

DATA SCIENCE 2

VORLESUNG - BIG DATA


PROF. DR. CHRISTIAN BOCKERMANN

HOCHSCHULE BOCHUM

SOMMERSEMESTER 2023

- 1 Was ist Big Data?
- 2 Big Data Techniken (Volume)
- 3 Mehr schneller! (Velocity)
- 4 Big Data Architektur
- 5 Beispiel: Besucherzahlen

Was ist Big Data?



SO WHAT IS A PETABYTE ANYWAY?

Source – www.mozy.com

WHAT IS A PETABYTE?

TO UNDERSTAND A PETABYTE WE MUST FIRST UNDERSTAND A GIGABYTE.

1 GIGABYTE = 7 MINUTES OF HD-TV VIDEO

2 GIGABYTES = 20 YARDS OF BOOKS ON A SHELF

4.7 GIGABYTES = SIZE OF A STANDARD DVD-R

THERE ARE A MILLION GIGABYTES IN A PETABYTE

“Let me repeat that: we create as much information in two days now as we did from the dawn of man through 2003.” (That’s something like 5 Exabytes of Data). - Eric Schmidt – Google 8/10

A PETABYTE IS A LOT OF DATA

1 PETABYTE = 20 MILLION FOUR-DRAWER FILING CABINETS FILLED WITH TEXT

1 PETABYTE = 13.3 YEARS OF HD-TV VIDEO

1.5 PETABYTES = SIZE OF THE 10 BILLION PHOTOS ON FACEBOOK

15+ PETABYTES = INTERNET USER'S DATA BACKED UP ON MOZY.COM

20 PETABYTES = THE AMOUNT OF DATA PROCESSED BY GOOGLE PER DAY

20 PETABYTES = TOTAL HARD DRIVE SPACE MANUFACTURED IN 1995


50 PETABYTES = THE ENTIRE WRITTEN WORKS OF MANKIND, FROM THE BEGINNING OF RECORDED HISTORY, IN ALL LANGUAGES

Twitter:
Over 7TB a Day in Tweets.


A ZETABYTE IS ONE MILLION PETABYTES!

Facebook:
More than 750 Million Users.
Average user creates 90 Pieces of content each month.
More than 30B pieces of content shared each month.

Die berühmten 4 V's



Die berühmten 5 V's



Big Data Techniken (Volume)

Beispiel: Durchschnitt berechnen

	X_2	

$$\bar{X}_2 = \frac{\sum_{i=1}^n X_{i,2}}{n}$$

Beispiel: Durchschnitt berechnen

X_2

$$\bar{X}_2 = \frac{\sum_{i=1}^n X_{i,2}}{n}$$

```
# mit Pandas DataFrame:  
df['X2'].sum() / len(df)
```

```
# oder:  
df['X2'].mean()
```

Beispiel: Durchschnitt berechnen

- Pandas liest DataFrame in Hauptspeicher
- Schnelle Berechnung, schneller Zugriff

Datensätze im DataScience Kurs

- Iris Daten - 3.8 KB
- Auto MPG Daten - 18 KB
- Hausarbeit - 3.7 MB und 5.8 MB
- RKI Covid19 Daten - 44 MB

Beispiel: Durchschnitt berechnen

- Pandas liest DataFrame in Hauptspeicher
- Schnelle Berechnung, schneller Zugriff

Datensätze im DataScience Kurs

- Iris Daten - 3.8 KB
- Auto MPG Daten - 18 KB
- Hausarbeit - 3.7 MB und 5.8 MB
- RKI Covid19 Daten - 44 MB

Was ist, wenn unsere Daten 4 TB groß sind?

Beispiel: Durchschnitt berechnen

X_2

4 TB = ca. 4000 GB
handelsübliche Festplatte

- Lesegeschwindigkeit einer Festplatte 100 - 200 MB/s
- Lesen der Daten benötigt 5,5 - 11 Minuten

Beispiel: Durchschnitt berechnen

X_2

4 TB = ca. 4000 GB
handelsübliche Festplatte

- Lesegeschwindigkeit einer Festplatte 100 - 200 MB/s
- Lesen der Daten benötigt 5,5 - 11 Minuten
- SSD Platte + SATA mit 600 MB/s braucht knapp 2 Minuten

Beispiel: Durchschnitt berechnen


x_2

4 TB = ca. 4000 GB
handelsübliche Festplatte

- Lesegeschwindigkeit einer Festplatte 100 - 200 MB/s
- Lesen der Daten benötigt 5,5 - 11 Minuten
- SSD Platte + SATA mit 600 MB/s braucht knapp 2 Minuten
- Festplatte: 0,024 EUR/GB, SSD-Platte: 0,09 EUR/GB
- Größte SSD 8 TB, sehr teuer

Wie können wir die Berechnung beschleunigen?


1. Durchsatz erhöhen mit mehreren Festplatten:



- Von allen Platten gleichzeitig lesen: ca. 1,5 Minuten

Wie können wir die Berechnung beschleunigen?

1. Durchsatz erhöhen mit mehreren Festplatten:



- Von allen Platten gleichzeitig lesen: ca. 1,5 Minuten
- Daten müssen dann auch **parallel** verarbeitet werden!!

2. Parallele Berechnung des Durchschnitts

Wir teilen die Daten in (z.B. 4) Blöcke auf

$$\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_{k_1}\} \cup \{\mathbf{x}_{k_1+1}, \dots, \mathbf{x}_{k_2}\}, \dots$$


und zerlegen auch die Berechnung in Teilprobleme:

$$\bar{\mathbf{x}}_2 = \frac{\sum_{i=1}^n x_{i,2}}{n} = \frac{s_1 + s_2 + s_3 + s_4}{n_1 + n_2 + n_3 + n_4}$$


mit

$$s_1 = \sum_{i=1}^{k_1} x_{i,2}, \quad s_2 = \sum_{i=k_1+1}^{k_2} x_{i,2}, \quad \dots, \quad s_4 = \sum_{i=k_3+1}^{k_4} x_{i,2}$$


Parallele Berechnung des Durchschnitts



Parallele Berechnung des Durchschnitts



Parallele Berechnung des Durchschnitts



Die Idee von Map-Reduce

Seien die Blöcke Python-Listen:

```
bloecke = [ [1,2,3,4], [5,6,7,8], ... ]
```

```
block0 = bloecke[0] # [1,2,3,4]
```

Wir definieren eine Funktion f , die für jeden Block s_i und n_i berechnet:

```
def f(block):  
    s = 0  
    for x in block:  
        s = s + x  
    return (s, len(block))
```

map: Funktion auf alle Elemente einer Liste anwenden

```
[ [1,2,3,4] , [5,6,7,8] , [..] ]
```

map: Funktion auf alle Elemente einer Liste anwenden

```
[ [1,2,3,4] , [5,6,7,8] , [..] ]  
  |           |           |  
  f           f           f  
  |           |           |  
[ (10,4) , (26,4) , (..,..) ]
```


map: Funktion auf alle Elemente einer Liste anwenden

```
[ [1,2,3,4] , [5,6,7,8] , [..] ]  
  |           |           |  
  f           f           f  
  |           |           |  
[ (10,4) , (26,4) , (..,..) ]
```

```
bloecke = [ [1,2,..] , [5,6,..] , [..] , .. ]
```

```
# Zwischenergebnisse:
```

```
xs = map(f, bloecke)
```


reduce: Liste zu Ergebnis aggregieren

Definiere eine Funktion **add**, die zwei Elemente verknüpft:

```
def add(x, y):  
    return (x[0] + y[0], x[1] + y[1])
```

Diese Funktion benutzen wir mit **reduce** ähnlich wie **f** mit **map** zum aggregieren.

reduce: Liste zu Ergebnis aggregieren




```
from functools import reduce
```

```
xs = map(f, bloecke)  
(s,n) = reduce(add, xs)
```

```
avg = s / n
```


Parallelisierung mit Map-Reduce



Parallelisierung mit Map-Reduce



Parallelisierung mit Map-Reduce



Scale-Up: Mehr Power + Speicher

Server aufrüsten mit

- mehr Speicher
- zusätzlichen CPUs
- weiteren Festplatten

Scale-Up: Mehr Power + Speicher

Server aufrüsten mit

- mehr Speicher
- zusätzlichen CPUs
- weiteren Festplatten

Aufrüstung begrenzt: max. Speicher, Anzahl Festplatten,...

Scale-Up: Mehr Power + Speicher

Server aufrüsten mit

- mehr Speicher
- zusätzlichen CPUs
- weiteren Festplatten

Aufrüstung begrenzt: max. Speicher, Anzahl Festplatten,...

Zur Erinnerung: Wir suchen nach **Big** Data!

4 PB = 4000 TB = 1000 Festplatten mit 4 TB Speicher.

Scale-Out: Mehr Server

- Verteilung auf mehrere Server
- Jeder Server hat zig Platten
- zur Erweiterung werden zusätzliche Server hinzugenommen

Scale-Out: Mehr Server

- Verteilung auf mehrere Server
- Jeder Server hat zig Platten
- zur Erweiterung werden zusätzliche Server hinzugenommen

4 PB = 4000 TB

1 Server mit 10 x 4 TB Platten = 100 Server für 4 PB

Apache Hadoop: Open-Source Map-Reduce System

- Hadoop ist ein populäres Map-Reduce System
- Enthält ein Dateisystem (HDFS) zum Speichern von Daten
- Einen Scheduler für Map- und Reduce-Jobs

Apache Hadoop: Open-Source Map-Reduce System

- Hadoop ist ein populäres Map-Reduce System
- Enthält ein Dateisystem (HDFS) zum Speichern von Daten
- Einen Scheduler für Map- und Reduce-Jobs

Wem ist bereits eine Festplatte kaputtgegangen?

Apache Hadoop: Open-Source Map-Reduce System

- Hadoop ist ein populäres Map-Reduce System
- Enthält ein Dateisystem (HDFS) zum Speichern von Daten
- Einen Scheduler für Map- und Reduce-Jobs

Wem ist bereits eine Festplatte kaputtgegangen?

Fault-Tolerance:

- Hadoop kümmert sich um Fehlerbehandlung
- Redundantes Speichern für Ausfallsicherheit



Apache Hive: Datenbank mit Map-Reduce

```
SELECT count(*) from txnrecords;
```

```
hive> select count(*) from txnrecords;
Total MapReduce jobs = 1
Launching Job 1 out of 1
Number of reduce tasks determined at compile time: 1
In order to change the average load for a reducer (in bytes):
  set hive.exec.reducers.bytes.per.reducer=<number>
In order to limit the maximum number of reducers:
  set hive.exec.reducers.max=<number>
In order to set a constant number of reducers:
  set mapred.reduce.tasks=<number>
Starting Job = job_201402270420_0005, Tracking URL = http://localhost:50030/jobdetails.jsp?jobid=job_201402270420_0005
Kill Command = /usr/lib/hadoop/bin/hadoop job -Dmapred.job.tracker=localhost:8021 -kill job_201402270420_0005
2014-02-28 20:02:41,231 Stage-1 map = 0%, reduce = 0%
2014-02-28 20:02:48,293 Stage-1 map = 50%, reduce = 0%
2014-02-28 20:02:49,309 Stage-1 map = 100%, reduce = 0%
2014-02-28 20:02:55,350 Stage-1 map = 100%, reduce = 33%
2014-02-28 20:02:56,367 Stage-1 map = 100%, reduce = 100%
Ended Job = job_201402270420_0005
OK
50000
Time taken: 19.027 seconds
hive> █
```

Mehr schneller! (Velocity)

Lebensdauer von Informationen



[@charlesluzar](#)

Charles Luzar

Think about this: I read about the earthquake on Twitter seconds before I felt it. Oh, times... how you've changed.

23 Aug. via [TweetDeck](#)

Lebensdauer von Informationen



static web



blogs



status



Lebensdauer von Informationen



static web



blogs



status



Lebensdauer von Informationen



static web



blogs



status



Google™

Map-Reduce

Lebensdauer von Informationen



static web



blogs



status



2008

Google™

Map-Reduce

Google

Caffeine

Lebensdauer von Informationen



static web



blogs



status



2008

2013

Google

Map-Reduce

Google

Caffeine

Google

MillWheel

Verarbeitung in Near-Time

- Map-Reduce funktioniert gut, ist aber träge
- Abfragen/Ausführung dauert lange

Wie funktionieren dann z.B. Trends?

- Big Data Verarbeitung in Echtzeit/Neartime
- Ähnliche Prinzipien: Verteilte Berechnungen

Twitter: >500k Tweets pro Minute

Sports · Trending ...

#FRASUI

Sports
France vs Switzerland:
Switzerland advances to ...



659K Tweets

Trending in Germany ...

#Unwetter

2,825 Tweets

Twitter Trends: Top-k Anfragen

Finde die k häufigsten Hashtags!

Twitter Trends: Top-k Anfragen

Finde die k häufigsten Hashtags!

Einfacher Ansatz:

- 4-Byte Zähler pro Hashtag
- Führt zu 1.8 GB Speicherverbrauch für 1-6 stellige Hashtags

Twitter Trends: Top-k Anfragen

Finde die k häufigsten Hashtags!

Einfacher Ansatz:

- 4-Byte Zähler pro Hashtag
- Führt zu 1.8 GB Speicherverbrauch für 1-6 stellige Hashtags

Auch hier: Das funktioniert nur verteilt! (Scale-Out)

Frage:


Wie können wir die Daten so aufteilen, dass sie zählbar bleiben?

Tweets




Frage:

Wie können wir die Daten so aufteilen, dass sie zählbar bleiben?




Frage:

Wie können wir die Daten so aufteilen, dass sie zählbar bleiben?



Frage:

Wie können wir die Daten so aufteilen, dass sie zählbar bleiben?





Big Data Architektur

Analytics: **Beantwortung von Fragen**

```
result = query ( all data )
```

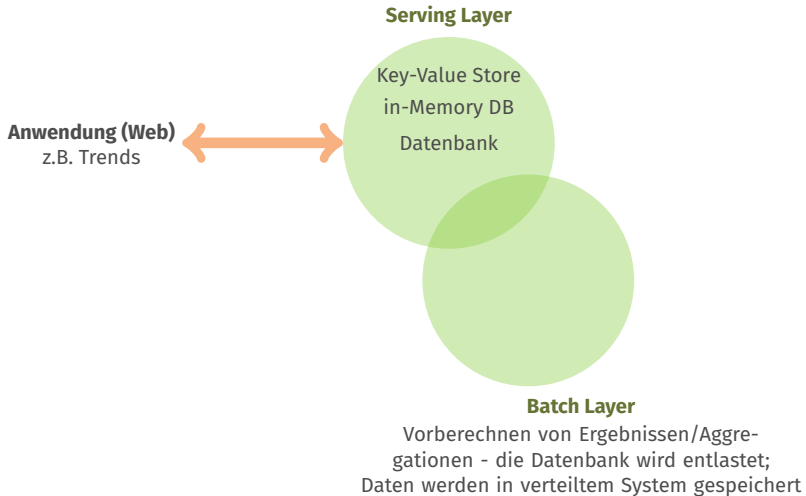







Typische Architektur einer Web-Anwendung

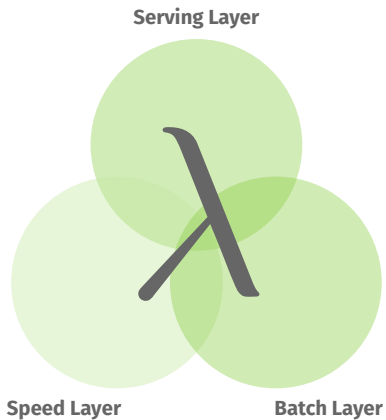
Irgendwann erreicht die Datenbank eine Größe/Komplexität, dass Anfragen nicht mehr ad-hoc berechnet werden können.





Aktuelle Informationen werden online vorberechnet
und die Ergebnisse in die Datenbank geschrieben.

Lambda Architektur



Kappa-Architektur

- Kein Batch-Layer mehr
- Berechnungen nur noch online/im Stream
- Großer Storage aus dem die Vergangenheit “gestreamt” werden kann

Beispiel: Besucherzahlen

Beispiel: Analyse von Studierenden-Zahlen



```
{id:252,date:'2022-12-06 09:47',room:'AW-01-39',value:+1}
```

Beispiel: Analyse von Studierenden-Zahlen



```
{id:252,date:'2022-12-06 09:47',room:'AW-01-39',value:+1}
```

Ziele:

- Echtzeit-Darstellung der Raumbellegung
- Möglichkeit zur Analyse historischer Daten

Beispiel: Analyse von Studierenden-Zahlen




```
{id:252,date:'2022-12-06 09:47',room:'AW-01-39',value:+1}
{id:253,date:'2022-12-06 09:48',room:'AW-01-39',value:-1}
{id:254,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}
{id:255,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}
{id:256,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}
{id:258,date:'2022-12-06 09:52',room:'AW-01-39',value:+1}
```

Beispiel: Analyse von Studierenden-Zahlen




```
{id:252,date:'2022-12-06 09:47',room:'AW-01-39',value:+1}  
{id:253,date:'2022-12-06 09:48',room:'AW-01-39',value:-1}  
{id:254,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:255,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:256,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:258,date:'2022-12-06 09:52',room:'AW-01-39',value:+1}
```



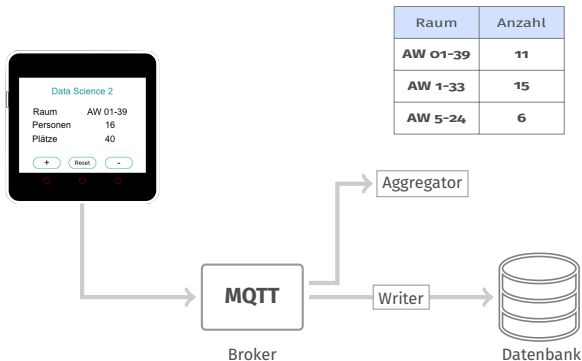
Beispiel: Analyse von Studierenden-Zahlen



```
{id:252,date:'2022-12-06 09:47',room:'AW-01-39',value:+1}  
{id:253,date:'2022-12-06 09:48',room:'AW-01-39',value:-1}  
{id:254,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:255,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:256,date:'2022-12-06 09:51',room:'AW-01-39',value:+1}  
{id:258,date:'2022-12-06 09:52',room:'AW-01-39',value:+1}
```



Beispiel: Analyse von Studierenden-Zahlen



Nachrichtenverarbeitung im Aggregator

```
def on_message(client, userdata, msg):  
    print(f"New message from '{msg.topic}' topic")  
    global counts  
    data = loads(msg.payload.decode())  
    room = data['room']  
  
    if room not in counts:  
        counts[room] = 1  
    else:  
        counts['room'] = counts['room'] + 1
```


```
# Topic, auf dem Messwerte publiziert werden  
topic = 'counts'  
  
def subscribe(mqtt):  
    mqtt.subscribe(topic)  
    mqtt.on_message = on_message
```


Going Big Data: **Was passiert, wenn der Aggregator abstürzt?**

- Status geht verloren (aktuelle Anzahlen)
- Neustart beginnt mit 0 Werten für alle Räume


Apache Kafka als Broker

- Hoch-Skalierbarer Message Broker
- Clusterfähig (hochverfügbar)
- Entwickelt bei LinkedIn, Open Source



Apache Kafka als Broker

- Hoch-Skalierbarer Message Broker
- Clusterfähig (hochverfügbar)
- Entwickelt bei LinkedIn, Open Source



Nachrichten im Topic werden
temporär gespeichert (z.B. 1 Monat)