



# Vorlesung

## **Datenschutz und Privatheit in vernetzten Informationssystemen**

Kapitel 7: Privacy Preserving Data Mining

Thorben Burghardt, Erik Buchmann

[buchmann@ipd.uka.de](mailto:buchmann@ipd.uka.de)

Thanks to Chris Clifton & Group



# Motivation

## Motivation

Background


Grundlagen

D ARM

PP ARM

Zusammenf.

- Data-Mining identifiziert interessante Muster und Trends in Datenbeständen.
- Dabei wird oftmals Data-Warehousing und Data-Mining kombiniert.
- Zweistufiges Vorgehen
  - Zusammenführen aller Informationen an einer Stelle (Warehouse)
  - Anwenden des Data-Mining Algorithmus auf diese Daten.






# Einschub Data-Mining Grundlagen

Dank an Frank Eichinger, Matthias Brach  
und Stephan Schosser

# Motivation - Warenkorbanalyse

- Gesucht: Einkaufsgewohnheiten
  - Höhere Kundenzufriedenheit durch günstige Anordnung
  - Höherer Absatz durch ungünstige Anordnung
- Warenkörbe (Beispiel)




- Fragestellung: Welche Kombinationen werden häufig gekauft (Frequent Itemsets)?

# Assoziationsregeln

- Darstellung von Assoziationsregeln
  - Antecedent  $X \Rightarrow$  Consequent  $Y$
- Wahrscheinlichkeitsbasierter Charakter
  - Consequent  $Y$  ist mit der Wahrscheinlichkeit  $P$  wahr,
  - ... wenn der Antecedent  $X$  wahr ist
  - Bedingte Wahrscheinlichkeit  $P(Y | X)$ !
- Zugelassene Wertebereiche
  - Besonders geeignet für kategorische Daten
  - Möglichkeit Grenzwerte für kontinuierliche Werte zu setzen

## Motivation – Warenkorbanalyse II

- Warenkörbe



- Frequent Itemsets (mit mind. 2 Items)
  - $\{\text{Brot, Bier}\}$ ,  $\{\text{Brot, Bier, Windeln}\}$ ,  $\{\text{Zucker, Eier}\}$ ,  
 $\{\text{Bier, Windeln}\}$ ,  $\{\text{Brot, Windeln}\}$
- Wie lassen sich aus Frequent Itemsets Assoziationsregeln ableiten?
  - Beispiel: Wer Windeln kauft, kauft auch Brot



## Wichtige Begriffe - Support

- Alternative Namen
  - Häufigkeit, Abdeckung
- Angabe bezüglich der Häufigkeit eines Portfolios
- Anzahl bzw. Anteil der Transaktionen, die  $X \cup Y$  enthalten
- Formal:  $P(X \cup Y)$
- Beispiel:
  - Die Kombination Windeln, Bier tritt in 50% der Warenkörbe auf.
  - Support = 50%






## Wichtige Begriffe – Confidence

- Alternative Namen
  - Genauigkeit
- „Überraschungsmass“
- Wenn eine Transaktion X enthält, dann auch Y (mit gegebener Genauigkeit)
- Formal:  $P(Y | X) = |X \cup Y| / |X|$
- Beispiel:
  - Wenn Windeln gekauft wurden, wurde in 100% aller Fälle auch Bier gekauft
  - Confidence = 100%
- Ziel: Finden von Regeln mit
  - ... hohem Support (support > minSup) und ...
  - ... hoher Confidence (confidence > minConf)



# Beispiel - Warenkorbanalyse

- Warenkörbe



- Frequent Itemsets ( $\text{minSup} = 1/2$ )
  - $\{\text{Brot, Bier}\}$  (Support =  $3/4$ );  $\{\text{Brot, Bier, Windeln}\}$  (Support =  $1/2$ );  
 $\{\text{Zucker, Eier}\}$  (Support =  $1/2$ );  $\{\text{Bier, Windeln}\}$  (Support =  $1/2$ );  
 $\{\text{Brot, Windeln}\}$  (Support =  $1/2$ )
- Assoziationsregeln (Auswahl)
  - $\text{Brot} \Rightarrow \text{Bier}$  (Confidence = 100%)
  - $\text{Brot, Bier} \Rightarrow \text{Windeln}$  (Confidence = 67%)
  - $\text{Zucker} \Rightarrow \text{Eier}$  (Confidence = 100%)



## A-Priori Eigenschaft

- Itemset häufig, wenn Supermenge häufig
- Beispiel:
  - {Bier, Windeln, Brot} häufig
  - ⇒ {Bier, Windeln}, {Bier, Brot}, {Windeln, Brot} und {Bier}, {Windeln}, {Brot} häufig
- Itemset kann nur häufig sein, ...  
... wenn alle Teilmengen häufig
- Dadurch:
  - Bestimmung von Frequent Itemset Kandidaten mit  $n$  Elementen aus solchen mit  $(n - 1)$  Elementen möglich





# A-Priori Algorithmus – Frequent Itemsets

Finden aller Itemsets mit ausreichendem Support:

- Beginn mit ein-elementigen Sets (1)-Sets:
  - einfaches Abzählen
- Berechnung der k-Sets aus den (k-1)-Sets:
  - Join-Step: Ermittlung von Kandidaten;  
*Aus A-Priori Eigenschaft:*  
Alle (k-1)-elementigen Teilmengen eines k-Sets sind (k-1)-Sets,
  - Prune-Step: Löschen aller Kandidaten, die eine „unzulässige“ (k-1)-elementige Teilmenge haben.
  - Support Counting, d. h. Abzählen, wie häufig die Kandidaten wirklich sind.





## A-Priori – Frequent Itemset (Bsp.) I

- Beispieletupel:
  - {A, B, E}
  - {B, D}
  - {B, C}
  - {A, B, D}
  - {A, C, D}
  - {B, C}
  - {A, C}
  - {A, B, C, E}
  - {A, B, C}
- MinSup:  $2/9$ ,
  - d.h. Itemset ist häufig, wenn 2 Tupel es enthalten



## A-Priori – Frequent Itemset (Bsp.) II

- Ein-elementige Frequent Itemsets

- {A}: 6
- {B}: 7
- {C}: 6
- {D}: 3
- {E}: 2

- D.h. Alle Items sind häufig!

Beispieltupel:

{A, B, E}

{B, D}

{B, C}

{A, B, D}

{A, C, D}

{B, C}

{A, C}

{A, B, C, E}

{A, B, C}



## A-Priori – Frequent Itemset (Bsp.) III

- Ein-elementige Frequent Itemsets
  - {A}: 6, {B}: 7, {C}: 6, {D}: 3, {E}: 2
- Zwei-elementige Frequent Itemsets
  - {A, B}: 4
  - {A, C}: 4
  - {A, D}: 2
  - {A, E}: 2
  - {B, C}: 4
  - {B, D}: 2
  - {B, E}: 2
  - ~~{C, D}: 1~~
  - ~~{C, E}: 1~~
  - ~~{D, E}: 0~~

Beispieltupel:

{A, B, E}

{B, D}

{B, C}

{A, B, D}

{A, C, D}

{B, C}

{A, C}

{A, B, C, E}

{A, B, C}



## A-Priori – Frequent Itemset (Bsp.) IV

- Zweielementige Frequent Itemsets
  - $\{A, B\}: 4, \{A, C\}: 4, \{A, D\}: 2, \{A, E\}: 2,$   
 $\{B, C\}: 4, \{B, D\}: 2, \{B, E\}: 2$
- Dreielementige Frequent Itemsets
  - $\{A, B, C\}: 2$
  - ~~$\{A, B, D\}: 1$~~
  - $\{A, B, E\}: 2$
  - ~~$\{A, C, D\}$~~
  - ~~$\{A, C, E\}$~~
  - ~~$\{A, D, E\}$~~
  - ~~$\{B, C, D\}$~~
  - ~~$\{B, C, E\}$~~
  - ~~$\{B, D, E\}$~~

Beispieltupel:

$\{A, B, E\}$

$\{B, D\}$

$\{B, C\}$

$\{A, B, D\}$

$\{A, C, D\}$

$\{B, C\}$

$\{A, C\}$

$\{A, B, C, E\}$

$\{A, B, C\}$

## A-Priori – Frequent Itemset (Bsp.) V

- Drei-elementige Frequent Itemsets
  - $\{A, B, C\}: 2, \{A, B, E\}: 2$
- Vier-elementige Frequent Itemsets
  - ~~$\{A, B, C, E\}$~~

Beispieltupel:

$\{A, B, E\}$

$\{B, D\}$

$\{B, C\}$

$\{A, B, D\}$

$\{A, C, D\}$

$\{B, C\}$

$\{A, C\}$

$\{A, B, C, E\}$

$\{A, B, C\}$



## A-Priori – Assoziationsregeln

- Assoziationsregel-Kandidaten
  - Aufteilen der Frequent Itemsets in Antecedents und Consequents
- Berechnung der Confidence pro Kandidat
  - Erfüllt Kandidat gegebene minimal Confidence  
⇒ Association Rule
  - Sonst verwerfen
- Modifikation: Andere Evaluierungsmasse
  - Chi-Quadrat-Maß, Informationsgewinn, ...



## A-Priori – Assoziationsregeln (Bsp.)

- Gesucht Assoziationsregeln mit mind. 2 Antecedents  
MinConf = 5/9

- Frequent Itemsets mit 3 oder mehr Elementen:

- {A, B, C}
- {A, B, E}

- Mögliche Assoziationsregeln

- ~~A, B  $\Rightarrow$  C; Confidence = 2/4~~
- ~~A, C  $\Rightarrow$  B; Confidence = 2/4~~
- ~~B, C  $\Rightarrow$  A; Confidence = 2/4~~
- ~~A, B  $\Rightarrow$  E; Confidence = 2/4~~
- A, E  $\Rightarrow$  B; Confidence = 2/2
- B, E  $\Rightarrow$  A; Confidence = 2/2

Beispieltupel:

{A, B, E}

{B, D}

{B, C}

{A, B, D}

{A, C, D}

{B, C}

{A, C}

{A, B, C, E}

{A, B, C}



# Ende Einschub Data-Mining Grundlagen

## Distributed Data-Mining



# Motivation

Motivation

[Background](#)

[Grundlagen](#)

[D ARM](#)

[PP ARM](#)

[Zusammenf.](#)

- Data-Mining erzeugt (unter anderem)
  - Frequent Itemsets
  - Association Rules
  - Classifiers
  - Clusters
- Diese Ergebnisse von Data-Mining (in gewisser Weise aggregiert) lassen im Normalfall keine Rückschlüsse auf Individuen zu.  
→ Wo soll da das Privatheitsproblem liegen?  
(abgesehen von outlier detection)

Das Problem:



- Wie berechne ich die Data-Mining Ergebnisse, ohne die zur Berechnung erforderlichen Daten zu kennen?





Motivation

[Background](#)


[Grundlagen](#)

[D ARM](#)

[PP ARM](#)

[Zusammenf.](#)

# Motivation



- **Beispiel Komplikationen bei Behandlung**
  - Eine Gesundheitsorganisation möchte in allen deutschen Krankenhäusern aufgetretene Komplikationen identifizieren.
  -  Alternative 1: Jedes Krankenhaus schickt alle Krankenakten an die Gesundheitsorganisation.
  -  Alternative 2: Alle einigen sich auf eine Trusted-Third Party.
    - Wer stellt sich hierfür zur Verfügung?
    - Gefahr der zentralen Datenhaltung?
  -  Lösungsansatz: Gibt es einen Weg, so dass keine Seite seine Daten preisgeben muss, die Analyse aber trotzdem möglich ist?





Universität Karlsruhe (TH)

Forschungsuniversität · gegründet 1825

# Grundlagen



# Motivation - Partitionierung

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Horizontal partitionierte Daten  
Daten *gleicher Semantik* über *unterschiedliche Individuen* sind auf mehrere Parteien verteilt.
- Vertikal partitionierte Daten  
Daten *unterschiedlicher Semantik* über die *gleichen Individuen* sind auf mehrere Parteien verteilt.
- Kombiniert (hier wenig interessant) **Warum?**  
Daten *unterschiedlicher Semantik* über *unterschiedliche Individuen* sind auf mehrere Parteien verteilt.





# Motivation

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

| ID | Adresse | Einkommen |
|----|---------|-----------|
| 1  | 68766   | 40k       |
| 2  | 76131   | 50k       |
| 3  | 68259   | 90k       |
| 4  | 68766   | 15k       |

Unser Fokus

Horizontal partitioniert

| ID | Adresse | Einkommen |
|----|---------|-----------|
| 1  | 68766   | 40k       |
| 2  | 76131   | 50k       |
| ID | Adresse | Einkommen |
| 3  | 68259   | 90k       |
| 4  | 68766   | 15k       |

Vertikal partitioniert

| ID | Adresse |
|----|---------|
| 1  | 68766   |
| 2  | 76131   |
| 3  | 68259   |
| 4  | 68766   |

| ID | Einkommen |
|----|-----------|
| 1  | 40k       |
| 2  | 50k       |
| 3  | 90k       |
| 4  | 15k       |





Motivation


Background

Grundlagen

D ARM

PP ARM

Zusammenf.





# Distributed Association Rule Mining



# Distributed A-Priori

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Lemma
  - Hat eine Regel einen globalen Support  $> k\%$ , dann muss mind. eine Seite einen Support  $> k\%$  haben.
- Algorithmus:
  - Fordere von jede Seite alle Regeln mit Support  $> k$ .
  - Fordere von jeder Seite die Anzahl der Transaktionen an, die die Regel unterstützen und die Anzahl aller Transaktionen der Seite.
  - Berechne den globalen Support jeder Regel. Das Lemma garantiert, dass alle Regeln mit Support  $k$  gefunden wurden.





# Distributed A-Priori

Motivation


Background

Grundlagen

D ARM

PP ARM

Zusammenf.





# Distributed A-Priori

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Berechnung der Confidence einer Association Rule  
 $AB \Rightarrow C$

$$\mathbf{support}_{AB} = \frac{\sum_{i=1}^{sites} \mathbf{support\_count}_{AB}(i)}{\sum_{i=1}^{sites} \mathbf{database\_size}(i)}$$

$$\mathbf{support}_{AB \Rightarrow C} = \frac{\sum_{i=1}^{sites} \mathbf{support\_count}_{ABC}(i)}{\sum_{i=1}^{sites} \mathbf{database\_size}(i)}$$

$$\mathbf{confidence}_{AB \Rightarrow C} = \frac{\mathbf{support}_{AB \Rightarrow C}}{\mathbf{support}_{AB}}$$

- Kein Austausch der Transaktionen selbst erforderlich
- Verlustfreies Vorgehen



Frage

- Sind die Regeln unter Umständen nicht selbst privat?





# Privacy Preserving Association Rule Mining



# Privacy Preserving Data Mining

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Regeln können private Information beinhalten
- Fortsetzung Bsp. Komplikationen
  - Versicherungen geben Informationen weiter
    - Problem mit Patientenakten
    - Aber auch Probleme bei Behandlungen, die ggf. nur in bestimmten Krankenhäusern auftreten
  - Versicherer kann bei Weitergabe solcher Informationen unter Druck geraten.





# Privacy Preserving Data Mining

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Im Folgenden wird eine Lösung für das Problem vorgestellt
  - Cryptographiebasierter Ansatz
  - Seiten lernen nahezu nichts voneinander
  - Ansatz ist effizient
    - Kosten im Vergleich zu einer nicht ‚securen‘ Lösung  $O(\text{candidate\_itemset} * \text{sites})$  Verschlüsselungen
    - Konstanter Anstieg in der Anzahl der erforderlichen Nachrichten
  - Achtung: Ansatz für drei oder mehr Seiten





# Secure Multiparty Computation

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Ziel: Berechnung des Ergebnisses, wenn jede Seite über Teile der erforderlichen Eingabe verfügt
- Yao's Millionaire's problem (*Yao '86*)
  - 'Secure' Berechnung ist möglich, wenn die Funktion als Schaltung modelliert werden kann
  - Idee: 'Secure' Berechnung der einzelnen Gates
  - Fortsetzen, bis Schaltung berechnet ist.
- Funktioniert auch für mehrere Parteien (*Goldreich, Micali, und Wigderson '87*)
- → Secure Multiparty Computation
- Was ist \*Secure\*?





# Secure Multiparty Computation: Definitions

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Unsere Definition von \*Secure\*
  - Niemand weiß irgend etwas bis auf die eigene Eingabe und das Ergebnis
  - Formal:  $\exists$  polynomial time  $S$  genau so, dass  $\{S(x, f(x, y))\} \equiv \{\text{View}(x, y)\}$
- Semi-Honest model: folgt dem Protokoll, eine Partei darf aber alles verwenden, was sie während des Protokolls lernen



Was wäre der Gegensatz

- Malicious: “cheaten” um etwas herauszufinden





# Beispiel: Exklusiv-Oder

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

Person A

- Wähle zufälliges Bit  $r_a$
- Schicke  $r_a$  an B
- Ersetze Input  $i_a$  durch  $(i_a \oplus r_a)$
- Berechne  $o_a = (i_a \oplus r_a) \oplus r_b$

Person B


- Wähle zufälliges Bit  $r_b$
- Schicke  $r_b$  and A
- Ersetze Input  $i_b$  durch  $(i_b \oplus r_b)$
- Berechne  $o_b = (i_b \oplus r_b) \oplus r_a$

| A | B | $A \vee B$ |
|---|---|------------|
| T | T | F          |
| T | F | T          |
| F | T | T          |
| F | F | F          |

Truth Table  
XOR?

Bisher nichts preisgegeben außer der Zufallszahl

$$\begin{aligned}
 o &= o_a \oplus o_b = ((i_a \oplus r_a) \oplus r_b) \oplus ((i_b \oplus r_b) \oplus r_a) \\
 &= i_a \oplus i_b \oplus r_a \oplus r_a \oplus r_b \oplus r_b \\
 &= i_a \oplus i_b
 \end{aligned}$$



XOR =  $(A + B) \bmod 2$

→ Assoziativ & Kommutativ





# Secure Sum

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Vorbedingung
  - $k$  Parteien
  - $k > 2$  warum?
  - Obere Schranke für die Summe ( $F$ ) bekannt





# Secure Sum

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Protokoll

- $P_1$  erstellt Zufallszahl  $r$  von Gleichverteilung über  $F$
- $P_1$  berechnet  $S_1 = x_1 + r \bmod |F|$  und sendet es an  $P_2$
- For  $P_2 \dots P_{k-1}$ 
  - $P_i$  empfängt  $S_{i-1} = r + \sum_{j=1}^{i-1} x_j \bmod |F|$
  - $P_i$  berechnet  $S_i = S_{i-1} + x_i \bmod |F| = \sum_{j=1}^i x_j \bmod |F|$   
und sendet es an  $P_{i+1}$
- $P_k$  empfängt  $S_{k-1} = r + \sum_{j=1}^{k-1} x_j \bmod |F|$
- $P_k$  berechnet  $S_k = S_{k-1} + x_k \bmod |F| = \sum_{j=1}^k x_j \bmod |F|$   
und sendet es an  $P_1$
- $P_1$  berechnet  $S = S_k - r \bmod |F| = \sum_{j=1}^k x_j \bmod |F|$   
und sendet es an alle anderen Parteien





# Beispiel: Secure Sum

Motivation


Background

Grundlagen

D ARM

PP ARM

Zusammenf.





# Secure Sum: Pro / Kontra

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Vorteile
  - Jeder außer  $P_1$  sieht nur Nachrichten, die von einer Zufallszahl maskiert sind.
  - $P_1$  sieht dafür nur das finale Ergebnis
  - Einfach
  - Nützlich für viele DM Applikationen
- Nachteile
  - Parteien können zusammenarbeiten
    - Lösung durch Shares von  $x_i$
    - Unterschiedliche Permutationen von Informationsflüssen
  - Anpassung an jede DM Applikation erforderlich

$$\text{support}_{AB} = \frac{\sum_{i=1}^{\text{sites}} \text{support\_count}_{AB}(i)}{\sum_{i=1}^{\text{sites}} \text{database\_size}(i)}$$

$$\text{support}_{AB \Rightarrow C} = \frac{\sum_{i=1}^{\text{sites}} \text{support\_count}_{ABC}(i)}{\sum_{i=1}^{\text{sites}} \text{database\_size}(i)}$$

$$\text{confidence}_{AB \Rightarrow C} = \frac{\text{support}_{AB \Rightarrow C}}{\text{support}_{AB}}$$





# Methode nach *Kantarcioglu and Clifton* (*DMKD'02*) Überblick

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

1. Finde die Vereinigung der lokalen large Candidate Itemsets *\*serurely\**
2. Nach dem lokalen Pruning, berechne die large Itemsets mit global support *\*securely\**
3. Zuletzt überprüfe die Konfidenz der potentiellen Assoziationsregeln *\*securely\**





# Secure Berechnung der Kandidaten

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Idee: Nutze kommutative Verschlüsselung
- $(E_a(E_b(x)) = E_b(E_a(x)))$
- Protokoll
  1. Berechne das lokale 'Candidate Set'
  2. Ergebnis verschlüsseln und an die nächste Seite schicken
    - So lange durchführen, bis alle Seiten ihre Regeln verschlüsselt haben
  3. Eliminieren von Duplikaten
    - Die kommutative Verschlüsselung stellt sicher, dass gleiche Regeln auch nach der Verschlüsselung, unabhängig von der Reihenfolge, identisch sind.
    - Jede Seite entschlüsselt die verbleibenden Regeln
    - Anschließend verbleiben die relevanten Regeln





# Anmerkung zu Schritt 1

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

tb2

- Anmerkungen
  - Vorsicht geboten, dass durch die Sortierung der Regeln keine Information preisgegeben wird.
  - Um die Sicherheit zu erhöhen, kann Redundanz eingefügt werden.
  - Nicht voll ‘secure’ gemäß der Definition von Secure Multiparty Computation.



**tb2**

**Warum?**

burgthor; 24.06.2009



# Berechnung des Candidate Sets

Motivation


Background

Grundlagen

D ARM

PP ARM

Zusammenf.





# Nomenklatur (gem. Paper)

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Variablen
  - $DB_i$  (Transaktions-)Datenbank auf Seite  $i$
  - $|DB_i|$  Größe der Datenbank auf Seite  $i$
  - $s$  Support Schranke (minimaler Support), (prozentual)
  - $c$  Konfidenz (prozentual)
  - $X$  Itemset
  - $x.\text{sup}$  Globaler Support von Itemset  $x$
  - $X.\text{Sup}_i$  Lokaler Support von Itemset  $X$  (absolut) an Seite  $i$





# Berechne, welche Kandidaten globalen Support haben

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

Ziel: Prüfen

$$x.\text{sup} \geq s^* |DB| \Leftrightarrow s^* \sum_{i=1}^n |DB_i| \quad (1)$$

$$\sum_{i=1}^n X.\text{sup}_i \geq \sum_{i=1}^n s^* |DB_i| \quad (2)$$

$$\sum_{i=1}^n (X.\text{sup}_i - s^* |DB_i|) \geq 0 \quad (3)$$

- Hinweis, das Prüfen von (1) ist identisch mit dem Prüfen von (3)





## Berechne, welche Kandidaten globalen Support haben (2)

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.


- Protokoll (Fortsetzung)
  - Berechne  $\text{Sum} \geq 0$ :
    - Seite<sub>0</sub> generiert zufälliges  $r$ 
      - Sendet  $r + \text{count}_0 - \text{frequency} * \text{dbsize}_0$  zur Seite<sub>1</sub>
    - Seite<sub>k</sub> addiert  $\text{count}_k - \text{frequency} * \text{dbsize}_k$ ,
    - Sendet Ergebnis zu Seite<sub>k+1</sub>
  - Endergebnis: Ist die Summe von Seite<sub>n</sub> -  $r \geq 0$ ?
    - Nutze \*secure\* two party computation
  - Dieses Protokoll ist \*secure\* im Sinne des semi-honest modells





# Berechne, welche Kandidaten globalen Support haben (3) : Ist der Support von ABC $\geq 5\%$ ?

- Motivation
- Background
- Grundlagen
- D ARM
- PP ARM
- Zusammenf.





# Berechnung der Konfidenz

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Protokoll
  - Gleich, wie für die Berechnung des supports
  - Berechnung der Konfidenz für  $X \Rightarrow Y$

$$\frac{\{X \cup Y\}.\text{sup}}{X.\text{sup}} \geq c \Rightarrow \frac{\sum_{i=1}^n XY.\text{sup}_i}{\sum_{i=1}^n X.\text{sup}_i} \geq c$$
$$\Rightarrow \sum_{i=1}^n (XY.\text{sup}_i - c * X.\text{sup}_i) \geq 0$$





Universität Karlsruhe (TH)

Forschungsuniversität · gegründet 1825

# Zusammenfassung



# Zusammenfassung

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

Einblicke in

- Data Mining
- Partitionierungen von Datenbeständen
- Verteiltes Data Mining
- Secure Multiparty computation
  - Yao's Millionaires Problem
  - Secure Sum
- Kommutative Verschlüsselung
- Secure Association Rule Mining





# Zusammenfassung

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

## Konkreter

- Data Mining wurde oftmals verpönt als privatheitsgefährdend.
- Hier gezeigt, dass Data Mining Ansätze die Privatheit in verteilten Systemen erst ermöglichen.
- Wir haben Muster auf verteilten Datenbeständen identifiziert, ohne dass die Originaldaten dazu preisgegeben werden mussten.
- Verlustfrei, unter Einsatz von Verschlüsselungstechniken.
- Verzicht auf zentrale Instanz.





# Mögliche Prüfungsfragen



# Mögliche Prüfungsfragen

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- Begründen Sie mit dem Datenschutzrecht, warum ein Krankenhaus nicht jede Krankenakte an eine Gesundheitsorganisation geben darf?
- Werden beim verteilten Finden von Association Rules mehr oder weniger Ass. Rules an den Kombiniierer gemeldet als tatsächlich vorliegen?
- Beschreiben Sie den Aufbau eines Securen 2-Bit Vergleichers.





# Literatur

Motivation

Background

Grundlagen

D ARM

PP ARM

Zusammenf.

- [1] Kantarcioglu, M. & Clifton, C.  
**Privacy-Preserving Distributed Mining of Association Rules on Horizontally Partitioned Data**, *IEEE Trans. on Knowl. and Data Eng., IEEE Educational Activities Department*, **2004**, 16, 1026-103
- [2] **Privacy-Preserving Data Mining (Models and Algorithms):**  
Charu Aggarwal
- [3] **Privacy-Preserving Data Mining:** Chris Clifton

