

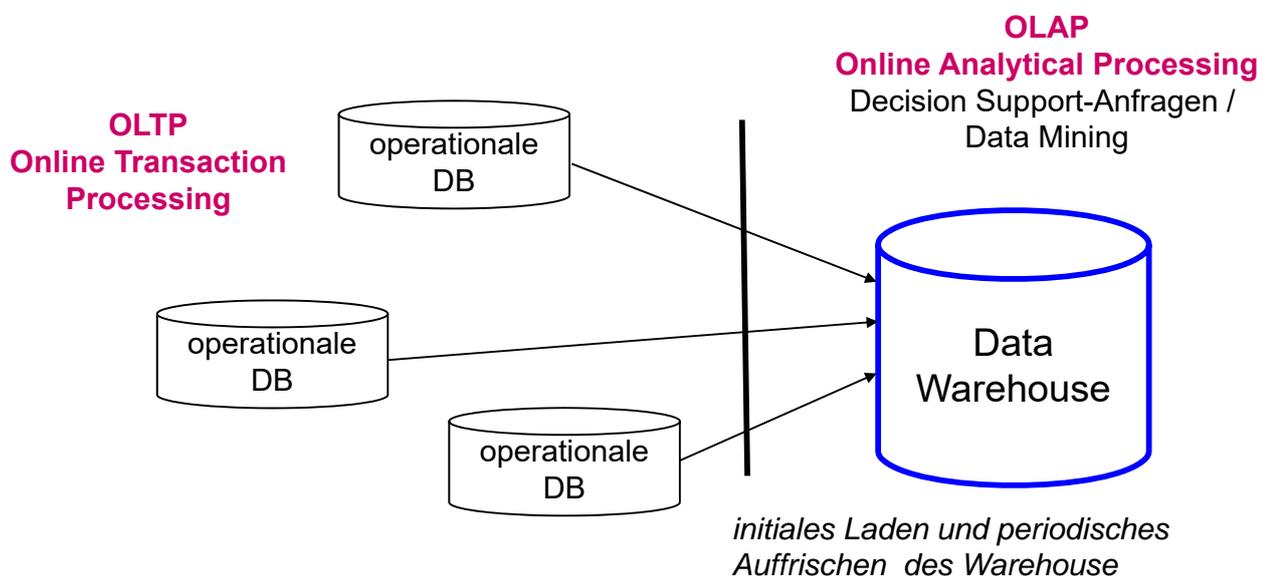
1. Data Warehouses - Einführung

- Definitionen und Merkmale
 - Grobdefinition
 - Einsatzbeispiele
 - DW-Merkmale nach Imnon
 - OLTP vs. OLAP
 - Grobarchitektur
 - virtuelle vs. physische Datenintegration
- Mehrdimensionale Datensicht
 - Stern-Schema und -Anfragen
- Analysearten (OLAP, Data Mining)
- Big Data

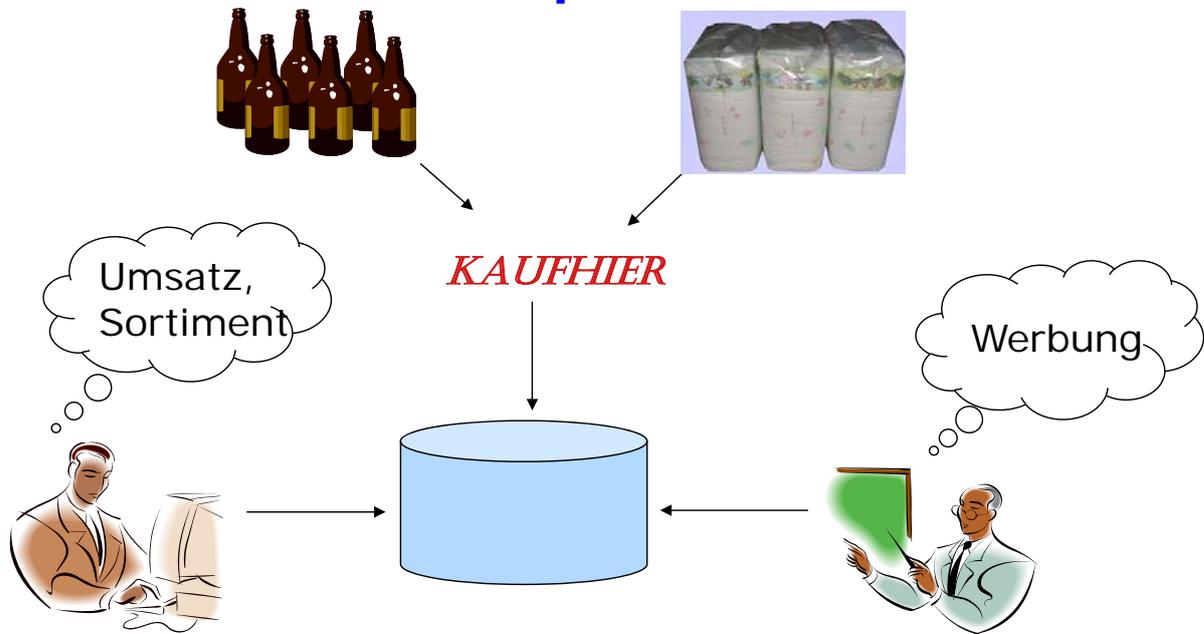


Data Warehouses

- Ausgangsproblem
 - viele Unternehmen haben Unmengen an Daten, ohne daraus ausreichend Informationen und Wissen für kritische Entscheidungsaufgaben ableiten zu können
- **Data Warehouse (Def.):** für Analysezwecke optimierte zentrale Datenbank, die Daten aus mehreren, i.a. heterogenen Quellen zusammenführt und verdichtet (Integration und Transformation)



Szenario: Supermarktkette



■ Anfragen:

- Wie viele Pakete Windeln wurden letzten Monat verkauft?
- Wie hat sich der Verkauf von Bier und Wasser im letzten Jahr entwickelt?
- Wo sind unsere Top-Filialen?
- Von welchem Lieferanten beziehen wir das meiste Bier?
- Wie wirkten sich die Werbepreise für Produkt X aus? ...



Einsatzbeispiele

■ Warenhauskette

- Verkaufszahlen und Lagerbestände aller Warenhäuser
- mehrdimensionale Analysen: Verkaufszahlen nach Produkten, Regionen, Warenhäusern
- Ermittlung von Kassenschlagern und Ladenhütern
- Analyse des Kaufverhaltens von Kunden (Warenkorbanalyse)
- Erfolgskontrolle von Marketing-Aktivitäten
- Minimierung von Beständen
- Optimierung der Produktpalette, Preisgestaltung •••

■ Versicherungsunternehmen

- Bewertung von Filialen, Vertriebsbereichen, Schadensverlauf, ...
- automatische Risikoanalyse
- schnellere Entscheidung über Kreditkarten, Lebensversicherung, Krankenversicherung ...

■ Banken, Versandhäuser, Restaurant-Ketten

■ wissenschaftliche Einsatzfälle •••

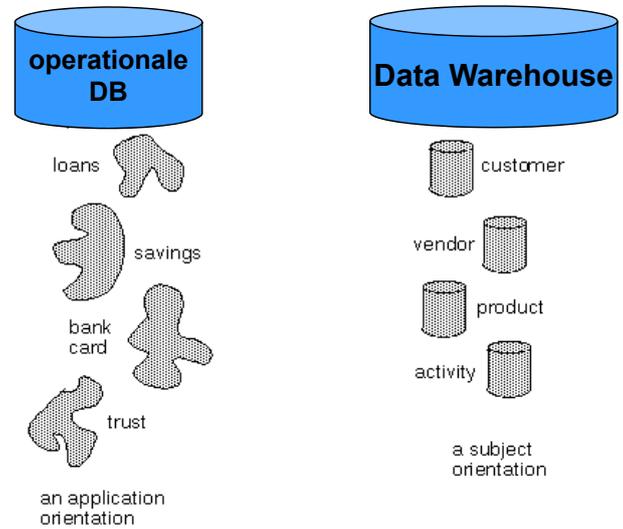


DW-Eigenschaften nach Inmon

A Data Warehouse is a *subject-oriented, integrated, non-volatile, and time variant* collection of data in support of management decisions (W. H. Inmon, *Building the Data Warehouse*, 1996)

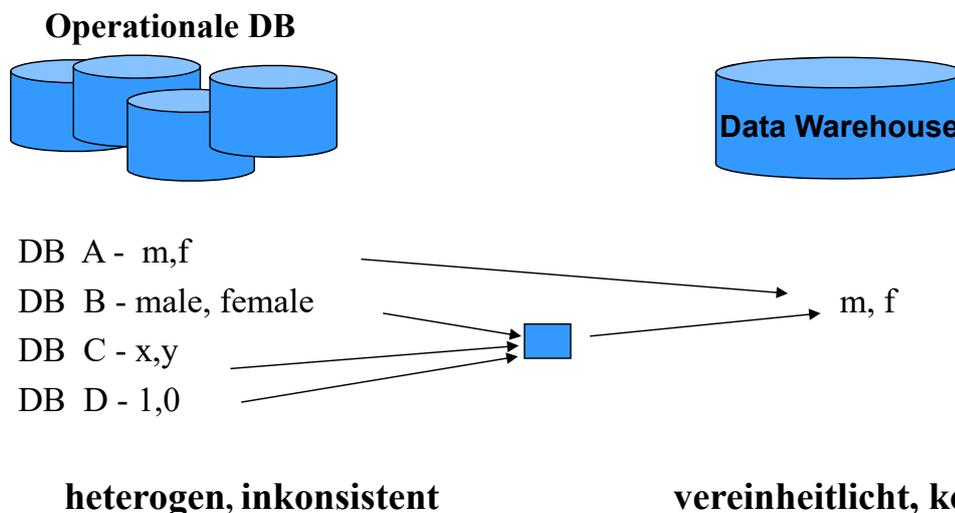
■ Subjekt-orientiert

- Zweck des Systems ist nicht Erfüllung einer dedizierten operationalen Aufgabe (z.B. Personaldatenverwaltung),
- alle Daten - unternehmensweit - über ein Subjekt (Kunden, Produkte, Regionen ...) und nicht „versteckt“ in verschiedenen Anwendungen
- Unterstützung übergreifender Auswertungsmöglichkeiten aus verschiedenen Perspektiven



DW-Eigenschaften nach Inmon (2)

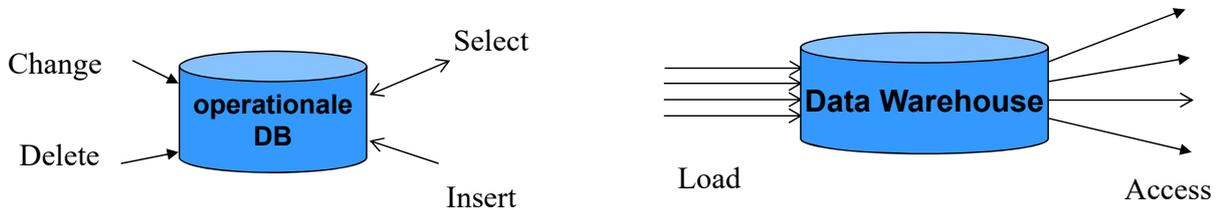
- integrierte Datenbasis (integrated): konsolidierte Daten aus mehreren verschiedenen Datenquellen



DW-Eigenschaften nach Inmon (3)

■ dauerhafte Datenbasis (non-volatile):

- Daten im DW werden i.a. nicht mehr geändert
- stabile, persistente Datenbasis



regelmäßige Änderungen von Sätzen



DW-Eigenschaften nach Inmon (4)

■ historische Daten (time-variant):

- Vergleich der Daten über Zeit möglich (Zeitreihenanalyse)
- Speicherung über längeren Zeitraum



aktuelle Datenwerte:

- Zeitbezug optional
- Zeithorizont: 60-90 Tage
- Daten änderbar



Schnappschuß-Daten

- Zeitbezug aller Objekte
- Zeithorizont: 2-10 Jahre
- keine Änderung nach Schnappschuß-Erstellung



Operationale Datenbanken vs. Data Warehouses (OLTP vs. OLAP)

	Operationale Datenbanken /OLTP	Data Warehouses/OLAP
<i>Entstehung</i>	für je eine Applikation / eine Perspektive	mehrere Perspektiven / anwendungs- übergreifend
<i>Bedeutung</i>	Tagesgeschäft	Entscheidungs-/Planungsaufgaben
<i>Nutzer</i>	Sachbearbeiter, Online-Nutzer	Analysten / Manager
<i>Datenzugriff</i>	sehr häufiger Zugriff, kleine Datenmengen pro Operation, Lesen, Schreiben, Modifizieren, Löschen	moderate Zugriffsfrequenz, große Datenmengen, vorwiegend lesender Zugriff
<i>Änderungen</i>	sehr häufig	periodisches Auffrischen
<i>#Datenquellen</i>	meist eine pro Anwendung	mehrere
<i>Datenmerkmale</i>	nicht abgeleitet, autonom, zeitaktuell, dynamisch	abgeleitet, integriert, i.a. leicht veraltet, stabil
<i>Optimierungsziele</i>	hoher Durchsatz, sehr kurze Antwortzeiten (ms .. s), hohe Verfügbarkeit	gute Antwortzeiten für komplexe Analysen

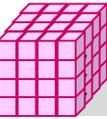
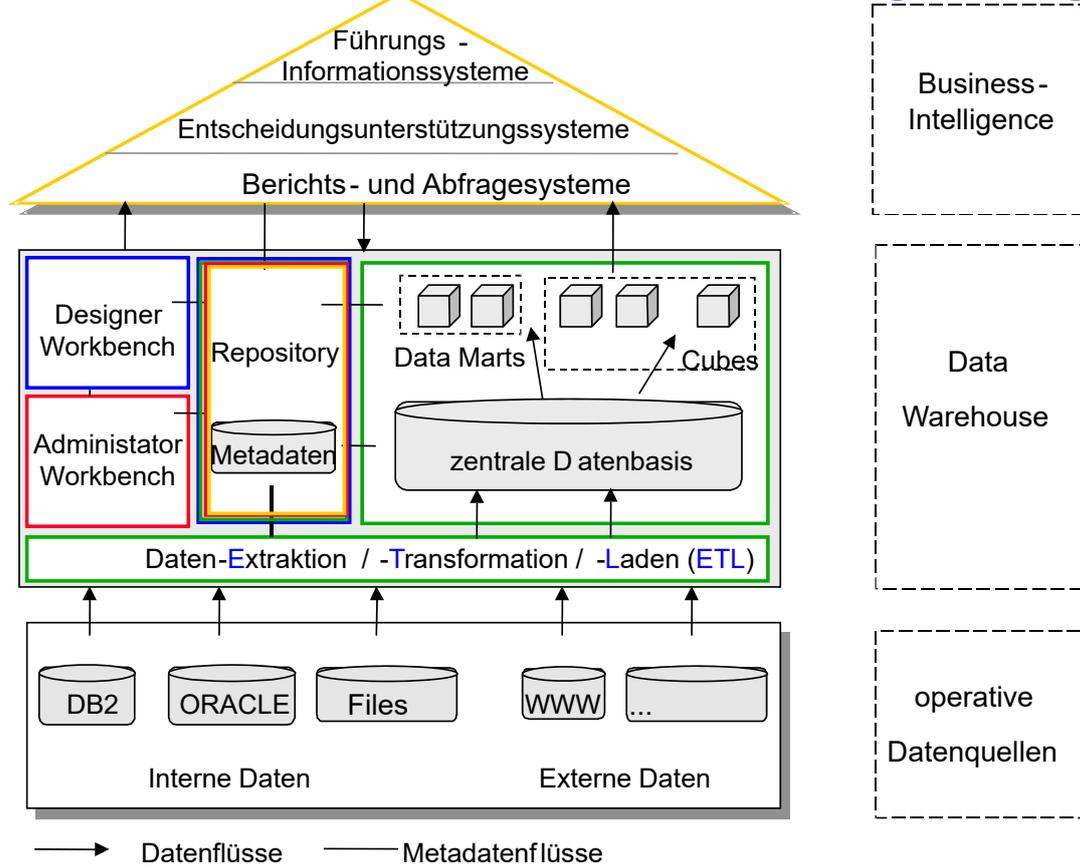


Warum separates Data Warehouse?

- unterschiedliche Nutzung und Datenstrukturierung
- unterschiedliche Funktionalität
 - historische Daten
 - Konsolidierung (Integration, Bereinigung und Aggregation) von Daten aus heterogenen Datenquellen
- Performance
 - OLTP optimiert für kurze Transaktionen und bekannte Lastprofile
 - komplexe OLAP-Anfragen würden gleichzeitige OLTP-Transaktionen ausbremsen
 - OLAP erfordert speziellen logischen / physischen DB-Entwurf für mehrdimensionale Anfragen
 - Transaktionseigenschaften (ACID) für OLAP weniger wichtig
- Sicherheit
- Nachteile der separaten Lösung
 - Datenredundanz
 - Daten nicht vollständig aktuell
 - hoher Administrationsaufwand
 - hohe Kosten

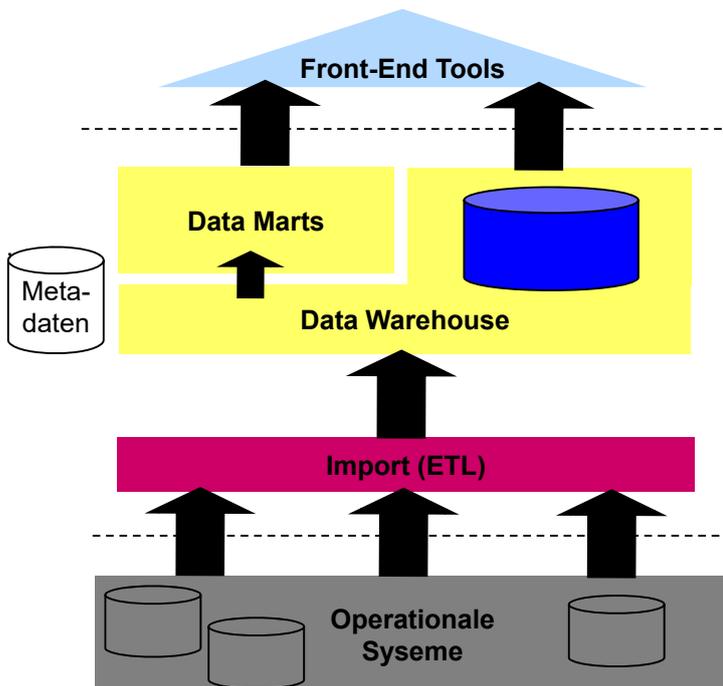


Grobarchitektur einer DW-Umgebung

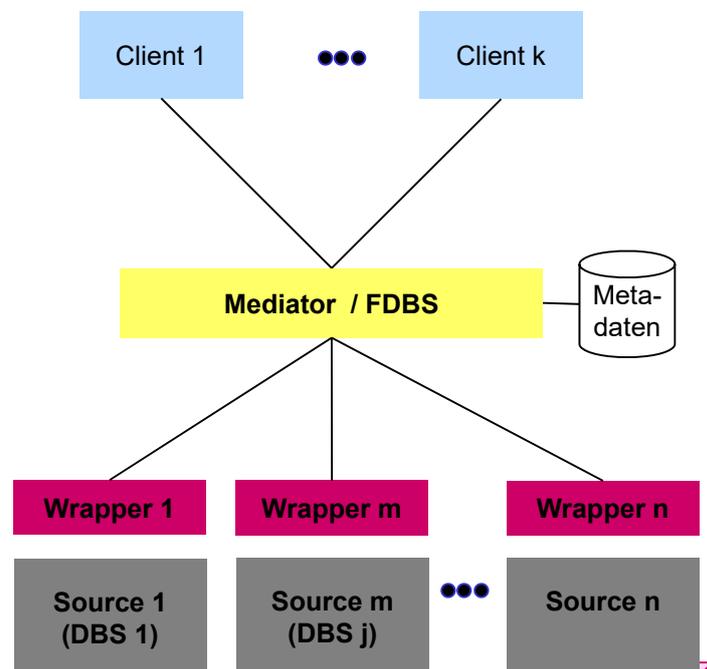


Datenintegration: physisch vs. virtuell

Physische (Vor-) Integration (Data Warehousing)



Virtuelle Integration (Mediator/Wrapper-Architekturen, föderierte DBS)



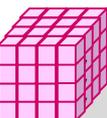
Datenintegration: physisch vs. virtuell (2)

	physisch (Data Warehouse)	virtuell
Integrationszeitpunkt: Metadaten	vorab (DW-Schema)	vorab (globale Sicht)
Integrationszeitpunkt: Daten	vorab	dynamisch (zur Anfragezeit)
Aktualität der Daten		
Autonomie der Datenquellen		
Erreichbare Datenqualität		
Analysezeitbedarf für große Datenmengen		
Hardwareaufwand		
Skalierbarkeit auf viele Datenquellen		

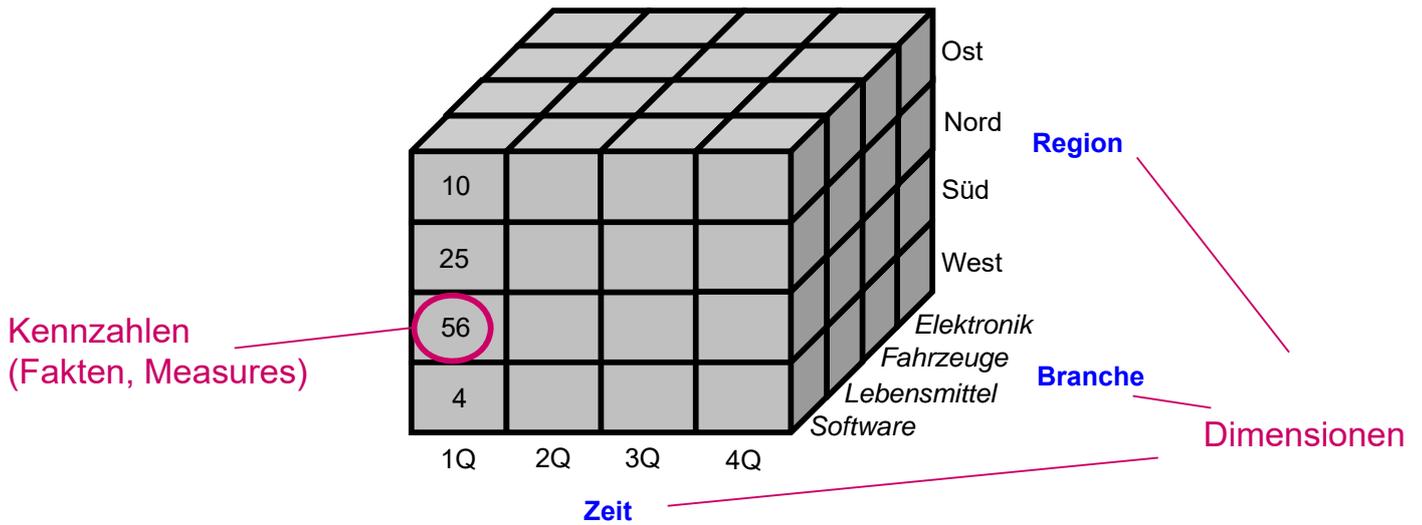


OLAP (Online Analytical Processing)

- interaktive multidimensionale Analyse auf konsolidierten Unternehmensdaten
- **FASMI**-Merkmale (Fast Analysis of Shared Multidimensional Information)
 - Skalierbarkeit auf große Datenmengen
 - stabile, volumenunabhängige Antwortzeiten
 - intuitive, interaktive Analyse und Visualisierung
 - Mehrbenutzerunterstützung
 - Client/Server-Architektur
 - mehrdimensionale, konzeptionelle Sicht auf die Daten
 - unbegrenzte Anzahl an Dimensionen und Aggregationsebenen
 - unbeschränkte dimensionsübergreifende Operationen
 - integrierter Zugang zu heterogenen Datenbeständen mit logischer Gesamtsicht



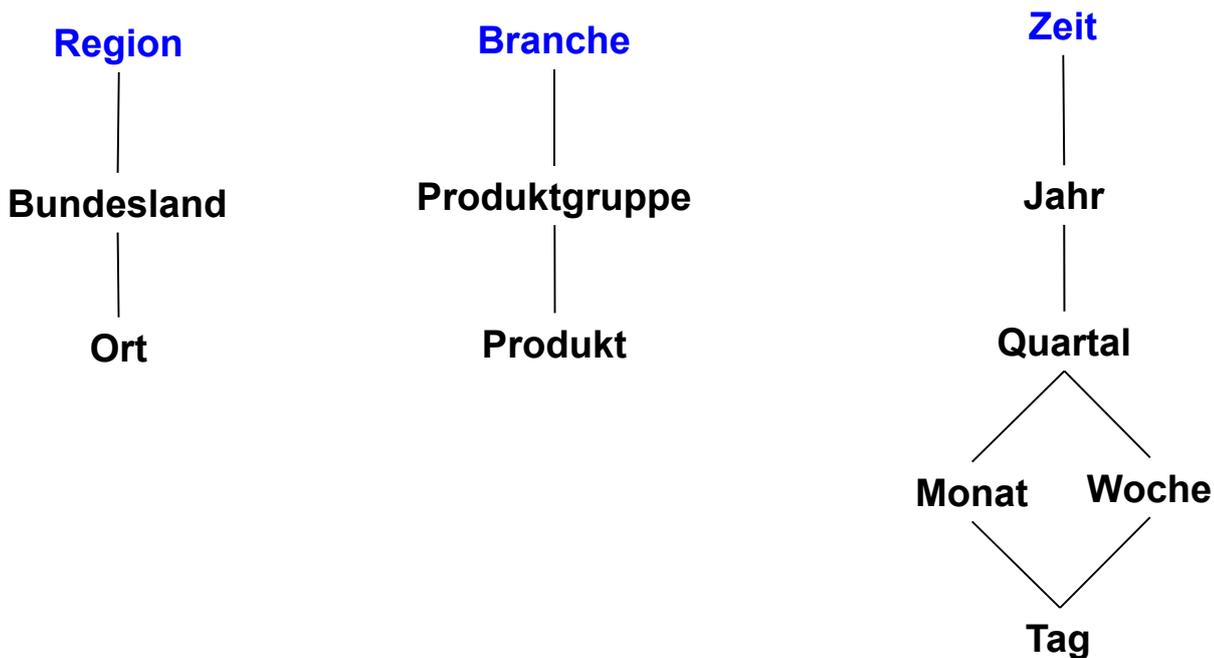
Mehrdimensionale Datensicht



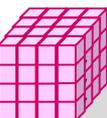
- Kennzahlen: numerische Werte als Grundlage für Aggregationen/Berechnungen (z.B. Absatzzahlen, Umsatz, etc.)
- Dimensionen: beschreibende Eigenschaften
- Operationen:
 - Aggregation der Kennzahlen über eine oder mehrere Dimension(en)
 - Slicing and Dicing: Bereichseinschränkungen auf Dimensionen



Hierarchische Dimensionierung

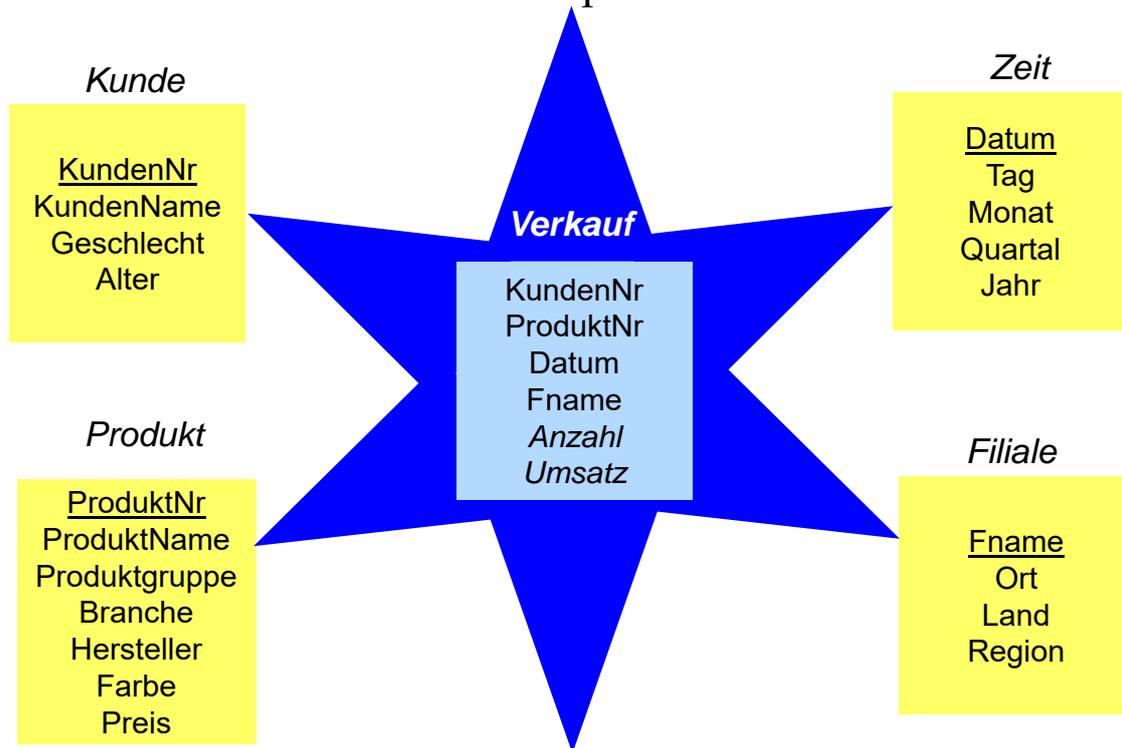


- Operationen zum Wechsel der Dimensionsebenen
 - Drill-Down
 - Roll-Up



Star-Schema

- zentrale **Faktentabelle** sowie 1 Tabelle pro Dimension



Anfragen

Beispielanfrage:

Welche Auto-Hersteller wurden von weiblichen Kunden in Sachsen im 1. Quartal favorisiert?

```
select p.Hersteller, sum (v.Anzahl)
from Verkauf v, Filialen f, Produkt p, Zeit z, Kunden k
where z.Quartal = 1 and k.Geschlecht = 'W' and
      p.Produkttyp = 'Auto' and f.Land = 'Sachsen' and
      v.Datum = z.Datum and v.ProduktNr = p.ProduktNr and
      v.Filiale = f.FName and v.KundenNr = k.KundenNr
group by p.Hersteller
order by 2 desc;
```

■ Star-Join

- sternförmiger Join der (relevanten) Dimensionstabellen mit der Faktentabelle
- Einschränkung der Dimensionen
- Verdichtung der Kennzahlen durch Gruppierung und Aggregation



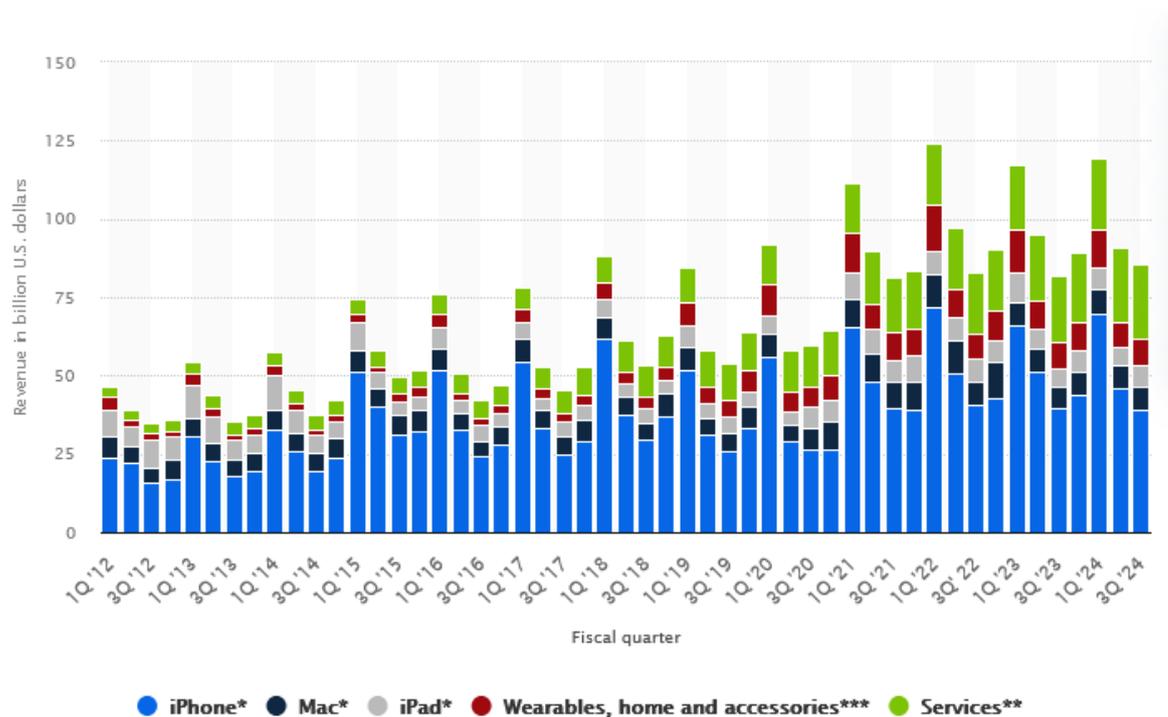
Analysewerkzeuge

- (Ad Hoc-) Query-Tools
- Reporting-Werkzeuge, Berichte mit flexiblen Formatierungsmöglichkeiten
- OLAP-Tools
 - OLAP-Unterstützung in Spreadsheet-Tools bzw. im Web-Browser
 - oft Datendarstellung als Pivot-Tabellen (Kreuztabellen)
 - interaktive mehrdimensionale Analyse und Navigation (Drill Down, Roll Up, ...)
 - Gruppierungen, statistische Berechnungen,
 - unterschiedlichste Visualisierungen
- Tools/Verfahren für Data Mining und maschinelles Lernen



Beispiel: OLAP-Ausgabe

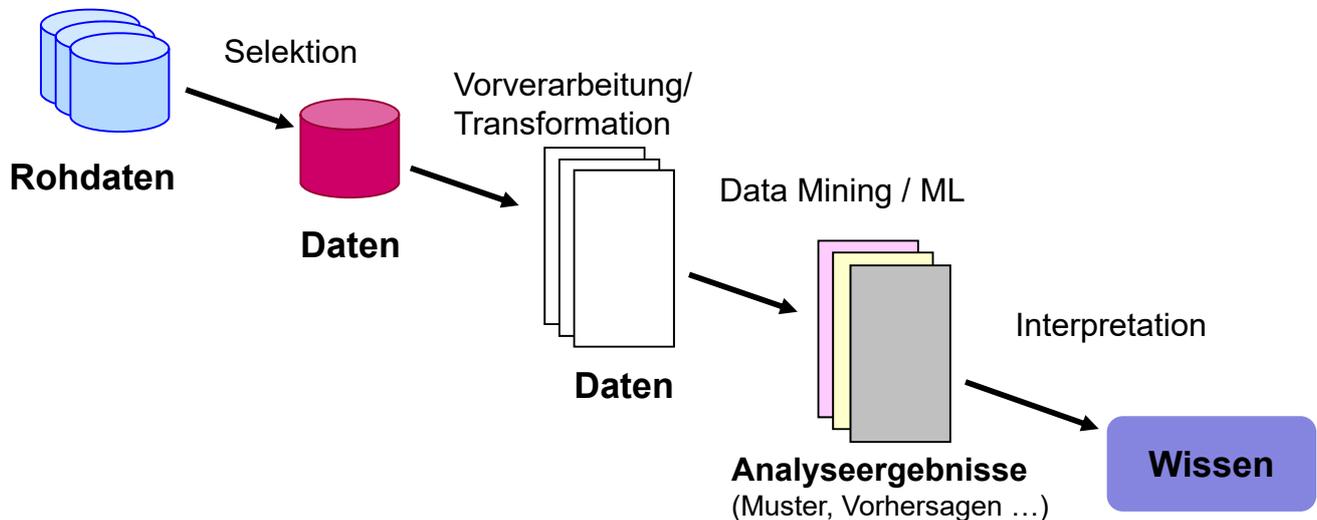
Apple quarterly revenue by operating segment (source: Statista)





Knowledge Discovery

- (semi-) automatische Extraktion von Wissen aus Daten
- Kombination von Verfahren zu Datenbanken, Statistik (Data Mining) und KI (maschinelles Lernen)

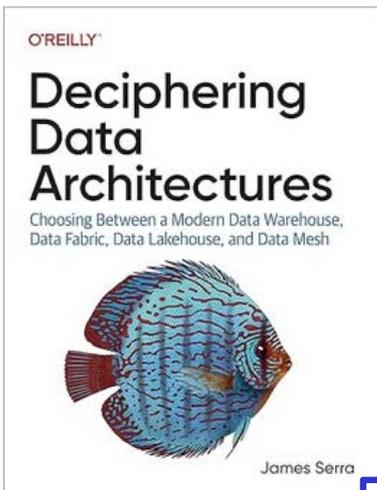


Techniken des Data Mining/ML

- Einsatz statistischer, wissens- und lernbasierter Methoden zur Datenanalyse
 - Auffinden von Korrelationen, Mustern und Trends in Daten, Vorhersagen
- Clusteranalyse
 - Objekte werden aufgrund von Ähnlichkeiten in Klassen eingeteilt (Segmentierung)
 - Bsp.: ähnliche Kunden, ähnliche Website-Nutzer ...
- Assoziationsregeln
 - Warenkorbanalyse (z.B. Kunde kauft A und B => Kunde kauft C)
 - Nutzung für Kaufvorhersagen / Recommendations, ...
- Klassifikation
 - Zuordnung von Objekten zu Gruppen/Klassen mit gemeinsamen Eigenschaften bzw. Vorhersage von Attributwerten
 - Verwendung von Stichproben (Trainingsdaten)
 - Ansätze: Entscheidungsbaum-Verfahren, neuronale Netze, statistische Auswertungen



Beispiel Warenkorbanalyse



Deciphering Data Architectures: Choosing Between a Modern Data Warehouse, Data Fabric, Data Lakehouse, and Data Mesh Taschenbuch – 12.

März 2024
Englisch Ausgabe von James Serra (Autor)
4,4 ★★★★★ 61 Sternebewertungen

Data fabric, data lakehouse, and data mesh have solid benefits, but this book provides a guided tour of these architectures.

James Serra, big data and data warehousing expert, helps you understand how data warehouses have had to evolve to help you achieve, as well as how to distinguish between appropriate data architecture for your needs. You will:

- Gain a working understanding of several data architectures
- Learn the strengths and weaknesses of each approach
- Distinguish data architecture theory from reality

Wird oft zusammen gekauft

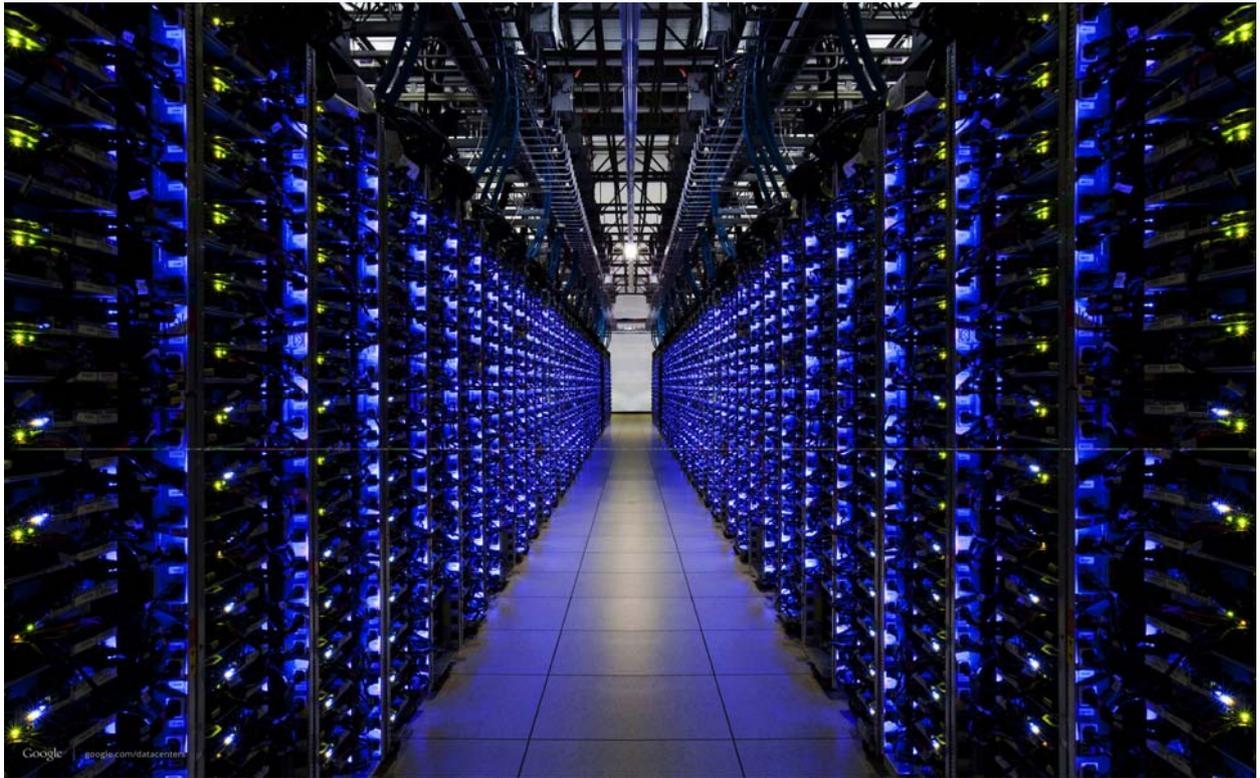
	+		+	
Dieser Artikel: Deciphering Data Architectures: Choosing Between a Modern Data Warehouse, Data...		Data Management at Scale: Modern Data Architecture with Data Mesh and Data Fabric		Fundamentals of Data Engineering: Plan and Build Robust Data Systems
54,99 €		51,99 €		46,64 €

Kunden, die diesen Artikel angesehen haben, haben auch angesehen

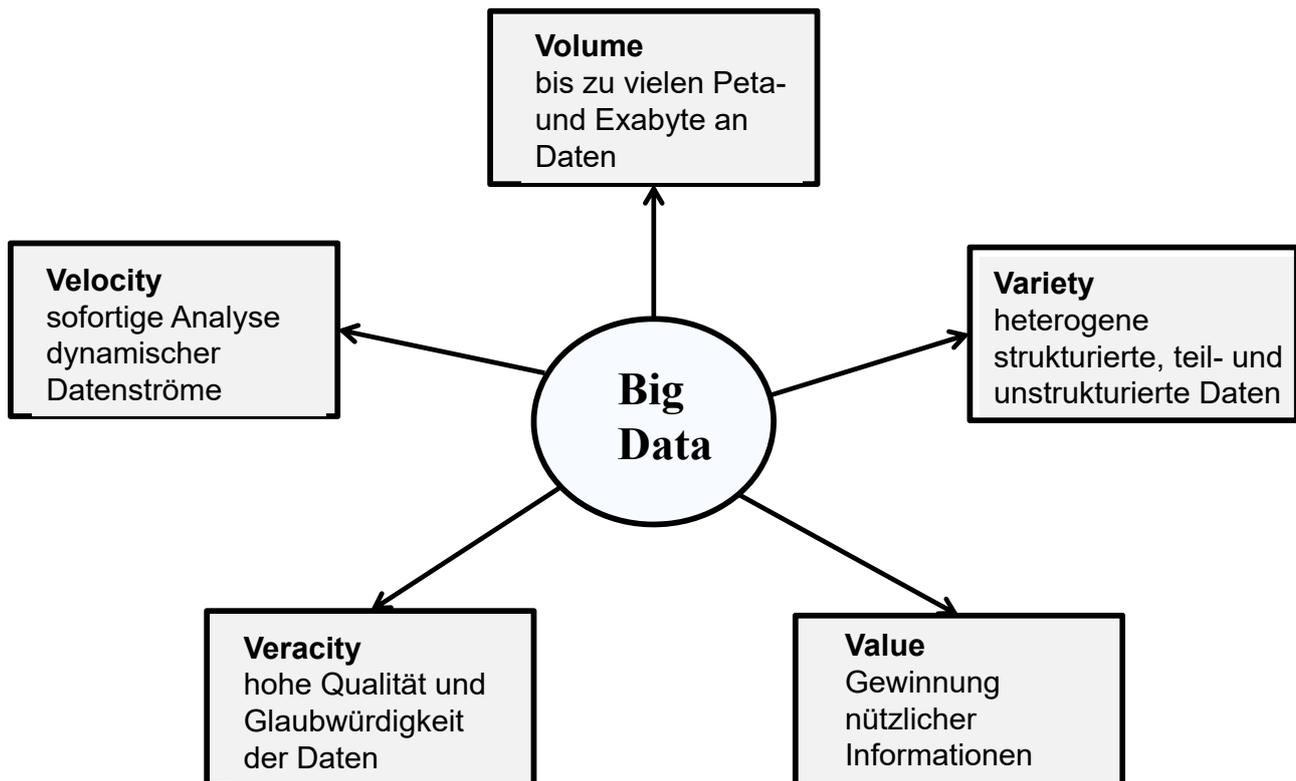
Data Management at Scale: Modern Data Architecture with Data Mesh and Data Fabric	Architecting Data and Machine Learning Platforms: Enable Analysis and AI Governance in the Cloud	Fundamentals of Data Engineering: Plan and Build Robust Data Systems
› Piethen Strengholt	› Marco Tranquillin	› Joe Reis



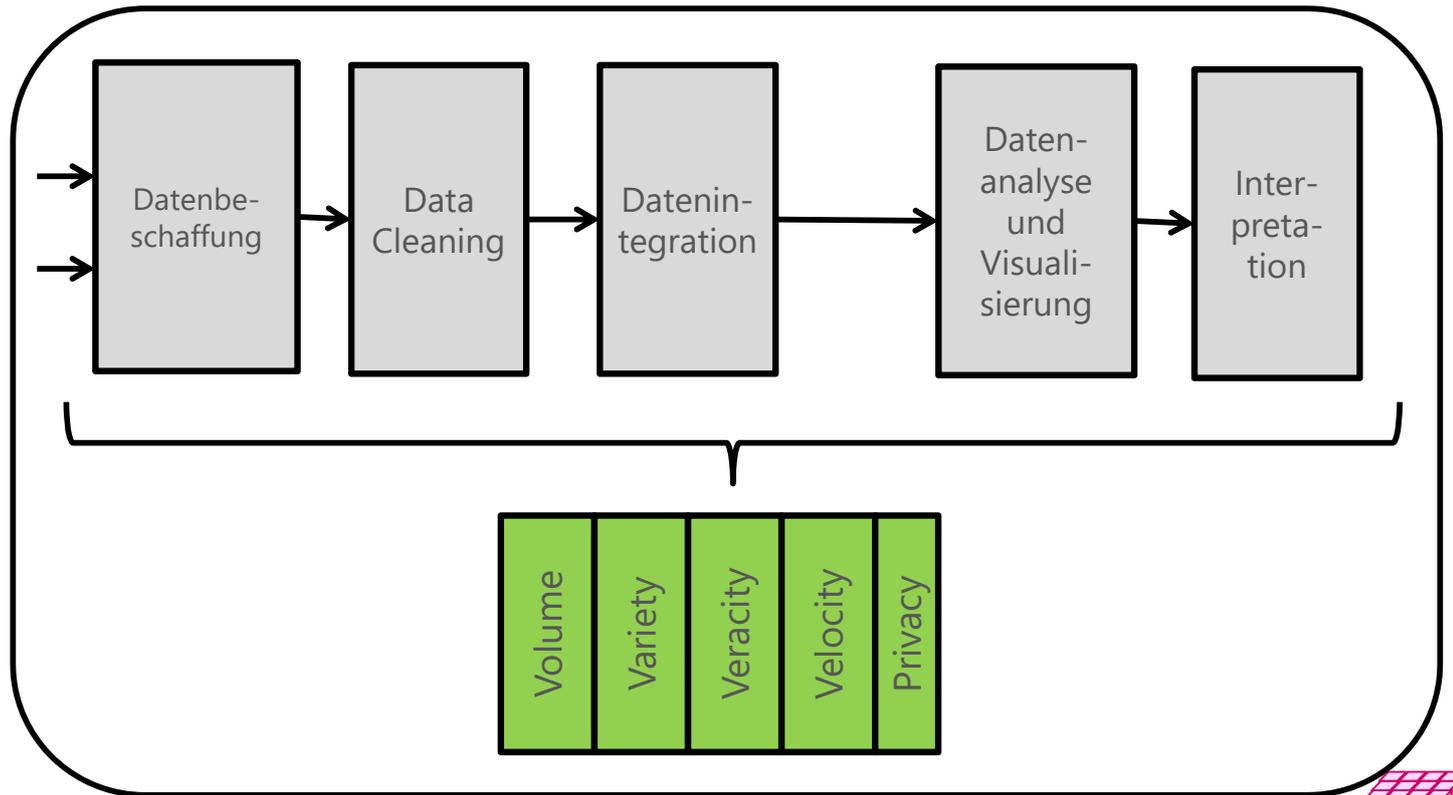
Big Data



Anforderungen für „Big Data“



Big Data Analyse-Pipeline



Zusammenfassung

- Data Warehousing: DB-Anfrageverarbeitung und Analysen auf integriertem Datenbestand für Decision Support (OLAP)
- riesige Datenvolumina
- Hauptschwierigkeit: Integration heterogener Datenbestände sowie Bereinigung von Primärdaten
- physische Datenintegration ermöglicht
 - aufwändige Datenbereinigung
 - effiziente Analyse auf großen Datenmengen
- mehrdimensionale Datenmodellierung und -organisation
- breites Spektrum an Auswertungs- und Analysemöglichkeiten
- Data Mining: selbständiges Aufspüren relevanter Muster in Daten
- Big Data: Datenanalysen auf großen Mengen auch unstrukturierter Daten

