

---

# Kapitel 4

## Anfragemethoden auf Verkehrsnetzwerke

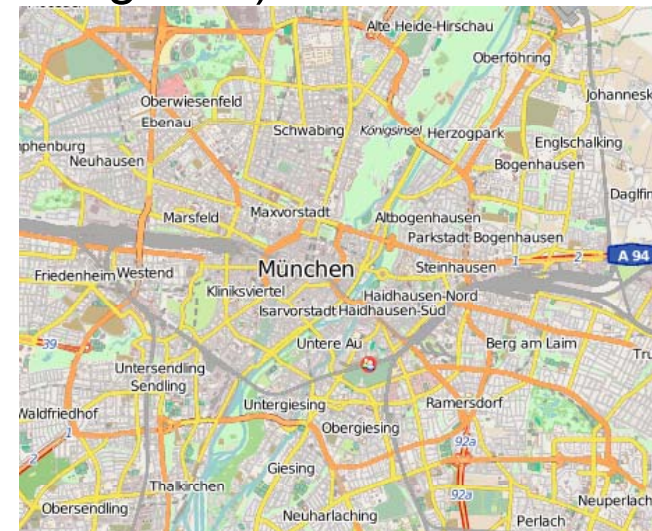
---

Skript zur Vorlesung: Spatial, Temporal, and Multimedia Databases II  
Wintersemester 2011/12, LMU München

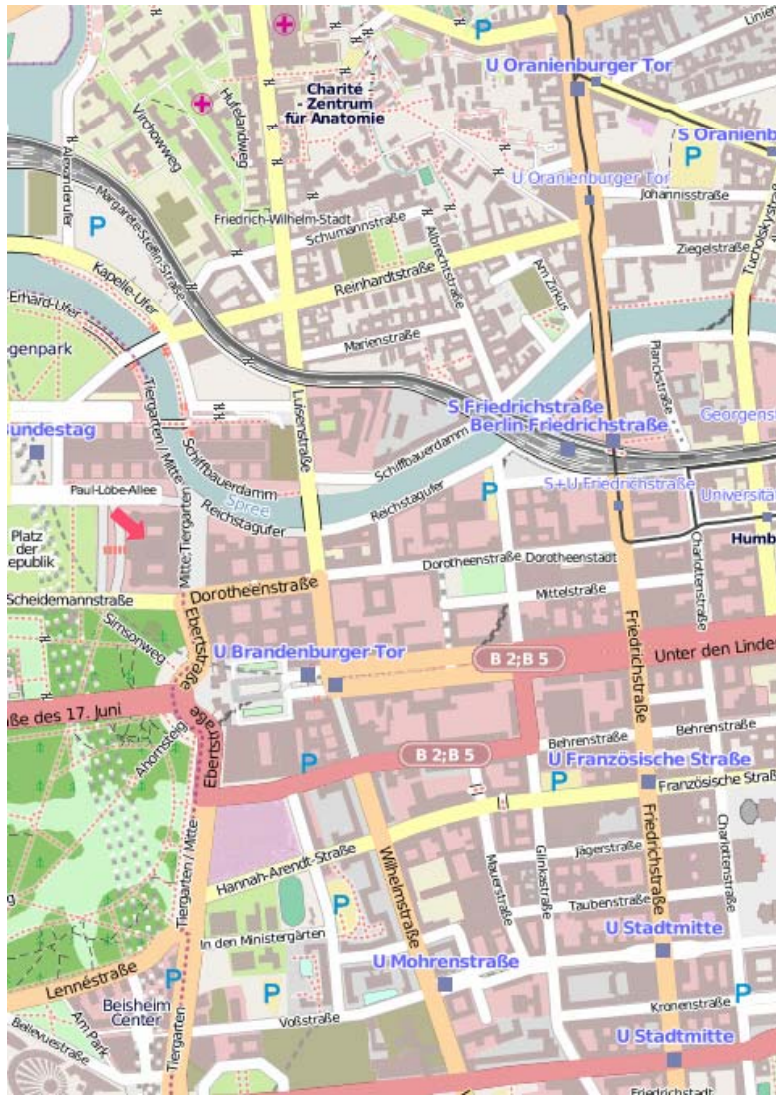
© 2011 PD Dr. Matthias Renz

## 4.1 Motivation


- Bisher: Distanz zwischen zwei Punkten über einfacher Distanzmaße wie z.B. die Euklidische Distanz berechnet.
- In vielen Anwendungen, z.B. im Straßenverkehr, existieren Einschränkungen bzgl. möglicher Bewegungsrichtungen.
- In Verkehrsnetzwerken wird als Distanz zwischen zwei Punkten i.d.R. die Länge des kürzesten Pfades (Netzwerkdistance) zwischen den Punkten angenommen
- (Beispiel: Distanzangaben bei der Navigation)
- Neue Herausforderung:  
Berechnung der Distanz  
(bzw. Nachbarschaft/Ähnlichkeit)  
ist sehr teuer  
=> Minimierung der  
Distanzvergleiche



# Straßen-, Fluss- und Schienennetzwerke



Maximilian Dörtbecker



## – Beispiel-Anfragen

- Schienennetzwerke:
  - “Finde die Stationen auf der ICE-Strecke von München nach Berlin.”
  - “Finde alle Stationen, die direkt vom Marienplatz erreicht werden können.”
  - “Finde die Linien, die Starnberg und Universität verbinden.”
  - “Was ist der vorletzte Halt der U-Bahn nach Messestadt-West?”
- Flussnetzwerke:
  - “Was sind die Namen aller direkten und indirekten Zuflüsse der Donau?”
  - “Was sind alle direkten Zuflüsse des Rheins?”
  - “Welche Gewässer wären von einem Chemieunfall in der Breg betroffen?”
- Straßennetzwerke:
  - “Finde den kürzesten Pfad von der LMU zur HU Berlin.”
  - “Finde das nächste Computergeschäft nach zu laufender Strecke.”
  - “Finde den kürzesten Pfad, um mehrere Shops zu beliefern.”
  - “Verweise Kunden auf den nächsten Kundendienst.”



## 4.2 Modellierung von Verkehrsnetzwerken


Drei-Ebenen-Modell:

1. Konzeptuelles Datenmodell: Graphen
2. Logisches Datenmodell
  - Datentypen
    - Graph, Vertex, Edge, Path, ...
  - Operationen (Queries)
    - is connected(...), shortest-path(), weitere Nachbarschaftsanfragen, ...
3. Physisches Datenmodell
  - Hauptspeicherbasierte Darstellung
  - Festplattenbasierte Darstellung

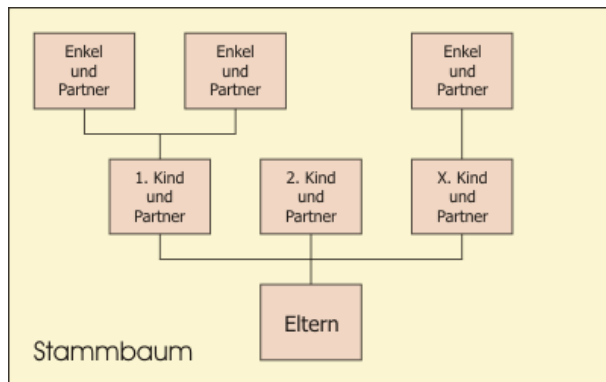
## 4.2.1 Konzeptuelles Modell

- Straßennetze können als Graph  $G=(V,E)$ , bestehend aus einer Menge von Knoten  $V$  sowie einer Menge von (gerichteten) Kanten  $E \subset \{(v_i, v_j) \mid v_i, v_j \in V\}$  modelliert werden
- Repräsentation 1: (üblich)
  - Knoten  $v_i \in V$ : Kreuzungen, Ende einer Straße, weitere relevante Punkte (z.B. Änderung der Geschwindigkeitsbeschränkung)
  - (Gerichtete) Kante  $e_i \in E$ : Straßenstück zwischen zwei Knoten, modelliert topologische Information
- Repräsentation 2:
  - Knoten  $v_i \in V$ : Straßen
  - Kanten  $e_i \in E$ : Kreuzungen zwischen Straßen

- Kanten haben Gewichte (Kosten), z. B.
  - reellwertig
    - Entfernung zwischen zwei Knoten
    - Fahrtdauer
    - Benzinverbrauch
    - gewichtete Kombination mehrerer Merkmale
  - vektorielle Kombination mehrerer reellwertiger Gewichte [KRS10]



- Klassifikation von Graphen
  - Repräsentieren Knoten räumliche Punkte?  
Räumlicher Graph ↔ Abstrakter Graph
  - Gerichteter Graph ↔ Ungerichteter Graph



## 4.2.2 Logisches Datenmodell – Datentypen


– Beschreibt das Schema einer Räumlichen Netzwerk Datenbank (Spatial Network Database SNDB)

- Vertex, Attribute:
  - label
  - isVisited
  - location (räumliche Graphen)
- DirectedEdge, Attribute:
  - startNode
  - endNode
  - label
- Graph, Attribute:
  - Set<Vertex>
  - Set<DirectedEdge>
- Path: Attribute
  - Sequence<Vertex>



## 4.2.3 Physisches Datenmodell


- Hauptspeicherbasiert:
  - Adjazenzmatrix:  $M[A, B] = 1$  gdw.  $\text{edge}(\text{vertex } A, \text{vertex } B)$  existiert
  - Adjazenzlisten: Bildet vertex A auf eine Liste von Nachfolgern von A ab
  - Beispiele: Abbildung (a), (b) und (c) auf der nächsten Folie
- Festplattenbasiert
  - Normalisiert -- Tabellen, eine für Knoten, die andere für Kanten
  - Denormalisiert – Tabelle für Knoten + Adjazenzlisten
  - Beispiele: Siehe Abbildung (a), (d) und (e) auf der nächsten Folie



(a)

		Destination				
		1	2	3	4	5
source	1	0	1	0	1	0
	2	0	0	1	1	0
	3	0	0	0	0	0
	4	0	0	0	0	1
	5	1	0	0	0	0

(b) Adjacency-matrix



(c) Adjacency-List

Node (R)

id	x	y
1	4.0	5.0
2	6.0	3.0
3	5.0	1.0
4	3.0	2.0
5	1.0	3.0

Edge (S)

source	dest	distance
1	2	$\sqrt{8}$
1	4	$\sqrt{10}$
2	3	$\sqrt{5}$
2	4	$\sqrt{10}$
4	5	$\sqrt{5}$
5	1	$\sqrt{18}$

(d) Node and Edge Relations

id	x	y	Successors	Predecessors
1	4.0	5.0	(2,4)	(5)
2	6.0	3.0	(3,4)	(1)
3	5.0	1.0	( )	(2)
4	3.0	2.0	(5)	(1,2)
5	1.0	3.0	(1)	(4)

(e) Denormalized Node Table

## 4.3 Basisalgorithmen auf Straßennetzen

- Von grundlegender Bedeutung für die Anfragebearbeitung auf Straßennetzwerken ist die Berechnung von Distanzen zwischen zwei Knoten
  - Dijkstra: Berechnung der kürzesten Pfade zwischen einem Startknoten und allen verbleibenden Knoten
  - A\*-Algorithmus: Berechnung des kürzesten Pfades zwischen einem Startknoten und einem Endknoten
  - Floyd: Berechnung des kürzesten Pfades von jedem Knoten zu jedem anderen Knoten
- Die berechneten Distanzen  $\text{dist}_{\text{net}}(v_i, v_j)$  können dann wiederum zur Bearbeitung komplexerer Anfragen auf Straßennetzen verwendet werden
  - Bereichsanfragen
  - Nächste-Nachbarn-Anfragen
  - Skyline-Queries
- $\text{dist}_{\text{net}}(v_i, v_j)$  im Gegensatz zur euklidischen Distanz nicht unbedingt symmetrisch (z.B. Einbahnstraßen):  $\text{dist}_{\text{net}}(v_i, v_j) \neq \text{dist}_{\text{net}}(v_j, v_i)$

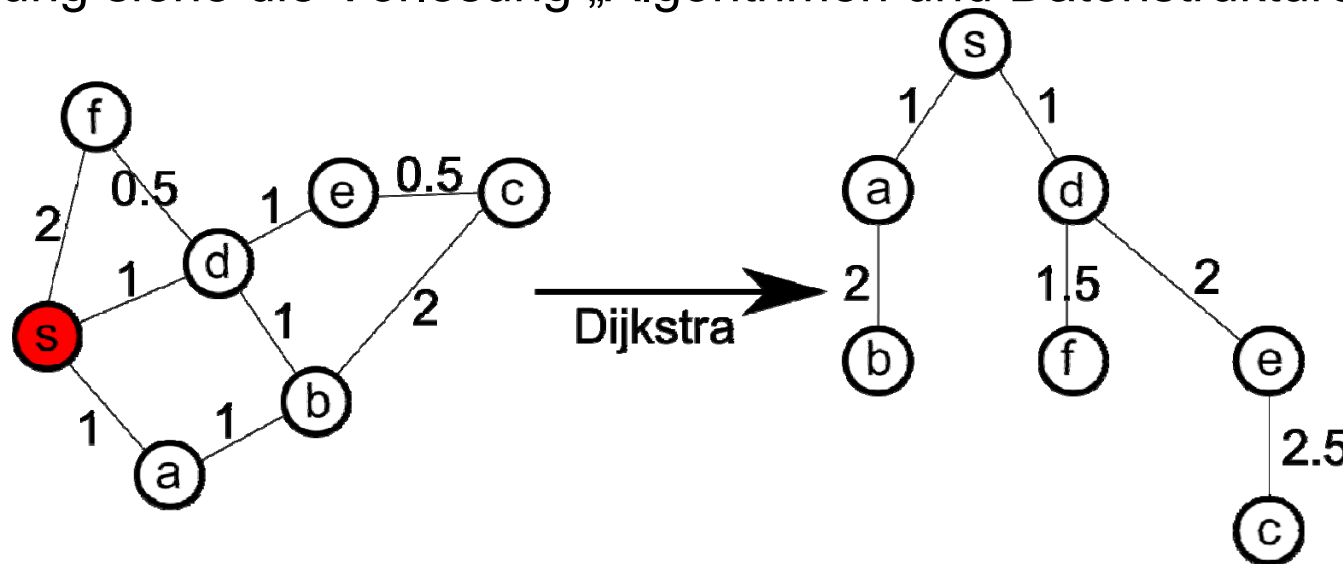
## 4.3.1 Single-Source Shortest Path – Dijkstra

- Gegeben:

- (gerichteter) Graph  $G=(V,E)$
- Kanten haben nicht-negative, reelle Gewichte


- Gesucht: Kürzester Pfad von einem Startknoten  $s$  zu allen erreichbaren verbleibenden Knoten

- Hier nur eine kurze Wiederholung des Algorithmus, für eine genaue Erläuterung siehe die Vorlesung „Algorithmen und Datenstrukturen“



## 4.3.2 Der A\*-Algorithmus<sup>[HNR68]</sup>

- Ziel: Bestimme den kürzesten Pfad von einem Startknoten  $s$  zu einem Zielknoten  $e$
- Nah verwandt mit dem Dijkstra-Algorithmus
- Heuristisches Verfahren: A\* schätzt Entfernungen zwischen Knoten, dadurch Reduktion des Suchaufwands
- Best-First-Search mit Hilfe der gewählten Heuristik
- Eigenschaften:
  - Korrekt: Findet trotz Verwendung einer Heuristik Immer den kürzesten Pfad von  $s$  nach  $e$



### Heuristik des A\*-Algorithmus:

- Knoten  $v_i \in V$  werden nicht wie bei Dijkstra in zufälliger Reihenfolge, sondern anhand ihrer erwarteten Relevanz in Best-First-Manier betrachtet
- Die Relevanz eines Knotens  $f(v_i)$  ist bestimmt durch die geschätzte Länge des Weges von  $s$  nach  $e$  über  $v_i$ :  $f(v_i) = g(v_i) + h(v_i)$ 
  - $f(v_i)$  – Kosten von  $s$  über  $v_i$  nach  $e$
  - $g(v_i)$  – bisher ermittelte minimale Kosten von  $s$  nach  $v_i$
  - $h(v_i)$  – Schätzung der Kosten von  $v_i$  nach  $e$ , z.B.  $L_2$ -Distanz
    - Wichtig: Lower-Bounding- Eigenschaft von  $h(n)$ .
    - Je besser die Schätzung von  $h(v_i)$ , desto weniger Knoten müssen besucht werden
    - Bei Verwendung von  $h(v_i) = 0$  verhält sich A\* wie Dijkstra



```
function A*(s,e)
  closedset =  $\emptyset$  // Bereits betrachtete Knoten
  g[s] = 0 // Kosten von s nach Knoten x über den besten bekannten Pfad
  h[s] = heuristicCostEstimate(s, e)
  openheap = {(s, g[s] + h[s])} // Zu betrachtende Knoten
  cameFrom =  $\emptyset$  // Zur Rekonstruktion des kürzesten Pfades

  while openheap  $\neq \emptyset$ 
    (x, f) = openheap.poll();
    if x == e
      rekonstruiere Pfad über cameFrom und gib Ergebnispfad zurück
    closedset.add(x);
    foreach y  $\in$  neighbors(x)
      if y  $\in$  closedset:
        continue
      gNew := g[x] + dist(x,y)
      if (y  $\notin$  openheap)  $\wedge$  (gNew < g[y])
        newPathIsBetter := true
      else
        newPathIsBetter := false
      if newPathIsBetter
        cameFrom[y] := x
        g[y] := tentativeGScore
        h[y] := heuristicCostEstimate(y, goal)
        lösche ggf. altes y aus openheap und füge (y, g[y] + h[y]) in openheap ein
  return null //kein Pfad gefunden
```

*Heuristiken für A\*: Setze  $h(v) = 0$*

- Die zurückzulegende Distanz wird immer auf 0 gesetzt
- Dadurch wird der Heap der zu besuchenden Knoten nur anhand der bereits zurückgelegten Strecke sortiert
- Das entspricht dem Dijkstra-Algorithmus
- Der Suchraum wird dadurch extrem groß

*Heuristiken für A\*: Setze  $h(v) = dist_{L_2}(v, e)$*

- Verwendet stets die geringste praktisch mögliche Distanz
- Reale Distanz ist normalerweise weit größer als euklidische Distanz
- Kleinerer Suchraum als bei Dijkstra, aber immer noch sub-optimale Schätzung

### Heuristiken für A\*: Graph Embedding (D-Distanz)<sub>[KKKRS08]</sub>

- Wähle eine Teilmenge von Knoten  $V' \subseteq V$ ,  $|V'| = k \geq 1$
- Definiere eine Funktion  $F^{V'} : V \rightarrow \mathbb{R}^k$
- Für das Reference Node Embedding definiere  $F^{V'}$  folgendermaßen:

$$F^{V'}(v_i) = (F_1^{V'}(v_i), \dots, F_k^{V'}(v_i))$$

$$F_j^{V'}(v_i) = \text{dist}_{\text{net}}(v_i, v_j) \text{ (Preprocessing!)}$$

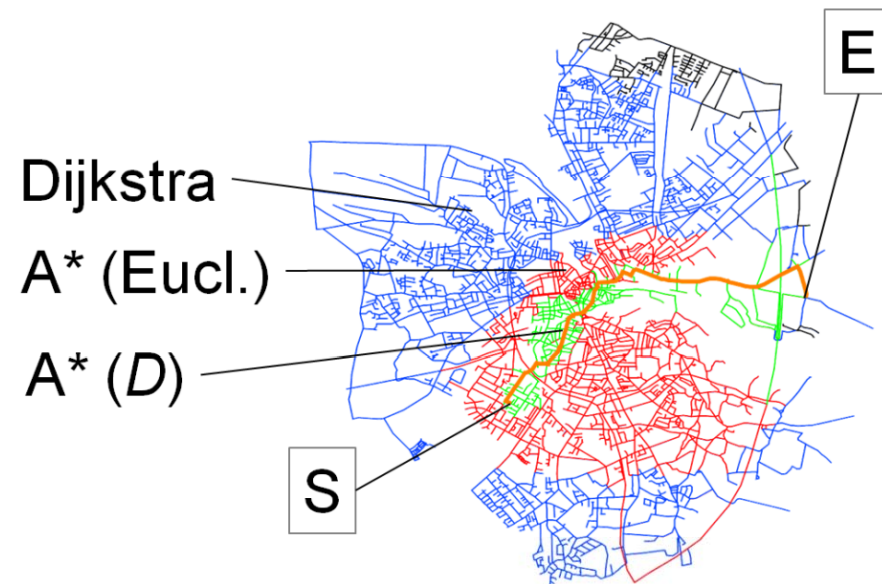
- $F^{V'}(v)$  kann direkt zur Berechnung von  $h(v)$  verwendet werden, denn es gilt  $\forall v_i, v_j \in V: \text{dist}_{L_\infty}(F^{V'}(v_i), F^{V'}(v_j)) \leq \text{dist}_{\text{net}}(v_i, v_j)$

#### – Beweis

Die Netzwerkdistanz  $\text{dist}_{\text{net}}(v_i, v_j)$  ist transitiv, deshalb gilt die folgende Aussage:

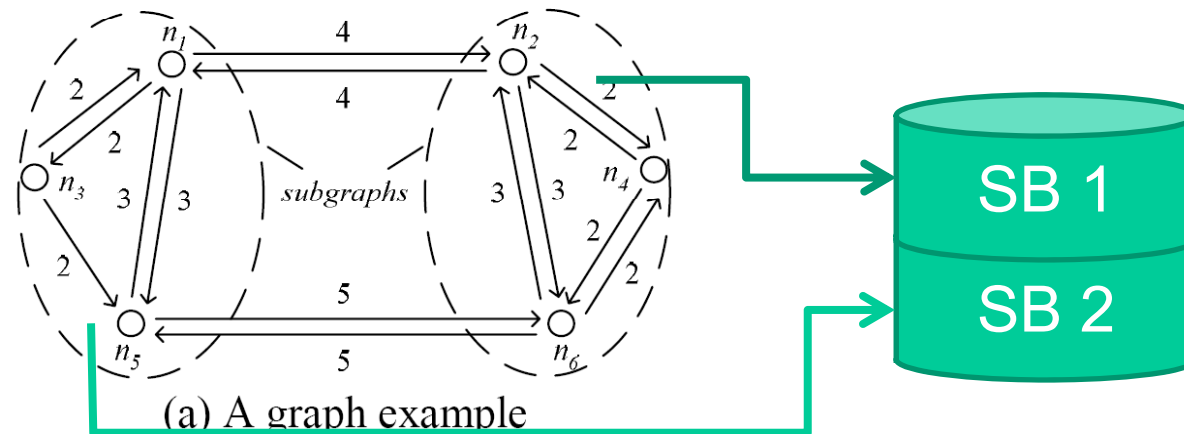
$$\begin{aligned} \text{dist}_{L_\infty}(F^{V'}(v_i), F^{V'}(v_j)) &= \\ &= \max_{l=1..k} |F_l^{V'}(v_i) - F_l^{V'}(v_j)| \\ &\leq \text{dist}_{\text{net}}(v_i, v_j) \end{aligned}$$

- Geringerer Suchraum als bei Verwendung der euklidischen Distanz





### 4.3.3 Effiziente Organisation des Straßen- Netzwerkgraphen

- Adjazenzlisten geeignet für Räumliche Netzwerkgraphen
- Ziel: Adaptierung der Adjazenzliste für Sekundärspeicherorganisation (Festplatte)
  - Effizienter Zugriff auf räumlich benachbarte Netzwerkelemente
  - Minimierung der I/O Kosten bei Anfragen
- Idee: Gruppiere Listen von adjazenten Knoten in gleichen Speicherblöcken (Seiten)



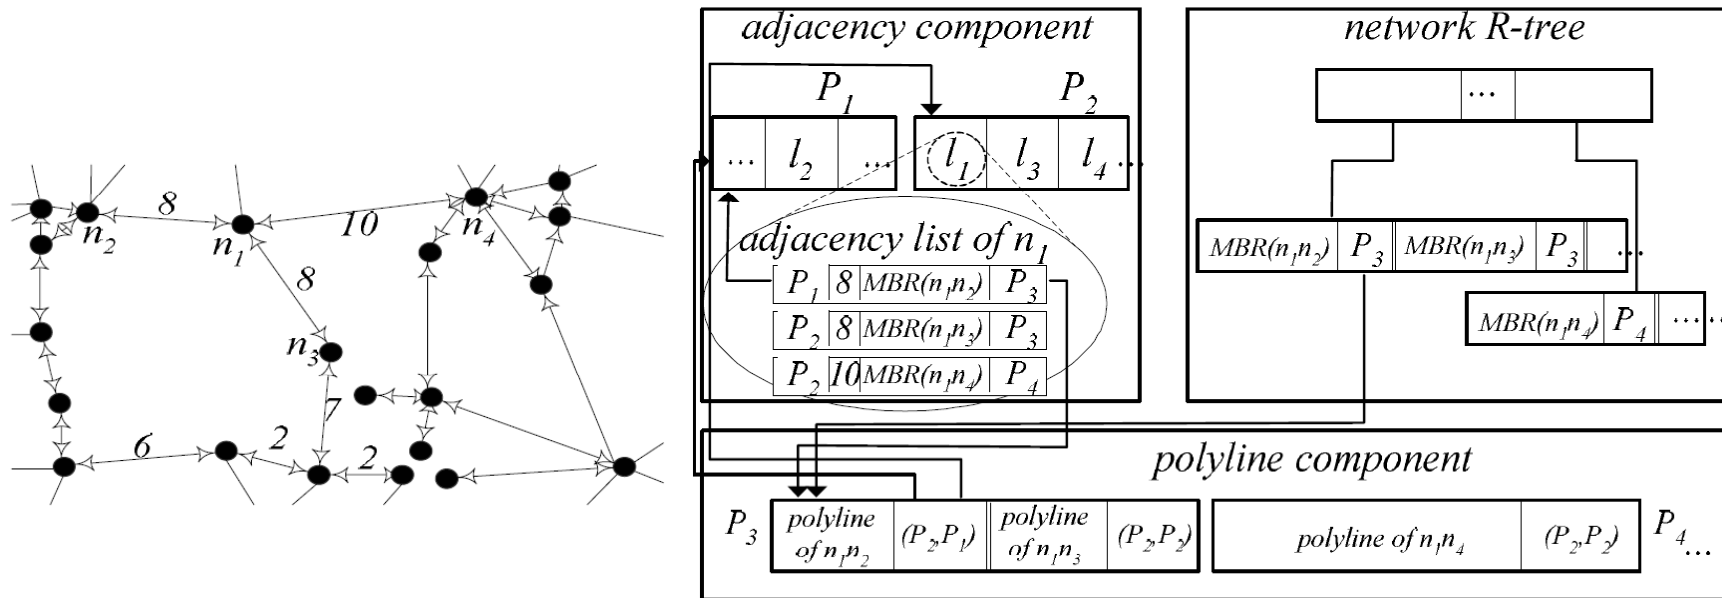
– Connectivity-Clustered Access Method (CCAM)

- Einbettung der Netzwerkknoten in den ein-dimensionalen Raum
  - Einbettung über raumfüllende Kurve, z.B. Z-Kurve
  - Z-Kurve erhält räumliche Nachbarschaft, d.h. räumlich nah beieinander liegende Knoten im Originalraum liegen auch nahe beieinander im eingebetteten Raum
- Adjazenzlisten nah beieinanderliegender Knoten werden in einer Seite (*list page*) abgespeichert
- List pages werden über einen B+-Baum auf den entsprechenden Knoten-Ids indexiert
- Eigenschaften:
  - Unterstützt Anfragen bzgl. der topologischen Verbundenheit im Netzwerkgraph z.B. shortest path, graph traversal - Anfragen
  - (Klassische) räumliche Anfragen mit Bezug zum Euklidischen Raum nicht gut unterstützt



– SNDB-Index-Architektur [PZMT03]

- Integriert Informationen über Raum und Verbundenheit
- Unterstützt (konventionelle) räumliche Anfragen als auch netzwerktopologische Anfragen
- 3-Komponenten-Architektur:
  - Adjazenz-Komponente (adjacency component)
  - Räumliche Komponente (network R-tree)
  - Polyline Komponente (polyline component)





- Folgende Funktionen werden im Folgenden benötigt. Sie basieren auf den vorgestellten Datenstrukturen, sollen aber nicht näher erläutert werden.
  - *check\_entity(segment, point)*: gibt *true* zurück, falls *point* auf *segment* liegt
  - *find\_segment(point)*: gibt das Segment zurück, auf dem *point* liegt. Liegt *point* auf mehreren Segmenten, wird das zuerst gefundene Segment zurückgegeben
  - *find\_entities(segment)*: Gibt alle Punkte zurück, die auf *segment* liegen
  - *compute\_ND(point1, point2)*: Berechnet Netzwerkdistanz zweier beliebiger Punkte *point1* und *point2*


## 4.4 Räumliche Anfragen in Straßennetzwerken

### 4.4.1 Bereichsanfragen

- Ziel: Bestimme alle Objekte in einem bestimmten Umkreis unter Beachtung des unterliegenden Netzwerkes:

$$Rq(q,r,DB) = \{x \in DB \mid \text{dist}_{\text{net}}(q,x) < r\}$$

Beispiel: „Finde alle Tankstellen in einer Umgebung von 15



– *Bereichsanfrage über Range Euclidean Restriction*<sub>[PZMT03]</sub>

- Bereichsanfrage auf DB bzgl. der euklidischen Distanz aller Objekte (**Punkte**) zu  $q$
- Weil  $\text{dist}_{\text{net}}(q,p) \geq \text{dist}_{L_2}(q,p)$  kommt es nicht zu false misses
- Es können aber sehr viele false hits entstehen
- Eliminierung der false hits über einmalige Network Expansion, um Kosten zu sparen

– Vorgehen

1. Suche Menge  $S'$  aller Punkte, die höchstens die euklidische Anfragedistanz  $e$  zum Anfragepunkt  $Q$  haben
2. Beginne eine Traversierung des Straßennetzes bei  $q$  entsprechend Dijkstra
3. Teste für jede mit dem Dijkstra-Algorithmus besuchte Kante  $k$ , ob ein Punkt  $p$  aus  $S'$  auf der Kante liegt.

Filter:  $p$  liegt in  $\text{MBR}(k)$ , Beschleunigung über Sortierung von  $S'$  bzgl. einer Dimension

Refinement:  $p$  liegt auf  $k$

– Durch dieses Vorgehen muss der Netzwerkgraph nur einmal durchlaufen werden

## - Algorithmus

**RER(q, e):**

result =  $\emptyset$

$S' = \text{Euclidean-range}(q, e)$

$n_i, n_j = \text{find\_segment}(q)$

$Q = \langle (n_i, d_N(q, n_i)), (n_j, d_N(q, n_j)) \rangle$

q

De-queue node n in Q with smallest  $d_N(q, n)$  //hole erstes Segment aus der Prioritätswarteschlange

while  $d_N(q, n) \leq e$  and  $S' \neq \emptyset$  //Traversiere den Graphen, zwei Abbruchbedingungen

  for each non-visited adjacent node  $n_x$  of n //Hole eine Nachfolgekante

    for each point s in  $S'$  //... und teste für jeden Punkt ...

      if  $\text{check\_entity}(n_x, n, s)$  //... ob er auf dem Segment  $n_x n$  liegt

        result = result  $\cup$  {s};  $S' = S' - \{s\}$

        en-queue ( $n_x, d_N(q, n_x)$ )

      de-queue the next node n in Q

end while

// $S'$  gibt alle Kandidaten mit euklidischer Distanz e zu q zurück

//Hole das Segment des Netzwerkgraphen, auf dem q liegt

//Q: Prioritätswarteschlange, sortiert nach Netzwerkdistanz zu

q

//hole erstes Segment aus der Prioritätswarteschlange

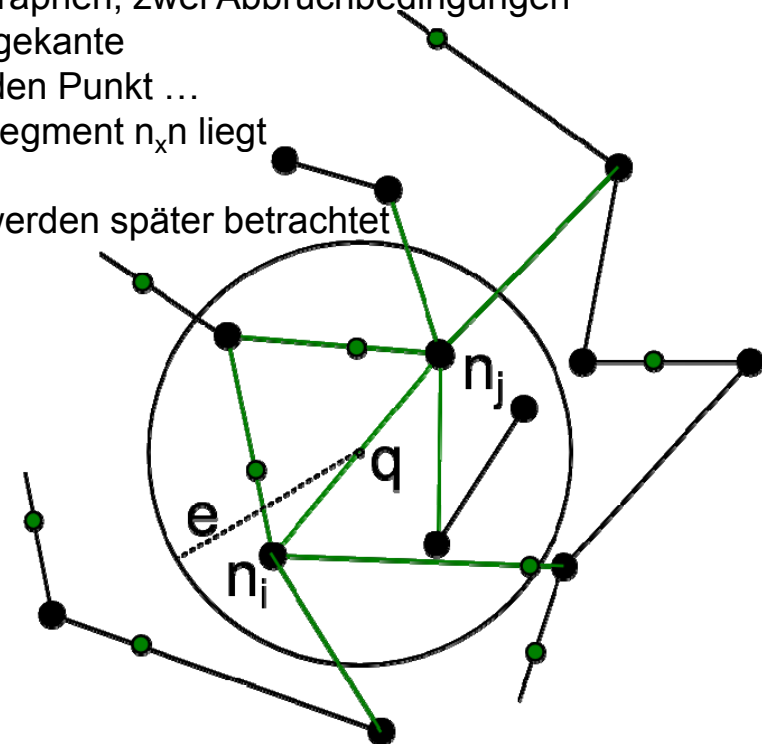
//Traversiere den Graphen, zwei Abbruchbedingungen

//Hole eine Nachfolgekante

//... und teste für jeden Punkt ...

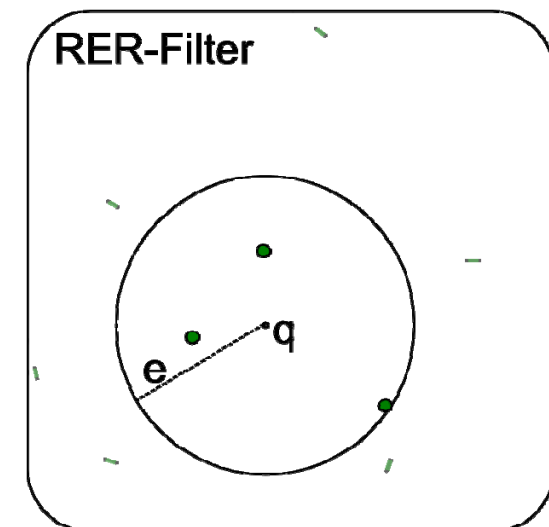
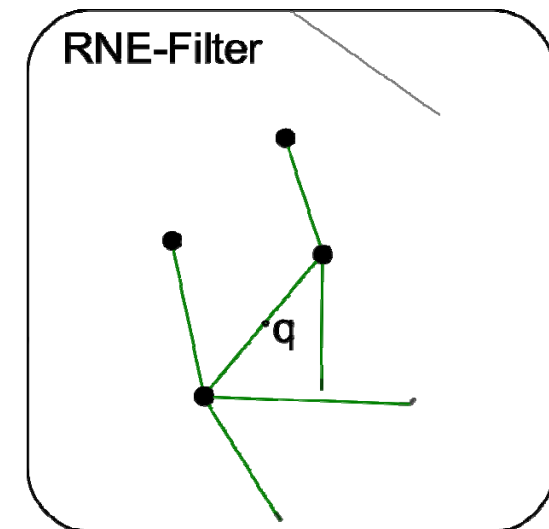
//... ob er auf dem Segment  $n_x n$  liegt

//die Kinder von  $n_x$  werden später betrachtet



– *Range Network Expansion* [PZMT03]

- Berechne Kandidatensegmente QS mit Entfernung  $e$  zur Anfrage  $q$
- Ergebnisse werden anhand dieser Kandidatensegmente ermittelt
- Damit können viele Anfragen gleichzeitig über den die Objekte verwaltenden R-Baum bearbeitet werden (Intersection Join): In jeden Teilbaum der Punktmenge, der mindestens ein Segment schneidet, wird abgestiegen
- Beim rekursiven Aufruf eines Teilastes werden nicht alle Elemente aus QS an den Teilbaum übergeben, sondern nur schneidende.
- Zuletzt müssen Duplikate entfernt werden, die direkt auf einem Knoten lagen und zweimal zurückgegeben wurden



– Algorithmus

**RNE(node\_id, QS, result):**

if (node\_id is an intermediate node)

    compute  $QS_i$  for each entry  $E_i$  in node\_id //join

    for each entry  $E_i$  in node\_id

        if ( $QS_i \neq \emptyset$ )

            RNE( $E_i$ .node\_id,  $QS_i$ , result)

Else

    result<sub>node\_id</sub> = plane-sweep(node\_id.entries,  $QS_i$ )

    sort result<sub>node\_id</sub> to remove duplicates

    result = result<sub>node\_id</sub>  $\cup$  result<sub>node\_id</sub>

//QS: Ergebnis einer Bereichsanfrage auf die

//Segmente mit Radius e

//Falls aktueller Knoten des Punkt-Index ein innerer

//Knoten ist ...

//... berechne für jedes Kind die Segmente, die das Kind

//schneiden ...

//... und rufe die Funktion rekursiv auf, wenn die

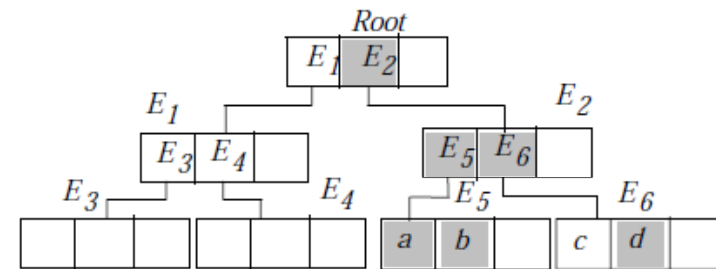

//Schnittmenge nicht leer ist

//Falls der Knoten ein Blatt ist, berechne über einen

//Plane-Sweep-Algorithmus alle Punkte, die auf das

//Segment fallen


//Und entferne ggf. Duplikate





## 4.4.2 Nächste-Nachbarn-Anfragen

- Ziel: Bestimme den nächsten Nachbarn bzgl. der zurückzulegenden Strecke.
- Beispiel: „Finde das mir am nächsten gelegene Hotel“
- Entspricht nicht unbedingt der euklidischen Distanz - im Beispiel hat  $d$  die kürzeste euklidische Distanz, aber eine sehr hohe Netzwerkdistanz.



[PZMT03]

## NN über Incremental Euclidean Restriction [PZMT03]

1. Berechne 1-NN  $p_{E1}$  bzgl. euklidischer Distanz über Standardalgorithmus



2. Berechne Netzwerkdistanz  $\text{dist}_{\text{net}}(q, p_{E1})$

- $\text{pruningdist} = \text{dist}_{\text{net}}(q, p_{E1})$
- $\text{resultCandidate} = p_{E1}$
- Da  $\text{dist}_{\text{net}}(q, p) \geq \text{dist}_{L_2}(q, p)$  haben alle möglichen Kandidaten  $c$  eine Distanz  $\text{dist}_{L_2}(q, c) < \text{dist}_{\text{net}}(q, p_{E1})$  (Pruningkriterium)

3. Solange für  $i$ -NN  $\text{dist}_{L_2}(q, p_{Ei}) \leq \text{pruningdist}$ :

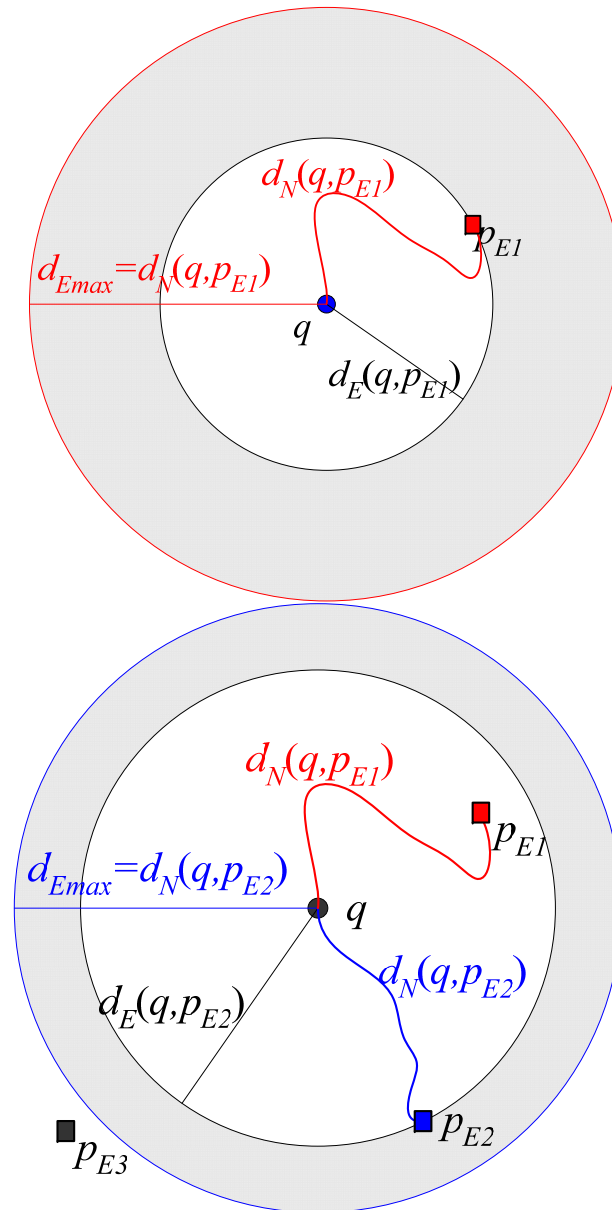
- Suche  $p_{E(i+1)}$
- Falls  $\text{dist}_{\text{net}}(q, p_{Ei}) < \text{dist}_{\text{net}}(q, \text{resultCandidate})$   
 $\text{resultCandidate} = p_{Ei}$   
 $\text{pruningdist} = \text{dist}_{\text{net}}(q, p_{Ei})$

Funktioniert gut, wenn NN-Ranking bzgl. euklidischer Distanz und Netzwerkdistanz ähnlich sind



**Algorithm IER ( $q, k$ )**/\*  $q$  is the query point \*/


1.  $\{p_1, \dots, p_k\} = \text{Euclidean\_NN}(q, k)$ ;
2. for each entity  $p_i$
3.      $d_N(q, p_i) = \text{compute\_ND}(q, p_i)$
4. sort  $\{p_1, \dots, p_k\}$  in ascending order of  $d_N(q, p_i)$
5.  $d_{E_{max}} = d_N(q, p_k)$
6. repeat
7.      $(p, d_E(q, p)) = \text{next\_Euclidean\_NN}(q)$ ;
8.     if  $(d_N(q, p) < d_N(q, p_k))$  //  $p$  closer than the  $k^{\text{th}}$  NN
9.         insert  $p$  in  $\{p_1, \dots, p_k\}$  // remove ex- $k^{\text{th}}$  NN
10.      $d_{E_{max}} = d_N(q, p_k)$
11. until  $d_E(q, p) > d_{E_{max}}$

**End IER****Figure 4.2:** Incremental Euclidean Restriction

### *NN über Incremental Network Expansion* [PZMT03]

- Sehr ähnlich zum Dijkstra-Algorithmus
- Das Netzwerk wird entsprechend des Dijkstra-Algorithmus durchsucht, bis der erste NN-Kandidat gefunden wird. Eine Variable speichert die aktuelle NN-Distanz.
- Werden weitere NN-Kandidaten gefunden, wird sowohl die NN-Distanz als auch der aktuelle NN-Kandidat ggf. aktualisiert
- Der Algorithmus terminiert, wenn alle Knoten in der Warteschlange eine größere Netzwerkdistanz zur Anfrage haben als die gespeicherte NN-Distanz erlaubt.

# k-NN-Suche über IER und INE<sup>[PZMT03]</sup>



## Algorithm INE ( $q, k$ )

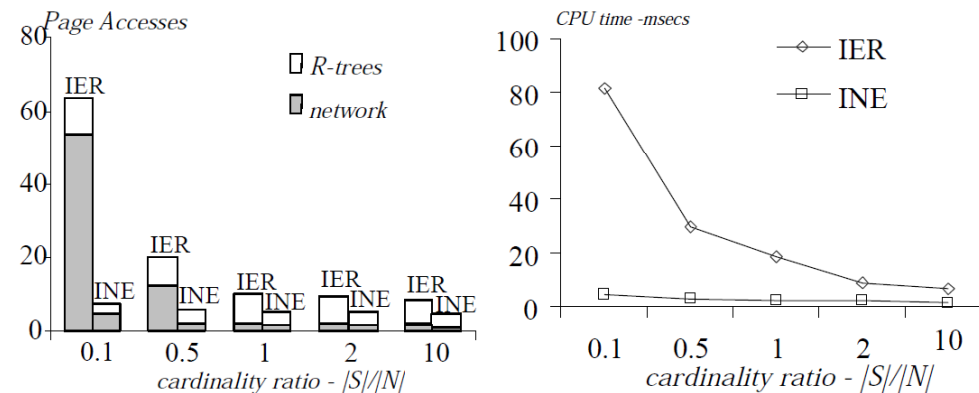
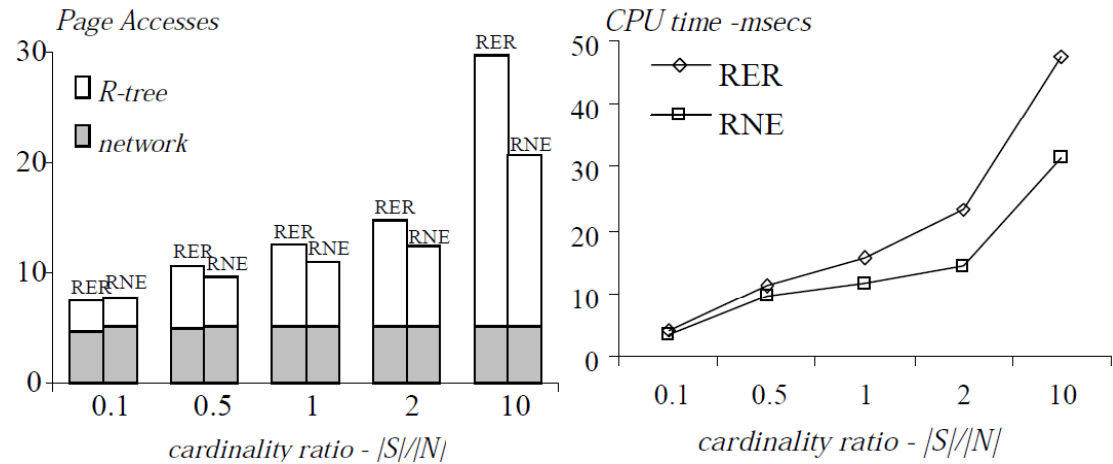
1.  $n_i n_j = \text{find\_segment}(q)$
2.  $S_{\text{cover}} = \text{find\_entities}(n_i n_j)$ ; //  $S_{\text{cover}}$  is the set of entities covered by  $n_i n_j$
3.  $\{p_1, \dots, p_k\}$  = the  $k$  (network) nearest entities in  $S_{\text{cover}}$  sorted in ascending order of their network distance ( $p_m, p_{m+1}, \dots, p_k$  may be  $\emptyset$  if  $S_{\text{cover}}$  contains  $< k$  points)
4.  $d_{N_{\text{max}}} = d_N(q, p_k)$  // if  $p_k = \emptyset$ ,  $d_{N_{\text{max}}} = \infty$
5.  $Q = \langle (n_i, d_N(q, n_i)), (n_j, d_N(q, n_j)) \rangle$  // sorted on  $d_N$
6. de-queue the node  $n$  in  $Q$  with the smallest  $d_N(q, n)$
7. while ( $d_N(q, n) < d_{N_{\text{max}}}$ )
8.     for each non-visited adjacent node  $n_x$  of  $n$
9.          $S_{\text{cover}} = \text{find\_entities}(n_x n)$ ;
10.         update  $\{p_1, \dots, p_k\}$  from  $\{p_1, \dots, p_k\} \cup S_{\text{cover}}$
11.          $d_{N_{\text{max}}} = d_N(q, p_k)$
12.         en-queue  $(n_x, d_N(q, n_x))$
13.     de-queue the next node  $n$  in  $Q$

End INE

Figure 4.4: Incremental Network Expansion

# • Performanz von RER, RNE, IER, INE

- Geprüft wurden
  - Seitenzugriffe (HDD)
  - CPU-Zeit




- Network Expansion meist besser als Euclidean Restriction



### 4.4.3 Routen-Suche in Multiattributs-Verkehrsnetzwerken

#### – Gegeben:

- Verkehrsnetzwerk
- Straßensegmente haben mehrere Kosten-Attribute, wie z.B.:  
Weglänge, Fahrzeit, Anzahl der Ampeln, Benzinverbrauch (abhängig vom Fahrzeugtyp), ...
- Graph  $G(V,E,c)$ :
  - $V$ : Menge von Knoten  $\leftrightarrow$  Kreuzungen, Sackgassen
  - $E \in V \times V$ : Menge von Kanten  $\leftrightarrow$  Strassensegmente zwischen Kreuzungen
  - $c: E \rightarrow \mathbb{R}^d$ : Kostenfunktion  $\leftrightarrow$  Kostenvektor für Kanten mit  $d$  Kostenattributen
- Annahmen:
  - Keine **negativen** Kosten (**Warum?**)
  - Alle Kostenattribute sind additiv  
(Gilt für Kosten eines Pfades (Route))



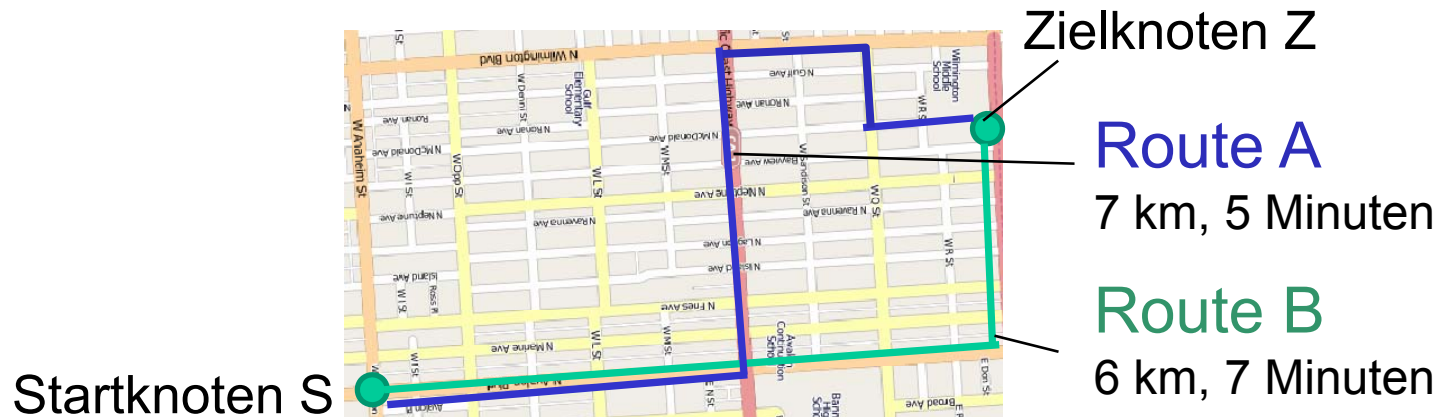
- Route:
  - $p = \langle v_1, \dots, v_n \rangle$  mit  $(v_i, v_{i+1}) \in E, \forall 1 \leq i < n$
  - ohne Zyklus, d.h.  $\forall 1 \leq i < n, \forall 1 \leq j < n, i \neq j, v_i \neq v_j$
  - Kosten einer Route:  $\text{cost}(p) = \sum_{e \in p} c(e) = \begin{pmatrix} \text{cost}(p)_1 \\ \vdots \\ \text{cost}(p)_d \end{pmatrix}$
- Gesucht:
  - “Bester” Pfad von S nach Z



**:= Pfad mit minimalen Kosten**  $\sum_{i=1}^d w_i \cdot \text{cost}(p)_i ?$

## – Problem

- Mehrere (Pfad-)Attribute (Kostenattribute) zu berücksichtigen (i.d.R. eine Auswahl an Kostenattribute)



## Welcher Pfad ist optimal A oder B?

- Kostenattribute schwierig zu vergleichen:  
#Ampeln  $\leftrightarrow$  Strecke?
- Präferenzen sind abhängig vom Benutzer und Anwendung:  
Geschäftlich oder privat unterwegs?
- Geeignete Gewichtung der Attribute schwer zu ermitteln

– Ansatz:

Ausgabe aller **pareto-optimaler** Pfade → **Route Skyline**

– Anfrage:

- Finde die Menge RS alle Pfade zwischen S und Z, sodaß für jeden Pfad  $p \in RS$  kein Pfad  $p'$  zwischen S und Z existiert mit der folgenden Eigenschaft:


$$\forall 1 \leq i \leq d : \text{cost}(p')_i \geq \text{cost}(p)_i$$

$$\exists 1 \leq i \leq d : \text{cost}(p')_i > \text{cost}(p)_i$$



- Man spricht:  $p$  wird **nicht** von  $p'$  dominiert

– Probleme:

- Anzahl potentieller Pfade extrem hoch
  - Materialisierung der Kosten aller Pfade extrem teuer
- => Skylineanfragemethoden für Vektorobjekte nicht (effizient) anwendbar




- Effiziente Route-Skyline Berechnung: [KRS 10]
- Idee:
  - Graphdurchlauf bei Startknoten S starten analog zu Dijkstra/A\*-Suche
  - Erweitere eine Route  $p'$  falls  $p'$  Teilroute einer Skylineroute  $p$  sein kann, d.h. erweitere  $p'$  nicht wenn abgeschätzt werden kann dass  $p$  von einer anderen Route  $p''$  dominiert wird
  - Stoppe falls keine Route mehr erweitert werden kann
- Gegeben eine Teilroute  $p' = \langle S, \dots, b \rangle$ ,



- Wie kann man abschätzen ob  $p'$  Teil einer Skylineroute ist? => **Pruningkriterien**

- Pruningkriterium I: Pruning mittels Vorwärtsabschätzung
  - Basiert auf Kostenabschätzung mittels Referenzknoten (siehe Kap. zu Graph Embedding)
  - Schätze Gesamtkosten (Kostenvektor)  $\text{cost}(p)$  einer potentiellen Route (über einen Referenzknoten  $R$ ) ab
  - Falls bereits ein Pfad  $p''$  existiert, der den Vektor  $\text{cost}(p)$  dominiert, dann kann  $p'$  nicht zu einer Skylineroute erweitert werden



$$\text{cost}(u)_i \geq |\text{cost}(x)_i - \text{cost}(y)_i|$$

- Funktioniert solange die Kostenabschätzung die untere Schrankeneigenschaft erfüllt



– Pruningkriterium II: Pruning unter Verwendung der Monotonieeigenschaft der Dominanzbeziehung

Theorem:

Gegeben sei eine Skyline Route  $p = \langle S, \dots, b, \dots, Z \rangle$ , d.h.  $p$  wird von keiner anderen Route zwischen  $S$  und  $Z$  dominiert. Dann wird jede Teilroute  $p' = \langle S, \dots, b \rangle$  von  $p$  von keiner anderen Teilroute  $p'' = \langle S, \dots, b \rangle$  dominiert.

Beweis:

Annahme es gibt eine Route  $p'' = \langle S, \dots, b \rangle$ , die die Teilroute  $p' = \langle S, \dots, b \rangle \neq p''$  von  $p$  dominiert. Dann würde die Erweiterung von  $p''$  über die Teilroute  $u = \langle b, \dots, Z \rangle$  von  $p$  zu einer Route führen, die die Route  $p$  dominiert  $\Rightarrow$  Widerspruch zur Annahme daß  $p$  Skylineroute ist.



## – Skyline-Route-Algorithmus:

- Idee: wie A\*-Suche, aber verwalte bei jedem Knoten n eine Skyline (Skyline bzgl. aller Pfade  $p' = \langle S, \dots, n \rangle$ )

- Algorithmus:

Input: Start S, Ziel Z, Graph(V,E,L) (mit Embedding)

Output: alle Skyline-Routen zwischen S und D

initialisiere Routen-Heap (queue);

queue.insert(S);

while (queue is not empty)

    aktRoute = queue.top();

*// erweitere alle Skyline Routen von Knoten aktNode*

    cand = extend(aktRoute.last\_node.SkR);

**for all**  $c \in \text{cand}$

**if**  $\exists p \in Z.SkR$ , p dominiert  $\text{cost}_{\text{est}}(c)$ , **then** lösche c aus cand;

**else**

            update(c.last\_node.SkylineRoutes,c);

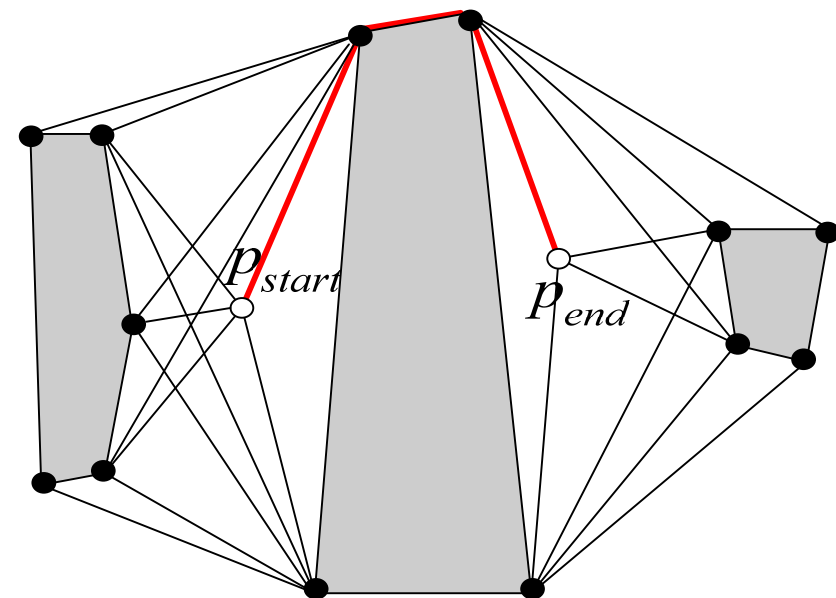
            queue.insert(c);

report(Z.SkR);




#### 4.4.4 Pfadsuche im euklidischen Raum mit Hindernissen [ZPMZ04]

- Ziel: Anfragebearbeitung (z.B. NN-Anfragen) im euklidischen Raum bei Anwesenheit von Hindernissen (Häuser, Seen, ...)
- Die zurückgelegte Strecke erhöht sich dabei wie in Graphen
- Zur Anfragebearbeitung können Graphalgorithmen verwendet werden




## – Sichtbarkeitsgraph

- Dient der Modellierung der kürzesten Pfade zwischen zwei beliebigen Punkten im Raum mit Hindernissen
- Hindernisse werden als Polygone modelliert
- Knoten: Eckpunkte von Hindernissen, Objekte ( $p_i$ )
- Kanten: Verbinden Knoten, dürfen kein Hindernis kreuzen
- Berechnung des gesamten Sichtbarkeitsgraphen zu aufwändig
- Deshalb Reduktion auf relevante Teilgraphen, bei denen nur relevante Hindernisse betrachtet werden.




## • Bereichsanfrage mit Hindernissen

1. Euklidische Bereichsanfrage auf Ergebniskandidaten  $P$  von Anfragepunkt  $q$  mit Distanz  $e$  (filter)
2. Suche von für die Anfrage relevanten Hindernissen  $O$ . Diese schneiden die Fläche der Bereichsanfrage.
3. Lokalen Sichtbarkeitsgraph über  $P$  und  $O$  aufbauen
4. False Hits aus  $P$  über Sichtbarkeitsgraph entfernen




(a) Obstacle range query



(b) Local visibility graph

## • NN-Anfrage mit Hindernissen

- Entspricht dem IER-Algorithmus, wobei jede Runde der entsprechende Sichtbarkeitsgraph erzeugt werden muss, um  $\text{dist}_{\text{NET}}(p,q)$  zu berechnen.
- Berechnung der Netzwerkdistanz  $\text{dist}_{\text{NET}}(p,q)$  über den Sichtbarkeitsgraphen:
  1. Berechne Hindernisse  $O$ , die  $[p,q]$  schneiden
  2. Berechne den Sichtbarkeitsgraph über  $O \cup \{p,q\}$  und daraus  $\text{dist}'_{\text{NET}}(p,q)$
  3. Frage alle Hindernisse  $O$  an, die die Bereichsanfrage von  $q$  bzgl.  $\text{dist}'_{\text{NET}}(p,q)$  schneiden
  4. Führe 3. und 4. so lange durch, bis  $O$  oder  $\text{dist}'_{\text{NET}}(p,q)$  sich nicht mehr verändert.  
Es gilt:  $\text{dist}_{\text{NET}}(p,q) = \text{dist}'_{\text{NET}}(p,q)$



- [HNR68]: Hart, Nilsson, Raphael. A Formal Basis for the Heuristic Determination of Minimum Cost Paths. In IEEE Transactions of Systems Science and Cybernetics, 1968.
- [KRS10]: Kriegel, Renz, Schubert: Route Skyline Queries: A Multi-Preference Path Planning Approach. In Proc. of ICDE, 2010.
- [KKKRS08]: Kriegel, Kröger, Kunath, Renz, Schmidt: Efficient Query Processing in Large Traffic Networks. In Proc. of ICDE, 2008.
- [PZMT03]: Papadias, Zhang, Mamoulis, Tao. Query Processing in Spatial Network Databases. In Proc. of VLDB, 2003.
- [ZPMZ]: Zhang, Papadias, Mouratidis, Zhou. Spatial Queries in the Presence of Obstacles. In Proc. of EDBT, 2004.