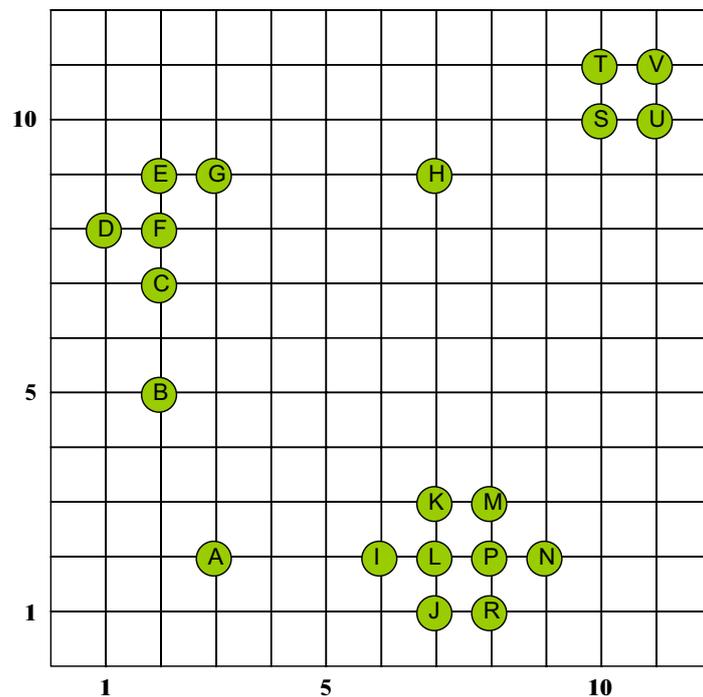


Knowledge Discovery in Databases
 WS 2008/09
Übungsblatt 9

Aufgabe 9-1 OPTICS

Gegeben sei der folgende 2-dimensionale Datensatz:



Verwenden Sie als Distanzfunktion zwischen den Punkten wieder die Manhattan-Distanz (L_1 -Norm)

Erzeugen Sie mit OPTICS (Pseudocode am Ende des Übungsblattes) jeweils ein Erreichbarkeitsdiagramm für die folgenden Parameter:

- (a) $\epsilon = 5$ und $MinPts = 2$
- (b) $\epsilon = 5$ und $MinPts = 4$
- (c) $\epsilon = 2$ und $MinPts = 4$
- (d) $\epsilon = \infty$ und $MinPts = 4$
- (e) Diskutieren Sie, welche Auswirkungen die Parameter $MinPts$ und ϵ haben.

Aufgabe 9-2 Outlier Detection

Gegeben der Datensatz und die Distanzfunktion aus Aufgabe 1. Berechnen Sie für die Punkte H und L den LOF-Wert für $MinPts = 3$.

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
```