


Knowledge Discovery in Databases
SS 2013

Übungsblatt 5: Clusteranalyse – OPTICS

Aufgabe 5-1 OPTICS



As distance function, use Manhattan distance $L_1(a, b) := |a_1 - b_1| + |a_2 - b_2|$.

Construct an OPTICS reachability plot (see pseudo-code below) for each of the following parameter settings:

- $\varepsilon = 5$ and $\text{minPts} = 2$
- $\varepsilon = 5$ and $\text{minPts} = 4$
- $\varepsilon = 2$ and $\text{minPts} = 4$
- $\varepsilon = \infty$ and $\text{minPts} = 4$

Pseudocode OPTICS

```
seedlist =  $\emptyset$  // implemented as a heap
for  $i = 0$  to  $n-1$  do
    if( $seedlist = \emptyset$ ) then  $seedlist = \{(random\_not\_handled\_point, \infty)\}$ 
     $(x, x.reach) = get\_and\_remove\_point\_with\_min\_reach(seedlist)$ 
     $x.pos = i$ 
     $x.handled = TRUE$ 
     $neighbors = rangeQuery(x, \epsilon)$ 
     $x.core = nnDist(x, neighbors, MinPts)$ 
    if( $x.core < \infty$ )
        for each  $y \in neighbors$  with  $not(y.handled)$ 
            if( $y \notin seedlist$ )  $seedlist = seedlist \cup \{(y, reach-dist(y,x))\}$ 
            else
                 $curr\_reach = lookup(seedlist, y)$ 
                update( $y, min(curr\_reach, reach-dist(y,x))$ )
        endfor
    endfor
endfor
```

Aufgabe 5-2 Zusammenhang DBSCAN/OPTICS und Single-Link

Was ist der Zusammenhang von DBSCAN bei $minPts = 2$ zu single-linkage Clustering?

Warum läuft DBSCAN in $\mathcal{O}(n^2)$ Zeitkomplexität (mit Index typischerweise sogar $\mathcal{O}(n \log n)$), während hierarchische Clusteranalyse normalerweise als $\mathcal{O}(n^3)$ angegeben wird, und optimal in $\mathcal{O}(n^2)$ läuft?

Warum ist das kein Widerspruch?