

Data Warehousing

Matthias Conrad
9711

DB Oberseminar

Inhaltsverzeichnis

- Einführung
- DWH - Architektur
- Akquisition
- Multidimensionales Datenmodell
- Materialisierte Sichten
- Metadaten
- Ausblick
- Referenzen

Einführung DWH

Einführung

„A Data Warehouse is a subject-oriented, integrated, non-volatile, and time variant collection of data in support of managements decisions.“

(W.H. Inmon 1996)

Einführung

- Unternehmen stehen heute immer mehr Daten elektronisch zur Verfügung
 - Großer Druck diese zur Unterstützung des Entscheidungsprozesses einzusetzen
 - Viele Daten können nicht genutzt werden (da nicht in interpretierbarer Art vorliegend, sich diese auf verschiedenen Systemen befinden)
- Braucht Systeme die Daten zu Informationen aufwerten
 - Technologien, die Daten aus verschiedenen Quellen in fundierte, einheitlich strukturierte Informationen auswerten, werden unter dem Begriff des *Data Warehousing* zusammengefasst.

Einführung

- Achtziger Jahren kamen erste Datenmodellierungsmethoden auf
 - Erlaubte die Anforderungen an die Daten und die dazu benötigten Strukturen formal zu dokumentieren
- Notwendigkeit einer Struktur und Architektur in Bezug auf die Datenbeschaffung → um Übersicht zu behalten
- Ende der achtziger Jahre Unterscheidung zwischen operativen und analytischen Informationssystemen
 - *OLTP* (On-line Transaction Processing)
 - *OLAP* (On-line Analytic Processing)

Einführung

- operative – analytische Datenbanken

	Operative DB	Analytische DB
Einsatz	operatives Geschäft	Analyse, Entscheidungsunterst.
Daten	aktuell, isoliert, detailliert	historisiert, integriert, detailliert, aggregiert
Verarbeitung	Transaktionen, häufige Änderungen	Anfragen, Ergänzungen
Eigenschaften	Konsistenz, Vollständigkeit	Qualität, Richtigkeit
Grösse	MB...GB	GB...TB

Einführung

- Analytische DB hauptsächlich entworfen um die Ausführung von komplexen meist read-only Anfragen zu unterstützen
 - Anfragedurchsatz und Antwortzeit, wichtiger als Transaktionsdurchsatz
- Die Industrie war nun vor neue Anforderungen gestellt
 - Technologische Einschränkungen, vor allem um Informationen von verschiedenen heterogenen Systemen zusammenzubringen, behinderten die Entwicklung von OLAP-Systemen.

Einführung

- Die Data Warehousing Technologie zielt darauf hin, Lösungen für diese Probleme zu liefern
- Seit Mitte der neunziger Jahre ist DWH ein fester Bestandteil unserer Informationsgesellschaft

Einführung

- Die Anforderung an ein Data Warehouse sind :
 - Informationen einer Unternehmung zugänglich machen
 - Der Inhalt der Daten muss klar, verständlich sein
 - Schnelle Ausführung von Anfragen mit minimaler Wartezeit
 - Informationen konsistent halten
 - Sämtliche Informationen sind vollständig und erklärt
 - Anpassbar und flexibel
 - Das Informationsvermögen sollte gut vor Missbrauch geschützt sein
 - Es soll die beste Grundlage für den Entscheidungsprozess bieten, so dass sich die getroffenen Entscheidungen auch bewähren

Einführung

- Anwender: Manager
Abteilungsleiter
Fachkräfte
- Formen der Bereitstellung :
 - Query-Ansätze: frei definierbare Anfragen und Berichte
 - Reporting: Zugriff auf vordefinierte Berichte
 - Redaktionell aufbereitete, personalisierte Informationen

Einführung

- Betriebswirtschaftliche Anwendungen

Analyse

- Detaillierte Analyse der Daten zur Untersuchung von Abweichungen oder Auffälligkeiten

Planung

- Unterstützung durch explorative Datenanalyse
- Aggregation von Einzelplänen

Einführung

Kampagnenmanagement

- Unterstützung strategischer Kampagnen
- Kundenanalyse, Risikoanalyse

Beispiel: Wal Mart (www.wal-mart.com)

- Größe: ca. 25 TB
- Täglich bis zu 20.000 DWH-Anfragen
- Basis für Warenkorbanalyse, Kundenklassifizierung

Einführung

- Wissenschaftliche Anwendungen

- Projekt Earth Observing System (Klima- und Umweltforschung)

- täglich ca. 1,9 TB meteorologischer Daten
 - Aufbereitung und Analyse (Data Mining)

- Öffentlicher Bereich: DW mit Umwelt- oder geographischen Daten (z.B. Bodenanalysen)


DWH – Architektur

DWH – Architektur

- Anforderungen an ein Data Warehouse
 - Unabhängigkeit zwischen Datenquellen und Analysesystemen
 - Dauerhafte Bereitstellung integrierter Daten
 - Mehrfachverwendbarkeit von Daten
 - Durchführung von Auswertungen
 - Erweiterbarkeit des DWH
 - Zweckorientiert
 - Unterstützung individueller Sichten

DWH – Architektur

Ein DWH System beinhaltet das Data Warehouse sowie alle Komponenten, die für die Entwicklung, den Unterhalt und den Zugriff auf das DWH benötigt werden.



DWH – Architektur

- Daten werden von operativen Systemen / externen Quellen bezogen
- Die Quellen sind autonome Komponenten
- DWH System hat keine Kontrolle über Inhalt und Form der Daten in den Quellen
- Der Bereich Akquisition dient der Datenaufbereitung
 - Dies beinhaltet :
 - bereinigen
 - vervollständigen
 - kombinieren
 - aggregieren
- Daten werden im Anschluss in das eigentliche DWH überführt

DWH – Architektur

- Im eigentlichen DWH werden die Daten abgespeichert
- Meistens in Data Marts (Daten Märkten)
 - Data Marts sind Teilmengen eines DWH
 - Natürliche Trennung (Unternehmensbereiche ...)
- Durch die Erstellung von Data Marts können die Abfragen beschleunigt werden
- In vielen Fällen werden Data Marts eingesetzt weil :
 - Anwenderzugriffswerkzeuge
 - Zugriffsrestriktionen
 - besondere Datenschutzbestimmungen es erfordern

DWH – Architektur

- Zugriffskomponente aller Applikationen
 - OLAP
 - Data Mining
- Der Endbenutzer des Data Warehouse greift nur über diese Zugriffskomponente auf die Daten im System zu
 - Hier werden also die Informationen gewonnen
- Weitere Informationen über OLAP / Data Mining siehe
 - 11.01.01 Maik Kurzhals (OLAP)
 - (→ 17.01.01 Katja Wachsmuth (Data Mining))

DWH – Architektur

- Zusätzlich gibt es → *Metadaten – Managementkomponente*
- Definiert, pflegt und arbeitet mit den verschiedenen Typen von Metadaten
- Allgemein sind Metadaten als Daten über Daten definiert
- DWH gibt es verschiedene Typen von Metadaten
 - Informationen über Struktur
 - Informationen über Semantik der Daten
 - Informationen über den Unterhalt und den Zugriff auf das DWH
- Dient dem schnellen und sicheren Auffinden der benötigten Daten / Informationen

Akquisition

Akquisition

- Ziel: Beschaffung und Aufbereitung von Daten für das DWH
- Aufgaben: Extraktion
Transformation
Bereinigung
Vervollständigung
Integration
- Datenakquisition sehr aufwendig 60 % bis 80 % der Projektzeit
 - Unterschiedliche Art der Datenquellen
 - Qualität der extrahierten Daten
 - Datenvolumina
 - Limitiertes Zeitfenster

Akquisition

- Datenextraktion

- Aus operativen Quellen ausgelesen → in Staging Area zwischengespeichert
- Meist über Standard-Middleware ausgelesen (z.B. ODBC)
- Bei älteren Datenquellen muss ein spezieller Extraktor erstellt werden
- Aktualisierung

- Datentransformation

- Daten liegen unterschiedlichen, quellenabhängigen Formaten vor
- Umwandlung in einheitliche Struktur

Akquisition

- Datenbereinigung

- Ungenügende Qualität der Daten (unvereinbare Datenformate, fehlende Werte, unlesbare Teile, Duplikate, Tippfehler)

„garbage in, garbage out“

- Zu beachten : Korrektheit

Konsistenz

Vollständigkeit

Aktualität

Glaubwürdigkeit

Redundanz

Verständlichkeit

Verfügbarkeit

Akquisition

- Datenvervollständigung
 - Behandlung fehlender Werte
 - Berechnen abgeleiteter Werte
 - Bilden von Aggregationen
- Datenintegration
 - Zusammenmischen der Daten anhand der definierten Beziehungen
 - Datenintegration über Mapping-Tabellen

Akquisition

- Laden ins DWH
 - Letzter Schritt der Datenakquisition
 - Laden der Daten aus Staging Area ins DWH
 - Logisches Schema des DWH wird beeinflusst
 - Daten werden mittels Regeln ins DWH eingefügt
(dabei indexiert und sortiert)
- Monitoring
 - Nach der Initialisierung des DWH fortlaufende Überwachung der Quellsysteme

Multidimensionales Datenmodell

Multidimensionales Datenmodell

- Datenmodell ausgerichtet auf Unterstützung der Analyse
 - Entscheidungsprozeß
- Betrachtung der Kennzahlen aus unterschiedlichen Perspektiven (zeitlich, produktbezogen) → Dimensionen
- Kennzahlen/Fakten (engl. facts):
 - Numerische Messgrößen
 - Beschreiben betriebswirtschaftliche Sachverhalte
 - Beispiele: Umsatz, Gewinn, Verlust

Typen: Additive Fakten
Semi-additive Fakten
Nicht-additive Fakten

Multidimensionales Datenmodell


- Dimension:
 - Beschreibt mögliche Sicht auf die Kennzahl / Fakten
 - Endliche Menge von n ($n \geq 2$) Dimensionselementen die eine semantische Beziehung aufweisen
 - Beispiele: Produkt, Geographie, Zeit
- Hierarchien in Dimensionen
 - Einfache Hierarchien
 - Parallele Hierarchien
 - Würfel

Multidimensionales Datenmodell

- Würfel (engl. cube)
 - Grundlage der multidimensionalen Analyse
 - Kanten (Dimensionen)
 - Zellen (ein oder mehrere Kennzahlen)
 - Visualisierung:
 - 2 Dimensionen: Tabelle
 - 3 Dimensionen: Würfel
 - >3 Dimensionen: Multidimensionale Domänenstruktur

Multidimensionales Datenmodell

- Würfel am Beispiel eines Kaufhauses



Multidimensionales Datenmodell

Days Dimension

```
Create Table Days (  
    date_desc      DATE,  
    day_WH         NUMBER ,  
    day_of_year    NUMBER ,  
    day_of_month   NUMBER ,  
    month_desc     VARCHAR2(9),  
    month_number   NUMBER ,  
    quarter        NUMBER ,  
    week_of_year   NUMBER ,  
    year           NUMBER )  
TABLESPACE USERS;  
  
ALTER TABLE Days ADD  
CONSTRAINT Day1_UK UNIQUE(day_WH);
```

Multidimensionales Datenmodell

```
CREATE FORCE DIMENSION Days_DIM
  LEVEL YearL IS DAYS.year
  LEVEL QuarterL IS DAYS.quarter
  LEVEL MonthL IS DAYS.day_of_month
  LEVEL WeekL IS DAYS.week_of_year
  LEVEL DayL IS DAYS.day_WH
  HIERARCHY DMQY (
    DayL CHILD OF
    MonthL CHILD OF
    QuarterL CHILD OF YearL )
  HIERARCHY dwy (
    DayL CHILD OF
    WeekL CHILD OF YearL )
  ATTRIBUTE MonthL DETERMINES (ml_month_desc,ml_month_number)
  ATTRIBUTE DayL DETERMINES (dl_date_desc,dl_day_of_year);
```

```
graph BT
  DayL[DayL] --> WeekL[WeekL]
  WeekL --> YearL[YearL]
```

Multidimensionales Datenmodell

- OLAP-Operationen zielen auf die multidimensionalen Datenstrukturen ab

→ Standardoperationen

Pivotierung / Rotation

Roll-Up, Drill-Down

Drill-Across


Slice, Dice

Materialisierte Sichten

Materialisierte Sichten

- Eine mögliche Realisierung eines DWH ist die Speicherung von Daten aus einer oder mehreren operativen Datenbanken in Form von materialisierten Sichten
 - Um so schnellen Zugriff auf die Daten zu ermöglichen unabhängig von der Verfügbarkeit der Datenquellen
 - Sonst Konsistenz schnell verloren / Daten unbrauchbar werden
- Eine Sicht wird aus einer Funktion und einer oder mehreren Basisrelationen generiert und ist selbst wieder eine Relation
- Sicht wird physisch auf dem Datenträger gespeichert (Unabhängigkeit gegenüber den Quelldaten)

Materialisierte Sichten




Materialisierte Sichten

```
CREATE VIEW <Sichtname> [(Spalte1, Spalte2...)] AS  
SELECT <Tabellenname Spaltennamen>  
FROM <Tabellenname/ Viewname>  
WHERE <Suchbedingung>
```

```
CREATE VIEW spiel_verk_2000 AS  
    SELECT f.Stadt, f.Manager, v.Verkaufs_id, v.Monat,  
           g.Gegenst_id, g.Gegenst_name, l.Linien_id, l.Verkaufs_Preis  
FROM Filiale f, Verkauf v, Linie l, Gegenstand g  
WHERE f.Filialen_id = v.Filialen_id and  
       v.Verkaufs_id = l.Verkaufs_id and  
       l.Gegenst_id = g.Gegenst_id and  
       f.Land = „D“ and  
       v.Jahr = „1999“ and  
       g.Kategorie = „Spielwaren“
```

Materialisierte Sichten

- Erstellung/Initialisierung von Sichten
 - Nach Modellierung der MS müssen diese im System spezifiziert werden
 - Integrationskomponente beauftragt, die entsprechenden Daten aus den Quellen zu holen
 - Diese nach den Vorgaben die MS zu erstellen
 - Diese werden im DWH abgespeichert
 - Sind nun für den Benutzer verfügbar



Materialisierte Sichten

- Konsistenz
 - Sicherstellung der Konsistenz nach Änderungen in den Quellbeständen
 - Drei verschiedene Konsistenzbereiche :

- Multiple Sichtenkonsistenz



- Sichtenkonsistenz



- Quellenkonsistenz



Materialisierte Sichten

- Oftmals Änderungen im Quelldatenbestand Auswirkung auf das DWH
- Die MS müssen so angepasst werden, damit Konsistenz erhalten bleibt
- Methoden :
 - DWH sendet Anfragen an die Quelle, worauf diese die Antworten auf die Anfragen ans DWH liefert
 - Die Quelle sendet automatisch Updates an das DWH, woraufhin das Update auf die Sichten angewendet wird

Metadaten

Metadaten

- Metadaten -- „Daten über den Daten,“ nehmen im DWH eine Schlüsselrolle ein
 - Beschreiben z.B. die im DWH vorhandenen 0 und 1 und ermöglichen deren Interpretation.
- Zu den Metadaten zählen :
 - Konzeptuelle Entwurf
 - Programmcodes
 - Sicherheitseinrichtungen
 - Namen und Eigenschaften von Tabellen
 - Weitere Informationen über Tabellen
 - Aus welchen operationalen Systemen die Daten ins DWH gelangt sind

Metadaten

- Klassifikation von Metadaten
→ Nach Benutzung

Technische Metadaten	Geschäftliche Metadaten
Logisches und konzeptuelles Datenmodell	Namen der Tabellen und Attribute (in klaren Bezeichnungen)
DWH -Tabellennamen, - Schlüssel und - Indizes (z.B. in der Form von Code)	Zeitpunkt der Aktualisierungen
Verantwortlichkeiten und Zugriffsrechte innerhalb des DWH	Abfragungs- und Navigationspfade


Metadaten

- Verfeinerung der Klassifikation
 - Typ :
 - Primärdaten
 - Metadaten für Prozesse
 - Abstraktion : Modellierung konzeptuell, logisch und physisch
 - Erstellungs- / Verwendungszeitpunkt

Erstellungszeitpunkt	Verwendungszeitpunkt
Entwurfsmetadaten	CASE-Werkzeuge
Aufbaumetadaten	Transformations- und Qualitätsregeln
Benutzungsmetadaten	OLAP

Metadaten

- Die Metadaten werden im Metadaten-Repository gespeichert
- Dem Repository vorgelagert befindet sich der Metadaten-Manager über den der gesamte Zugriff und Austausch erfolgt



Metadaten

- Das Metadaten Repository soll allen Benutzergruppen einen optimalen Informationsgewinn aus dem DWH ermöglichen
- Diverse Standards :
 - Open Information Model (OIM)
 - Common Warehouse Model (CWM)

welche auf unterschiedliche Art und Weise Metadaten strukturieren und austauschen

Ausblick

Ausblick

- DWH raschen Veränderungen unterworfen
- Der Markt wächst extrem schnell
- Ende 1998 betrug er 5 Milliarden US\$
→ 2002 auf 21 Mrd. US\$ prognostiziert
- DWH sehr dynamisch
- Kontinuierliche Weiterentwicklung
- Unternehmen ohne die Informationen aus einem DWH müssen Wettbewerbsnachteile in Kauf nehmen

Referenzen

- Wolfgang Martin „ Data Warehousing “
- TECHNET.ORACLE.COM
- ORACLE.COM
- OWB Users Guide
- Institut für Informatik der Universität Zürich
- W.H. Inmon „ Building the Warehouse “
- Bauer, Günzel „ Data Warehouse – Architektur, Entwicklung, Anwendung “