

Einsatz von Datenbanken im Forschungslabor

Workflow und Data Mining

Friedrich-Alexander-Universität Erlangen-Nürnberg
Technische Fakultät, Institut für Informatik
Lehrstuhl für Informatik 6 (Datenbanksysteme)

Prof. Dr. Klaus Meyer-Wegener

Datenbanken – weshalb?

- ❑ **Speichergeräte**
 - werden immer größer und preiswerter
- ❑ **immer mehr Vorgänge**
 - werden mit Rechnern gesteuert und verwaltet
 - z.B. Paketversand, Zahlungsverkehr
- ❑ **digitale Aufzeichnung**
 - z.B. Photos, Messwerte in Physik und Astronomie, Genom
- ❑ **Datenvolumen wächst enorm**
 - nach Mega und Giga und Tera (10^{12}) und Peta (10^{15})
- ❑ **zunächst alles Dateien**
 - Suche? Auswertung? (Handel mit Daten?)

Datenbanken – wann?

bei einer großen Menge von Daten!

auch, aber vor allem:

- ❑ vielseitig verwendbar (offen für neue Anwendungen)
- ❑ wohlstrukturiert
- ❑ redundanzfrei
- ❑ flexibel abfragbar (recherchierbar)
- ❑ von mehreren Anwendungen gleichzeitig nutzbar, bei hoher Aktualität der Daten
- ❑ ausfallsicher

Dienste von Datenbanken

❑ Datenmodell und Schema

- Datenmodellierung (DB-Design) schwierig und aufwändig
- enge Kooperation zwischen Entwickler und Anwender notwendig

❑ Normalisierung

- Richtlinien für "gute" Schemata

❑ Anfragesprache (query language)

- Selektionen, Verknüpfungen, Aggregationen

❑ Synchronisation der Zugriffe


- fiktiver Ein-Benutzer-Betrieb
- tatsächlich aber gleichzeitige Zugriffe

❑ Transaktionen

- "Alles oder nichts" für eine Sequenz von Änderungen
- automatische Reparatur von inkonsistenten Zuständen

- ❑ **unteilbare Übergänge für zusammengehörige Änderungen**
 - Banküberweisung:
 - Beginn der Transaktion
 - Abbuchen Konto 1
 - Zubuchen Konto 2
 - Ende der Transaktion
- ❑ **Konsistenzerhaltung**
- ❑ **Vollständigkeit der Eingaben / Änderungen**
- ❑ **Garantie des Datenbanksystems**
- ❑ **mehrere zusammengehörige Transaktionen verschiedener Benutzer: Workflow**

Datenerfassung



❑ Information

- Wie macht man das (in dieser Firma)?
 - Beschaffung, Dienstreise, Laborversuch,
- Wer muss gefragt werden?
- Was muss man alles angeben?

❑ Vollständigkeit

- an alles denken

❑ Reihenfolge

- technische Präzedenzen u.a.


❑ Kontrolle

- Zwang, Überwachung ("Assistent" oder "Polizist"?)
- interne Überprüfbarkeit, Nachvollziehbarkeit:

Good Laboratory Practice

- ❑ **Abläufe (Prozesse)**
- ❑ **Definition**
 - Schritte, Bedingungen, Akteure, Daten,
- ❑ **Durchführung**
 - Initiierung
 - automatische Weiterleitung
 - Eingangskorb bzw. Aufgabenliste bei den Klienten
 - Bereitstellung von Anwendungen (**Transaktionen!**) und Daten
 - Zustandsinformation im Management
- ❑ **Einsatz für Erfassung, Datenpflege, operatives Geschäft**


Workflow-Beispiel



Auswertung: Data Warehouse, OLAP

- ❑ **große Datenmengen**
- ❑ **historische Daten (z.B. Messreihen)**
- ❑ **gesucht: Entwicklungen, Trends, Zusammenhänge**
- ❑ **nicht auf demselben Datenbestand wie Erfassung**
 - Leistungsfähigkeit: gegenseitige Behinderung vermeiden
 - Umstrukturierung für Optimierung
 - Verteilung der Originaldaten
 - Bereinigung
- ❑ **zusammenfassende Kopie: Data Warehouse**

Data Warehouse



Data Warehouse: Modelle


- ❑ **Stern-Schema:**
 - Faktentabelle und Dimensionstabellen
- ❑ **Fakten:**
 - Verkäufe, Messwerte,
- ❑ **Dimensionen:**
 - Zeit, Ort, Beteiligte, Einstellungen,
- ❑ **auch hierarchisch: Uhrzeit – Tag – Woche – Monat**
- ❑ **typische Anfragen: Gruppierung und Aggregation**
 - Summe, Mittelwert, Maximum, Minimum usw.
- ❑ **Drill-Down: mehr Detail**
 - von den Monatssummen zu den einzelnen Tagen
- ❑ **Roll-up: mehr Verdichtung**
- ❑ **wenn man so will: Statistik**

- ❑ **große Datenmengen (im Data Warehouse) nach bisher unbekanntem Zusammenhängen durchsuchen**
 - basiert auf Knowledge Discovery (daher KDD)
- ❑ **Auswertungen über die Anfragesprache hinaus**
- ❑ **Suche nach Mustern, Regelmäßigkeiten, Ausnahmen ("das Signal im Rauschen")**
- ❑ **wichtige Methoden:**
 - Klassifikation (Entscheidungsbäume)
 - Finden von Assoziationsregeln

Klassifikationen

- ❑ **eine Form der multivariaten Analyse**
- ❑ **Herleitung aus einer repräsentativen Datenmenge**
- ❑ **Unterscheidung von Merkmalen und Klassen**
 - z.B. Symptome und Diagnose
- ❑ **Entscheidungsbäume**
 - genutzt für Vorhersagen bei neuen Merkmalskombinationen
 - liefert Hinweise auf Ursachen, aber nicht die Ursachen selbst

Klassifikationen: Beispiel



Assoziationsregeln

- ❑ **Implikationsregeln**
für Zusammenhänge zwischen verschiedenen Fakten:
 - "Wenn jemand Windeln kauft, kauft er auch Bier"
- ❑ **Vertrauen (confidence):**
 - Anteil der Datensätze, bei denen Folgerung erfüllt ist, an denen, die Voraussetzung erfüllen
- ❑ **Unterstützung (support):**
 - Anteil der Datensätze, bei denen die Regel stimmt

Zusammenfassung und Ausblick

- ❑ **Datenbanken:**
 - Grundlage für die systematische Erfassung und Auswertung von Datenmengen
- ❑ **Workflows:**
 - Systemunterstützung für operative Abläufe
- ❑ **Data Warehouses:**
 - Kopien von Datenbeständen für umfangreiche Auswertungen
- ❑ **Data Mining:**
 - Finden von Zusammenhängen
- ❑ **bisher oft nur für Geschäftsdaten, zunehmend auch für Experimentaldaten ("scientific databases"):**
 - Arbeitserleichterung
 - neue Auswertungen

- Stefan Jablonski, Markus Böhm und Wolfgang Schulze: *Workflow Management - Entwicklung von Anwendungen und Systemen*. Heidelberg : dpunkt, 1997. - ISBN 3-920993-73-X
- Usama Fayyad, David Haussler and Paul Stolorz: Mining Scientific Data. *Communications of the ACM* 39 (1996), Nr. 11, S. 51-57