Data Warehousing

Kapitel 1: Data-Warehousing-Architektur

Folien teilweise übernommen von Matthias Gimbel

Analyse von Geschäftsprozessen

- Mögliche Fragestellungen
  - Wie entwickelt sich unser Umsatz im Vergleich zum letzten Jahr?
  - In welchen Regionen liegt der erzielte Gewinn unterhalb der Erwartungen?
  - Mit welchen Produktgruppen erzielen wir den größten Gewinn?
  - Ich möchte wöchentlich einen Bericht über die wichtigsten Kennzahlen und deren Veränderung in den letzten Wochen!
  - Welchen durchschnittlichen Umsatz erwirtschaften wir pro Filiale?

Herausforderungen

- Die benötigten Daten
  - sind eventuell auf die verschiedenen Filialen **verteilt**,
  - werden teilweise **unterschiedlich benannt,**
  - müssen aus **verschiedenen Anwendungen** extrahiert werden,
  - liegen in **unterschiedlicher Granularität** (Lebensmittel – Milchprodukte, Obst & Gemüse) oder in **unterschiedlicher Struktur** vor,
  - sind
    - **fehlerbehaftet** oder **unvollständig**,
    - bereits **gelöscht** oder auf Band **archiviert**.
- Analyse-Anfragen
  - **stören** möglicherweise **den laufenden Betrieb**

Früher …

- Telefonaktionen
- Taschenrechner
- Listen
- …

→ hoher zeitlicher Aufwand
→ hoher Personalaufwand
→ hohe Kosten
→ hohe Fehleranfälligkeit
→ schwierige Nachvollziehbarkeit

Ziel

- Daten sollen
  - **einheitlich benannt** sein,
  - **einheitliche Bedeutung** besitzen.
- Zugriff soll
  - **jederzeit**, möglichst **aktuell** und **schnell** möglich sein,
  - auch **komplexe Fragestellungen** erlauben,
  - **laufenden Betrieb** nicht beeinträchtigen,
  - auch auf **historische Daten** möglich sein,
  - **automatisiert** ablaufen,
  - **nachvollziehbar** sein,
  - **zuverlässig** erfolgen.

Definition

"A **Data Warehouse** is a

- **subject oriented**,
- **integrated**,
- **non-volatile**, and
- **time variant**

collection of data in support of management's **decision-making** process."

(Inmon, 1996)

Definition

- **Fachorientierung (subject oriented)**
  themenbezogen, nicht auf einzelne Anwendungen bezogen
- **Integrierte Datenbasis (integrated)**
  integriert Daten aus verschiedenen Systemen und Standorten
- **Nicht flüchtige Datenbasis (non-volatile)**
  dauerhafte Speicherung der Daten, kein Ändern, kein Löschen von Daten
- **Historische Daten (time variant)**
  zeitpunktbezogene Speicherung, häufig Vergleiche von Werten zu verschiedenen Zeitpunkten

transaktional vs. analytisch

- Transaktionale/Operative Systeme
  - Benutzer: Sachberarbeiter, Verkäufer
  - dienen der täglichen Arbeit
  - **OLTP** = OnLine Transactional Processing
- Analytische/Entscheidungsunterstützende Systeme
  - Benutzer: Analysten, Management
  - helfen, strategische Entscheidungen zu fällen
  - Basis für alle entscheidungsunterstützenden Anwendungen, wie z. B.
    - Reporting
    - **OLAP** = (OnLine Analytical Processing)
    - Data Mining
  - DSS = Decision Support System
  - EUS = Entscheidungsunterstützendes System

Analytische Systeme

- Eigenschaften:
  - enthalten sehr große Datenmengen (möglichst alle relevanten Unternehmensdaten) über mehrere Jahre
  - wenige Benutzer und Zugriffe, aber mit hohem Datenvolumen
  - keine Änderungen oder Löschungen von Einträgen
  - überwiegend historische, zusammengefasste Daten
  - "Schnappschüsse" der operativen Daten
  - relativ hohe Redundanz
  - Daten strukturiert, integriert und konsolidiert

OLTP vs. OLAP

	OLTP (transaktional)	**OLAP (analytisch)**
Fokus	Lesen, Schreiben, Modifizieren, Löschen	Lesen, periodisches Hinzufügen
Transaktionsdauer und –typ	kurze Lese-/ Schreibtransaktionen	lange Lesetransaktionen
Anfragestruktur	einfach strukturiert	komplex
Datenvolumen einer Anfrage	wenige Datensätze	viele Datensätze
Datenvolumen eines Systems	Gigabyte (GB) – Terabyte (TB)	Terabyte (TB) – Petabyte (PB)
Datenalter	aktuell - mehrere Monate	aktuell - viele Jahre
Datenmodell	anfrageflexibles Datenmodell	analysebezogenes Datenmodell
Verfügbarkeit	sehr hoch	hoch
Anzahl Benutzer	hoch	gering

Referenzarchitektur eines DWS

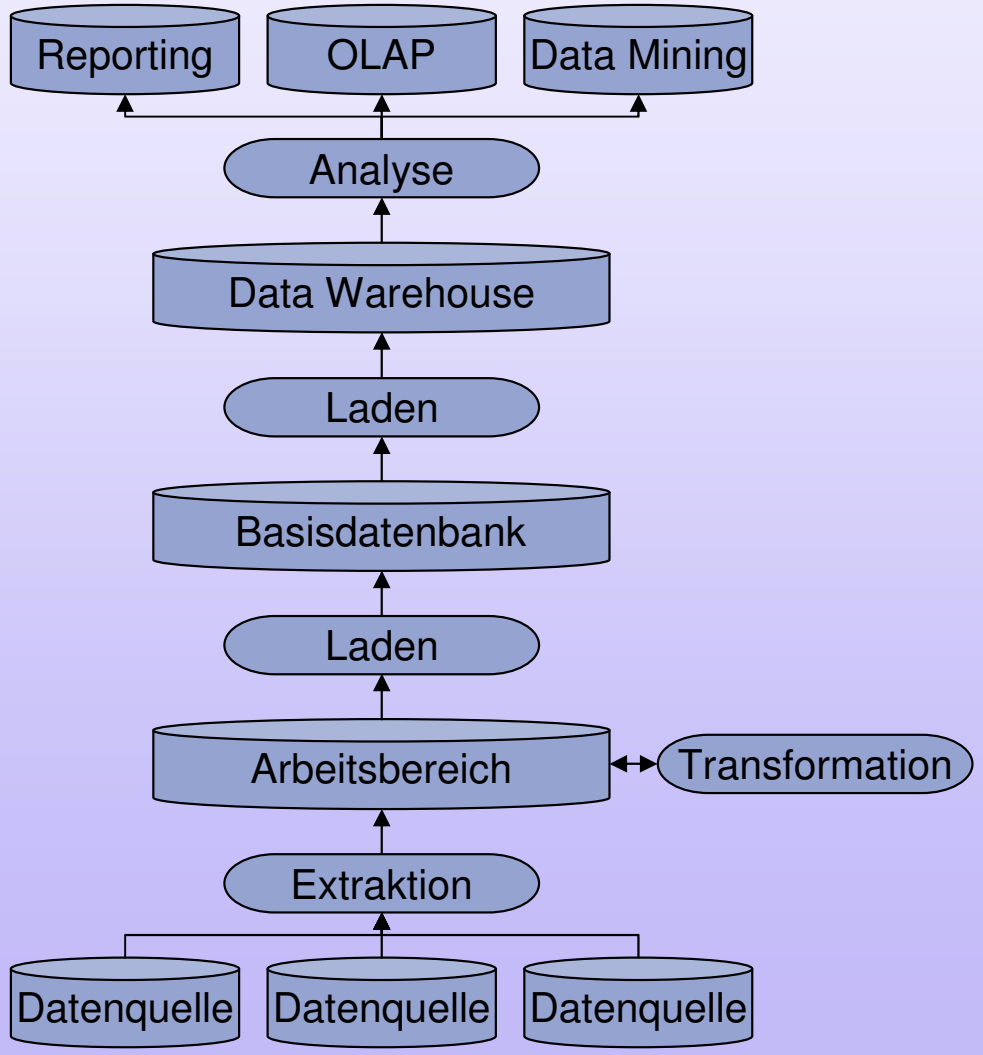

Data-Warehouse-Manager

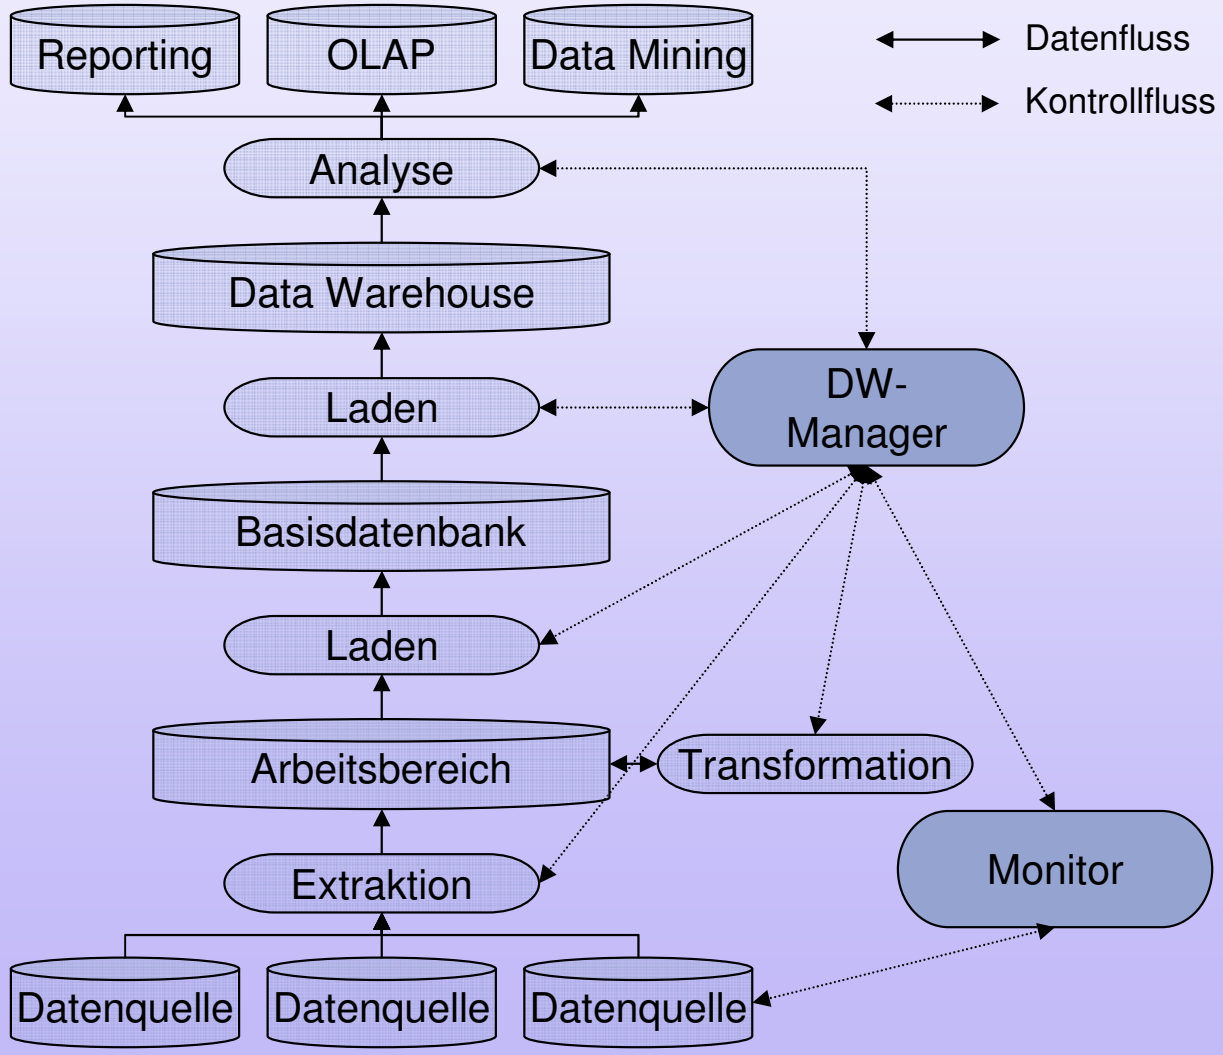

Metadatenmanager

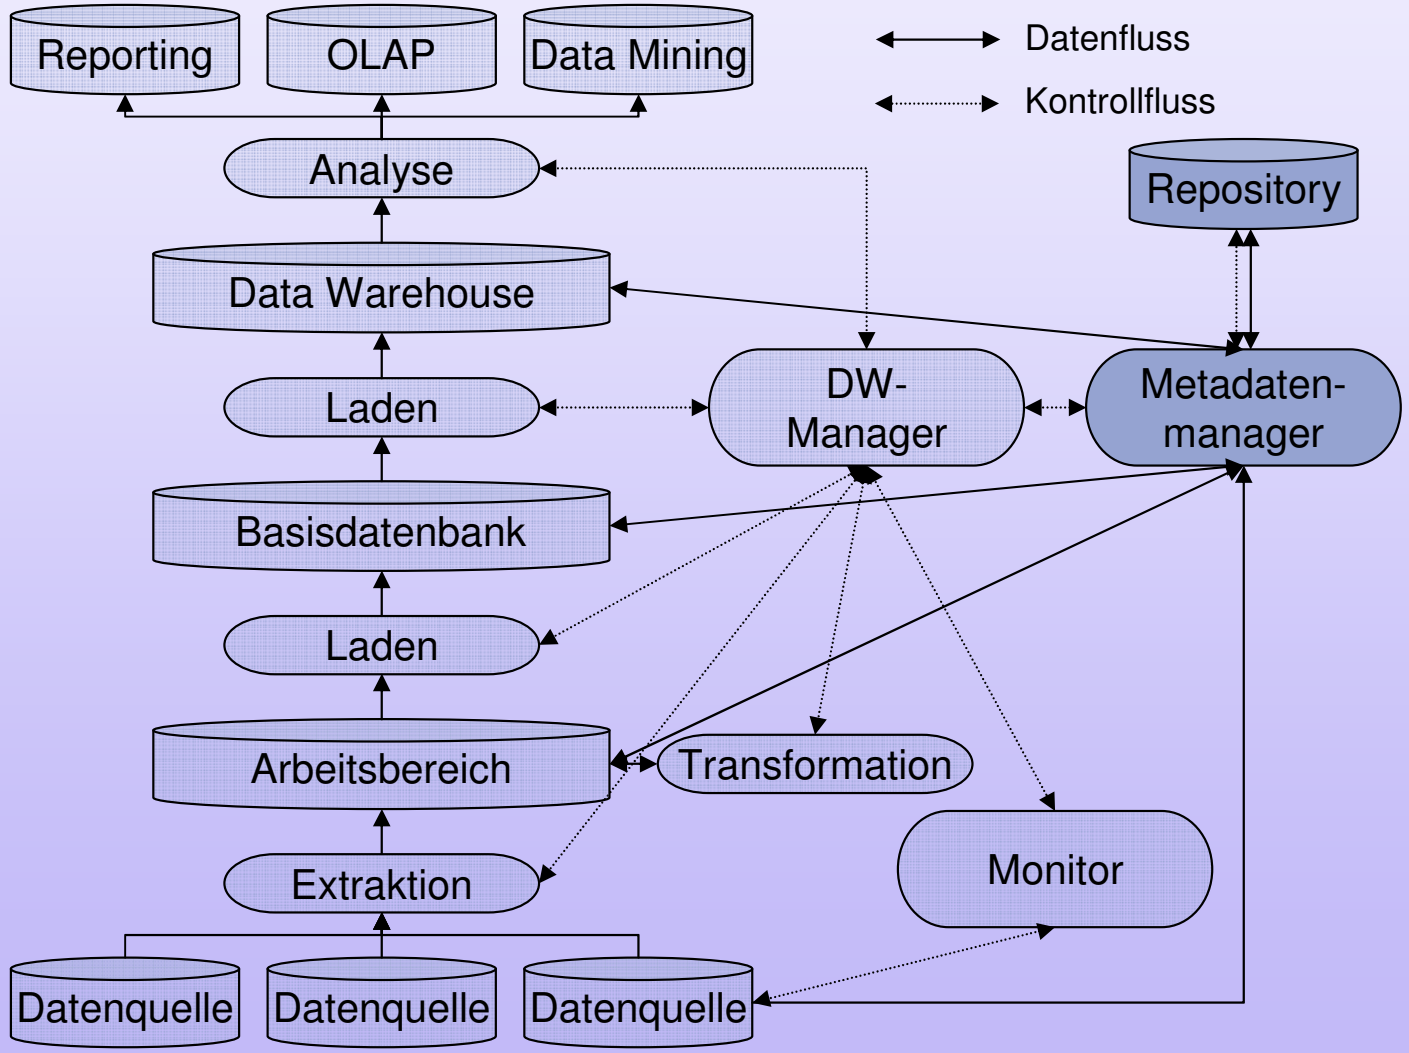

Referenzarchitektur eines DWS

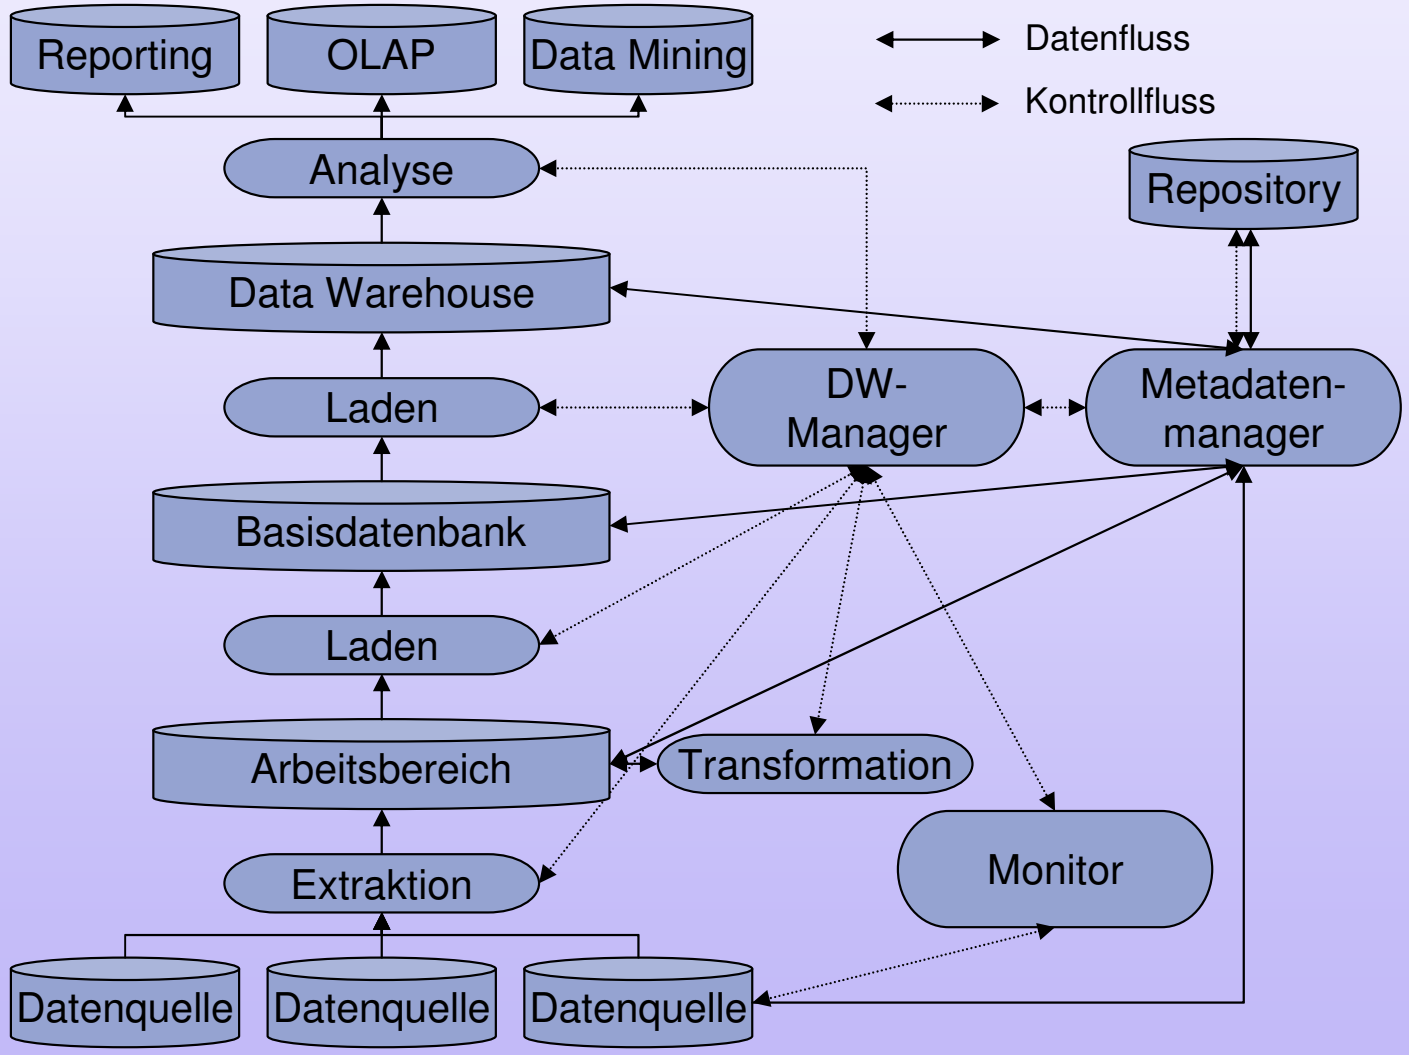

ETL-Prozess

ETL =

- Extraktion
- Transformation
- Laden

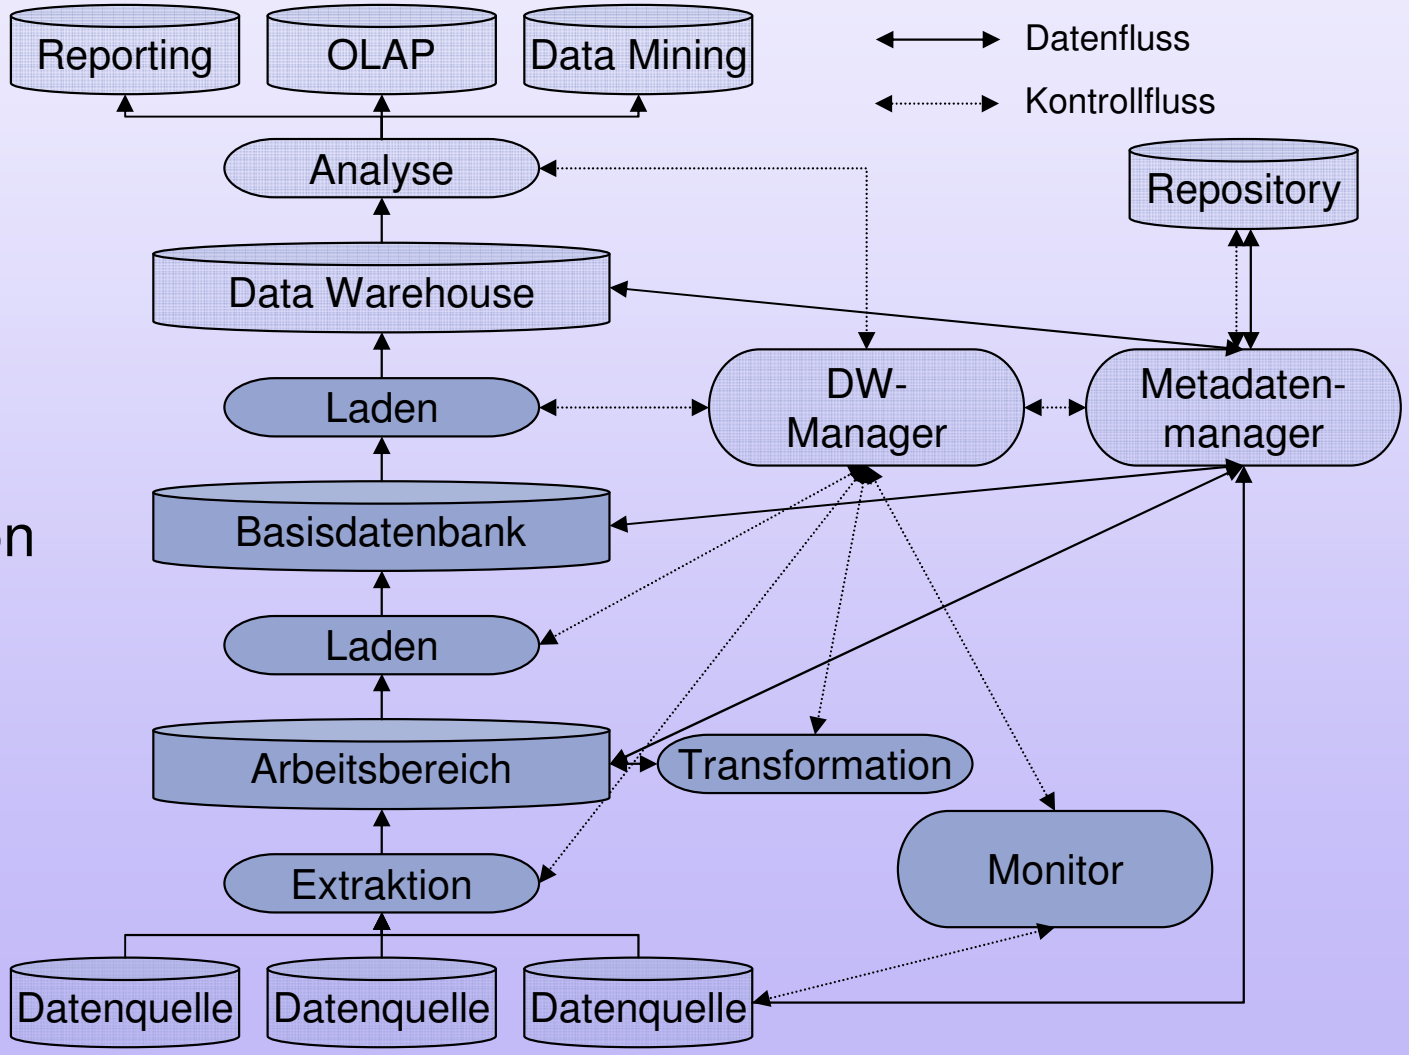

ETL-Prozess: Extraktion

- Extrahieren der Daten aus den Quellsystemen
  - Wann?
    - periodisch
    - auf Anfrage
    - ereignisgesteuert (z. B. nach x Änderungen)
    - sofort
  - Wie?
    - vollständig
    - inkrementell
  - Wie bekommt man Änderungen mit?
    - Trigger
    - SQL-Anfrage
    - Zeitstempel-basiert
    - Snapshot-Vergleich
- Unterschiedliche Quellen
  - Datenbanken
  - Webseiten
  - Dateien
  - …

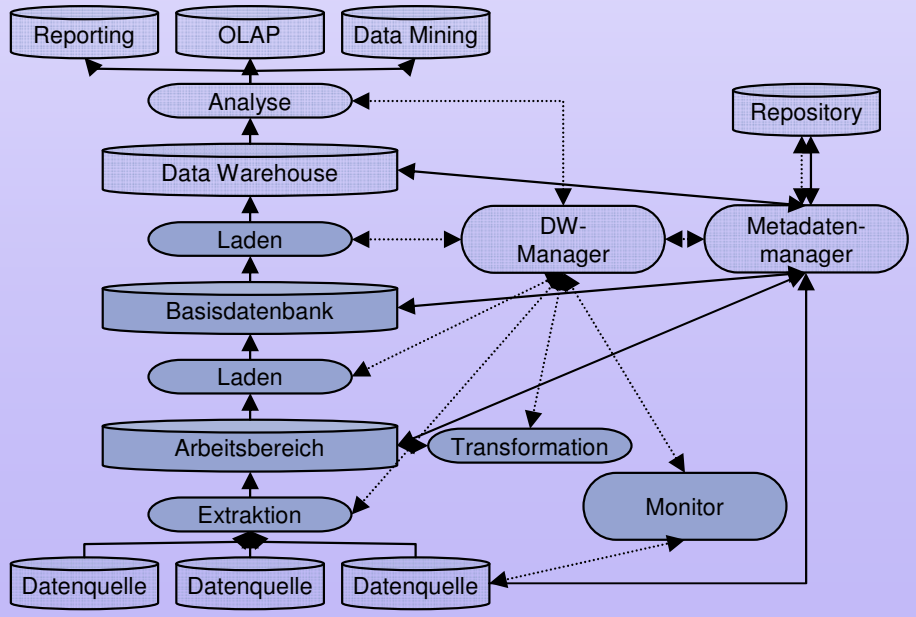

ETL-Prozess: Transformation #1

- Entfernen irrelevanter Daten
- Säubern der Daten
  - Ergänzung fehlender Werte
  - Belegung mit default-Werten
  - Prüfung auf falsche Werte (Plausibilitätsprüfung)
- Überbrückung struktureller Differenzen
  Beispiel: Speditionsfilialen:
  - 1 Tabelle pro Filiale: Gut, Menge
    - 1 Zeile pro Gut
  - 1 Tabelle pro Gut: Auftraggeber, Menge
    - 1 Zeile pro Auftraggeber
  - 1 Tabelle pro Filiale: Kohle, Öl, …
    - 1 Zeile pro Verkaufstag

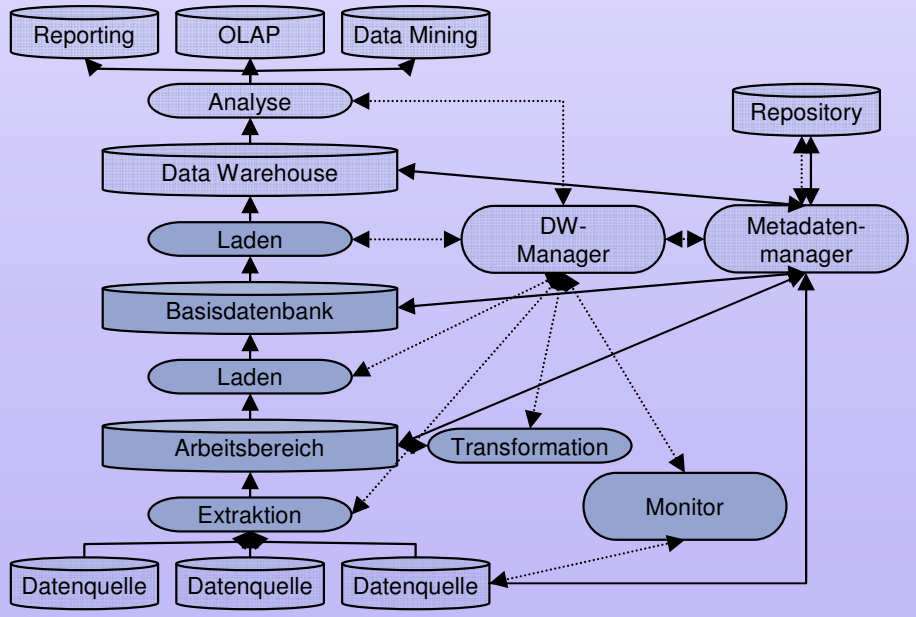

ETL-Prozess: Transformation #2

- Anpassen der Werte
  - Übersetzungen zwischen Bezugssystemen
    - Maßeinheiten (inch/m, EUR/$)
    - Kodierungen (ASCII/Unicode)
    - Datumsangaben (D/US)
  - Anpassungen bei semantischen Differenzen
    - Umsatz brutto oder netto
    - Gewinn vor Steuern, nach Steuern
    - mit/ohne Sonderbelastungen
    - …

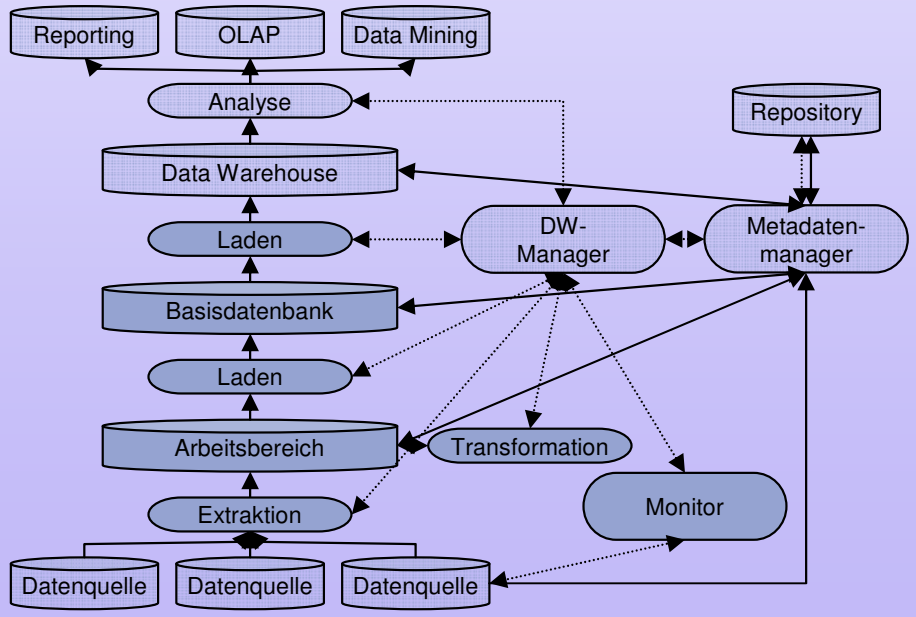

ETL-Prozess: Laden

- Laden von analyseunabhängigen Detaildaten in die Basisdatenbank
- Laden von analyseabhängigen Daten in das Data Warehouse

➔ Definition und Befüllen der Basistabellen

➔ Aufbau und Wartung von Indexstrukturen

➔ Anpassen abgeleiteter Sichten

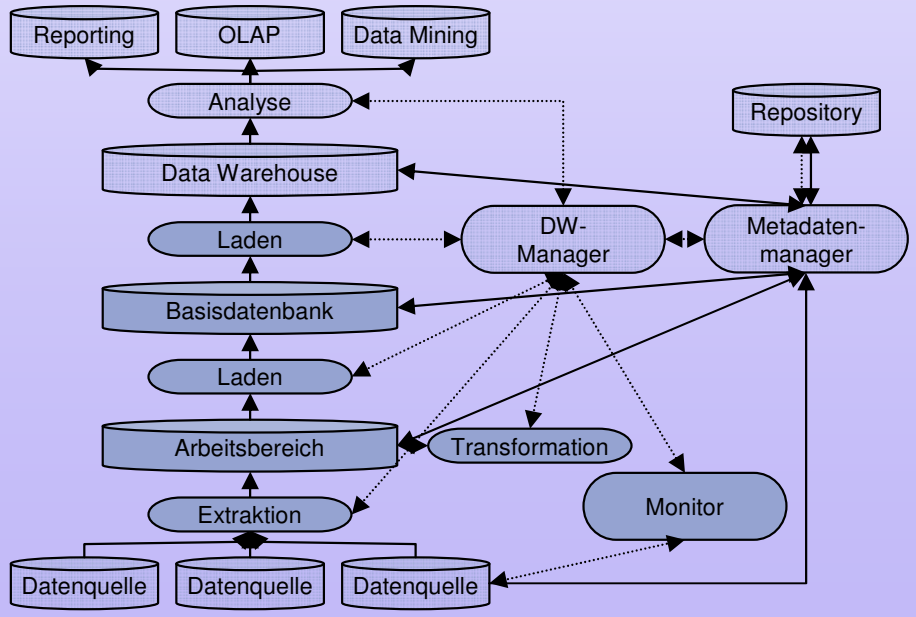

Basisdatenbank

- Eigenschaften
  - integrierte Sicht
  - umfassend bezüglich Zeit und Granularität
  - Modellierung und Optimierung anwendungsneutral
  - Daten werden nach definierter Zeit in ein Data Warehouse übertragen
  - Aktualisierung zu beliebigem Zeitpunkt möglich
  - Daten liegen bereinigt vor

- Funktion
  - Sammel- und Integrationsfunktion
    (logisch) zentrales Datenlager
  - Distributionsfunktion
    Versorgung aller Data Warehouses
  - Auswertungsfunktion
    Nur wenn direkt auf Basisdatenbank zugegriffen wird!

Basisdatenbank

- Nabe-Speiche-Architektur

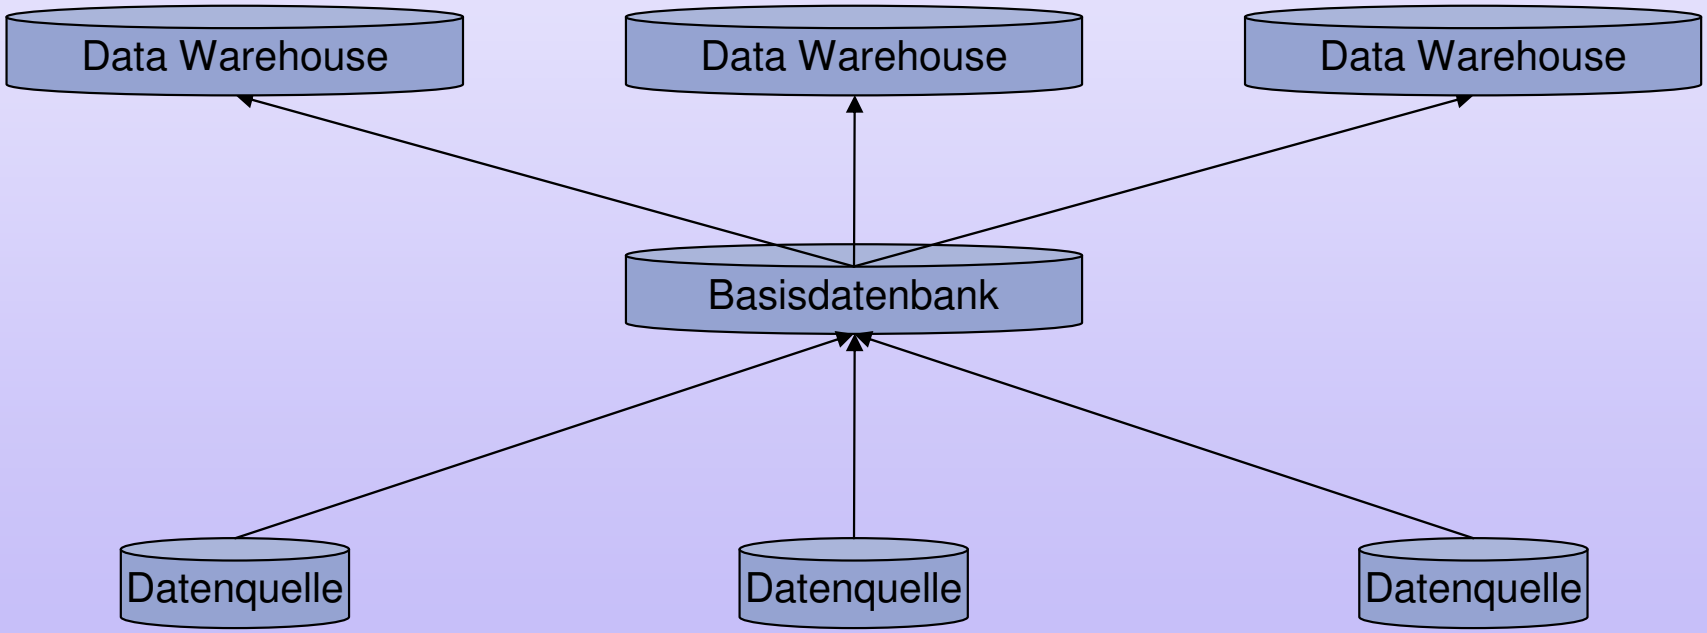

Data Warehouse

- Eigenschaften
  - Datenbank für Analysezwecke
  - Enthält alle für Analysezweck benötigten Daten
  - Strukturierung orientiert sich an Analysebedürfnissen
- Funktion
  - Unterstützung des Ladeprozesses
  - Unterstützung des Analyseprozesses

Data Warehouse und Data Mart

- Erfahrung:
  - Data-Warehouse-Projekte scheitern oft an ihrer Größe
  - Anwender brauchen oftmals keine Sicht auf das komplette Data Warehouse
- Daher oftmals auch sogenannte Data Marts:
  - „kleine Data Warehouses“ für überschaubaren Bereich
  - Entwicklung entweder
    - als Teilbestand eines bereits existierenden großen Data Warehouse oder
    - als erster Schritt hin zu einem integrierten unternehmensweiten Data Warehouse.

Aggregierung und Gruppierung

Durch Aggregierung und Gruppierung werden die einzelnen Sichten anwendergerecht verdichtet.

- Aufbereitung der Daten für verschiedene Nutzersichten
- Ableitung von Sichten verschiedener Granularität aus den Basisdaten

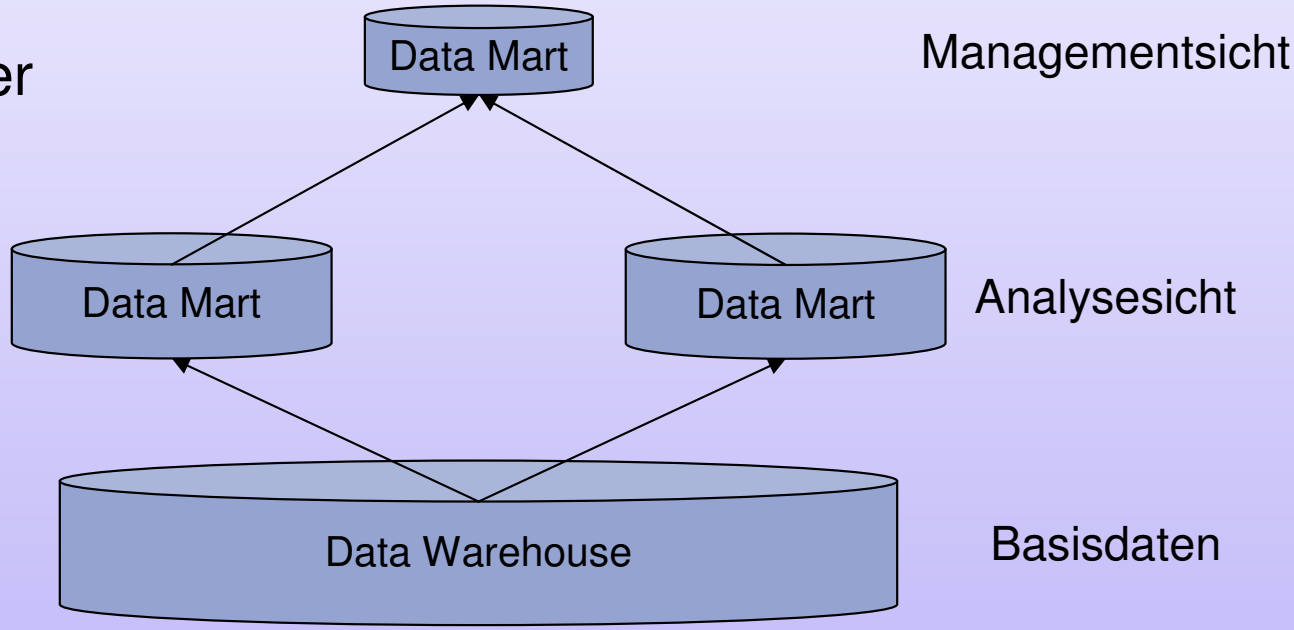

Data-Warehouse-Manager

- Zentrale Steuerung aller Data-Warehouse-Komponenten
  - Monitore
  - Extraktoren
  - Transformatoren
  - Ladekomponenten
  - Analysekomponenten
- Initiierung des Datenbeschaffungsprozesses
  - regelmäßige Zeitintervalle
  - von Datenänderungen abhängig
  - auf explizites Verlangen

Metadaten

- Metadaten sind Daten über Daten
- Wozu werden Metadaten benötigt?
- Welche Metadaten werden in einem Data-Warehouse-System benötigt?

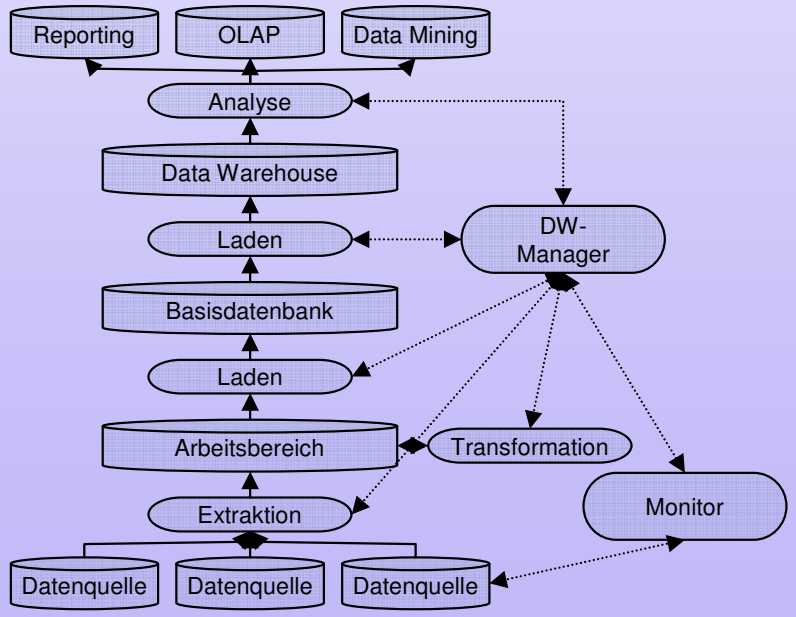

Metadaten

- Partnerarbeit:
  - **Variante A**
    Sie sind ab sofort für ein laufendes Data-Warehouse-System verantwortlich: Welche Informationen benötigen Sie? Woher bekommen Sie diese Informationen?
  - **Variante B**
    Sie waren für ein laufendes Data-Warehouse-System verantwortlich: Welche Informationen geben Sie bei der Übergabe Ihrem Nachfolger?
  - **Variante C**
    Sie sind der Vorgesetzte eines für ein Data-Warehouse-System verantwortlichen Mitarbeiters und haben schlechte Erfahrungen mit der Dokumentation gemacht: Welche Vorgaben geben Sie einem neuen Verantwortlichen bezüglich der Dokumentation des Data-Warehouse-Systems?

Metadaten sind wichtig!

- Historie
  - Warum wurde eine Entscheidung getroffen?
    - beim Aufbau,
    - bei der Erweiterung
    - beim Betrieb
- Unternehmen
  - Ansprechpartner
  - Datenqualität der Datenquellen
  - ...

Metadaten sind wichtig!

- Konzeptuelle Sicht
  - Anforderungen
    - Welche Anfragen möchten Analyseanwender stellen?
  - Terminologie
    - Einheitliche Begriffsdefinitionen: Welche Terminologie verwenden Analyseanwender?
  - ETL-Prozess
    - Welche Quelldaten werden benötigt?
    - Welche Transformationen werden benötigt?
  - Aggregierung
    - Wann werden welche Daten wie aggregiert?
    - Welche Aggregierungen sind erlaubt?

Metadaten sind wichtig!

- Logische Sicht
  - Schemata
    - Datenquellen, Basisdatenbank, Data Warehouse, Analyseanwendungen, …
  - Regeln
    - Transformationsregeln
    - Aggregierungsregeln
- Physische Sicht
  - Tabellen
  - Indexstrukturen
  - Sichten
  - Materialisierung
  - Partitionierung
  - …

Metadaten sind wichtig!

- Organisation
  - Wann werden Daten ins Data Warehouse geladen?
  - Welche Datenmengen sind zu verwalten bzw. zu laden?
  - Benutzergruppen, Zugriffsrechte
  - Backup-Strategie
  - Datensicherheit
  - Datenschutz
  - …

Metadatenmanager

- Der Metadatenmanager
  - sammelt alle Metadaten,
  - speichert Metadaten zentral im Repository,
  - arbeitet mit dem Data-Warehouse-Manager zusammen.

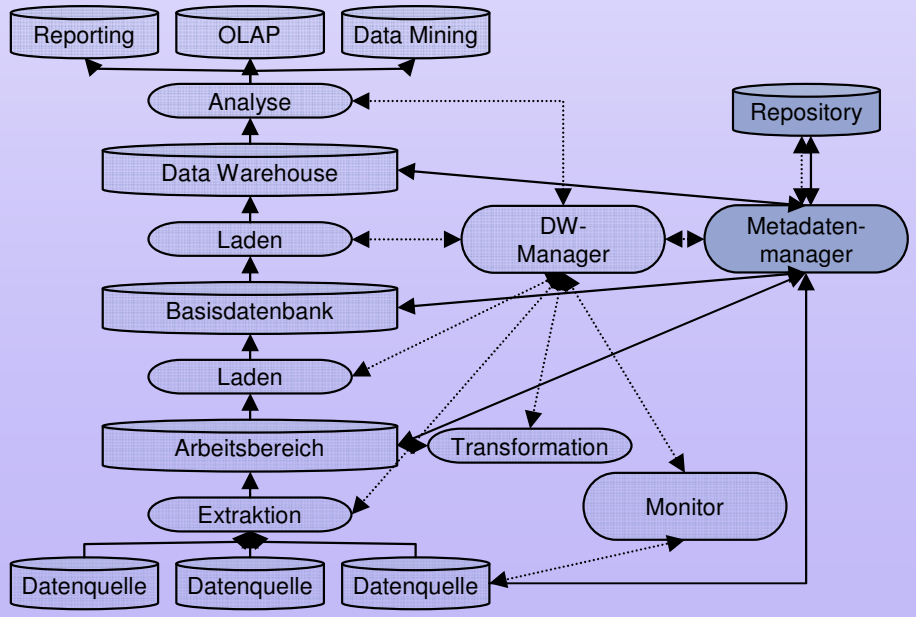

Analyseanwendungen

- Reporting
  - einfache, automatisch erzeugbare Berichte
- OLAP
  - aufwändige, automatisch erzeugbare Berichte mit Navigationsmöglichkeit
  - ➔ später
- Data Mining
  - Suche von Mustern in Daten
  - ➔ siehe Teil „Data Mining“

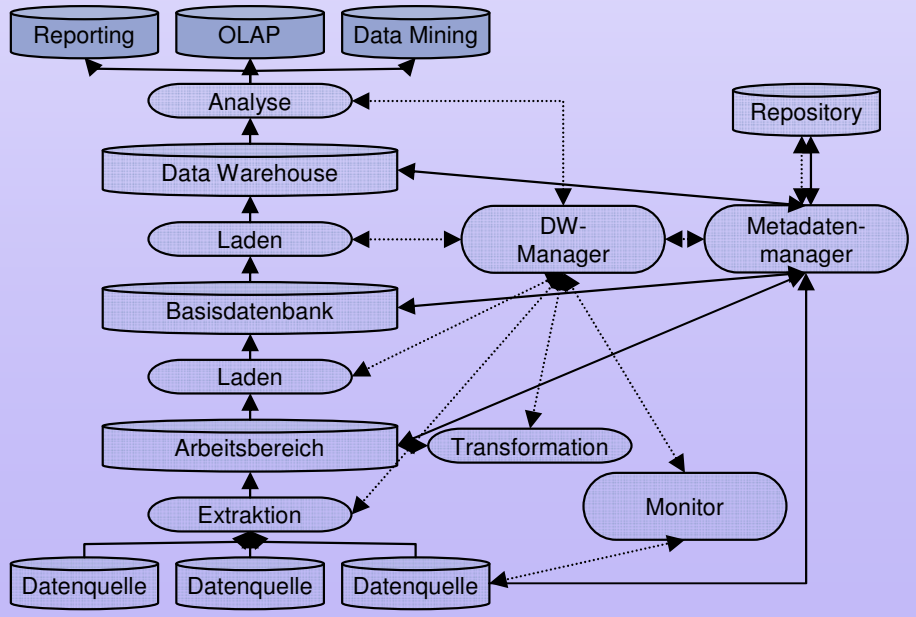

DW-Entwicklungszyklus

- Iterativer Prozess
  - Anfangs ist den Beteiligten das Potential eines DWS unklar.
  - ➔ Neue Anforderungen kommen erst bei laufendem Betrieb oder nach erstem Prototyp.
  - ➔ Qualität steigt durch **Anwender-Feedback**!
  - Aufbau eines DWS in einem einzigen Schritt besitzt hohe **Komplexität** und erfordert hohen **zeitlichen** und **personellen Aufwand**
  - Management oft erst nach ersten Ergebnissen zu überzeugen
  - ➔ besser erst vielversprechenstes Anwendungsgebiet aufbauen (positives Feedback)
  - ➔ sukzessive weitere Datenquellen integrieren und weitere Data Marts aufbauen
  - ➔ **„Think big, start small, grow step by step!“**

DW-Entwicklungszyklus

- Laufender Betrieb: Alles erledigt?
  - Nein!
  - Monitoring der DW-Benutzung
    - Welche Daten werden regelmäßig genutzt?
    - Wie schnell wächst der Datenbestand?
    - Wer benutzt das DW?
    - Sind die Antwortzeiten noch akzeptabel?
  - ... und natürlich sämtliche Veränderungen im Unternehmen im Auge behalten und gegebenenfalls reagieren ...

Literatur

- A. Bauer, H. Günzel: ***Data Warehouse Systeme***. Architektur, Entwicklung, Anwendung. dpunkt, 2001.
- W. Lehner: ***Datenbanktechnologie für Data-Warehouse-Systeme***. dpunkt, 2003.