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

# Kapitel 9:Räumliche Verhaltensmodelle



http://www.dbs.informatik.uni-muenchen.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 räumliche und räumlich zeitlichen Abläufen wird unter dem Begriff *Spatial Data Mining* zusammengefasst

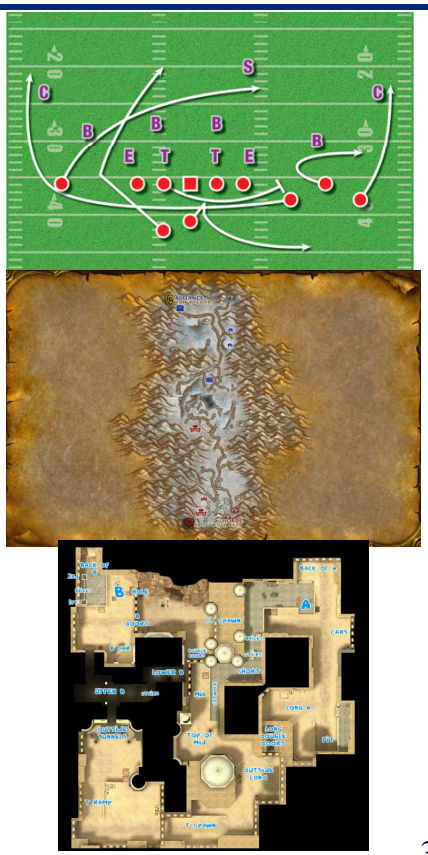



# Aufgaben Spatial Game Analytics

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


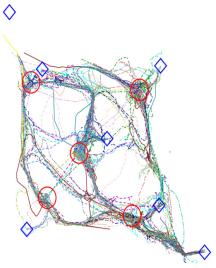

⇒ Suche bestimmte Orte(Heatmaps, Spatial Prediction, Spatial Outlier)

⇒ 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.

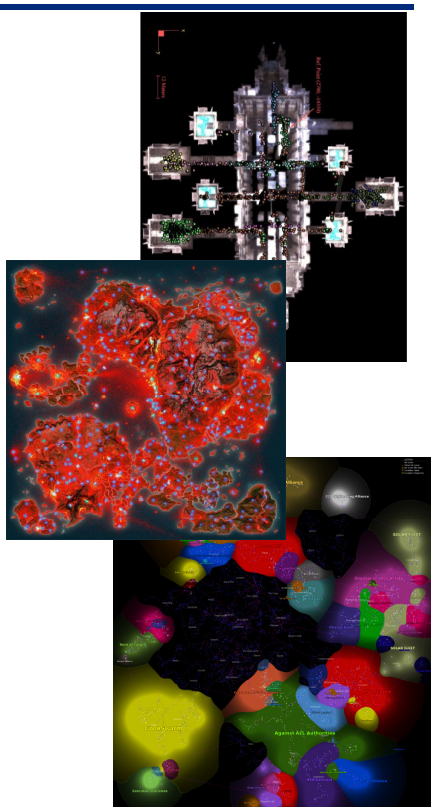

⇒ Darstellung von aggregierten Informationen über 2D Histogramme (Bin Counting)

⇒ 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 unidistantes Grid über die Karte
2. Für jedes Ereignis
   1. Bestimme 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.

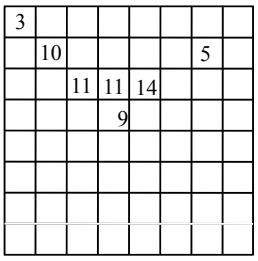


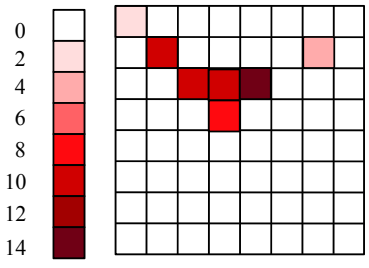

# Heat Maps

**Probleme bei Bin Counting**:

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

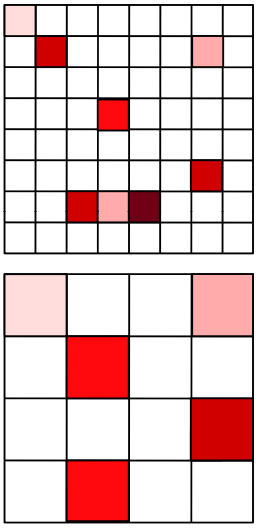

**Abhilfe**: Glätten der Kurve mit Kerndichteschätzung
Abschätzung der Objektdichte über Summe von Kernfunktionen

⇒ Kontinuierliche und geglättete Dichtfunktion

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

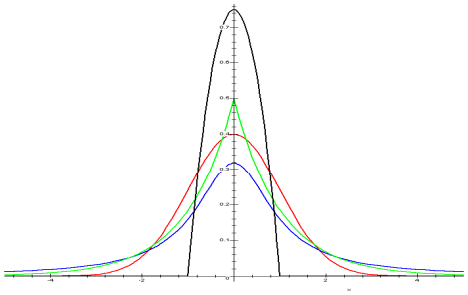

# Heatmaps mit Kerndichteschätzern

- 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.*

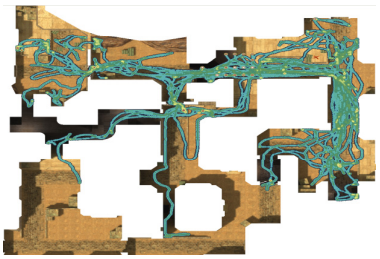

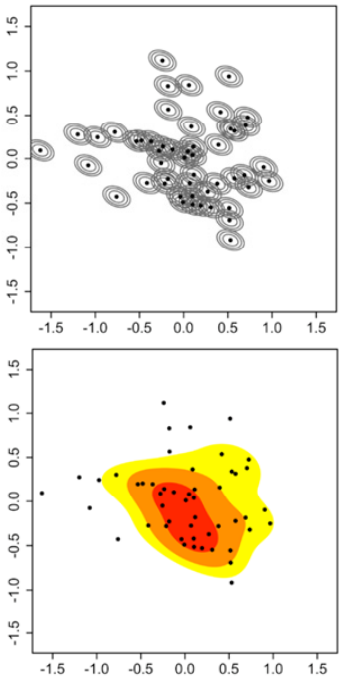




# Spatial Data Mining

- Spezialbereich des Data Mining das 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 Stelle ein 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 50km 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 räumlich 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.

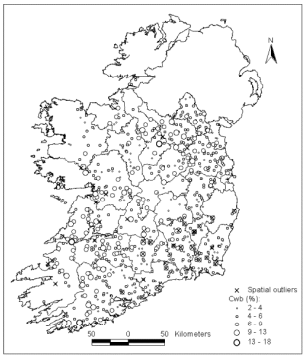


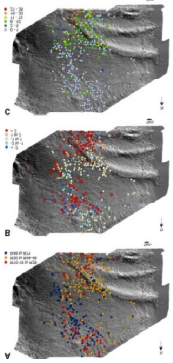

# Spatial Outlier Detection

***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

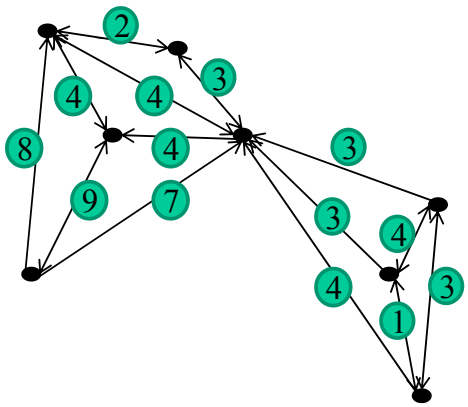




# Beispiel POD

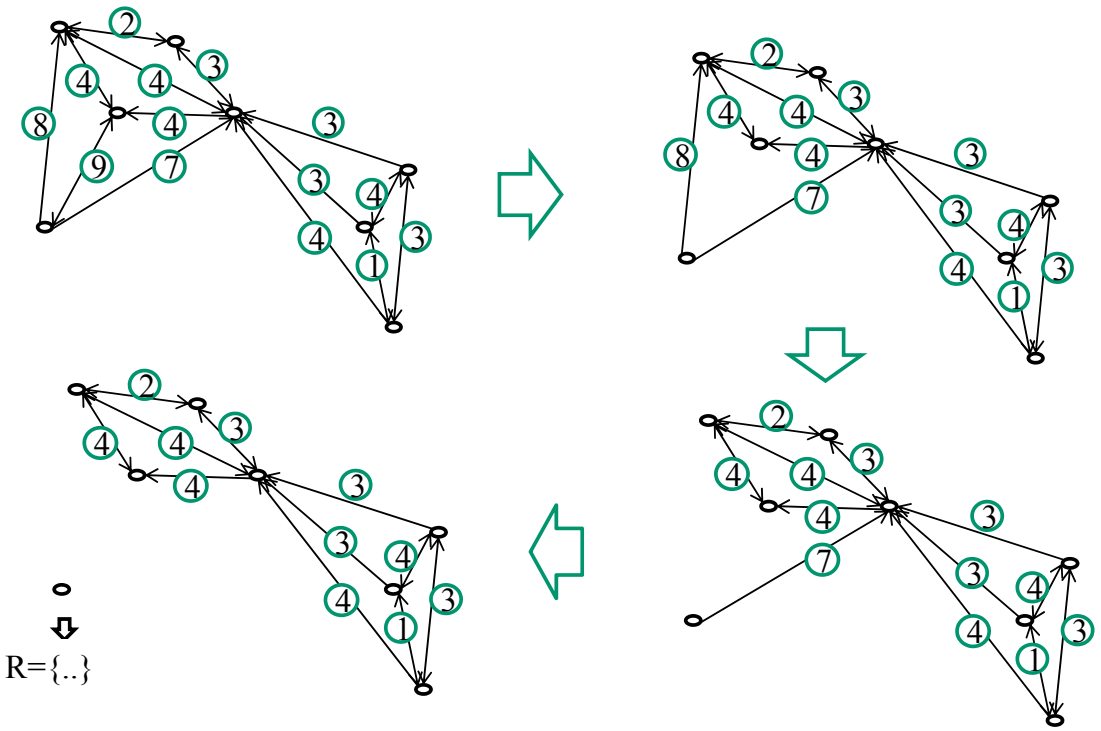

# Trajektorien

- Trajektorien beschreiben eine Bewegung durch den Raum (Zeitreihen über räumliche Positionen)
- **Räumliche Trajektorie**: $Q=(x_1,..,x_l) \in IR^2 \times .. \times IR^2$ 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.

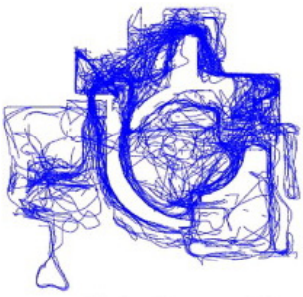

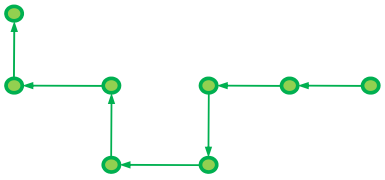

go , go, turn left, go, turn right, go, turn right, go, turn left, go, turn right, go

- Bewegung ist kontinuierlich: Um einen kontinuierlichen Pfad zu erhalten, wird idR 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 $Q=((x_1,t_1),..,(x_l,t_l))$ :

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

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

*Closest Pair Distanz:*

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

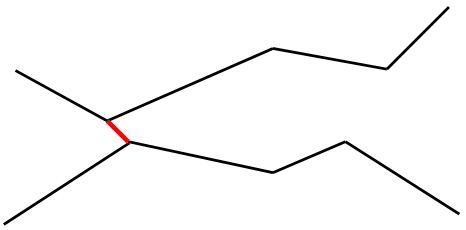

*Sum-of-Pairs:*

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

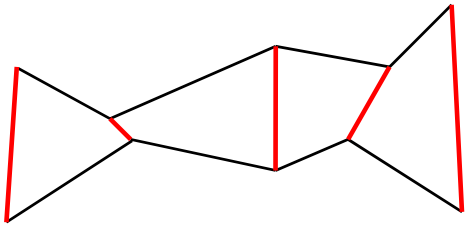

# Abstandsmaße für Trajektorien

- bei unterschiedlicher Länge: DTW (Sieh Kapitel 8)
  Aber: DTW ist anfällig für Ausreißer.
- Längste gemeinsame Subsequenz (Ähnlichkeitsmaß!)
  LCSS (Longest Common SubSequenz):

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

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

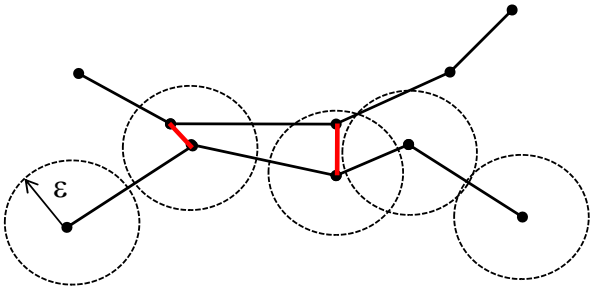




# LCSS Ähnlichkeit

- 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:

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

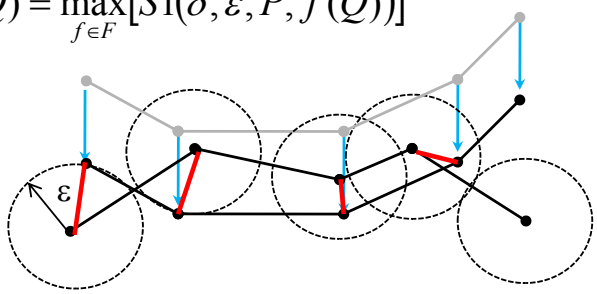

# Kompression von Trajektorien

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
- Vergleich werden sehr teuer (alle DTW basierten Maße sind quadratisch)

Lösungsansatz: Reduktion der Wegpunkte

⇒ Kompression durch Weglassen von Wegpunkten

⇒ Gute Verfahren minimieren  Approximationsfehler



# Douglas-Peuker Algorithmus

**Gegeben**: Eine Trajektorie $Q=((x_1,t_1),..., (x_l,t_l))$ 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‘*

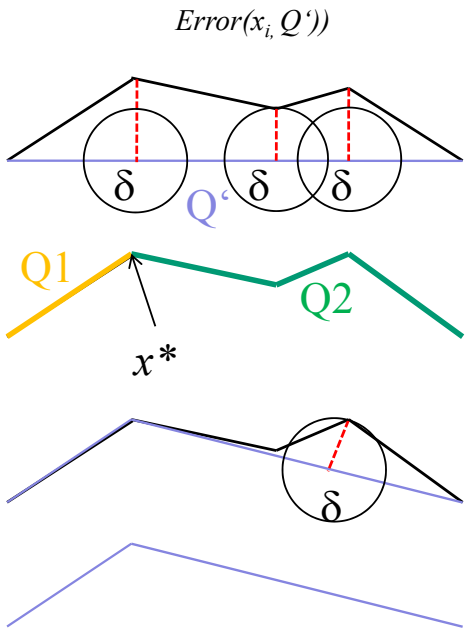

# Kompression mit Geschwindigkeit und Richtung

- 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 $i+1$

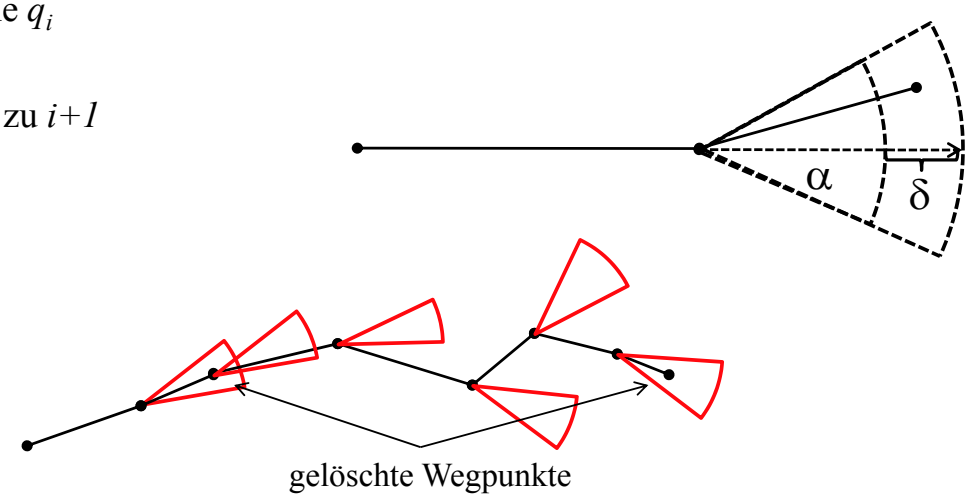


gelöschte Wegpunkte



# 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..

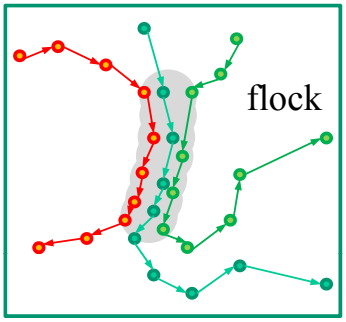


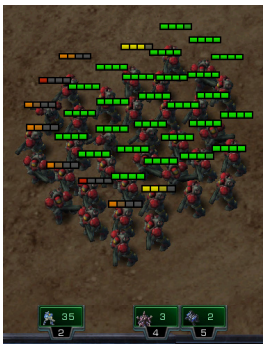

**Definition:** *Kontinuierlicher (m,k,r)-Flock*

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

# Suche nach Flocks

**Vorgehen umfasst 2 Teilaufgaben**:

1. Finde alle Scheiben mit Radius *r* die mindesten *m* Punkte zum Zeitpuntk $t_i$ enthalten.
   => Sequenz aus Teilmengen von DB
   => Ein Trajektorie kann auch in mehreren Teilmengen enthalten ein.

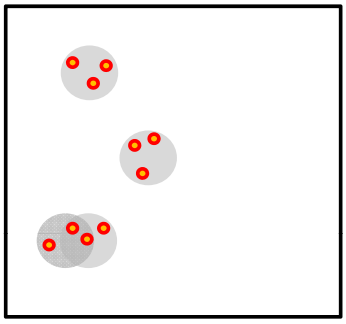

2. Finde Sequenz $(S(t_i),..,S(t_j))$ von Scheiben $S(t_l)$ für die Zeitpunkte $t_l$ mit $i \leq l \leq j$ für die gilt:

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

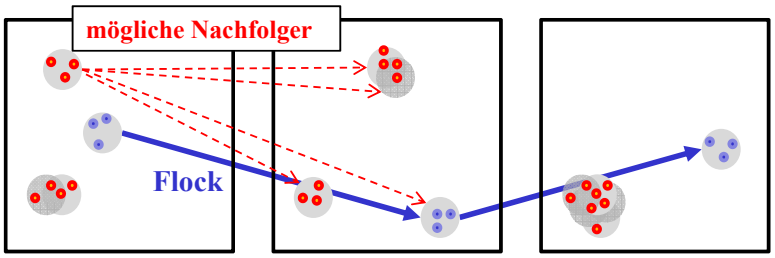




# Finden aller Scheiben zum Zeitpunkt t

**Disks**($t_i$)
Generiere Grid-Index I über $DB_i$
**FOR ALL** non-empty cells gx ∈ I **DO**
  *Pr = gx*
  *Ps= NeigborCells(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*

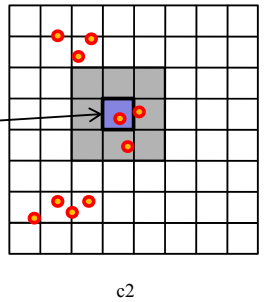


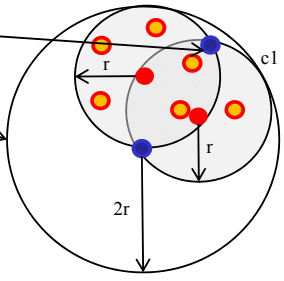

# Finden von (m,k,r)-Flocks

**Continous 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 1 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.

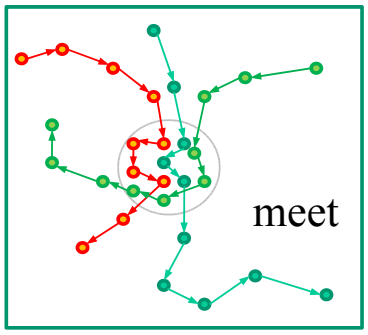


**Definition:** (m,k,r)-Meet

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

**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.

# 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
  (Douglas-Peuker, geschwindigkeits- und richtungbasierte Komp.)
- Mustersuche in Trajektorien
  - Definition von Flocks
  - Berechnung von Flocks
  - Definition von Meets



# 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 16$^{th}$ 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 8$^{th}$ 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*