, P]}{\Pr[S] \cdot \Pr[P]}$$



- **Odds Ratio**

$$\text{oddsR}_S(G_1, G_2) = \frac{\varphi(S, G_1)}{\varphi(S, G_2)}$$

11

## Verwendung von Frequent Subsequences

- **Identifikation von Spieler:** Verwende das Vorkommen der k-„interessantesten“ Teilsequenzen als Dimensionen eines Vektorraums. (hier Interessantheit = höchst MI mit Player\_id)  
=> Beschreibe Spieler als Vektor der beobachteten Teilsequenzen.
- **Suche ortsspezifisches Verhalten:** Vergleiche die Häufigkeit von Handlungen auf der gesamten Karte mit der Anzahl der Handlungen in einem bestimmten Gebiet. (Odds-Ratio)



12

## Vergleiche zwischen 2 Sequenzen

---

**Gegeben:** Alphabet  $A$  und eine Sequenzdatenbank

$$DB \subseteq \{(x_1, \dots, x_k) \mid k \in \mathbb{N} \wedge x_i \in A \text{ für } 1 \leq i \leq k\}.$$

**Gesucht:** Die Ähnlichkeit von  $S1, S2 \in DB$ .

- **Hamming Distanz:** Anzahl der unterschiedlichen Einträge aller Positionen.

Für 2 Sequenzen mit  $|S1|=|S2|=k$ :

$$Sim_{Ham}(S1, S2) = \sum_{i=0}^k \begin{cases} 0 & \text{if } s_{1,i} = s_{2,i} \\ 1 & \text{else} \end{cases}$$

*Anmerkung:* Bei unterschiedlich langen Sequenzen auffüllen der kürzeren mit „-“ (Gap Symbol).

Beispiel:  $S1 = (A, B, B, A, B)$  und  $S2 = (A, A, A, A, A)$

$$\left. \begin{array}{l} (A, B, B, A, B) \\ (A, A, A, A, A) \end{array} \right\} Sim_{Ham}(S1, S2) = 2$$

13

## Levenshtein Distanz

---

- **Hamming Distanz:** Berechnet minimale Kosten um  $S1$  in  $S2$  zu verwandeln. Dabei sind nur Substitutionen der einzelnen Elemente erlaubt. (Aus B mache A.)
- **Idee:** Erweitere die erlaubten Änderungsoperationen durch Löschen und Einfügen von Symbolen.
- **Levenshtein Distanz:** Minimale Kosten um  $S1$  in  $S2$  mit den 3 Operationen „Löschen“, Einfügen und Substitution zu verwandeln.

$$\left. \begin{array}{l} (A, B, B, A, B) \\ (A, -, -, A, B) \end{array} \right\} Sim_{Lev}(S1, S2) = 2$$

14

# Berechnung der Levenshtein Distanz

**Gegeben:** Zwei Sequenzen  $S1, S2$  über dem Alphabet  $A$  mit  $|S1|=n$  und  $|S2|=m$ .

**Gesucht:**  $Dist_{Lev}(S1, S2)$

Berechnung der Levenshtein Distanz mit dynamischer Programmierung:

Sei  $D$  eine  $n \times m$ -Matrix über  $IN$  mit:

$$D_{0,0} = 0$$

$$D_{0,i} = i, \quad 0 \leq i \leq n$$

$$D_{j,0} = j, \quad 0 \leq j \leq m$$

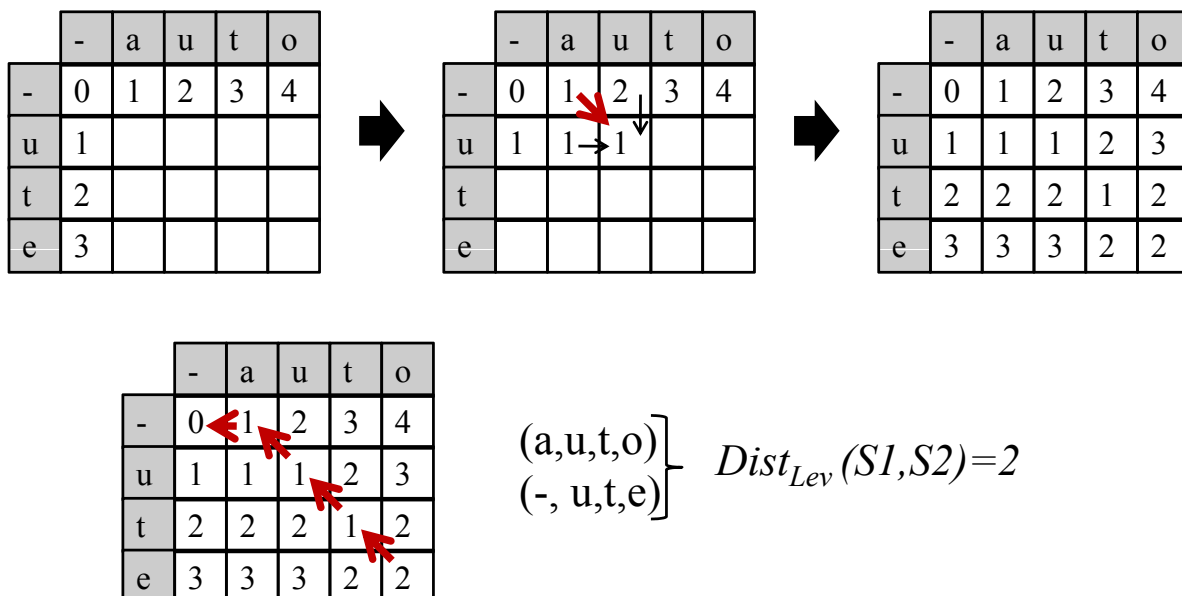
$$D_{i,j} = \min \begin{cases} D_{i-1,j-1} + 0, \text{ falls } s_{1i} = s_{2j} \\ D_{i-1,j-1} + 1, (\text{Ersetzung}) \\ D_{i,j-1} + 1, (\text{Einfügung}) \\ D_{i-1,j} + 1, (\text{Löschung}) \end{cases} \quad \text{für } 1 \leq i \leq n, \quad 1 \leq j \leq m$$

Nach Aufbau der Matrix enthält der Eintrag  $D_{n-1,m-1}$  die Levenshtein-Distanz.

15

## Beispiel Levenshtein Distanz

$S1 = \text{auto}, S2 = \text{ute}$



16



## Edit Distanzen

---

- Verallgemeinerung der Levenshtein-Distanzen:
  - andere Kosten Matrix: Substitution kostet 4, Löschen 1, Einfügen 2..
  - weitere Operationen:
    - Reihenfolge Vertauschen
$$\left. \begin{array}{l} (A, B, B, A, B) \\ (A, B, A, B, B) \end{array} \right\} 1 \text{ Vertauschung}$$
    - Vervielfältigen,...
$$\left. \begin{array}{l} (A, B, B, B, B) \\ (A, B, ) \end{array} \right\} 3 \text{ Vervielfältigungen von } B$$
- Kosten können für Werte unterschiedlich sein:  
 $Subst.(A, B) \neq Subst.(A, Z)$
- Funktioniert auch bei Sequenzen über reellwertigen Alphabeten  
zum Beispiel: Für  $A = IR$ :  $Subst(5, 1) = |5-1|$

17

## Markow-Ketten und Sequenzen

---

- Sequenzen aus Aktionen unterliegen bestimmten Regeln
- Modellierung über endliche Automaten:  
(Test auf Gültigkeit der Sequenz)
- Markow-Ketten sind probabilistische Automaten:  
Modellieren nicht nur erlaubte Zustandsübergänge sondern auch Wahrscheinlichkeitsverteilungen über Zustandsübergänge.
- **Markow-Annahme 1. Ordnung:** Der Zustand zum Zeitpunkt  $t+1$  ist nur vom Zustand zum Zeitpunkt  $t$  abhängig.
- Ordnung einer Markow-Kette ist die Anzahl der Vorgängerzustände von denen die Auswahl des nächsten Zustands abhängig ist.

18


# Markow-Ketten 1 Ordnung

**Definition:** Eine Markow-Kette  $M$  ist definiert über eine Zustandsmenge  $A$  und eine stochastische  $|A| \times |A|$  Übergangsmatrix  $D$ .

**Erläuterungen:**

- $A$  kann einen Start- und einen Absorbtionszustand enthalten (Modellierung von Start und Ende)
- Stochastische Matrix: Zeilen addieren sich auch 1 auf.  
(Zeile  $i$  enthält die Verteilung der Nachfolger von Zustand  $i$ )

**Beispiel:**



	-	A	B	C
-	0.0	0.3	0.3	0.4
A	0.1	0.25	0.5	0.15
B	0.1	0.5	0.4	0.0
C	0.1	0.1	0.7	0.1

$$p(ACBB) = P(A | -) \cdot P(C | A) \cdot P(B | C) \cdot P(B | B) \cdot P(- | B) \\ = 0.1 \cdot 0.15 \cdot 0.4 \cdot 0.7 \cdot 0.4 \cdot 0.1$$

19

## Hidden Markow Modelle

**Training einer Markow Kette:**

- Zerlegen der Trainings Sequenzen in 2-Gramme und bestimme die relative Häufigkeit.  
(Wie häufig folgt auf A ein B?)  $P(B | A) = \frac{fr(AB)}{fr(A)}$

**Problem:**


- Beobachtungen entsprechen häufig nicht direkt dem beobachtetem Verhalten:
  - Action-Log ist verfügbar aber Spielgeschehen soll analysiert werden
  - Fehlerhafte Ausführung verschleiert die tatsächliche Intention
  - Analyse der Zustandswechsel einer KI  
(beobachtete Aktionen können in verschiedenen Zuständen angewendet werden.)

20

# Hidden Markow Modelle

**Definition:** Ein Hidden Markow Model  $M$  ist definiert über eine Zustands-menge  $A$ , eine stochastische  $|A| \times |A|$  Übergangsmatrix  $D$ , ein Beobachtungsmenge  $B$  und eine stochastische  $|A| \times |B|$  Output-Matrix  $F$ .

**Beispiel:**  $A = \{A, B, C\}$ ,  $B = \{1, 2, 3\}$



$P(122)$ : Bestimme alle Zustandstripel, die 122 erzeugen können:

BAA, BAC, BCA, BCC

$$P(122) = P(BAA) \cdot P(122 | BAA) + P(BAC) \cdot P(122 | BAC) + P(BCA) \cdot P(122 | BCA) + P(BCC) \cdot P(122 | BCC)$$

21

## Verwendung von HMMs

- **Evaluierung:** Wie wahrscheinlich ist eine Beobachtung  $O = (o_1, \dots, o_k)$  mit  $o_i \in B$  für das HMM  $(A, B, D, F)$ ?  
(*Forward Estimation*)
- **Erkennung:** Gegeben die Beobachtung  $O = (o_1, \dots, o_k)$  und das HMM  $(A, B, D, F)$ , welche Sequenz  $(s_1, \dots, s_k)$  mit  $s_i \in A$  erklärt  $O$  am besten? (*Viterbi-Algorithmus*)
- **Training:** Gegeben die Beobachtung  $O = (o_1, \dots, o_k)$ , wie kann man  $D$  und  $F$  anpassen um  $P(O | (A, B, D, F))$  zu maximieren?  
(*Baum-Welch Estimation*)

22

## Evaluierung: Forward Variablen

---

**Gegeben:**  $O=(o_1, \dots, o_k)$  und  $(A, B, D, F)$

**Gesucht:**  $P(O|(A, B, D, F))$

**Naive Lösung:** Berechne  $P(O|S)$  für alle k-elementigen Sequenzen S über A.  
(Anzahl steigt exponentiell mit k)

**Bessere Lösung:** Ausnutzen der Markow -Annahme

Definiere Forward-Variable  $\alpha_j(t)$  als

$$\alpha_j(t) = P(o_1, o_2, \dots, o_t, s_t = a_j | (A, B, D, F))$$

Berechnung durch Induktion:

$$\alpha_j(1) = d_{-,j} \cdot f_{j,o_1}, 1 \leq j \leq |A|$$

$$\alpha_j(t+1) = \left( \sum_{i=1}^{|A|} \alpha_i(t) \cdot d_{i,j} \right) \cdot f_{j,o_{t+1}}, 1 \leq t \leq k-1$$

Berechnung mit  $|A|^2 \cdot k$  Operationen:

$$P(O | (A, B, D, F)) = \sum_{i=1}^{|A|} P(O, s_t = a_i | (A, B, D, F)) = \sum_{i=1}^{|A|} \alpha_i(k)$$

23

## Erkennung: Viterbi Algorithmus

---

**Gegeben:**  $O=(o_1, \dots, o_k)$ , und Model  $(A, B, D, F)$ .

**Gesucht:**  $S=(s_1, \dots, s_k)$ , die  $P(O|S, (A, B, D, F))$  maximiert.

- definiere  $\delta(t)$  als höchste Wahrscheinlichkeit einer einzelnen Sequenz über A der Länge t für die Beobachtung O.

$$\delta_j(t) = \max_{s_1, \dots, s_{t-1}} P(s_1, \dots, s_{t-1}, O | (A, B, D, F))$$

- Berechnung durch Induktion

$$\delta_j(1) = d_{-,j} \cdot f_{j,o_1}, 1 \leq j \leq |A|$$

$$\delta_j(t+1) = (\max_{1 \leq i \leq k} \delta_i(t) d_{i,j}) f_{j,o_{t+1}}, 1 \leq j \leq k-1$$

- Ähnlich dem Forward Algorithmus, aber effizienter da immer nur die beste Lösung verfolgt wird.

24

# Backward Variablen

Analog zur Forward-Variable lässt sich auch eine Backward-Variable definieren, die für das Training des HMM verwendet wird.


Definiere Backward-Variable  $\beta_j(t)$  als

$$\beta_j(t) = P(o_{t+1}, \dots, o_k | s_t = a_j, (ABDF))$$

Berechnung durch Induktion:

$$\beta_i(k) = 1, 1 \leq i \leq |A|$$

$$\beta_i(t-1) = \sum_{j=1}^{|A|} d_{i,j} \cdot f_{j,o_t} \cdot \beta_j(t), 2 \leq t \leq k$$



25

## Training: Baum-Welch Reestimation

**Gegeben:**  $O=(o_1, \dots, o_k)$ ,  $A$  und  $B$ .

**Gesucht:**  $D, F$  die  $P(O|(A,B,D,F))$  maximieren.

- Lokal optimierende Lösung durch *Expectation Maximization (EM)*
- Definiere  $\xi_{i,j}(t)$  als Wahrscheinlichkeit, das man zum Zeitpunkt  $t$  in Zustand  $a_i$  ist und zum Zeitpunkt  $t+1$  in Zustand  $a_j$ .

$$\begin{aligned} \xi_{i,j}(t) &= P(s_t = a_i, s_{t+1} = a_j | O, (A, B, D, F)) \\ &= \frac{\alpha_i(t) \cdot d_{i,j} \cdot f_{j,o_{t+1}} \beta_j(t+1)}{P(O | (A, B, D, F))} \\ &= \frac{\alpha_i(t) \cdot d_{i,j} \cdot f_{j,o_{t+1}} \beta_j(t+1)}{\sum_{k=1}^{|A|} \sum_{l=1}^{|A|} \alpha_k(t) \cdot d_{k,l} \cdot f_{l,o_{t+1}} \beta_l(t+1)} \end{aligned}$$

- Definiere  $\gamma_i(t)$  als die Wahrscheinlichkeit, dass man zum Zeitpunkt  $t$  in State  $a_i$  ist:

$$\gamma_i(t) = \sum_{j=0}^{|A|} \xi_{i,j}(t)$$

26

## Training: Baum-Welch Estimation

---

- $\sum_{t=1}^{k-1} \xi_{i,j}(t)$  entspricht der erwarteten Anzahl von Zustandsübergängen von  $a_i$  auf  $a_j$ .
- $\sum_{t=1}^{k-1} \gamma_i(t)$  entspricht der erwarteten Anzahl an Zustandsübergängen von  $a_i$  auf andere Zustände.

- Parameter werden jetzt wie folgt neu abgeschätzt:

$$d_{-,a_i} = \gamma_i(1) \quad , \quad d_{i,j} = \frac{\sum_{t=1}^{k-1} \xi_{i,j}(t)}{\sum_{t=1}^{k-1} \gamma_i(t)} \quad , \quad f_{j,b_l} = \frac{\sum_{t \in \{t | o_t = b_l\}} \gamma_i(t)}{\sum_{t=1}^{k-1} \gamma_i(t)}$$

- Training erfolgt durch abwechselndes
  - Berechnen von  $\gamma_i(t)$ ,  $\xi_{i,j}(t)$  und  $P(O|(A,B,D,F))$
  - Update von  $D$  und  $F$  (Neuabschätzung wie oben)
- Algorithmus terminiert wenn  $P(O|(A,B,D,F))$  weniger als  $\varepsilon$  wächst.

27

## Reellwertige Sequenzen

---

- **Bisher:** Alphabet ist eine diskrete Domäne
- Sequenzen können aber auch über reellwertige Domänen zum Beispiel  $\mathbb{R}^d$  gebildet werden.
- Frequent Pattern Mining auf reellwertigen Domänen ist idR nicht möglich.
- Vergleich von 2 reellwertigen Sequenzen über der Domäne  $D$  mittels einer Distanzfunktion  $dist: D \times D \rightarrow \mathbb{R}_0^+$ .

- Analog zur Hamming Distanz kann man die Summe der Distanzen an jeder Position der Sequenz bestimmen.

$$dist_{sequ}(S_1, S_2) = \sum_{i=1}^{|S_1|} dist(s_{1,i}, s_{2,i}) + (|S_2| - |S_1|) \cdot \varphi, \quad \text{für } |S_2| \geq |S_1|, \varphi \in \mathbb{R}^+$$

- Erweitern der Edit-Distanz ist ebenfalls möglich: Kosten für Substitution von  $v$  und  $u$  entsprechen dann  $dist(v, u)$ .  
(Genaueres kommt später beim Dynamic Time Warping)

28

# Zeitreihen

- **Bisher:** Sequenzen modellieren nur die Reihenfolge, nicht aber die Zeitpunkte der Handlungen.

**Aber:** In Echtzeitspielen ist Timing entscheidend.

⇒ RTS Spiele: Build-Order sind nur dann effektiv, wenn Sie in minimaler Zeit realisiert werden

⇒ In MMORPGs hängt der ausgeteilte Schaden von der Anzahl der Aktionen pro Zeiteinheit ab.

⇒ Schach mit Schachuhr: Ein Zug wird auch daran gemessen wie viel Zeit man zum Nachdenken gebraucht hat.

- **Zeitreihe:** Sei  $T$  eine Domäne zur Darstellung der Zeit und sei  $F$  eine Objektdarstellung, dann heißt:

$Z = ((x_1, t_1), \dots, (x_l, t_l)) \in (F \times T) \times \dots \times (F \times T)$  Zeitreihe der Länge  $l$  über  $F$ .


29

## Beispiele für Zeitreihen

- SC2-Logs: Zeitreihe über diskrete Handlungen

```
0:00 TSLHyuN Select Hatchery (10230)
0:00 TSLHyuN Select Larva x3 (1027c,10280,10284), Deselect all
0:00 TSLHyuN Train Drone
0:01 TSLHyuN Train Drone
0:01 TSLHyuN Select Drone x6 (10234,10238,1023c,10240,10244,10248), Deselect all
0:01 TSLHyuN Right click; target: Mineral Field (10114)
0:01 TSLHyuN Deselect 6 units
0:02 TSLHyuN Right click; target: Mineral Field (10170)
....
```

- Netzwerk-Traffic:
  - Verwendung in der Bot-Erkennung
  - Abschätzung der Spielintensität





30

# Vorverarbeitung von Zeitreihen (1)

## Offset Translation


- Ähnlich Zeitreihen mit unterschiedlichen Offsets
- Verschiebung aller Zeitreihen um den Mittelwert  $MW$ :

$$\forall 1 \leq i \leq |o|: o_i = o_i - MW(o)$$



$$q = q - MW(q)$$

$$o = o - MW(o)$$





31

# Vorverarbeitung von Zeitreihen(2)

## Amplituden Skalierung

- Zeitreihen mit ähnlichem Verlauf aber unterschiedlichen Amplituden
- Verschiebung der Zeitreihen um den Mittelwert ( $MW$ ) und Normierung der Amplitude mittels der Standard Abweichung ( $StD$ ):

$$\forall 1 \leq i \leq |o|: o_i = (o_i - MW(o)) / StD(o)$$



$$q = (q - MW(q)) / StD(q)$$

$$o = (o - MW(o)) / StD(o)$$


32




## Vorverarbeitung von Zeitreihen (3)

### Lineare Trends


- Ähnliche Zeitreihen mit unterschiedlichen Trends
- Intuition:
  - Bestimme Regressionslinie
  - Verschiebe Zeitreihe anhand dieser Linie



Offset Translation + Amplituden  
Skalierung



Offset Translation + Amplituden Skalierung  
+ **Lineare Trend Beseitigung**





33

## Voverarbeitung von Zeitreihen (4)

### Bereinigung von Rauschen

- Ähnliche Zeitreihen mit hohem Rauschanteil
- Glättung: Bilde für jeden Wert  $o_i$  den Mittelwert über alle Werte  $[o_{i-k}, \dots, o_i, \dots, o_{i+k}]$  für ein gegebenes  $k$ .




34

# Diskrete Fourier Transformation (DFT)

## Idee:

- Beschreibe beliebige periodische Funktion als gewichtete Summe periodischer Grundfunktionen (Basisfunktionen) mit unterschiedlicher Frequenz. Aus einer Zeitreihe wird ein Vektor mit fester Länge.
- Basisfunktionen: sin und cos




35

# Diskrete Fourier Transformation (DFT)

**Fouriers Theorem:** Jede beliebige periodische Funktion lässt sich als Summe von Kosinus- und Sinus-Funktionen unterschiedlicher Frequenzen darstellen.

## Eigenschaften:

- Transformation verändert eine Funktion nicht, sondern stellt sie nur anders dar
- Transformation ist umkehrbar  $\Rightarrow$  inverse DFT
- Analogie: Basiswechsel in der Vektorrechnung



36

# Diskrete Fourier Transformation (DFT)

---

## Formal:

- Gegeben sei eine Zeitreihe der Länge  $n$ :  $x = [x_t]$ ,  $t = 0, \dots, n-1$
- Die DFT von  $x$  ist eine Sequenz  $X = [X_f]$  von  $n$  komplexen Zahlen für die Frequenzen  $f = 0, \dots, n-1$  mit

$$X_f = \frac{1}{\sqrt{n}} \sum_{t=0}^{n-1} x_t \cdot e^{\frac{-i \cdot 2\pi \cdot f \cdot t}{n}} =$$
$$\underbrace{\frac{1}{\sqrt{n}} \sum_{t=0}^{n-1} x_t \cos\left(\frac{2 \cdot \pi \cdot f \cdot t}{n}\right)}_{\text{Realteil}} - i \cdot \underbrace{\frac{1}{\sqrt{n}} \sum_{t=0}^{n-1} x_t \sin\left(\frac{2 \cdot \pi \cdot f \cdot t}{n}\right)}_{\text{Imaginärteil}}$$

wobei  $i$  die imaginäre Einheit bezeichnet, d.h.  $i^2 = -1$ .

- Der Realteil gibt den Anteil der Kosinus- und der Imaginärteil den Anteil der Sinusfunktionen in der jeweiligen Frequenz  $f$  an.

37

# Diskrete Fourier Transformation (DFT)

---

- Durch die inverse DFT wird das ursprüngliche Signal  $x$  wieder hergestellt:

$$x_t = \frac{1}{\sqrt{n}} \sum_{f=0}^{n-1} X_f \cdot e^{\frac{i \cdot 2\pi \cdot f \cdot t}{n}}$$

$t = 0, \dots, n-1$  ( $t$ : Zeitpunkte)

$[x_t] \leftrightarrow [X_f]$  bezeichnet ein **Fourier-Paar**,  
d.h.  $\text{DFT}([x_t]) = [X_f]$  und  $\text{DFT}^{-1}([X_f]) = [x_t]$ .

- Die DFT ist eine **lineare Abbildung**, d.h. mit  $[x_t] \leftrightarrow [X_f]$  und  $[y_t] \leftrightarrow [Y_f]$  gilt auch:
  - $[x_t + y_t] \leftrightarrow [X_f + Y_f]$  und
  - $[ax_t] \leftrightarrow [aX_f]$  für ein Skalar  $a \in \mathbb{R}$
- **Energie einer Sequenz**
  - Die Energie  $E(c)$  von  $c$  ist das Quadrat der Amplitude:  $E(c) = |c|^2$ .
  - Die Energie  $E(x)$  einer Sequenz  $x$  ist die Summe aller Energien über die Sequenz:  $E(x) = \|x\|^2 = \sum_{t=0}^{n-1} |x_t|^2$

38


# Diskrete Fourier Transformation (DFT)

**Satz von Parseval:** Die Energie eines Signals im Zeitbereich ist gleich der Energie im Frequenzbereich.

**Formal:** Sei  $X$  die DFT von  $x$ , dann gilt:

$$\sum_{t=0}^{n-1} |x_t|^2 = \sum_{f=0}^{n-1} |X_f|^2$$

- Folge aus Parsevals Satz und der Linearität der DFT: Die euklidische Distanz zweier Signale  $x$  und  $y$  stimmt im Zeit- und im Frequenzbereich überein:  $\|x - y\|^2 = \|X - Y\|^2$



39

# Diskrete Fourier Transformation (DFT)

## Grundidee der Anfragebearbeitung:

- Als Ähnlichkeitsfunktion für Sequenzen wird die euklidische Distanz verwendet:

$$\text{dist}(x, y) = \|x - y\| = \sqrt{\sum_{t=0}^{n-1} |x_t - y_t|^2}$$

- Der Satz von Parseval ermöglicht nun, die Distanzen im Frequenz- statt im Zeitbereich zu berechnen:  $\text{dist}(x, y) = \text{dist}(X, Y)$
- In der Praxis haben die tiefsten Frequenzen die größte Bedeutung.
- Die ersten Frequenz-Koeffizienten enthalten also die wichtigste Information.
- Für den Aufbau eines Index werden die transformierten Sequenzen gekürzt, d.h. von  $[X_f], f = 0, 1, \dots, n-1$  werden nur die ersten  $c$  Koeffizienten  $[X_f < c]$ ,  $c < n$ , indexiert.

$$\text{dist}_c(x, y) = \sqrt{\sum_{f=0}^{c-1} |x_f - y_f|^2} \leq \sqrt{\sum_{f=0}^{n-1} |x_f - y_f|^2} = \text{dist}(x, y)$$

- Im Index kann dann eine untere Schranke der echten Distanz berechnet werden:


Filter-Refinement:

- Filterschritt auf gekürzten Zeitreihen (mit Indexunterstützung),
- Refinement auf kompletten Zeitreihen

# Distanzen auf Zeitreihen

**Probleme:** Welche Zeitpunkte sollen verglichen werden?

- Offset am Anfang: S2 ist zu S1 zeitlich verschoben.
- Taktung der Messwerte: Zeitpunkte der Messungen sind unterschiedlich.
- Länge der Zeitreihe: Dauer der Messung ist unterschiedlich.



- Bei gleicher Taktung und Länge können Zeitreihen als Vektoren verglichen werden. (Dimension = Zeitpunkt)

$$Dist_{timeseries}(S1, S2) = \sum_{t=1}^T dist_{obj}(s_{1t}, s_{2t})$$


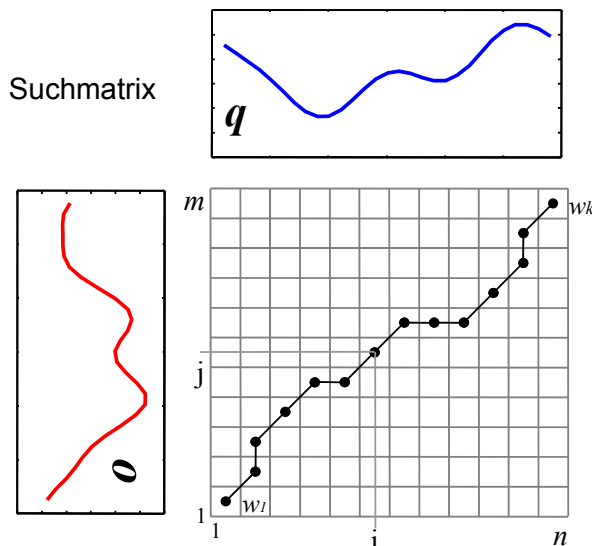

- Bei Variable Länge, Taktung und bei Offsets, Adaption der Edit-Distanz für Sequenzen => **Dynamic Time Warping**

41

## Dynamic Time Warping Distanz

**Berechnung:**

- Gegeben: Zeitreihen  $q$  und  $o$  unterschiedlicher Länge
- Finde Mapping von allen  $q_i$  auf  $o$  mit minimalen Kosten



42 42


# Dynamic Time Warping Distanz

## Suchmatrix

- Alle möglichen mappings von  $q$  auf  $o$  können als „warping“ Pfad in der Suchmatrix aufgefasst werden
- Von all diesen Mappings suchen wir den Pfad mit den niedrigsten Kosten

$$DTW(q, o) = \min \left\{ \sqrt{\sum_{k=1}^K w_k} / K \right\}$$

- Dynamisches Programmieren  
=> Laufzeit ( $n \cdot m$ )  
(vgl. Edit Distanz)




43

## Approximative Dynamic Time Warping Distanz

### Idee:

- Approximiere die Zeitreihen  
(komprimierte Repräsentation, Sampling, ...)
- Berechne DTW auf den Approximationen



44

# Statistische Modelle für die Zeit

## Problem:



Wie kann man den Zeitpunkt der nächsten Aktion modellieren?

⇒ Statistische Modelle für die Zeit zwischen 2 Ereignissen werden benötigt.

⇒ Zeit ist eine kontinuierliche Variable ⇒ Wahrscheinlichkeitsdichtefunktion

⇒ Gesucht: Wahrscheinlichkeit das das nächste Ereignis  $e$  im Zeitraum  $t + \Delta t$  stattfindet.

⇒ Beschreibung über kumulierte Wahrscheinlichkeitsdichtefunktion




45


## Homogene Poisson Prozesse

- einfachster Prozess zur Modellierung von Zeit.
- Zeitpunkte zwischen 2 Ereignissen sind exponentiell verteilt.  
Wahrscheinlichkeitsdichte der Exponentialverteilung:  $p_\lambda(x) = \lambda \cdot e^{-\lambda \cdot x}$
- Durch Integration erhält man die kumulierte Dichtefunktion, die die Wahrscheinlichkeit beschreibt, dass die nächste Aktion im Zeitintervall zwischen 0..x stattfinden wird.

$$P_\lambda(x) = \int_0^x p_\lambda(t) dt = 1 - e^{-\lambda \cdot x}$$



Dichtefunktion der Exponential-Verteilung



kumulierte Dichtefunktion der Exponential-Verteilung

46

# Parameterschätzung

---

**Gegeben:** Eine Trainingsmenge aus Zeitpunkten  $X = \{x_1, \dots, x_n\}$ , die exponentialverteilt sind.

**Gesucht:** Der wahrscheinlichste Wert für den Intensitätsparameter  $\lambda$ .

Abschätzung über Maximum Likelihood

=> Suche den Wert für  $\lambda$  bei dem die Wahrscheinlichkeit der Generierung von  $X$  am höchsten ist. Likelihood Funktion  $L$  für Sample  $X$ :

$$L_X(\lambda) = \prod_{i=1}^n \lambda \cdot e^{-\lambda \cdot x_i} = \lambda^n \cdot e^{-\lambda \cdot \sum_{i=1}^n x_i} = \lambda^n \cdot e^{-\lambda \cdot n \cdot E(X)} \quad \text{mit} \quad E(X) = \frac{\sum_{i=1}^n x_i}{n}$$

Ableiten der logarithmischen Likelihood nach  $\lambda$  und bestimmen der Nullstellen:

$$\begin{aligned} \frac{d}{d\lambda} \ln L(\lambda) &= \frac{d}{d\lambda} (n \cdot \ln L(\lambda) - \lambda \cdot n \cdot E(X)) = \frac{n}{\lambda} - n \cdot E(X) \\ \Rightarrow \lambda^* &= \frac{1}{E(X)} \end{aligned}$$

47

## Lernziele

---

- Sequenzen und Zeitreihen
- Frequent Subsequenz Mining mit Suffix-Bäumen
- Distanzmaße auf Sequenzen
  - Hamming Distanz
  - Levenshtein Distanz
- Markow-Ketten
- Hidden Markow Ketten
- Zeitreihen und Vorverarbeitungsschritte
- Dynamic Time Warping
- Poisson Prozesse

48



# Literatur

---

- Kyong Jin Shim, Jaideep Srivastava: **Sequence Alignment Based Analysis of Player Behavior in Massively Multiplayer Online Role-Playing Games (MMORPGs)**, in Proceedings of the 2010 IEEE International Conference on Data Mining Workshops, 2010.
- Ben G. Weber, Michael Mateas: **A data mining approach to strategy prediction**, in Proceedings of the 5th international conference on Computational Intelligence and Games, 2009.
- K.T. Chen, J.W. Jiang, P. Huang, H.H. Chu, C.L. Lei, W.C. Chen: **Identifying MMORPG bots: A traffic analysis approach**, In Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology, 2006.