Ludwig Maximilians Universität München
Institut für Informatik
Lehr- und Forschungseinheit für Datenbanksysteme

Skript zur Vorlesung

Managing and Mining Multiplayer Online Games

im Sommersemester 2016

Kapitel 9:Räumliche Verhaltensmodelle

http://www.dbs.ifi.lmu.de/cms/VO_Managing_Massive_Multiplayer_Online_Games

Kapitelüberblick

- Spatial Data Mining in Games
- Visual Analytics und Heat Maps
- Spatial Prediction
- Spatial Outliers
- Trajektorien Darstellungen und Vergleiche
- Mustersuche in Trajektorien

Spatial Data Mining und Spiele

- Viele Spiele finden in einer virtuellen 2D-/3D- Welt statt.
- Bewegung und Positionierung ist häufig ein wichtiger Teil des Game Plays.
- Aufbau der Spielwelt ist relevant für das Balancing.
- Analyse von räumlichen und räumlich-zeitlichen Abläufen wird unter dem Begriff *Spatial Data Mining* zusammengefasst.

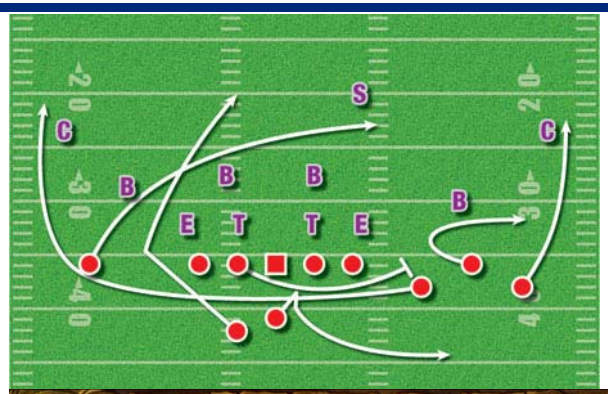

Aufgaben Spatial Game Analytics

- Finde Exploitation-Spots
- Extraktion von Spielzügen
  und Bewegungsstrategien
- Erkennen von Encountern (Open PVP)
- Sub-Team Erkennung
- Dynamisches Anpassen von Respawn-Raten
- Erkennen von Bots und Multi-Boxing
- Erkennen von Bewegungs- und Teleportations-Hacks

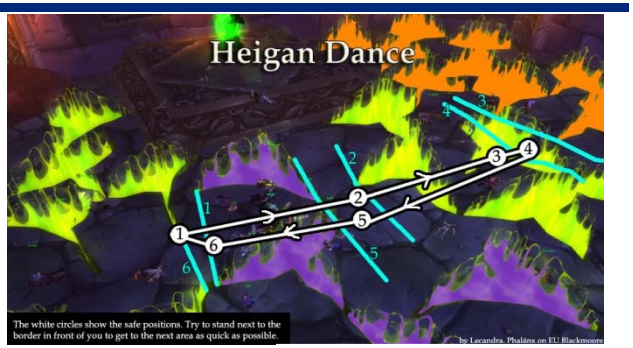

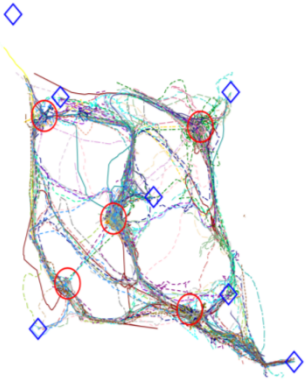

⇒ Suche bestimmte Orte
(Heatmaps, Spatial Prediction, Spatial Outlier)

⇒ Suche nach Bewegungsmustern (Trajectory Mining)

Räumliche Daten und Visualisierung

- Räumliche Daten bestehen aus Objektbeschreibung und Position.
  (Beispiel: Marine, 43,56)
- Um besondere Orte zu finden, werden die Objektbeschreibungen bzgl. der Position aggregiert.
  (z.B. Anzahl der Kills an einer Position,
  Spawn-Häufigkeit eines Monsters an einem Ort)
- Räumliche Kontinuität: i.d.R. geht man davon aus, dass sich benachbarte Positionen ähnlich verhalten.

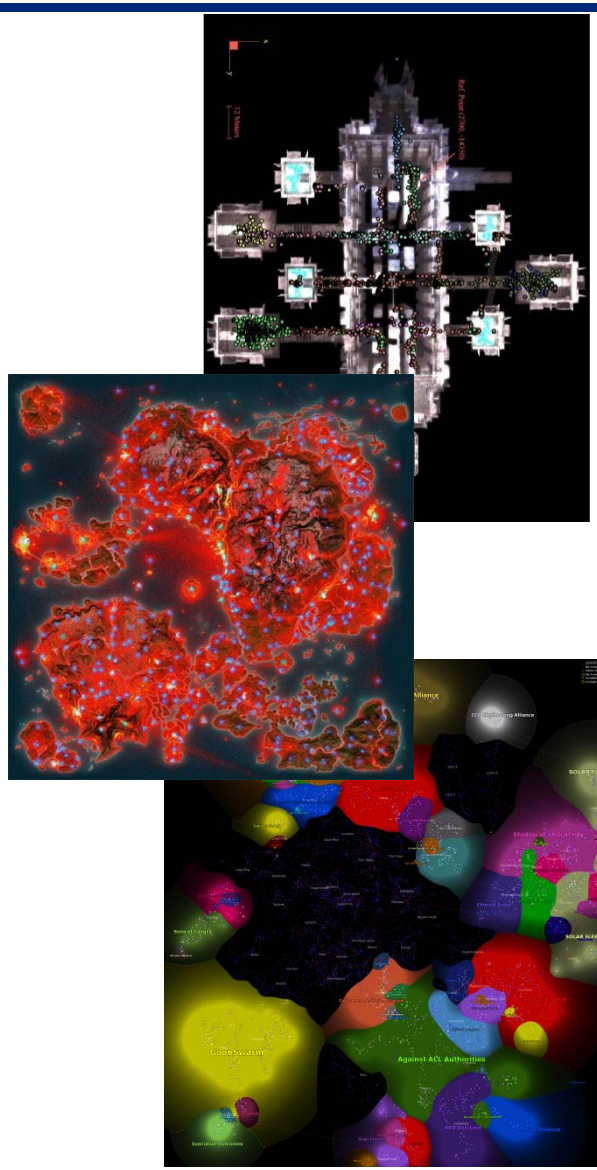

⇒ Darstellung von aggregierten Informationen über 2D Histogramme (Bin Counting)

⇒ Darstellung der räumlichen Kontinuität über Glättungsansätze (Kerndichteschätzer)

Heat Maps

- Visualisierung der Verteilung der Ereignisse über die X- ,Y- Koordinaten einer Karte.
- Darstellung der Verteilung als 2D-Dichteverteilung.
- Die Höhe der Bins wird durch Farbe kodiert.

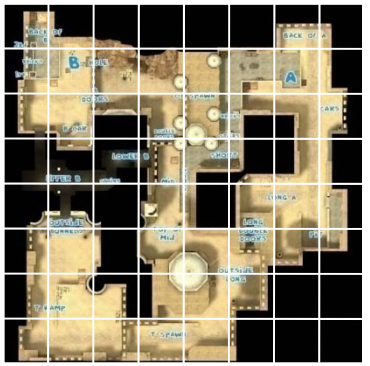

Einfacher Algorithmus: Bin Counting

1. Lege uni-distantes Grid über die Karte
2. Für jedes Ereignis
   1. Bestimme die Gridzelle
   2. Erhöhe Zähler der Gridzelle um 1
3. Zeichne das Grid und färbe jede Zelle mit einer Farbe, die der Zahl in der Zelle entspricht.

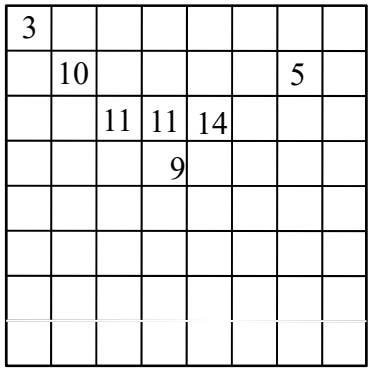

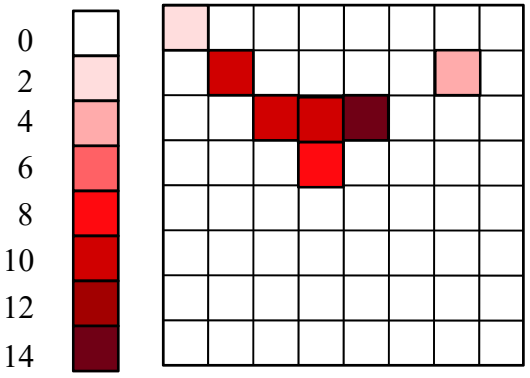

Heat Maps

Probleme bei Bin Counting:

- Einstellung der Grid-Größe:
  - zu klein: zerrissene Darstellung,
    wenige dichte Bereiche
  - zu groß: grobe Darstellung,
    wenig Unterscheidung
- Position des Grids beeinflusst Ergebnis
- räumliche Kontinuität kann schlecht erkennbar sein

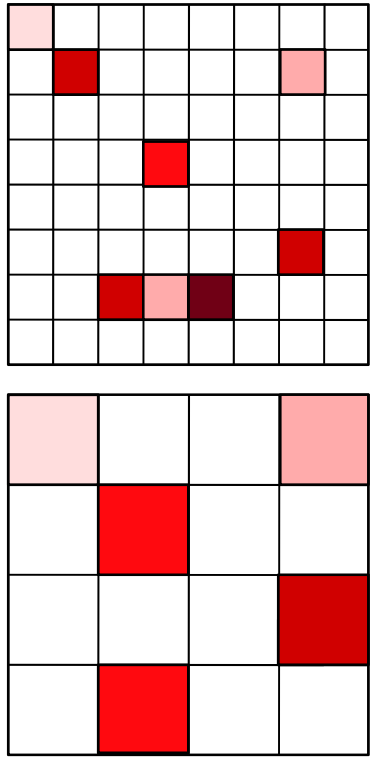

Abhilfe: Glätten der Kurve mit Kerndichteschätzung
Abschätzung der Objektdichte über Summe
von Kernfunktionen

$\Rightarrow$ Kontinuierliche und geglättete Dichtefunktion

$\Rightarrow$ Rasterung der Daten erst beim Zeichnen

Kerndichteschätzer

- Verfahren zur Abschätzung einer kontinuierlichen Dichtefunktion aus einer Samplemenge *X*.
- Betrachte Dichte *p(t)* als Mixture-Model von |*X*| Verteilungen, die alle mit der Kernfunktion *k(t)* verteilt sind:

$$p(x) = \frac{1}{|X|} \sum_{t \in X} k(t - x)$$

- Gängige Kernfunktion:
  - Gaußkern : $k(t) = \frac{1}{\sqrt{2\pi}} e^{\left(-\frac{1}{2}t^2\right)}$
  - Cauchy-Kern: $k(t) = \frac{1}{\pi\left(1 + t^2\right)}$
  - Picard-Kern : $k(t) = \frac{1}{2} e^{(-|t|)}$
  - Epanechnikow-Kern: $k(t) = \begin{cases} \frac{3}{4}\left(1 - t^2\right), & falls \quad t \in [-1;1] \\ 0 & sonst \end{cases}$

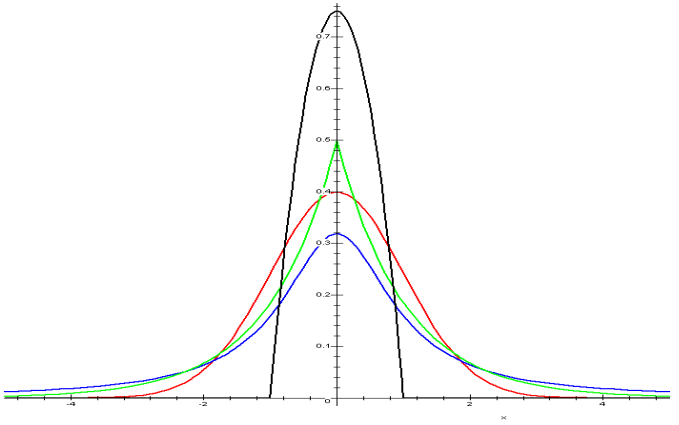

Heatmaps mit Kerndichteschätzern

- Kerne im *2D*-Raum unter der Annahme unabhängiger Dimensionen:

$$p(t) = \left(\frac{1}{|X|} \sum_{x \in X} k(t_1 - x_1) \right) \cdot \left(\frac{1}{|X|} \sum_{x \in X} k(t_2 - x_2) \right)$$

- Jedes Bin entspricht einem Pixel
- Für jedes Pixel *P* wird *p(m)* am Pixelmittelpunkt *m* berechnet
- Zur effizienten Berechnung:

  Gehe über alle Punkte *x*:

  Gehe über alle Pixel *p*:

  Gehe über beide Dimensionen:

  Erhöhe den Wert von *p* um $k(x\text{-}p_m)$ mit p_m *Mittelpunkt von p*

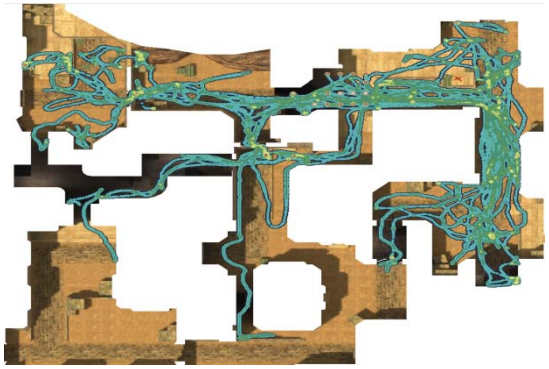

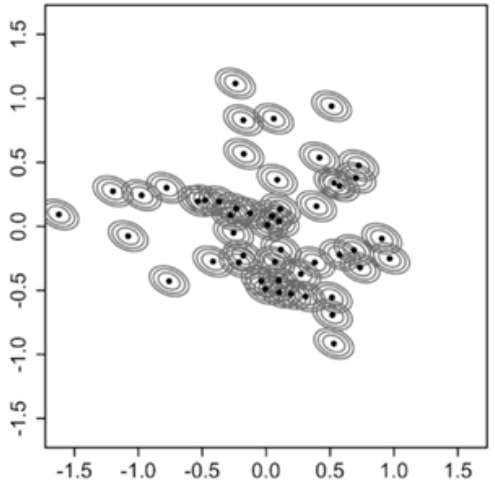

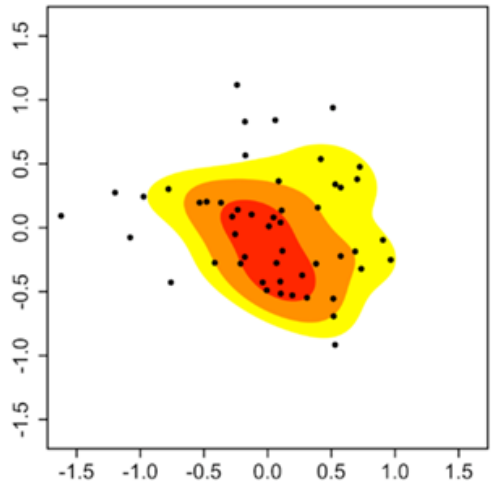

Spatial Data Mining

- Spezialbereich des Data Minings, der sich mit räumlichen Objekten beschäftigt.
- Objekt *O* besteht aus einer räumlichen Komponente $p \in IR^2/IR^3$ und einer Objektbeschreibung v $\in F$. *(F ist ein beliebiger Feature-Raum)*
- Spezielle Tasks im Spatial Data Mining:
  - **Spatial Outlier Detection**: Finde Orte, bei denen die Feature-Beschreibung deutlich von der Beschreibung der räumlich nahen Objekte abweicht.

    (Beispiel: Exploitation Spots, bei denen man nicht getroffen werden kann.)
  - **Spatial Prediction**: Vorhersage von Orten, an denen bestimmte Phänomene häufig auftreten.

    (Beispiel: Berechne die Wahrscheinlichkeit, ob an einer bestimmten Stelle, ein bestimmtes Verhalten beobachtet werden kann.)
  - **Spatial Clustering**: Clustering, das sowohl die räumliche Nähe als auch die Ähnlichkeit im Feature-Raum verwendet, um Cluster zu bilden bzw. voneinander abzugrenzen.

    (Beispiel: Werden beliebige Aktivitäten häufig an bestimmten Stellen der Karte unternommen.)
  - **Spatial Rule Mining:** Ableiten von Assoziationsregeln auf Basis häufiger räumlicher Muster. (Beispiel: 80% der Städte, die innerhalb von 50 km der Siedlung eines anderen Spielers gebaut werden, überleben nicht bis zum Ende des Spiels.)

Spatial Prediction

- Supervised Learning auf räumlichen Daten.
- Spatial Auto Regression (SAR): Erweitern von Regressionsmodellen zur Berücksichtigung der Zielwerte naher Objekte (hier Matrixschreibweise):

$$y = \rho \cdot W \cdot y + X \cdot \beta + \varepsilon$$

  - y: Vektor der Zielwerte
  - W: Matrix, die die räumliche Nähe der Objekte darstellt
  - X: Datenmatrix, die aus den Trainingsvektoren gebildet wird
  - ε: Normalverteilter Fehler/Rauschen
  - ρ: Gewichtungsfaktor für räumliche Komponente
  - β: Gewichtungsvektor für inhaltliche Komponente
- Umformung für die Berechnung: $(1 - \rho \cdot W)\vec{y} = X\beta + \varepsilon$

$$y = (1 - \rho \cdot W)^{-1} X\beta + (1 - \rho \cdot W)^{-1} \varepsilon$$

- $(1 - \rho \cdot W)^{-1}$ kann als räumliche Glättung des Feature-Raums aufgefasst werden.
- Bestimmen von ρ und β mit Maximum Liklihood Schätzern oder Markov-Chain-Monte-Carlo Abschätzung.

Spatial Outlier Detection

Gegeben: Eine Menge DB von räumlichen Objekte O = (p,v).

Gesucht: Objekte, die in ihrer räumlichen Umgebung ungewöhnlich sind.

Allgemeines Vorgehen:

1. Bestimme für jedes Objekt *O* eine räumliche Nachbarschaft *N*.
   (z.B. *N* besteht aus den räumlich k-nächsten Nachbarn von *O*).
2. Vergleiche die Feature-Beschreibungen *O.v*
   mit der Verteilung der Feature-Beschreibungen in *N*.

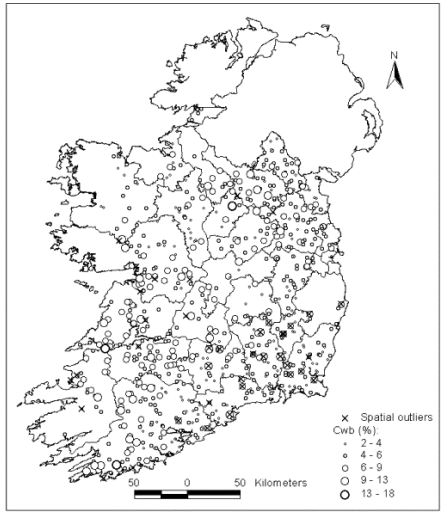

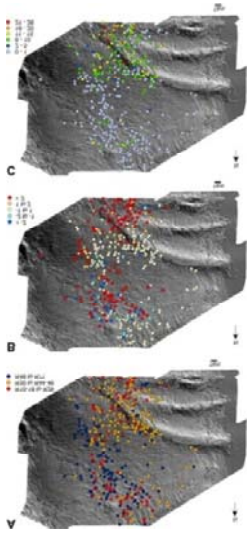

Spatial Outlier Detection

Point Outlier Detection (POD):

1. Aufstellen eines Nearest Neighbor Graphen G(DB,E) auf den räumlichen Positionen.
   E:= $\{(o_i,o_j) | o_i,o_j \in DB \wedge o_j \in NN_k(o_i)\}$
   Gewichtungsfunktion:
   $w(o_i,o_j) = || o_i.v - o_j.v ||$
2. Sortiere E absteigend nach $w(o_i,o_j)$
3. Solange $|R| < m$
   (noch keine m Outlier gefunden)
   1. Entferne die Kante (o_i,o_j) mit max. Gewicht $w(o_i,o_j)$
   2. Falls o_i jetzt isoliert ist

      Füge o_i in das Ergebnis R ein

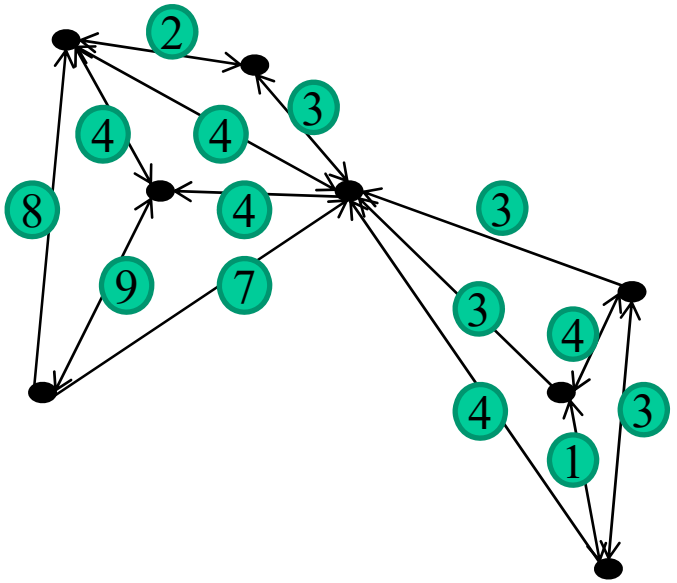

Beispiel POD

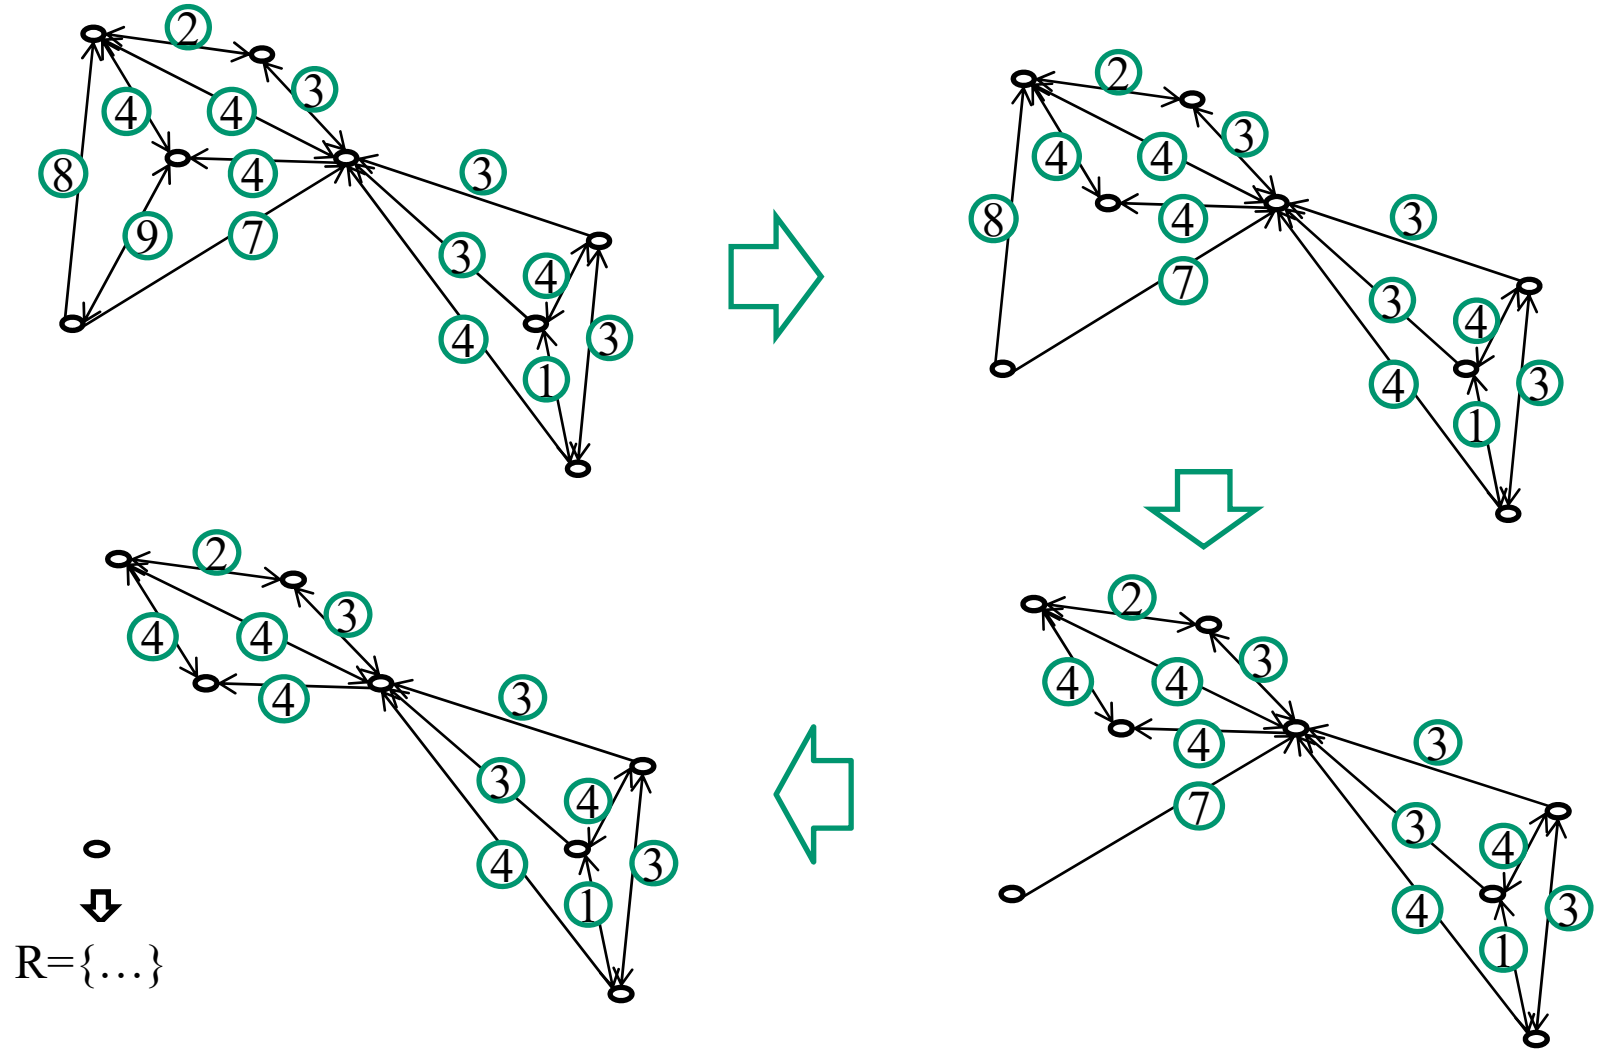

Trajektorien

- Trajektorien beschreiben eine Bewegung durch den Raum (Zeitreihen über räumliche Positionen)
- **Räumliche Trajektorie**: $Q=(x_1, \ldots, x_l) \in IR^2 \times \ldots \times IR^2$ heißt räumliche Trajektorie der Länge l über IR^2.
- **Räumlich-Zeitliche Trajektorie**: Sei T eine Domäne zur Darstellung der Zeit, dann heißt $Q=((x_1, t_1),.., (x_l, t_l)) \in (IR^2 \times T) \times .. \times (IR^2 \times T)$ räumlich-zeitliche Trajektorie der Länge l über IR^2.
- Alternativ können Trajektorien auch relativ zu einer Startposition beschrieben werden.

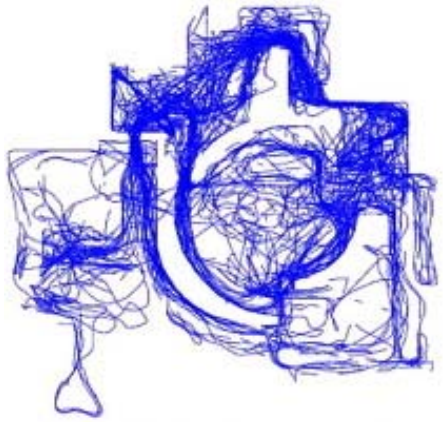

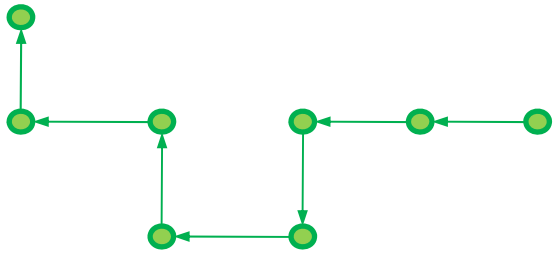

go , go, turn left, go, turn right, go, turn right, go, turn left, go, turn right, go

- Bewegung ist kontinuierlich: Um einen kontinuierlichen Pfad zu erhalten, wird i.d.R. angenommen, dass die Bewegung zwischen 2 Positionen linear und mit konstanter Geschwindigkeit zurückgelegt wird.

Distanzmaße für Trajektorien

- **Punkt zu Trajektorie**: Gegeben $p \in IR^2$ und Trajektorie $Q=((x_1,t_1), \ldots, (x_l,t_l))$:

$$D(p,Q) = \min_{(x,t)\in Q} d(p,x)$$

- **Trajektorie zu Trajektorie**: Gegeben $Q=((x_1,t_1), \ldots, (x_l,t_l))$ *und* $P= ((y_1,t'_1), \ldots, (y_l,t'_l))$:

Closest Pair Distanz:

$$CPD(Q,P) = \min_{(x_i,t_i)\in Q,(y_j,t'_j)\in Q} d(x_i,y_j)$$

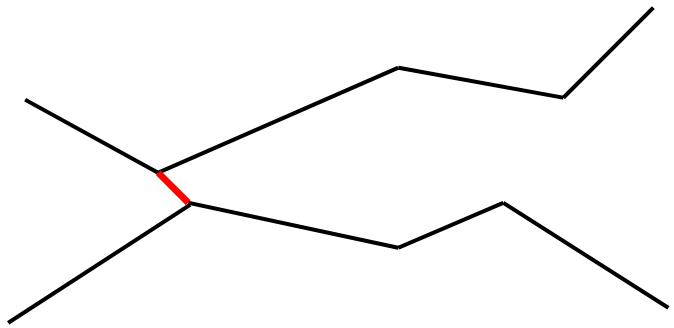

Sum-of-Pairs:

$$SPD(Q,P) = \sum_{i=1}^{n} d(x_i,y_i)$$

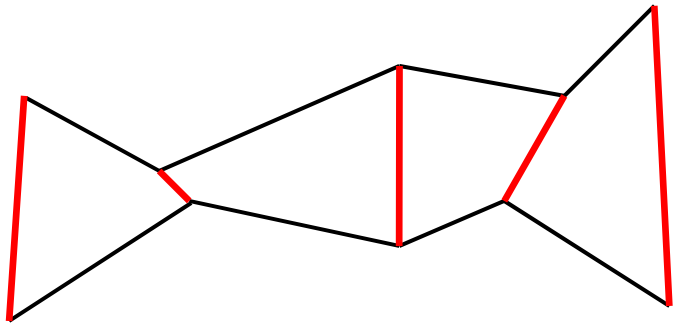

Abstandsmaße für Trajektorien

- bei unterschiedlicher Länge: DTW (Siehe Kapitel 8)

  Aber: DTW ist anfällig für Ausreißer.
- Längste gemeinsame Subsequenz (Ähnlichkeitsmaß!)
  LCSS (Longest Common SubSequenz):

$$LCSS(Q,P) = \begin{cases} 0, \ falls \quad n = 0 \vee m = 0 \\ 1 + LCSS(\text{Rest}(Q), \text{Rest}(P)), \ falls \quad d(Head(Q), Head(P)) \le \varepsilon \wedge |n - m| < \delta \\ \max(LCSS(\text{Rest}(Q), P), LCSS(Q, \text{Rest}(P)), sonst \end{cases}$$

- ε: Grenzwert für Positionsmatching, δ max. Verschiebung
- Berechnung durch Rekursion

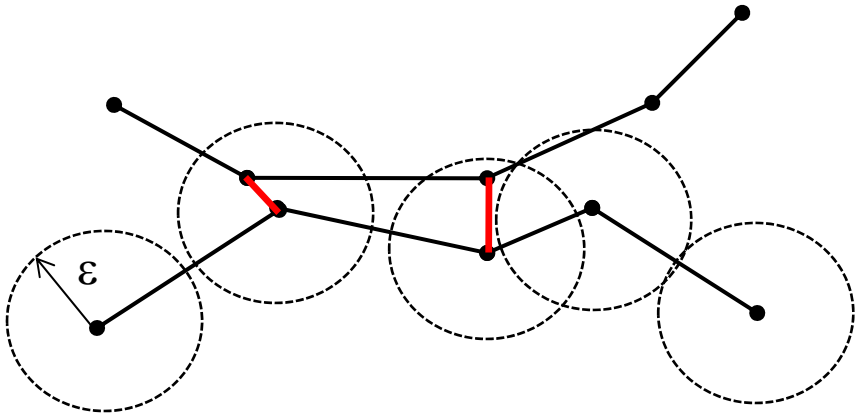

LCSS Ähnlichkeit

- LCSS(P,Q) zählt bis jetzt nur die Länge der größten gemeinsamen Subsequenz, ist aber nicht normiert:

$$S1(\delta,\varepsilon,P,Q)=\frac{LCSS(P,Q)}{\min(|P|,|Q|)}$$

- Ähnlichkeit berücksichtigt noch nicht die Translation von Trajektorien (Translation: Verschiebung aller Positionen um einen festen Vektor):

  Sei F die Menge aller Translationen und $f(Q) \in F$ eine Translation:

$$S2(\delta,\varepsilon,P,Q)=\max_{f\in F}\left[S1(\delta,\varepsilon,P,f(Q))\right]$$

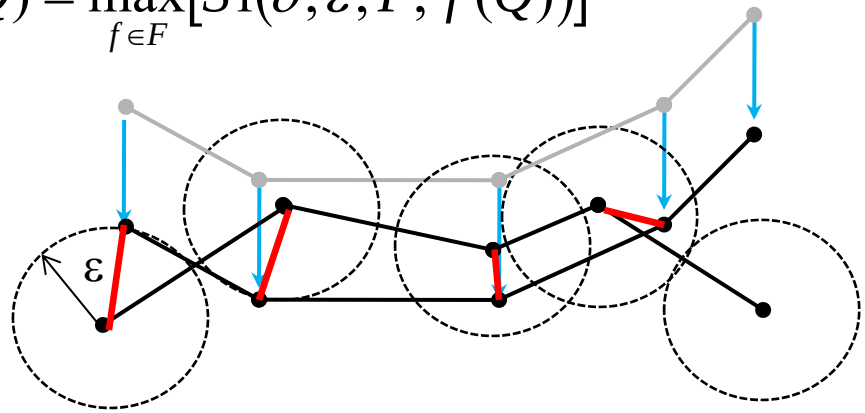

Kompression von Trajektorien

Eigenschaften von Trajektorien in Spielen:

- hohe Auflösung (ca. 20-30 Punkte/s)
- keine Positionsmessfehler (Position ist exakt hinterlegt)
- Geschwindigkeit ist häufig fest abgestuft und Bewegung ist häufig linear.

Probleme: Auflösung ist häufig zu hoch und redundant

- Speicherbedarf ist extrem hoch
- Vergleiche werden sehr teuer (alle DTW basierten Maße sind quadratisch)

Lösungsansatz: Reduktion der Wegpunkte

$\Rightarrow$ Kompression durch Weglassen von Wegpunkten

$\Rightarrow$ Gute Verfahren minimieren Approximationsfehler

Douglas-Peuker Algorithmus

Gegeben: Eine Trajektorie $Q=((x_1,t_1), \ldots, (x_l,t_l))$ der Länge l.

Gesucht: Q‘ mit | Q‘ |<< l und Approximationsfehler ist kleiner als δ.

Algorithmus:

DP(Q, δ)

Q‘ = $((x_1,t_1), (x_l,t_l))$

FOR ALL (x_i,t_i) *in Q*

IF $Error(x_i, Q‘)$ > δ THEN

bestimme x^* mit max($Error(x_i, Q‘)$)

$(Q1,Q2) = split(Q,x^*)$

RETURN $DP(Q1, \delta) \circ DP(Q2, \delta)$

ENDFOR

RETURN Q‘

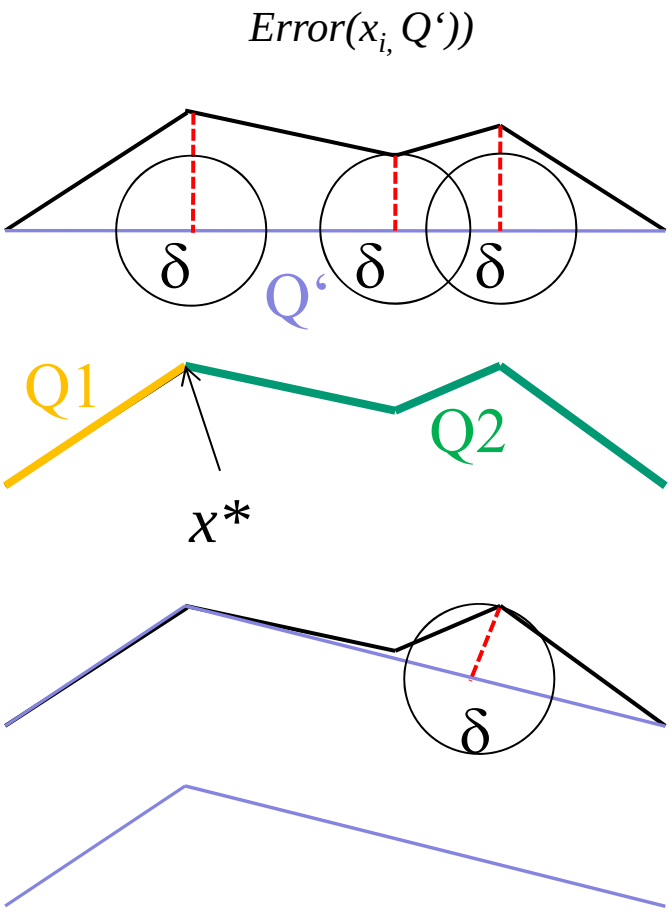

Kompression mit Geschwindigkeit und Richtung

- Betrachte letzte 2 Wegpunkte q_{i-2}, q_{i-1} und berechne Bewegungsrichtung $d_i = \frac{q_{i-2} - q_{i-1}}{\|q_{i-2} - q_{i-1}\|}$ und Geschwindigkeit $v_i = \frac{\|q_{i-2} - q_{i-1}\|}{t_{i-2} - t_{i-1}}$

- Extrapoliere den nächsten Wegepunkt $q_{i-1} + d_i\, v_i(t_{i+1} - t_i)$ und teste:
  Wenn $|v_i(t_i - t_{i-1}) - (q_i - q_{i-1})| \leq \delta$ und $\frac{\langle d_i, q_i - q_{i-1} \rangle}{\|d_i\| \cdot \|q_i - q_{i-1}\|} \leq \alpha$

  lösche q_i

  sonst

  gehe zu $i+1$

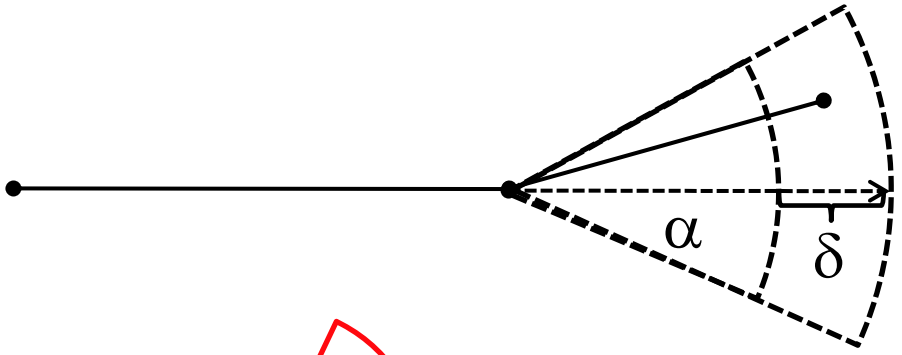

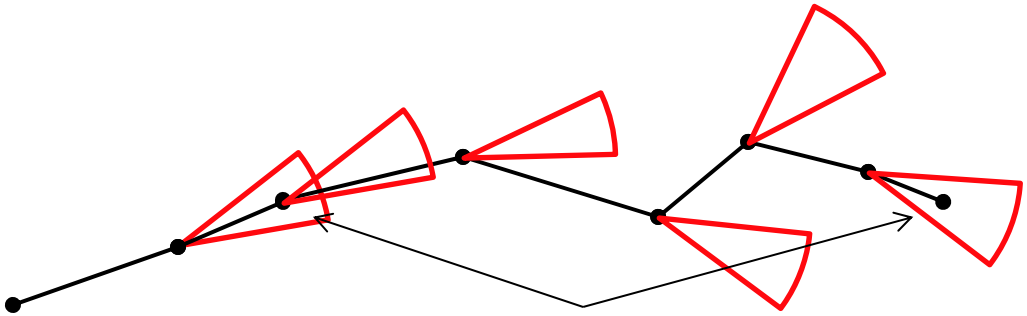

gelöschte Wegpunkte

Mustersuche in Trajektorien

- Trajektorien können wie andere Objekte auch mittels distanzbasiertem Data Mining (z.B. OPTICs) und entsprechenden Distanzmaßen (LCSS) analysiert werden.

- Die resultierenden Muster bestehen aber aus global ähnlichen Trajektorien.

- Viele interessante Muster auf Trajektorien basieren aber nur auf einem verhältnismäßig kleinen Teil der Trajektorie.

- Interessante Muster haben häufig bestimmte räumliche Nebenbedingungen.

=> Spezielle Mustersuche für Trajektorien

Kontinuierliche Flocks

Idee: Finde Objekte die für eine gewisse Zeit einen gemeinsamen Weg hatten.

Beispiel: Subteams in Spielen, Convoys, Verbände, …

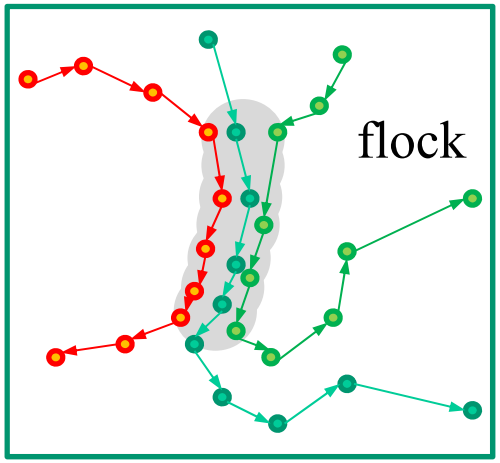

Definition: *Kontinuierlicher (m,k,r)-Flock*

Sei *DB* eine Menge von Trajektorien der Länge *l*, ein Flock im Zeitinterval $I=[t_i,t_j]$ mit $j-i+1 \geq k$ besteht aus mindestens *m* Objekten, so dass es für jeden Zeitpunkt in *I* eine Scheibe mit Radius *r* gibt, die alle *m* Objekte umschließt.

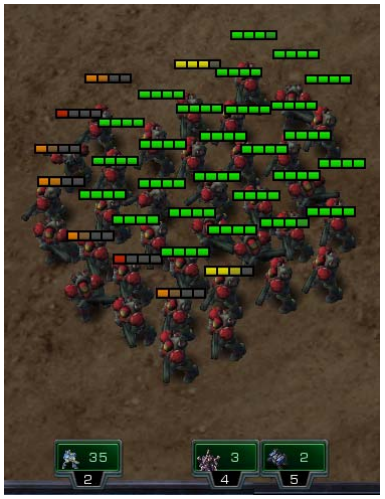

Bemerkung: Berechnung des Flocks mit der längsten Dauer und Berechnung des Flocks mit dem größten Subset sind NP-harte Probleme.

=> Lösungen sind aufwändig oder nur approximativ

Flocks mit diskreter Zeit

Definition: *Diskreter (m,k,r)-Flock*

Sei *DB* eine Menge von Trajektorien der Länge *l*, ein Flock im $I=[t_i,t_j]$ mit $j-i+1 \geq k$ besteht aus mindestens *m* Objekten, so dass es für jeden diskreten Zeitpunkt t_l mit $i \leq l \leq j$ eine Scheibe mit Radius *r* existiert, die alle *m* Objekte umschließt.

- **Lemma**: Wenn sich die Objekte mit konstanter Geschwindigkeit und auf einer direkten Linie zwischen den Wegpunkten bewegen, sind diskrete und kontinuierliche Flocks äquivalent.
- **Vorteil**: Man kann aus dem kontinuierlichen Problem ein diskretes machen.

  Aber: Die Komplexität bleibt und steckt in der Kombinatorik der möglichen Teilmengen. Mögliche Anzahl von Flocks mit *m* Elementen:

$$\binom{|DB|}{m} \cdot (l-k+1)$$

Suche nach Flocks

Vorgehen umfasst 2 Teilaufgaben:

1. Finde alle Scheiben mit Radius *r*, die mindestens *m* Punkte zum Zeitpunkt t_i enthalten.
   => Sequenz aus Teilmengen von DB
   => Eine Trajektorie kann auch in mehreren Teilmengen enthalten ein.

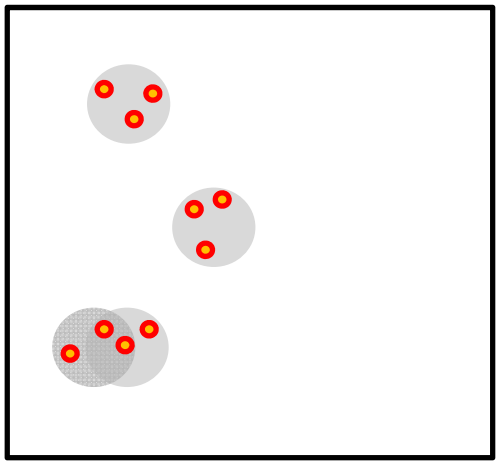

2. Finde Sequenz $(S(t_i), \ldots, S(t_j))$ von Scheiben $S(t_l)$ für die Zeitpunkte t_l mit $i \leq l \leq j$ für die gilt:

$$\left| \bigcap_{i \leq l \leq j} S(t_l) \right| \geq m$$

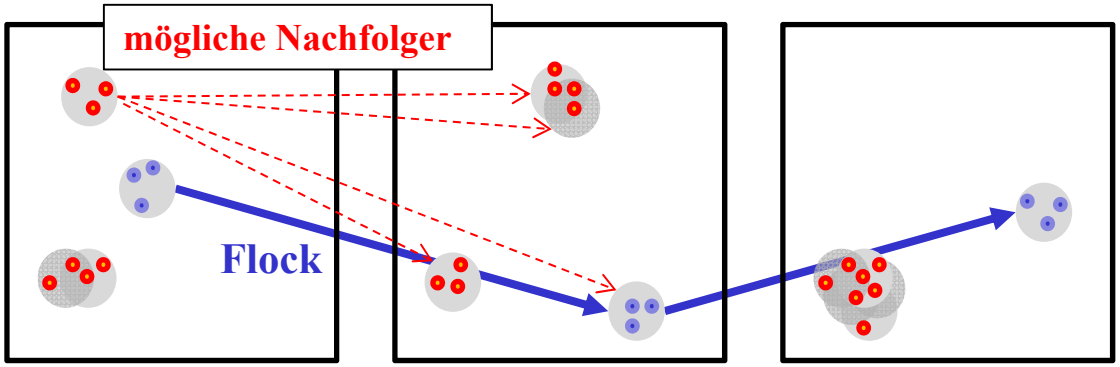

Finden aller Scheiben zum Zeitpunkt t

Disks(t_i)

Generiere Grid-Index I über DB_i

FOR ALL non-empty cells gx ∈ I **DO**

Pr = gx

Ps= NeighborCells(gx)

IF *|Ps| ≥ m* **THEN**

FOR EACH *pr ∈ Pr* **DO**

H=Range(pr,2r)

FOR *each pj* ∈ H **DO**

IF *not computed {pr,pj }* **THEN**

compute disks {c1,c2} from {pr,pj }

FOR EACH *disk ck ∈ {c1,c2}* **DO**

c = ck∩ H

IF *|c| ≥ m* **THEN**

C.add(c)

RETURN *C*

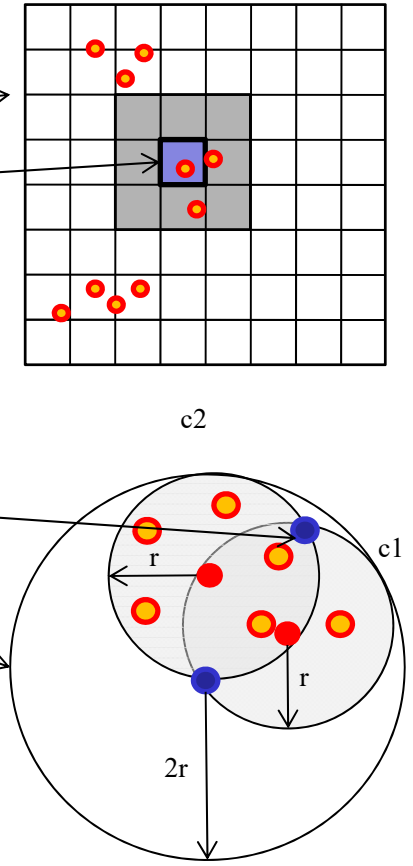

Finden von (m,k,r)-Flocks

Continuous Refinement Evaluation (CRE)

CRE(DB,k)

FOR EACH point in time t_i **DO**

L: Trajectories in time interval t_{i-k} to t_i

$C^1 = Disks(L[t_{i-k}])$ // alle Scheiben an denen Trajektorien aus L zu t_{i-k} *beteiligt sind*

$F = \{\}$ // Ergebnis

FOR EACH c1 $\in C^1$ **DO** // Für jede Startscheibe

$L'[1] = trajectories\ in\ c1$

$F^1 = c1, F^t = \{\}$

FOR $t = 2\ to\ k$ **DO** // Für die nächsten k-1 Zeitpunkte

$C^t = Disks(L'[t])$

$F^t = \{\}$

FOR EACH $c \in C^t$ **DO** // Für alle Scheiben zum Zeitpunkt t

FOR EACH $f \in F^{t-1}$ **DO** // Für alle bisher gültigen Flocks

IF $|c \cap f| \geq m$ **THEN**

$F^t = F^t \cup \{c \cap f\}$ // Erweitern des Flocks um einen Zeitpunkt

IF $|F^t| = 0$ **THEN**

BREAK

$F = F \cup F^t$

RETURN F

Meets (Encounter)

Idee: Finde Objekte, die sich für eine gewisse Zeit zusammen an einem Ort aufhalten.

Beispiel: Encounter, Kämpfe.

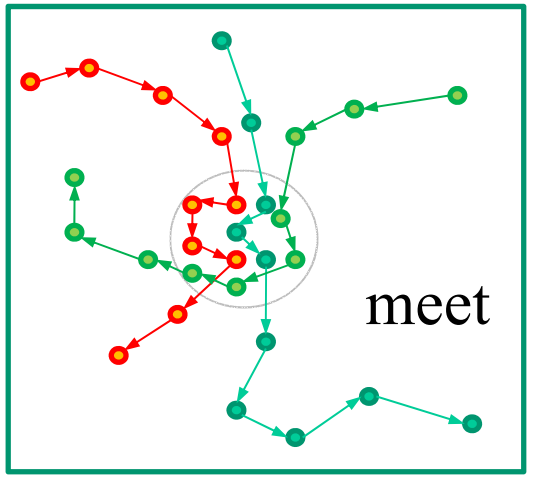

Definition: (m,k,r)-Meet

Sei *DB* eine Menge von Trajektorien der Länge *l*, ein Meet im Zeitinterval $I=[t_i,t_j]$ mit $j-i+1 \geq k$ besteht aus mindestens *m* Objekten, so dass für jeden Zeitpunkt in I alle *m* Objekte in einer Scheibe mit Radius *r* und Mittelpunkt M liegen.

Bemerkung: Die Berechnung von Meets ist einfacher als die Berechnung von Flocks, da bei 2 aufeinander-folgenden Zeitpunkten nur die Positionen der Scheiben aber nicht deren Trajektorien untersucht werden müssen.

Encounter Detection

Idea: To find out where a team succeeded /failed and find the decisive moments in a game.

- In Dota2 defeating enemy heroes grants the biggest advantage in gold/XP
- Find situations where this was possible or succeeded
- => Encounters

Encounter characteristics

- Encounters represent only a portion of the game
- Encounters can happen simultaneously
- Often only sub teams are involved in encounters

Defining Encounters

Idea: Fights happen when opponents can influence each other.

- opponents have to be in fighting range
- each hero unit might have an individual attack range
- heroes can support (e.g. heal) a friendly unit

Which kind of information is necessary?

- Spatial position and unit type for each controlled hero unit
- Attack and support ranges for all units types

Encounter Situations

- ***Combat link***: 2 hero units from different teams A and B. Either A can attack B or vice versa
- ***Support lin***k: 2 hero units from the same team A and B. Either A can support B or vice versa
- Each hero type has individual ***attack and support ranges*** (Ranges are mean values plus to standard deviations)
- ***Component Graph***: Connected Graph build by Combat/support Links

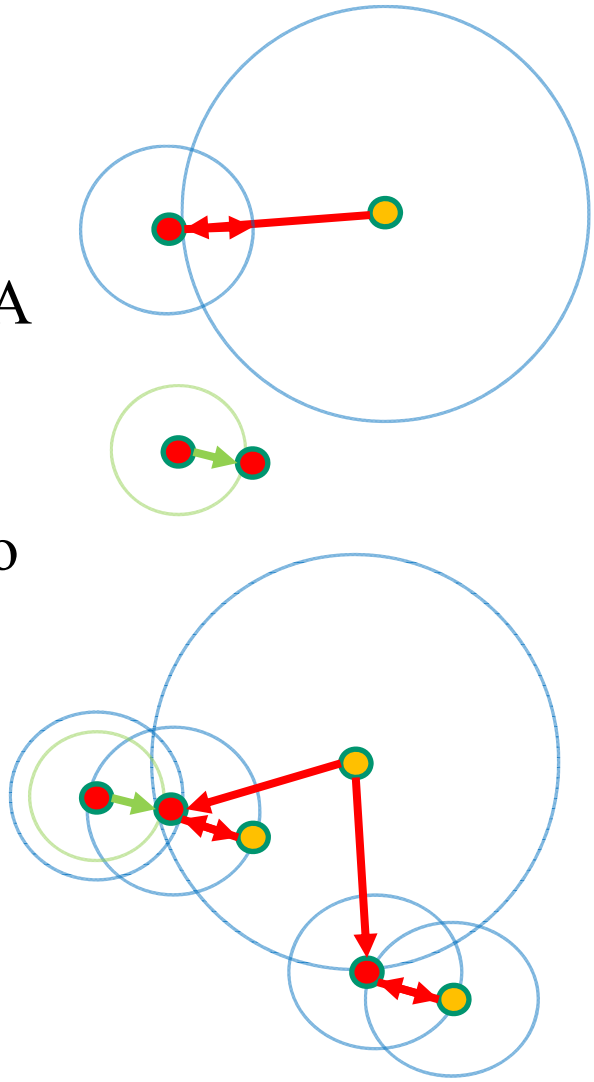

Encounter Situations

Formally…

Definition: Combat Component

- *units U and the union* $E_d = CL \cup SL$ *of combat links CL and support links SL* between the units in *U*.
- $E_u = \{(u_i, u_j)|(u_i, u_j) \in E_d \vee (u_j, u_i) \in E_d\}$
- Situation graph $G(U, E_u)$.
- Combat component *C:* Connected subgraph $G(\overline{U}, \overline{E})$ of $G(U, E_u)$ where $\overline{U} \subseteq U, \overline{E} \subseteq \overline{U} \times \overline{U}$
  and $\forall u_1, u_l \in \overline{U}: \exists (u_1, u_2, .. u_l)$
  where $i \in \{1, .., l\}: (u_i, u_{i+1}) \in \overline{E}$
  and $\exists u_i, u_j \in \overline{U}: u_1.team \neq u_2.team.$

Defining Encounters

- Component Graphs describe an Encounter at tick *t*
- An encounter usually lasts multiple consecutive ticks
- Hero Units can join encounters
- Hero Units might be defeated or leave
- Encounters can split
- Encounters can join

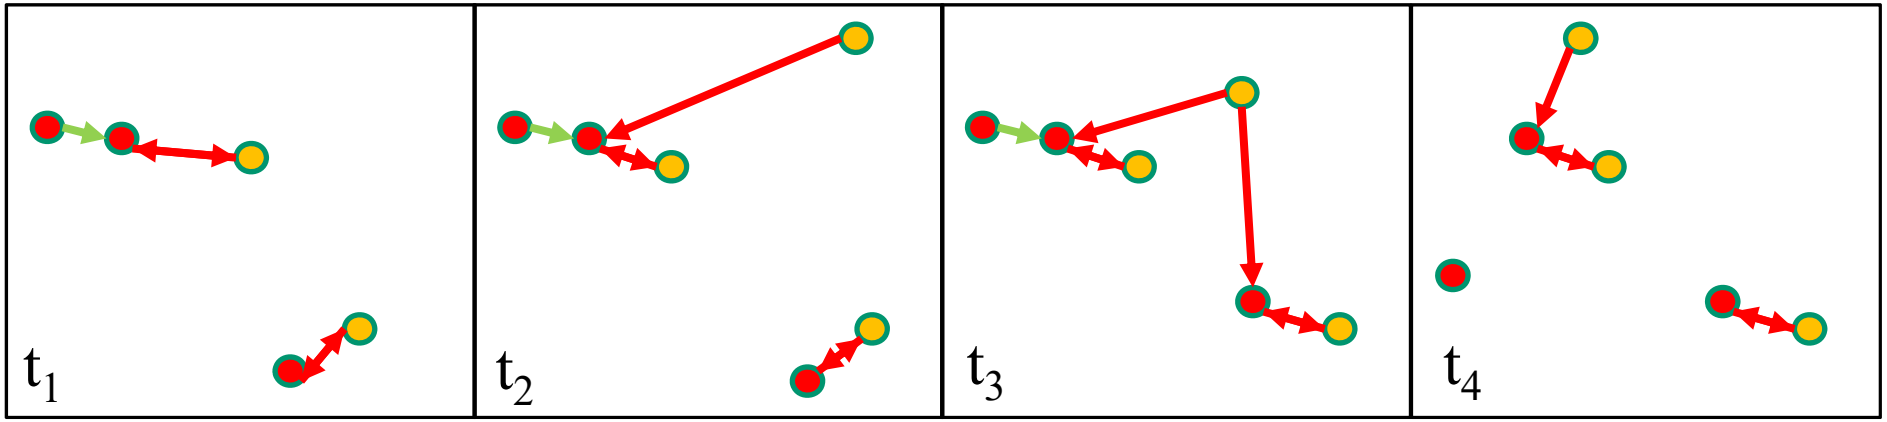

Defining Encounters

Formally…

Definition: Successor

Given a set of components CS_t=$\{ C_{1,t}, \ldots, C_{l,t} \}$ describing encounter *E* at tick *t*. Let τ be a timeout threshold. A component $C_{t+\Delta t}$ is a successor of CS_t denoted as $CS_t \rightarrow C_{t+\Delta t}$ if the following conditions hold:

- $\Delta t \leq \tau$
- $\exists u_1, u_2 \in C_{t+\Delta t} : \exists C_{i,t} \in CS_t : u_1 \in C_{i,t} \wedge C_{j,t} \in CS_t : u_2 \in C_{j,t} \wedge u_1.team \neq u_2.team$

Defining Encounters

Formally….

Definition: Encounter

An encounter is a sequence $(CS_0,..,CS_{,l})$ of lists of components CS_i where the following condition holds: : $\forall C_{i,t} \in CS_t : CS_{t-1} \rightarrow C_{i,t}$ with $t \in \{1,..,l\}$.

Encounter Detection

What is the input data ?

- hero type (combat range, support range), team
- time series of position updates (one at a time)

Algorithm:

- Initialize hero information
- Stream over position updates and update distances
- For each player movement process the impact to the current component graphs
- Keep lists of open encounters
- Move encounters to a closed set if they time out

The Algorithms

```
Encounter Detection (position_stream)
While position_stream.hasNext():
    component = build_component(unit,distance_table)
    If component is combat component:
        compute predecessors(component, open_encounters)
        If predecessors.size() == 0:
          open_encounters.add(new Encounter(component)
        If predecessors.size() == 1:
          predecessors.get(1).update(component)
        If predecessors.size() >1:
          open_encounters.join(predecessors,component)
        For encounter in open_encouters:
          If encounter has timeout:
            move encounter from open_encounter to closed_encounters
For encounter in open_encouters:
        move encounter from open_encounter to closed_encounters
return closed_encounters
```

An Example Encounter (Detailed View)

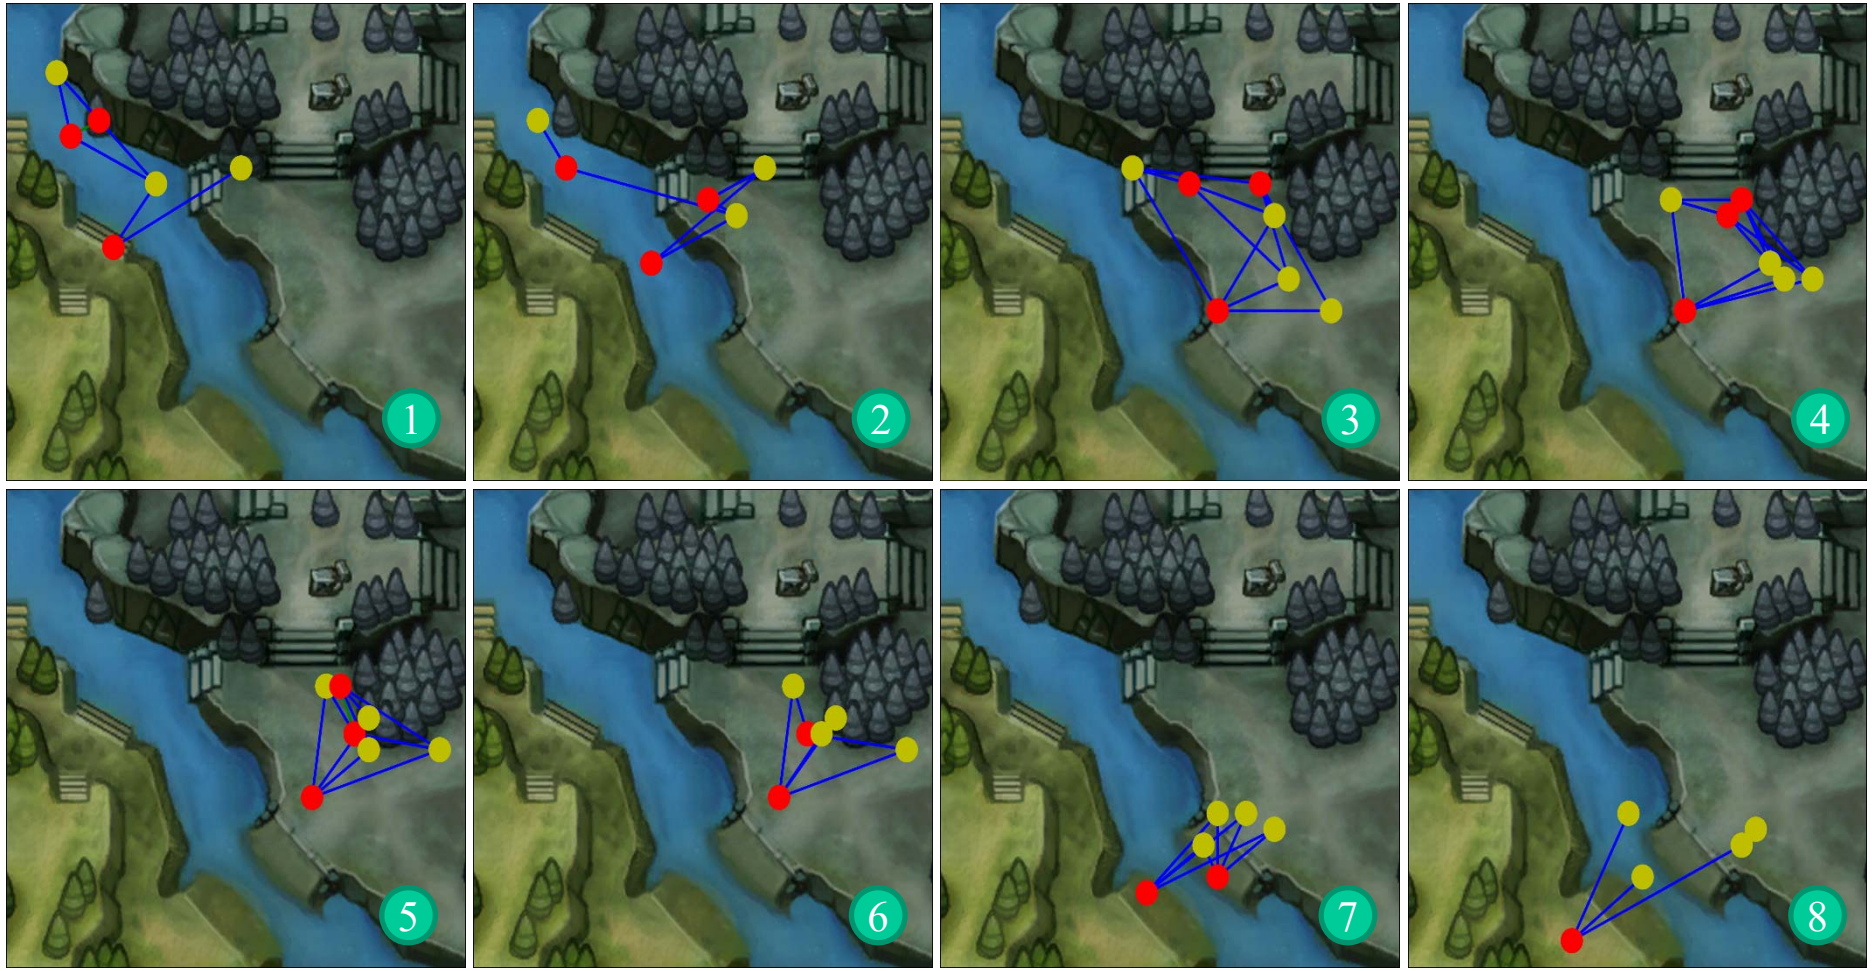

Lernziele

- Anwendungen für Spatial Game Analytics
- Heat Maps mit Bin Counting und Kerndichteschätzer
- Tasks im Spatial Data Mining
- Spatial Prediction mit Autoregression
- Spatial Outlier Detection mit POD
- Trajektorien, relative und absolute Trajektorien
- Vergleiche zwischen Trajektorien (LCSS)
- Kompression von Trajektorien
- Mustersuche in Trajektorien
  - Definition von Flocks
  - Berechnung von Flocks
  - Definition von Meets
  - Encounter Detection

Literatur

- Marcos R. Vieira, Petko Bakalov, and Vassilis J. Tsotras. 2009. ***On-line discovery of flock patterns in spatio-temporal data***. In *Proc of the 17t*th*ACM SIGSPATIAL Int. Conf. on Advances in Geographic Information Systems* (GIS '09). ACM, New York, NY, USA, 286-295.
- Yu Zheng, Xiaofang Zhou: ***Computing with Spatial Trajectories***, Springer, 2011.
- Marc Benkert, Joachim Gudmundsson, Florian Hübner, and Thomas Wolle. ***Reporting flock patterns***. *Comput. Geom. Theory Appl.* 41, 3 (November 2008), 111-125.
- Anders Drachen, Alessandro Canossa : **Evaluating Motion: Spatial User Behavior in Virtual Environments** International Journal of Arts and Technology, 4(3): 1--21, 2011.
- H.K. Pao, K.T. Chen, H.C. Chang: **Game Bot Detection via Avatar Trajectory Analysis** Computational Intelligence and AI in Games, IEEE Transactions on, 2(3): 162--175, 2010.
- Jehn-Ruey Jiang, Ching-Chuan Huang, Chung-Hsien Tsai: **Avatar Path Clustering in Networked Virtual Environments** In Proceedings of the 2010 IEEE 16th International Conference on Parallel and Distributed Systems, 2010.
- C. Thurau, C. Bauckhage, G. Sagerer: **Learning human-like movement behavior for computer games,** In From animals to animats 8: Proceedings of the 8th International Conference on Simulation of Adaptive Behavior, 2004.
- Yufeng Kou, Chang-Tien Lu, Raimundo F. Dos Santos: ***Spatial Outlier Detection: A Graph-Based Approach***, 19th IEEE International Conference on Tools with Artificial Intelligence , pp. 281-288, Vol.1 (ICTAI 2007), 2007.
- Shekhar, Shashi and Schrater, Paul and Vatsavai, Ranga Raju and Wu, Wei Li and Chawla, Sanjay. **Spatial Contextual Classification and Prediction Models for Mining Geospatial Data**. *IEEE Transactions on Multimedia. 4(2):174-188, 2002.*