



Skript zur Vorlesung
Knowledge Discovery in Databases
im Wintersemester 2010/2011

Kapitel 6: Outlier Detection

Vorlesung+Übungen:
PD Dr. Peer Kröger, Dr. Arthur Zimek

Skript © 2011 Peer Kröger, Arthur Zimek
basiert auf Tutorial von Hans-Peter Kriegel, Peer Kröger, Arthur Zimek:
Outlier Detection Techniques (PAKDD-09, Bangkok, Thailand)

[http://www.dbs.ifi.lmu.de/cms/Knowledge_Discovery_in_Databases_I_\(KDD_I\)](http://www.dbs.ifi.lmu.de/cms/Knowledge_Discovery_in_Databases_I_(KDD_I))

Übersicht

6.1 Einleitung

6.2 Statistical Tests

6.3 Depth-based Approaches

6.4 Deviation-based Approaches

6.5 Distance-based Approaches

6.6 Density-based Approaches

6.7 High-dimensional Approaches

6.8 Summary

Literatur

Was ist ein Outlier?

Definition nach Hawkins [Hawkins 1980]:

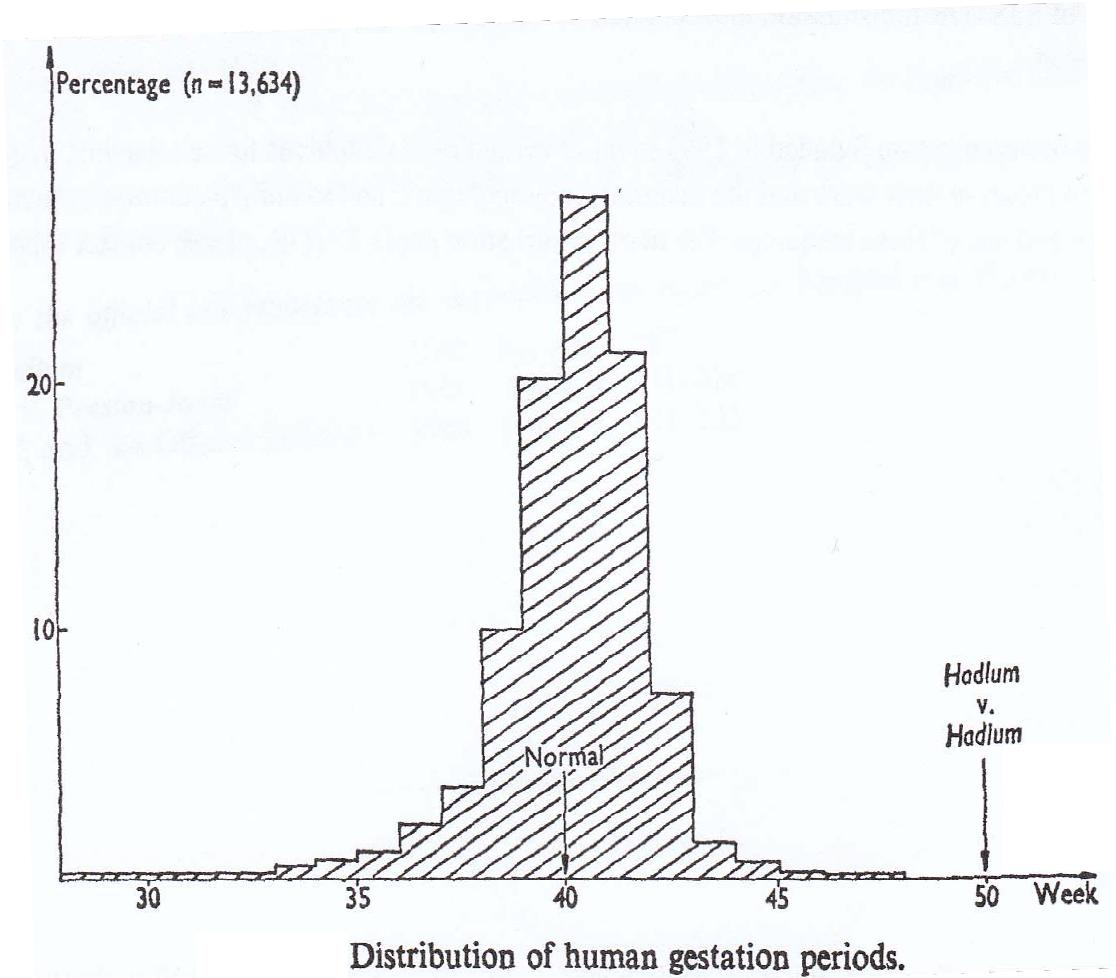
“Ein Outlier ist eine *Beobachtung*, die sich von den anderen *Beobachtungen* so deutlich unterscheidet, daß man denken könnte, sie sei von einem anderen Mechanismus generiert worden.”

Was meint “Mechanismus”?

- Intuition aus der Statistik: “erzeugender Mechanismus” ist ein (statistischer) Prozess.
- Abnormale Daten (outlier) zeigen eine verdächtig geringe Wahrscheinlichkeit, aus diesem Prozess zu stammen.

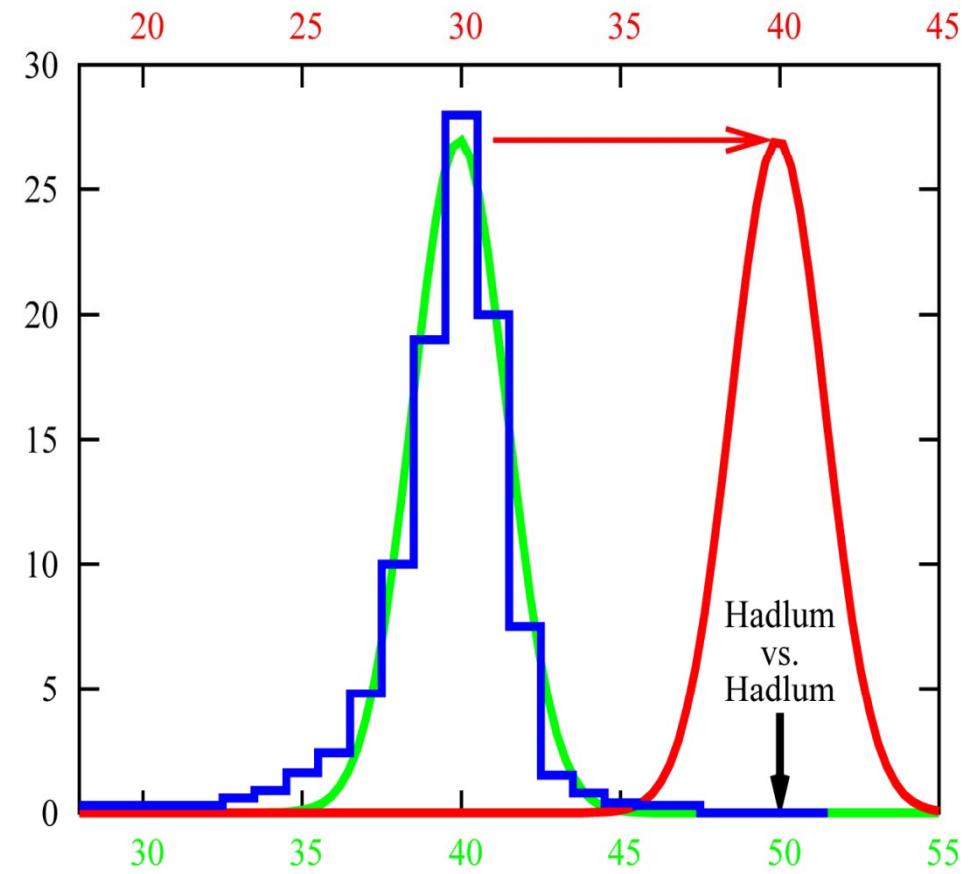
Beispiel: Hadlum vs. Hadlum (1949) [Barnett 1978]

- Geburt eines Kindes von Mrs. Hadlum 349 Tage nachdem Mr. Hadlum zum Militärdienst abwesend war.
- Durchschnittliche Dauer einer menschlichen Schwangerschaft ist 280 Tage (40 Wochen)
- Ist eine Schwangerschaftsdauer von 349 Tagen ein Outlier?



Beispiel: Hadlum vs. Hadlum (1949) [Barnett 1978]

- Blau: statistische Beobachtungsbasis (13634 erhobene Schwangerschaften)
- Grün: angenommener zugrundeliegender Gauss-Prozess
 - sehr geringe Wahrscheinlichkeit, dass die Geburt aus diesem Prozess stammt
- Rot: Annahme von Mr. Hadlum (ein anderer Gauss-Prozess, in dem die Schwangerschaft später beginnt, ist für die Geburt verantwortlich)
 - unter dieser Annahme hat die Schwangerschaftsdauer einen Durchschnittswert und höchst-mögliche Wahrscheinlichkeit



Anwendungsgebiete:

- Betrugsentdeckung
 - Kaufverhalten mit einer Kreditkarte ändert sich, wenn die Karte gestohlen wurde
 - Ungewöhnliche Kauf-Muster können Kreditkarten-Mißbrauch anzeigen
- Medizin
 - Ungewöhnliche Symptome oder Test-Ergebnisse können mögliche gesundheitliche Probleme eines Patienten anzeigen
 - Ob ein bestimmtes Testergebnis ungewöhnlich ist, kann von anderen Eigenschaften des Patienten abhängen (z.B. Geschlecht, Alter, Gewicht, ...)
- Öffentliches Gesundheitswesen
 - Auftauchen einer bestimmten Krankheit (z.B. Tetanus) verstreut über verschiedene Krankenhäuser einer Stadt zeigt Probleme mit dem zugehörigen Impfprogramm an
 - Ob das Auftreten der Krankheit unnormal ist hängt von verschiedenen Aspekten ab, z.B. Häufigkeit, räumliche Korrelation etc.

Anwendungsgebiete:

- Sport Statistiken
 - In vielen Sportarten werden diverse Parameter aufgezeichnet, um die Leistung eines Spielers zu bewerten
 - Außergewöhnliche (in positivem wie negativem Sinne) Spieler können durch ungewöhnliche Werte bestimmt werden
 - Manchmal ist nur eine Teilmenge der Parameter ungewöhnlich
- Entdecken von Messfehlern
 - Daten aus Sensoren (z.B. in einem wissenschaftlichen Experiment) können Meßfehler enthalten
 - Ungewöhnliche Werte können ein Hinweis auf Meßfehler sein
 - Solche Meßfehler aus den Daten zu entfernen, kann wichtig sein für erfolgreiche Datenanalyse und Data Mining

„One person's noise could be another person's signal.“

Diskussion der Intuition von Hawkins

- Daten sind gewöhnlich multivariat (mehr-dimensional)
=> Basis-Modell ist univariat (ein-dimensional)
- Ein Datensatz stammt oft aus mehr als einem erzeugenden Prozess
=> Basis-Model nimmt nur einen einzelnen genuinen erzeugenden Mechanismus an
- Anomalien können eine andere Klasse von Objekten sein (aus einem anderen Prozess erzeugt), die nicht besonders selten sind
=> Basis-Model nimmt an, dass Outlier sehr selten sind

Eine große Zahl von Methoden wurde entwickelt, um über die Basis-Annahmen hinauszugelangen. Dabei liegen jedoch stets andere, oft nicht explizite Annahmen zugrunde.

Generelle Szenarien der Anwendung:

- supervised
 - in manchen Anwendungsgebieten gibt es Trainingsdaten mit normalen und ungewöhnlichen Fällen
 - es kann mehrere normale und ungewöhnliche Klassen geben
 - meist ist das Klassifikationsproblem unbalanziert
- semi-supervised
 - in manchen Szenarien gibt es Trainingsdaten nur für die normale oder nur für die ungewöhnliche Klasse
- unsupervised
 - in den meisten Szenarien gibt es keine Trainingsdaten

In dieser Vorlesung konzentrieren wir uns auf das unsupervised Szenario.

Erkennung von Outliern

- Nebenprodukt von Clustering?
- Manche Cluster-Algorithmen ordnen nicht jeden Punkt einem Cluster zu, sondern lassen "Noise" übrig.
- Idee: Wende Cluster-Verfahren an, betrachte Noise als Outlier.

- Problem:
 - Clustering Algorithmen sind daraufhin entwickelt und optimiert, Cluster zu finden.
 - Qualität der Outlier Detection hängt von Qualität der Cluster-Struktur und der Eignung des Clustering Algorithmus für diese Struktur ab.
 - Mehrere Outlier, die einander ähnlich sind, bilden eventuell auch selbst ein (kleines) Cluster, können also nicht entdeckt werden.

Klassifikation von Outlier Detection Algorithmen

- Globaler vs. lokaler Ansatz:
Wird die “Outlierness” bestimmt bezüglich des gesamten Datensatzes (global) oder nur bezüglich einer Auswahl?
- Labeling vs. Scoring
Bestimmt der Algorithmus den Outlier-Grad eines Punktes (Scoring) oder wird für jeden Punkt eine Entscheidung getroffen (Label: Outlier/kein Outlier)
- Eigenschaften des Outlier Modells
Auf welchen Eigenschaften beruht die Modellierung von “Outlierness”

6.1 Einleitung

- Global vs. Lokal
 - bezieht sich auf die Auflösung der Referenzmenge bezüglich derer die "Outlierness" bestimmt wird
 - Globale Ansätze:
 - Referenzmenge enthält gesamten Datensatz
 - Basis-Annahme: nur ein einziger (normaler) erzeugender Mechanismus
 - Grundlegendes Problem: Outlier sind auch in Referenzmenge und verfälschen die Ergebnisse
 - Lokale Ansätze:
 - Referenzmenge enthält nur eine (kleine) Teilmenge des Datensatzes
 - Meist keine Annahme über Anzahl der Mechanismen
 - Grundlegendes Problem: wie ist eine geeignete Referenzmenge zu bestimmen?
 - Beachte: Manche Ansätze liegen dazwischen
 - Auflösung der Referenzmenge wird im Verfahren variiert

- Labeling vs. Scoring
 - bezieht sich auf das Ergebnis, das der Algorithmus liefert
 - Labeling Ansätze:
 - binäre Entscheidung
 - Daten-Objekt wird als Outlier markiert oder als normal
 - Scoring Ansätze:
 - kontinuierlicher Output: für jedes Objekt wird ein Score geliefert (z.B. die Wahrscheinlichkeit, ein Outlier zu sein)
 - Objekte können nach ihrem Score geordnet werden
 - Beachte:
 - Viele Scoring-Ansätze bestimmen nur die top-n Outlier (Parameter n wird durch Benutzer angegeben)
 - Scoring-Ansätze können grundsätzlich in Labeling-Ansätze transformiert werden, wenn ein geeigneter Grenzwert angegeben werden kann, dessen Überschreitung zum Label "Outlier" führt

6.1 Einleitung

- Klassen von zugrundeliegenden Modellen
 - Statistisches Modell
 - Überlegung:
 - Wende ein Modell an, das die normalen Daten statistisch beschreibt (z.B. Gauss-Verteilung)
 - Outlier sind Punkte, die nicht gut zu diesem Modell passen (eine geringe Erzeugungswahrscheinlichkeit haben)
 - Beispiele:
 - Wahrscheinlichkeitstests basierend auf statistischen Modellen
 - Tiefen-basierte Ansätze
 - Deviation-based Ansätze
 - Manche Subspace Outlier Detection Ansätze

6.1 Einleitung

- Modellierung durch räumliche Nähe
 - Überlegung:
 - Untersuche die räumliche Nachbarschaft jedes Punktes im Datenraum
 - Wenn die Nachbarschaft deutlich andere Struktur (z.B. geringere Dichte) aufweist als die Nachbarschaften von anderen Punkten, kann der betreffende Punkt als Outlier angesehen werden.
 - Beispiele:
 - Distanz-basierte Ansätze
 - Dichte-basierte Ansätze
 - Manche Subspace Outlier Detection Ansätze

6.1 Einleitung

- Modellierung durch Winkel-Spektrum
 - Überlegung:
 - Bestimme das Spektrum paarweiser Winkel zwischen einem gegebenen Punkt und anderen (alle? Auswahl?) Punkten
 - Outlier sind Punkte, die eine geringe Varianz haben

Im Folgenden:

Orientierung an den verschiedenen Modellierungen

Übersicht

6.1 Einleitung ✓

6.2 Statistical Tests

6.3 Depth-based Approaches

6.4 Deviation-based Approaches

6.5 Distance-based Approaches

6.6 Density-based Approaches

6.7 High-dimensional Approaches

6.8 Summary

Literatur



Statistisches Modell



Modellierung durch
räumliche Nähe



Anpassung verschiedener
Modelle an spezielles Problem

General idea

- Given a certain kind of statistical distribution (e.g., Gaussian)
- Compute the parameters assuming all data points have been generated by such a statistical distribution (e.g., mean and standard deviation)
- Outliers are points that have a low probability to be generated by the overall distribution (e.g., deviate more than 3 times the standard deviation from the mean)

Basic assumption

- Normal data objects follow a (known) distribution and occur in a high probability region of this model
- Outliers deviate strongly from this distribution

6.2 Statistical Tests

A huge number of different tests are available differing in

- Type of data distribution (e.g. Gaussian)
- Number of variables, i.e., dimensions of the data objects (univariate/multivariate)
- Number of distributions (mixture models)
- Parametric versus non-parametric (e.g. histogram-based)

Example on the following slides

- Gaussian distribution
- Multivariate
- 1 model
- Parametric

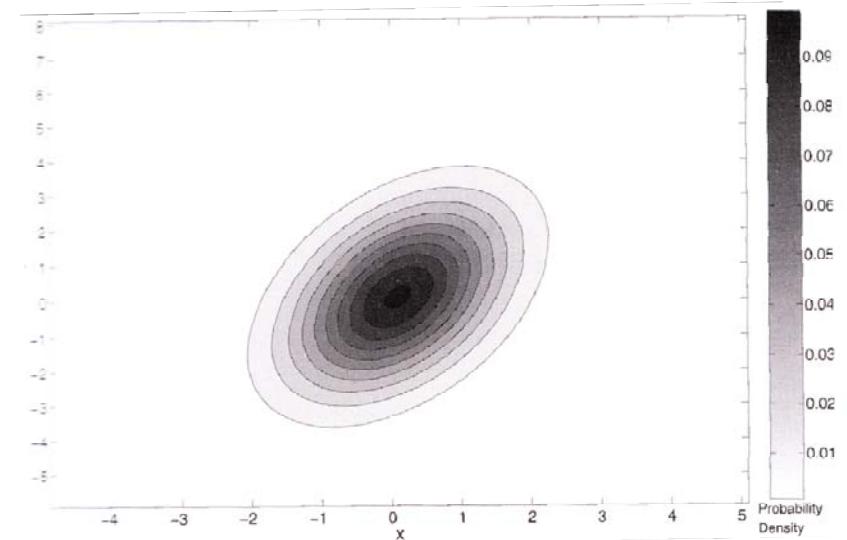
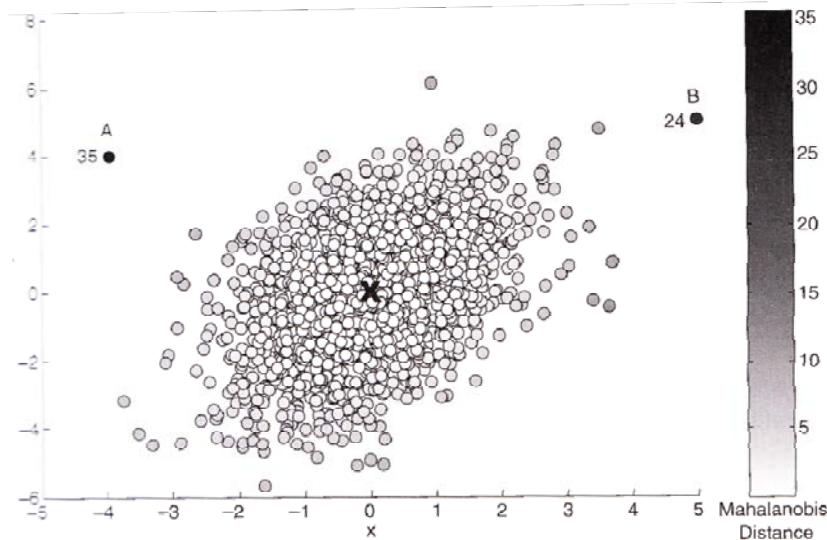
Probability density function of a multivariate normal distribution

$$N(x) = \frac{1}{\sqrt{(2\pi)^d |\Sigma|}} e^{-\frac{(x-\mu)^T \Sigma^{-1} (x-\mu)}{2}}$$

- μ is the mean value of all points (usually data are normalized such that $\mu=0$)
- Σ is the covariance matrix from the mean
- $MDist(x, \mu) = (x - \mu)^T \Sigma^{-1} (x - \mu)$ is the Mahalanobis distance of point x to μ
- MDist follows a χ^2 -distribution with d degrees of freedom (d = data dimensionality)
- All points x , with $MDist(x, \mu) > \chi^2(0, 975)$ [$\approx 3 \cdot \sigma$]

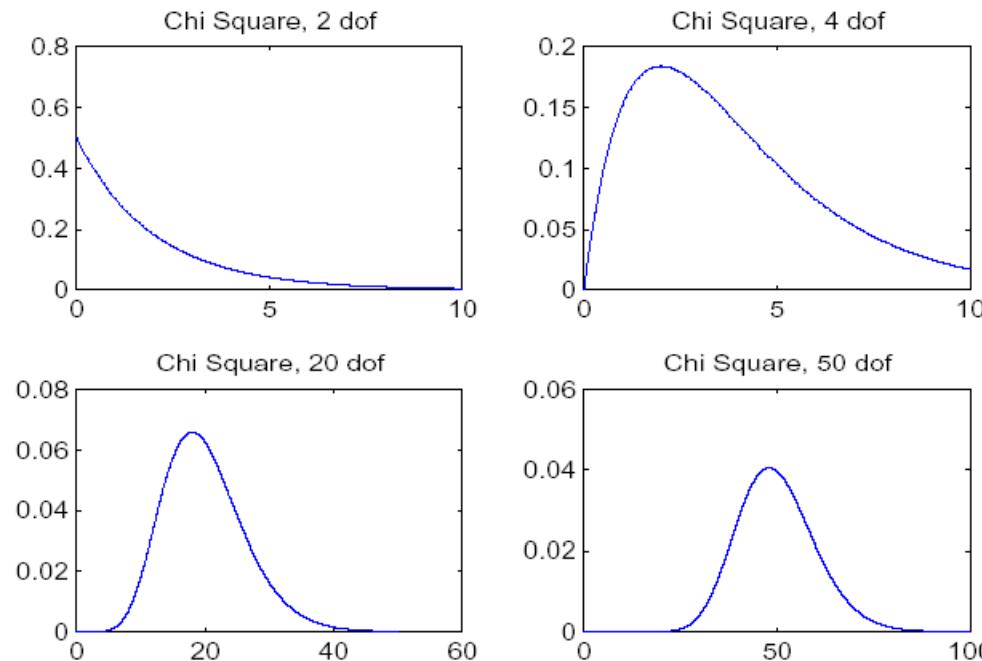
6.2 Statistical Tests

Visualization (2D) [Tan et al. 2006]



Problems

- Curse of dimensionality
 - The larger the degree of freedom, the more similar the MDist values for all points



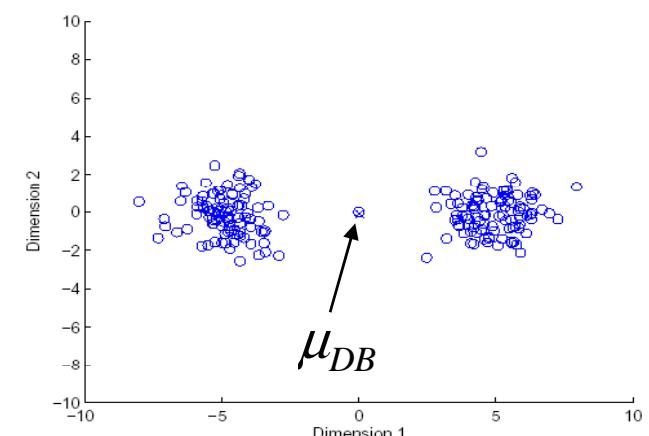
x-axis: observed $MDist$ values
y-axis: frequency of observation

Problems (cont.)

- Robustness
 - Mean and standard deviation are very sensitive to outliers
 - These values are computed for the complete data set (including potential outliers)
 - The $MDist$ is used to determine outliers although the $MDist$ values are influenced by these outliers
- => Minimum Covariance Determinant [Rousseeuw and Leroy 1987]
 minimizes the influence of outliers on the Mahalanobis distance

Discussion

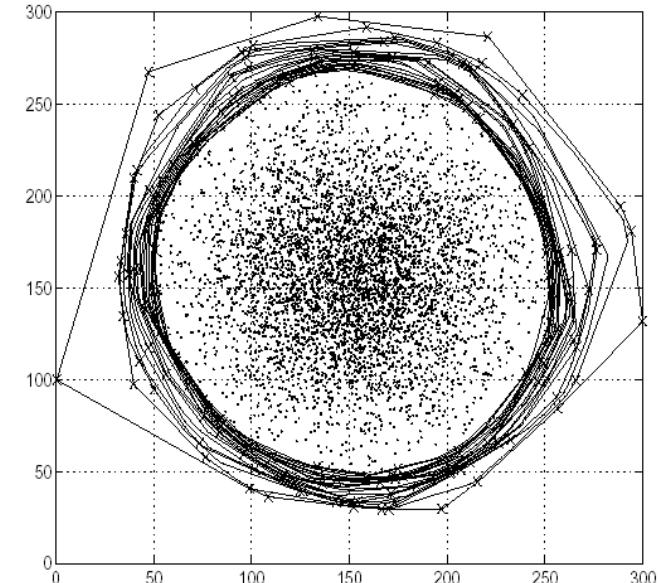
- Data distribution is fixed
- Low flexibility (no mixture model)
- Global method
- Outputs a label but can also output a score



6.3 Depth-based Approaches

General idea

- Search for outliers at the border of the data space but independent of statistical distributions
- Organize data objects in convex hull layers
- Outliers are objects on outer layers



Picture taken from [Johnson et al. 1998]

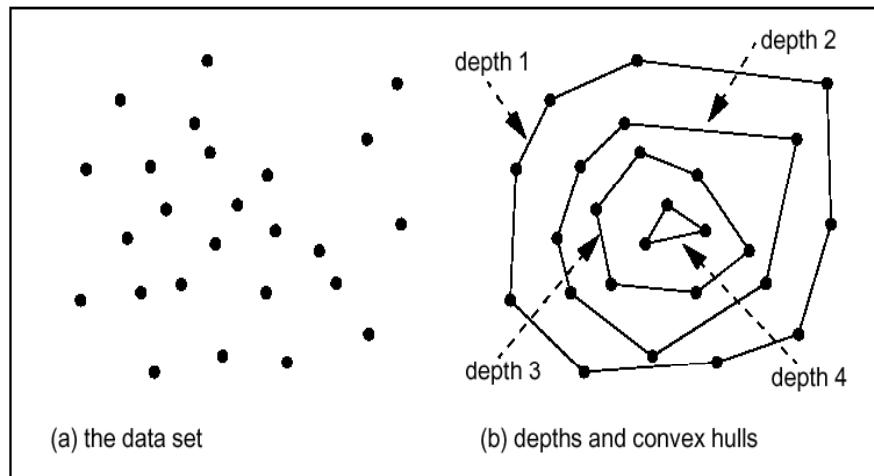
Basic assumption

- Outliers are located at the border of the data space
- Normal objects are in the center of the data space

6.3 Depth-based Approaches

Model [Tukey 1977]

- Points on the convex hull of the full data space have depth = 1
- Points on the convex hull of the data set after removing all points with depth = 1 have depth = 2
- ...
- Points having a depth $\leq k$ are reported as outliers



Picture taken from [Preparata and Shamos 1988]

Sample algorithms

- ISODEPTH [Ruts and Rousseeuw 1996]
- FDC [Johnson et al. 1998]

Discussion

- Similar idea like classical statistical approaches ($k = 1$ distributions) but independent from the chosen kind of distribution
- Convex hull computation is usually only efficient in 2D / 3D spaces
- Originally outputs a label but can be extended for scoring easily (take depth as scoring value)
- Uses a global reference set for outlier detection

General idea

- Given a set of data points (local group or global set)
- Outliers are points that do not fit to the general characteristics of that set, i.e., the variance of the set is minimized when removing the outliers

Basic assumption

- Outliers are the outermost points of the data set

Model [Arning et al. 1996]

- Given a smoothing factor $SF(I)$ that computes for each $I \subseteq DB$ how much the variance of DB is decreased when I is removed from DB
- With equal decrease in variance, a smaller exception set is better
- The outliers are the elements of the **exception set** $E \subseteq DB$ for which the following holds:

$$SF(E) \geq SF(I) \quad \text{for all } I \subseteq DB$$

Discussion:

- Similar idea like classical statistical approaches ($k = 1$ distributions) but independent from the chosen kind of distribution
- Naïve solution is in $O(2^n)$ for n data objects
- Heuristics like random sampling or best first search are applied
- Applicable to any data type (depends on the definition of SF)
- Originally designed as a global method
- Outputs a labeling

Übersicht

6.1 Einleitung ✓

6.2 Statistical Tests ✓

6.3 Depth-based Approaches ✓

6.4 Deviation-based Approaches ✓

6.5 Distance-based Approaches

6.6 Density-based Approaches

6.7 High-dimensional Approaches

6.8 Summary

Literatur

} Statistisches Modell

} Modellierung durch
räumliche Nähe

} Anpassung verschiedener
Modelle an spezielles Problem

General Idea

- Judge a point based on the distance(s) to its neighbors
- Several variants proposed

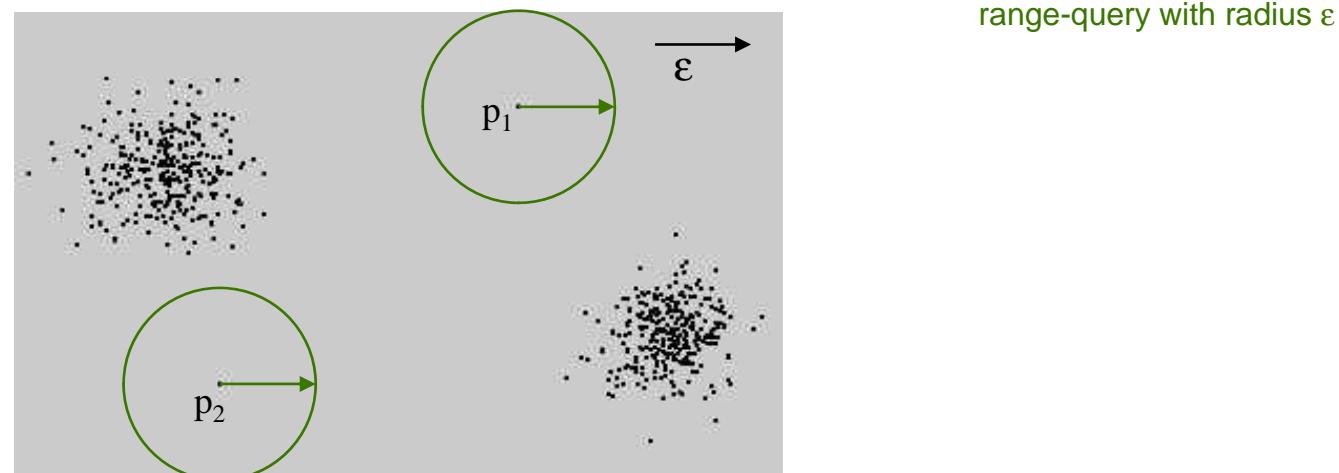
Basic Assumption

- Normal data objects have a dense neighborhood
- Outliers are far apart from their neighbors, i.e., have a less dense neighborhood

DB(ε, π)-Outliers

- Basic model [Knorr and Ng 1997]
 - Given a radius ε and a percentage π
 - A point p is considered an outlier if at most π percent of all other points have a distance to p less than ε

$$\text{OutlierSet}(\varepsilon, \pi) = \{ p \mid \frac{\text{Card}(\{q \in DB \mid \text{dist}(p, q) < \varepsilon\})}{\text{Card}(DB)} \leq \pi \}$$



6.5 Distance-based Approaches

- Algorithms
 - Index-based [Knorr and Ng 1998]
 - Compute distance range join using spatial index structure
 - Exclude point from further consideration if its ϵ -neighborhood contains more than $\text{Card}(DB) \cdot \pi$ points
 - Nested-loop based [Knorr and Ng 1998]
 - Divide buffer in two parts
 - Use second part to scan/compare all points with the points from the first part
 - Grid-based [Knorr and Ng 1998]
 - Build grid such that any two points from the same grid cell have a distance of at most ϵ to each other
 - Points need only compared with points from neighboring cells

6.5 Distance-based Approaches

- Deriving intensional knowledge [Knorr and Ng 1999]
 - Relies on the DB(ϵ, π)-outlier model
 - Find the minimal subset(s) of attributes that explains the “outlierness” of a point, i.e., in which the point is still an outlier
 - Example
 - Identified outliers

Player Name	Power-play Goals	Short-handed Goals	Game-winning Goals	Game-tying Goals	Games Played
MARIO LEMIEUX	31	8	8	0	70
JAROMIR JAGR	20	1	12	1	82
JOHN LECLAIR	19	0	10	2	82
ROD BRIND'AMOUR	4	4	5	4	82

- Derived intensional knowledge (sketch)

MARIO LEMIEUX:

- (i) An outlier in the 1-D space of Power-play goals
- (ii) An outlier in the 2-D space of Short-handed goals and Game-winning goals
 (No player is exceptional on Short-handed goals alone;
 No player is exceptional on Game-winning goals alone.)

ROD BRIND'AMOUR:

- (i) An outlier in the 1-D space of Game-tying goals
- JAROMIR JAGR:
 - (i) An outlier in the 2-D space of Short-handed goals and Game-winning goals
 (No player is exceptional on Short-handed goals alone;
 No player is exceptional on Game-winning goals alone.)
 - (ii) An outlier in the 2-D space of Power-play goals and Game-winning goals

Outlier scoring based on k NN distances

- General models
 - Take the k NN distance of a point as its outlier score [Ramaswamy et al 2000]
 - Aggregate the distances of a point to all its 1NN, 2NN, ..., k NN as an outlier score [Angiulli and Pizzuti 2002]
- Algorithms
 - General approaches
 - Nested-Loop
 - » Naïve approach:
For each object: compute k NNs with a sequential scan
 - » Enhancement: use index structures for k NN queries
 - Partition-based
 - » Partition data into micro clusters
 - » Aggregate information for each partition (e.g. minimum bounding rectangles)
 - » Allows to prune micro clusters that cannot qualify when searching for the k NNs of a particular point

6.5 Distance-based Approaches

- Sample Algorithms (computing top- n outliers)
 - Nested-Loop [Ramaswamy et al 2000]
 - Simple NL algorithm with index support for k NN queries
 - Partition-based algorithm (based on a clustering algorithm that has linear time complexity)
 - Algorithm for the simple k NN-distance model
 - Linearization [Angiulli and Pizzuti 2002]
 - Linearization of a multi-dimensional data set using space-fill curves
 - 1D representation is partitioned into micro clusters
 - Algorithm for the average k NN-distance model
 - ORCA [Bay and Schwabacher 2003]
 - NL algorithm with randomization and simple pruning
 - Pruning: if a point has a score greater than the top- n outlier so far (cut-off), remove this point from further consideration
 - => non-outliers are pruned
 - => works good on randomized data (can be done in linear time)
 - => worst-case: naïve NL algorithm
 - Algorithm for both k NN-distance models and the $\text{DB}(\varepsilon, \pi)$ -outlier model

6.5 Distance-based Approaches

- Sample Algorithms (cont.)
 - RBRP [Ghoting et al. 2006],
 - Idea: try to increase the cut-off as quick as possible => increase the pruning power
 - Compute approximate k NNs for each point to get a better cut-off
 - For approximate k NN search, the data points are partitioned into micro clusters and k NNs are only searched within each micro cluster
 - Algorithm for both k NN-distance models
 - Further approaches
 - Also apply partitioning-based algorithms using micro clusters [McCallum et al 2000], [Tao et al. 2006]
 - Approximate solution based on reference points [Pei et al. 2006]
- Discussion
 - Output can be a scoring (k NN-distance models) or a labeling (k NN-distance models and the $DB(\epsilon, \pi)$ -outlier model)
 - Approaches are local (resolution can be adjusted by the user via ϵ or k)

Variant

- Outlier Detection using In-degree Number [Hautamaki et al. 2004]
 - Idea
 - Construct the k NN graph for a data set
 - » Vertices: data points
 - » Edge: if $q \in k\text{NN}(p)$ then there is a directed edge from p to q
 - A vertex that has an indegree less or equal T (user defined threshold) is an outlier
 - Discussion
 - The indegree of a vertex in the k NN graph equals to the number of reverse k NNs (R k NN) of the corresponding point
 - The R k NNs of a point p are those data objects having p among their k NNs
 - Intuition of the model: outliers are
 - » points that are among the k NNs of less than T other points
 - » have less than T R k NNs
 - Outputs an outlier label
 - Is a local approach (depending on user defined parameter k)

Resolution-based outlier factor (ROF) [Fan et al. 2006]

- Model

- Depending on the resolution of applied distance thresholds, points are outliers or within a cluster
- With the maximal resolution R_{max} (minimal distance threshold) all points are outliers
- With the minimal resolution R_{min} (maximal distance threshold) all points are within a cluster
- Change resolution from R_{max} to R_{min} in certain steps: points change from being outlier to being a member of a cluster
- Cluster is defined similar as in DBSCAN as a transitive closure of r -neighborhoods (where r is the current resolution)
- ROF value
$$ROF(p) = \sum_{R_{min} \leq r \leq R_{max}} \frac{clusterSize_{r-1}(p)-1}{clusterSize_r(p)}$$

- Discussion

- Outputs a score (the ROF value)
- Resolution is varied automatically from local to global