

Digital Innovation Hub Süd

Big Data Technologies

Wilhelm Zugaj, Joachim Schauer (IIT/FH JOANNEUM)



Das Land
Steiermark

LAND  KÄRNTEN

Agenda

- | | |
|---|------------|
| - Einführung in Big Data & Distributed Storage (Hadoop) | 40 Minuten |
| - Fragen & Pause | 15 Minuten |
| - Verteilte Datenbanksysteme (NoSQL) | 40 Minuten |
| - Fragen & Pause | 15 Minuten |
| - Data Analytics & Machine Learning | 40 Minuten |
| - Diskussion & Fragen | 30 Minuten |

Big Data: Einführung



Das Land
Steiermark

LAND  KÄRNTEN

Globales Datenwachstum


Typische Treiber:

- Cloud
- IOT
- Sensoren
- Smart meters
- Social Networks
- Online Shopping
- Mobile

Figure 1

Data is growing at a 40 percent compound annual rate, reaching nearly 45 ZB by 2020

Data in zettabytes (ZB)




Source: Oracle, 2012

http://www.atkearney.com/strategic-it/ideas-insights/article/-/asset_publisher/LCcgOeS4t85g/content/big-data-and-the-creative-destruction-of-today-s-business-models/10192

Definition Big Data

- Es gibt keine einheitliche Definition
- Wird beschrieben durch die 3-9 V's:
 - Volume
 - Velocity
 - Variability





<http://www.zarantech.com/blog/the-4-vs-of-big-data/>

- Validity
- Value
- Variety
- Velocity
- Veracity
- Viability
- Visibility
- Volatility
- Volume

Definitionsversuche

SAS

Big data is a term that describes the large volume of data – both structured and unstructured – that inundates a business on a day-to-day basis. But it's not the amount of data that's important. It's what organizations do with the data that matters. Big data can be analyzed for insights that lead to better decisions and strategic business moves.

NIST

Big data is data which “exceed(s) the capacity or capability of current or conventional methods and systems.”

Ward/Barker University of St. Andrews

“Big data is a term describing the storage and analysis of large and or complex data sets using a series of techniques including, but not limited to: NoSQL, MapReduce and machine learning.”

Big Data ist ein Paradigmenwechsel: Technologien & Methoden

- Storage Systems
 - alt: Centralized local Storage & Relational Database Systems
 - neu: Distributed remote Storage & NoSQL Database Systems
- Processing
 - alt: Single Transaction Processing
 - neu: Parallel Data Processing
- Analytics
 - alt: Statistische Datenanalyse
 - neu: Machine Learning Algorithms


Data Warehouse vs. Data Lake

Data Warehouse	Data Lake
Kontrolle	Flexibilität
Persistieren bereits transformierter Daten	Daten werden unverändert persistiert und beim Auslesen transformiert
Strukturiert	Unstrukturiert
Hoher Kostenaufwand bei großer Datenmenge	Konzipiert für günstige Hardware (horizontale Skalierbarkeit)
Eingeschränkte Flexibilität der Konfiguration	Konfiguration ist flexibel

SQL vs NoSQL

SQL		NoSQL
Relational	Schema	Keines/Flexibel
Strukturiert	Daten	Unstrukturiert Semi-strukturiert Strukturiert
Vertikal	Skalierbarkeit	Horizontal
Fixes Schema	Flexibilität	Flexibles Schema
SQL	Abfrage	Nicht standardisiert, Parallel (Map-Reduce)
ACID	Modell	Eventual Consistency/CAP Theorem

Hauptkategorien von NoSQL Datenbanksystemen



Scalability: Scale Out vs. Scale Up




Image Credit: DataJobs.com


Stapelverarbeitung

- Daten ersistiert
- Keine Echtzeitanforderung
 - Hohe Latenz
- Beispiel:
Kundenanalyse



Datenstromverarbeitung

- Ereignisse in Echtzeit
 - Zeitreihen
- Echtzeitanforderung
 - Geringe Latenz
- Beispiel:
Sensordaten einer
Produktionsanlage




http://www.bfe-inf.org/sites/default/files/data-curve-stream-for-earthcube-01_0.png


Lambda Architektur

Kombiniert Vorteile von
Batch & Stream Processing

- Balance zwischen
 - Latenz
 - Durchsatz
 - Fehlertoleranz



Big Data Analytics



Anwendungsgebiete von Big Data

1. Konsumentenverhalten verstehen und vorhersagen

- Ziel: 360° Sicht auf Kunden --> Zielgerichtete Werbung schalten
- Kunden und deren Verhalten besser verstehen und vorhersagen
- Ziel: ein möglichst vollständiges Profil der Kunden
- Risiko: Persönlichkeitsschutz

Beispiel: Target

- Jeder Target Kunde bekommt eine ID
 - Alle Einkäufe werden zum Kunden verlinkt
- Einkaufsmuster von Kunden werden analysiert
- Produkte identifiziert, die Schwangere vermehrt vor der Geburt kaufen
- Bier - Windel Korrelation
- Ziel: Gezieltes senden von Werbung, passend zum Kunden.



NETFLIX

- Big Data Analyse:
 - Welche Inhalte wollen Kunden sehen?
 - Wer sieht welche Inhalte und wie präsent sind diese in Sozialen Medien?
- Ziel: Mit hoher Gewissheit Kundenwünsche vorhersagen

2. Geschäftsprozesse verstehen und optimieren

- Warenlager anpassen, basierend auf:
 - Daten aus Sozialen Medien
 - Web search trends
 - Wettervorhersagen

Beispiel: Sendungsverfolgung



- "Delivery Route Optimisation"
 - Analyse von Echtzeit-Verkehrsdaten, Wetterdaten, GPS Position, ...
 - Ziel: Lieferungen möglichst schnell zustellen

3. Quantified Self

- Big Data für den persönlichen Nutzen
- Daten werden von tragbaren Geräten erzeugt
 - Smartwatch / Wearables
 - Kalorienverbrauch, Aktivität, Schlafmuster
- Most online dating sites apply big data tools and algorithms to find us the most appropriate matches

4. Gesundheitsversorgung

- Gesammelte Daten von Smartphones und Wearables bereitstellen
- Ziel: (Medizinische) Daten nutzen um
 - Epidemien vorherzusagen
 - Krankheiten zu heilen
 - Lebensqualität erhöhen

Beispiel: Google

- Von 2008 – 2014: "Google Flu Trends"
- Datenerhebung:
 - Abgleich von Suchbegriffen mit realen Krankheitsdaten
 - Identifizieren von Suchbegriffen, die mit Grippe korrelieren
- Ziel: Vorhersagen von Epidemien
- Problem: Vorhersagen zu oft unpräzise

5. Performance-Optimierung

- Idee: Maschinen und Geräte "smarter" bzw. autonom machen
- Beispiel: Einsatz von Kameras, GPS und Sensoren für das selbstfahrende Auto




Distributed Storage Beispiel: Hadoop



Das Land
Steiermark

LAND  KÄRNTEN

Technologietreiber: Cloud-Systeme



Grundidee Cloud

IT-Infrastruktur

ERP ←


CRM ←

BA/BI ←


Office ←

Entwicklungsinfrastr. ←

Infrastruktur extern





Cloud Service Models






HDFS (Hadoop File System): Idee



Lösung: Simultanes Lesen von vielen Disks
~ 30 Disks -> 1 TB in 5 Min

Problem: Ausfallgefahr bei hoher Diskzahl

HDFS - Grobe Architektur




NameNode:

- Regelt Zugang zu DataNode
- Überwacht und Verwaltet DataNodes
- Öffnen, schließen, umbenennen von Dateien und Verzeichnissen

DataNode:

- Führt Lese/Schreibbefehle durch


HDFS - Details: Blöcke - Sharding - Replikation



Zusammenfassung: Blöcke - Sharding - Replikation

- HDFS Dateien bestehen aus mehreren Blöcken.
- Standardgröße der Blöcke ist 128 MB.
- Die Blöcke einer HDFS-Datei werden auf unterschiedlichen Datenknoten gespeichert
- Die Blöcke werden zusätzlich auf weitere Knoten repliziert
- Standardreplikationsfaktor ist 3

HDFS Lese/Schreib-Zugriff:





HDFS Write: Replikation

Client wartet
auf Rückmeldung




Datenknoten
replizieren
die neuen
Datenblöcke




HDFS - Skalierbarkeit

Neue Nodes können in bestehenden
Cluster ohne Downtime integriert werden




HDFS Cluster Rebalancing

Datanode2 ist deutlich mehr belegt, als die anderen Datanodes.



Verschiebung
von Blöcken
vereinbart





HDFS Cluster Rebalancing

Datanode2 ist deutlich mehr belegt, als die anderen Datanodes.



Verschiebung wird durchgeführt!



HDFS-Datei



HDFS: Partition-Tolerance



Primärkontakt ist immer ein Namenode.

Ausfall des Namenodes: wäre Systemausfall!



HDFS: Availability

Ausfall von Datenknoten:
kann je nach Replikationsfaktor verkräftet werden




HDFS: Consistency

Alle Blöcke sind im Regelbetrieb
garantiert auf demselben Versionsstand




HDFS-Datei



Name Node
Duplikat



Getrennt Datanodes
werden als tot markiert.



Netzwerkpartition

HDFS Consistency: Auto-Replikation

Durch Netzwerkpartition fehlende Blöcke werden automatisch repliziert!




Getrennte Datanodes

wurden als tot markiert.

Netzwerkpartition

Hadoop/HDFS: Distributed Computing (Map-Reduce)



Verteilung der Berechnung auf viele Nodes

Fragen & Pause



Das Land
Steiermark

LAND  KÄRNTEN