

Big Data & Analytics

Nationaler Akademietag, Fulda

20.04.2018

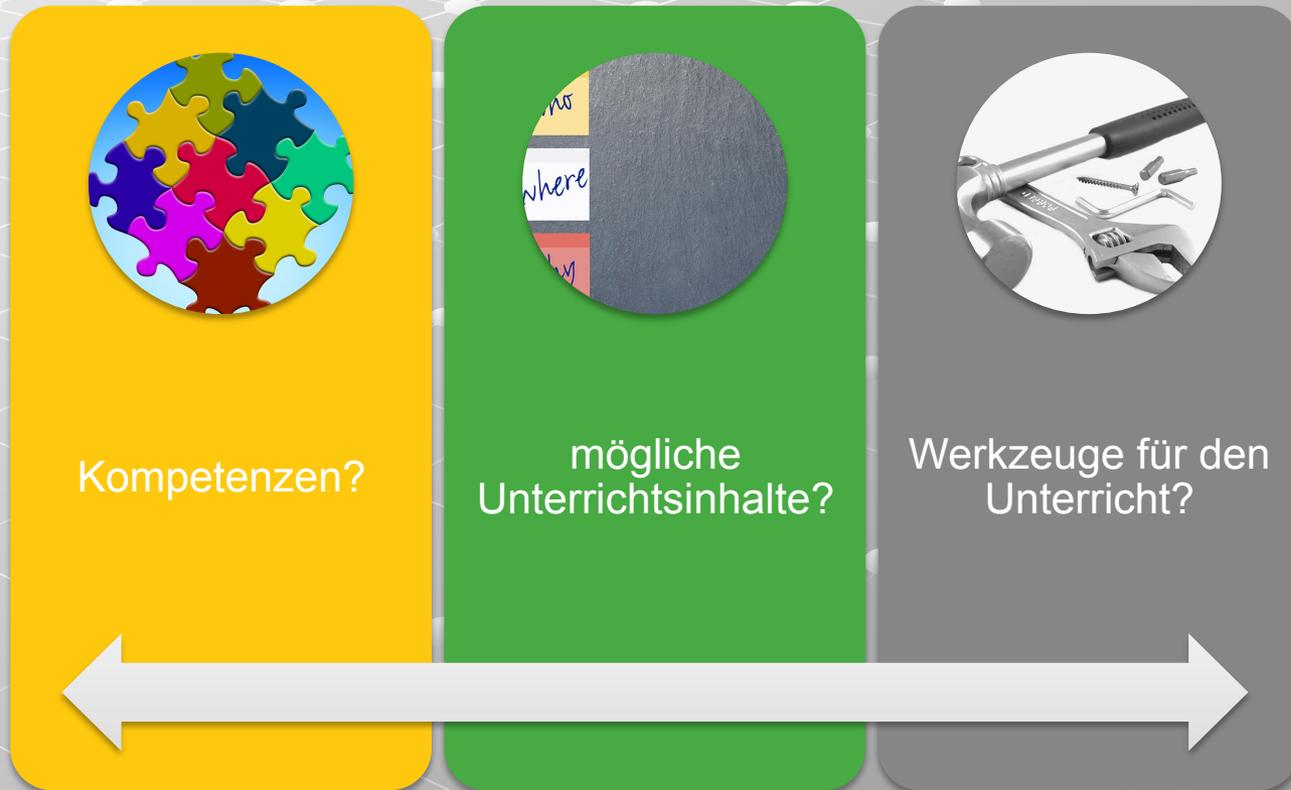


Referent: Meinhard Lingo

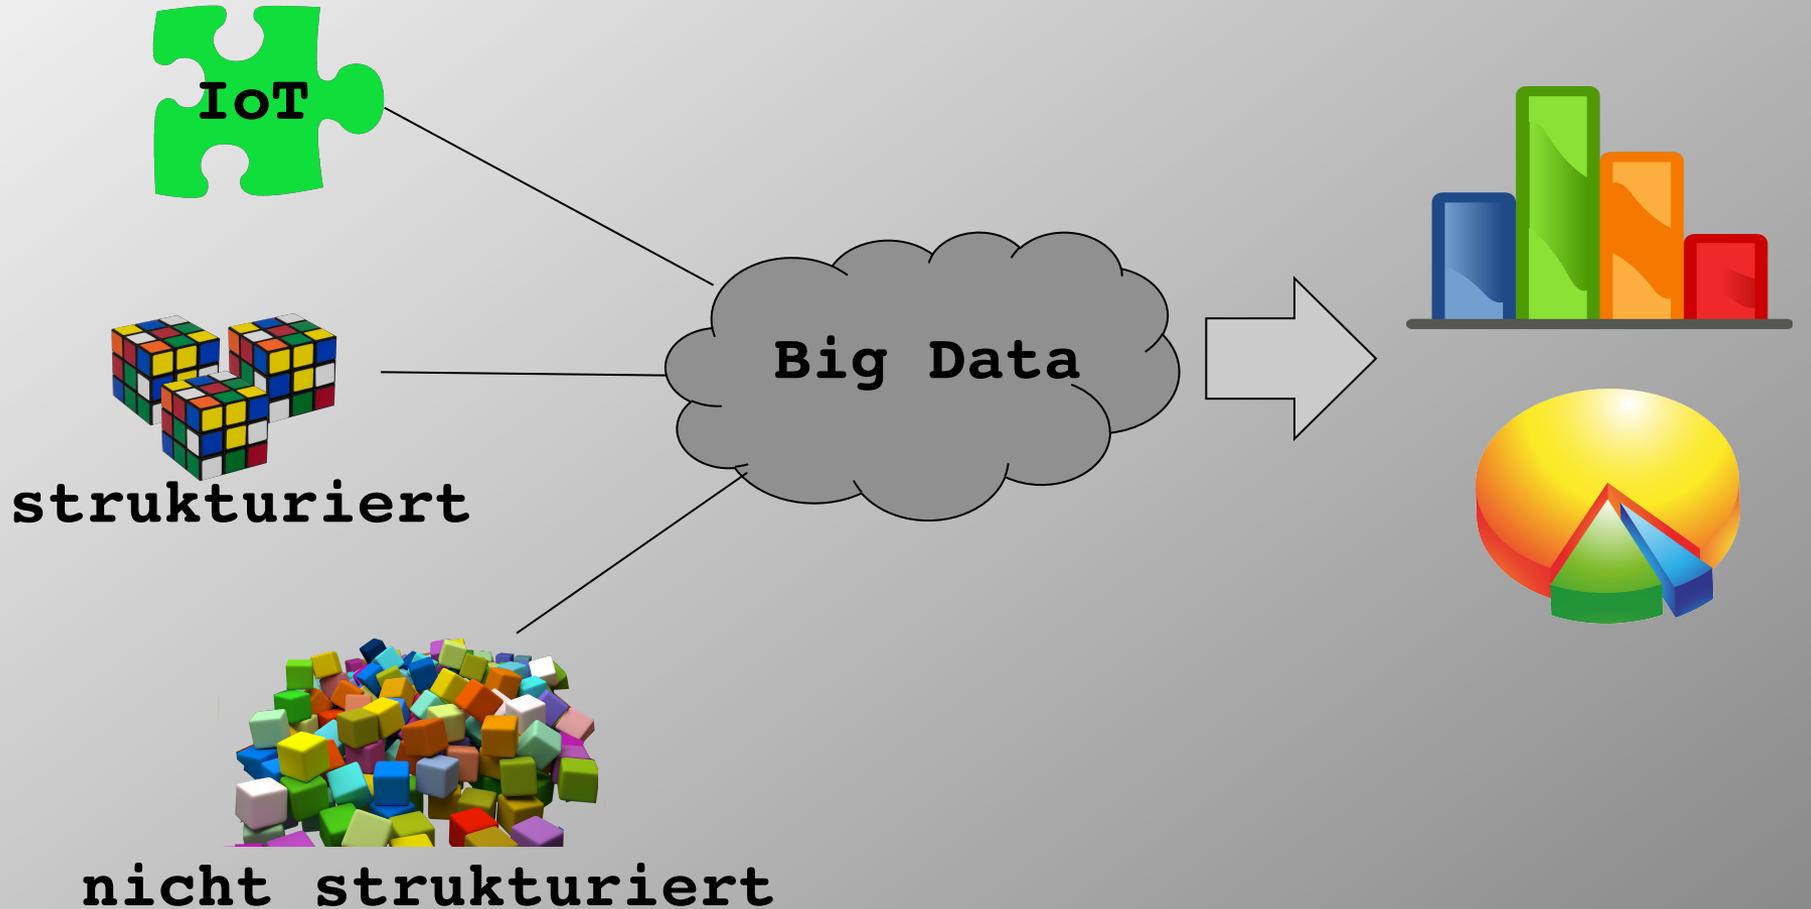
E-Mail: meinhard.lingo@bs1in.de

Big Data & Analytics

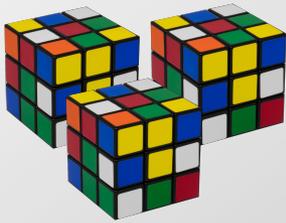
Big Data-Anwendungen: Ein Paradigmenwechsel.



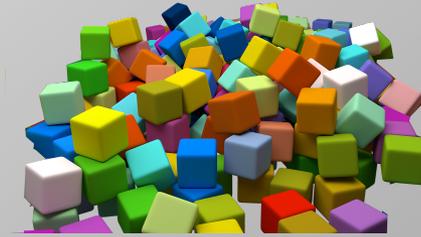
From Data To Sense...



Informationen, strukturiert und unstrukturiert



- Datenbank-Anwendungen
- Excel-Anwendungen,
- Formulare,
- CSV, XML, ...
- ...



- Dokumente
- Web 2.0 (facebook, Twitter, Blogs, ...)
- Fotos, Musik, Videos
- 'OK Google', Siri, Alexa, Google home ...
- ...



Volume

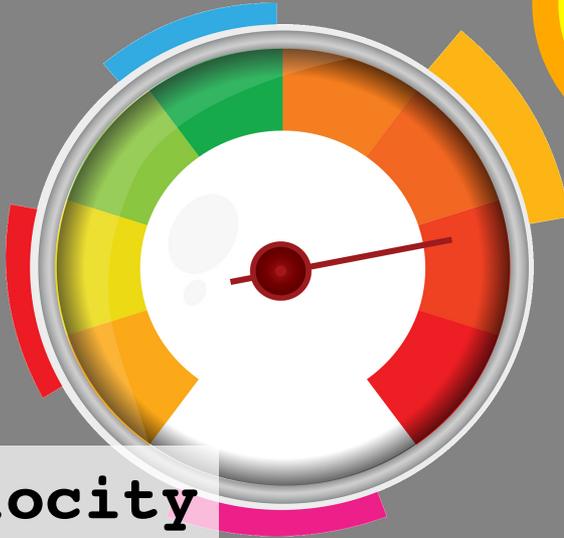


Variety



**BIG
DATA**

Velocity



Veracity



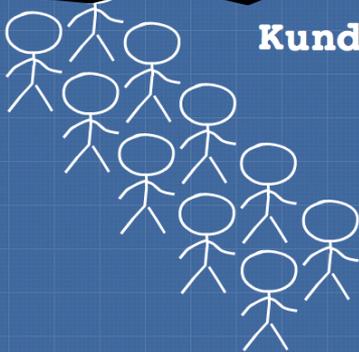
Teil 1:

Relationale Datenbanken

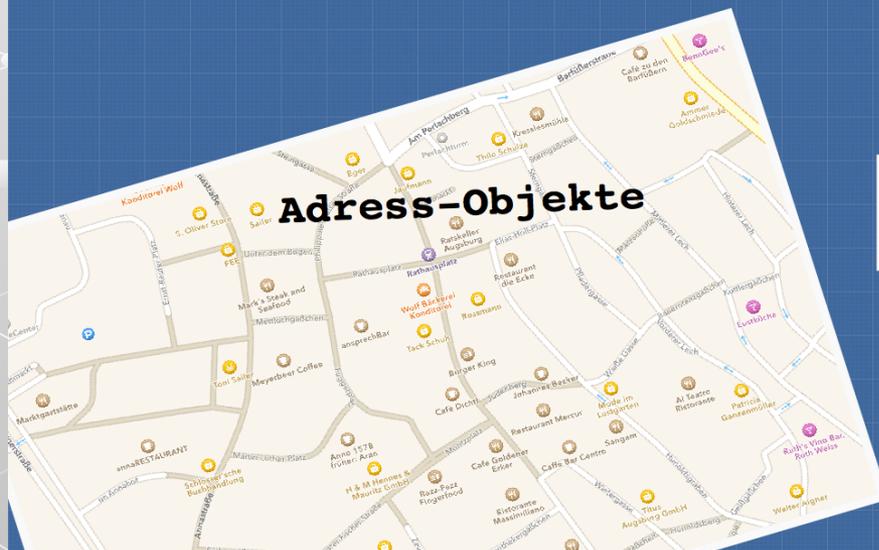


Erklären Sie den Zusammenhang zwischen einem semantischen Modell und dem Datenmodell in der 3NF.

Kunden-Objekte



Sportart-Objekte



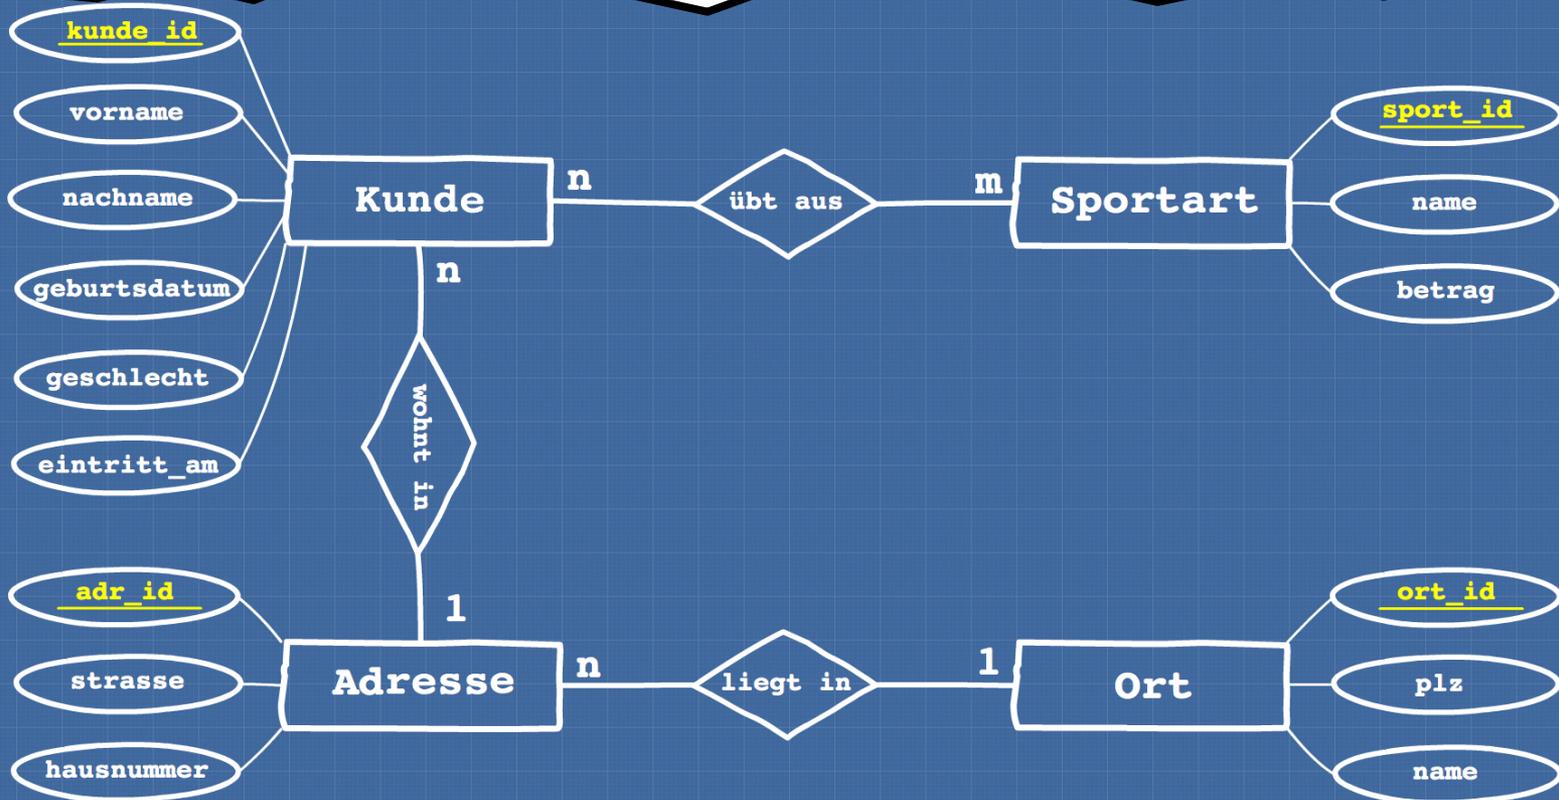
Adress-Objekte



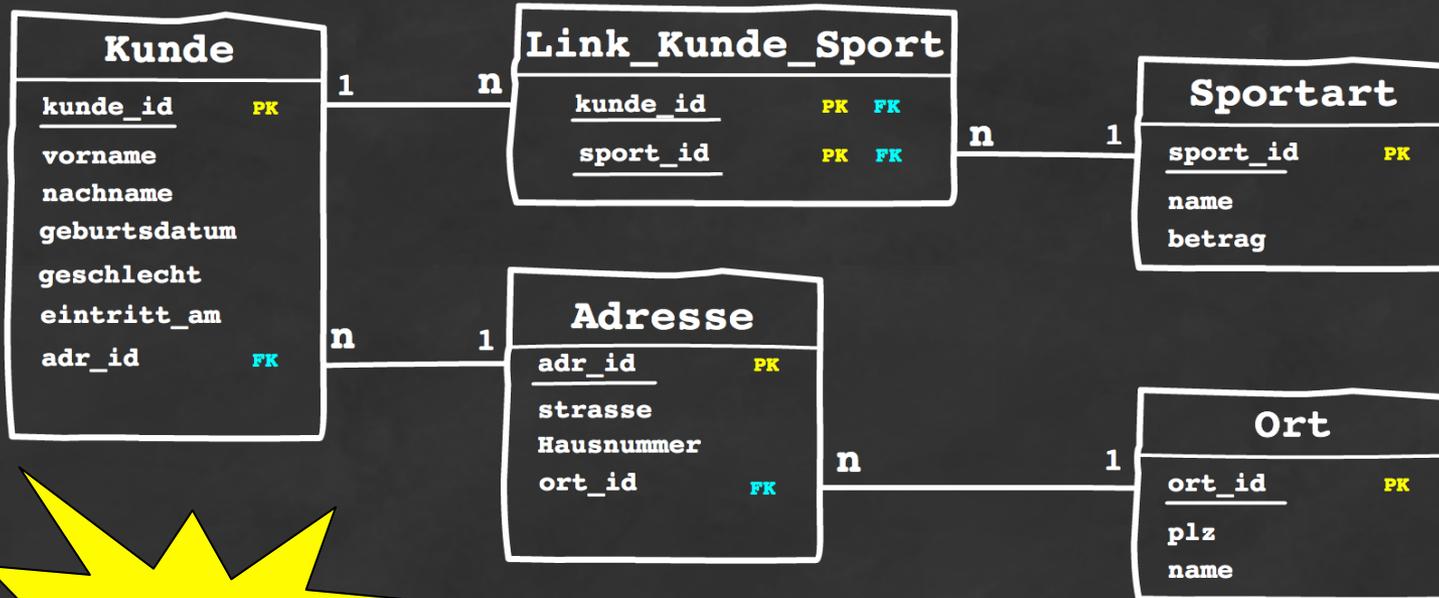
ort-objekte



Erklären Sie den Zusammenhang zwischen einem semantischen Modell und dem Datenmodell in der 3NF.



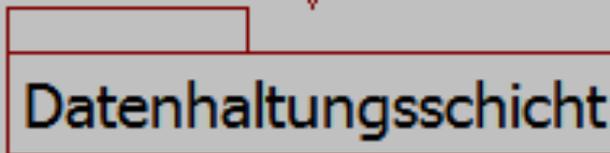
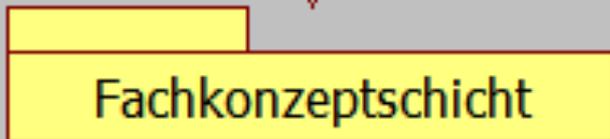
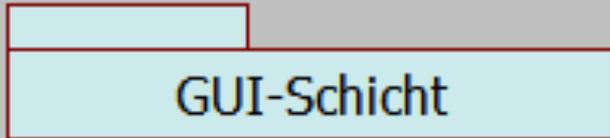
Erklären Sie den Zusammenhang zwischen einem semantischen Modell und dem Datenmodell in der 3NF.



Relationales Datenmodell, Sportverein Augsburg, SVA

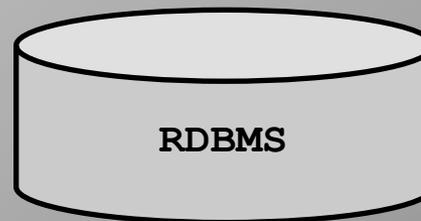
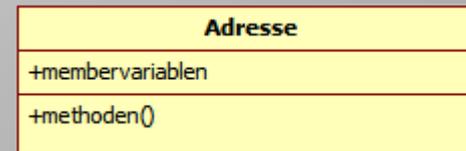


Skizzieren Sie die Architektur einer 3-Schicht-Datenbankanwendung.



A screenshot of a database application interface. It features a table with columns "ID" and "Vorname". The table contains several rows, with the row for ID 52 and name "Maximilian" highlighted. Below the table are buttons for "Neu", "Bearbeiten", "Löschen", and "Schließen". To the right of the table is a form for editing a record, with fields for "Id", "Vorname", "Nachname", "Strasse", "PLZ", and "Ort". The "Id" field contains "52", "Vorname" contains "Maximilian", "Nachname" contains "Altenburger", "Strasse" contains "Forststr 45", "PLZ" contains "86159", and "Ort" contains "Augsburg". There are "Speichern" and "Schließen" buttons at the bottom of the form.

ID	Vorname
70	Silvia
108	Walter
52	Maximilian
125	Kathrin
61	Ulrike
96	Sepp
191	Gerda
49	Josef
43	Klaus



Für viele Datenbank-Anwendungen werden relationale Datenbanken verwendet.
Welche wichtigen RDBMS kennen Sie?



DB-ENGINES

342 Systeme im Ranking

Rang			DBMS	Datenbankmodell	Punkte		
Apr 2018	Mär 2018	Apr 2017			Apr 2018	Mär 2018	Apr 2017
1.	1.	1.	Oracle +	Relational DBMS	1289,79	+0,18	-112,21
2.	2.	2.	MySQL +	Relational DBMS	1226,40	-2,46	-138,22
3.	3.	3.	Microsoft SQL Server +	Relational DBMS	1095,51	-9,28	-109,26
4.	4.	4.	PostgreSQL +	Relational DBMS	395,47	-3,88	+33,69
5.	5.	5.	MongoDB +	Document Store	341,41	+0,89	+15,98
6.	6.	6.	DB2 +	Relational DBMS	188,95	+2,28	+2,29
7.	7.	7.	Microsoft Access	Relational DBMS	132,22	+0,27	+4,04
8.	↑ 9.	↑ 11.	Elasticsearch +	Suchmaschine	131,36	+2,81	+25,69
9.	↓ 8.	9.	Redis +	Key-Value Store	130,11	-1,12	+15,75
10.	10.	↓ 8.	Cassandra +	Wide Column Store	119,09	-4,40	-7,10
11.	11.	↓ 10.	SQLite +	Relational DBMS	115,99	+1,17	+2,19
12.	12.	12.	Teradata	Relational DBMS	73,68	+1,21	-2,88
13.	13.	↑ 17.	Splunk	Suchmaschine	65,06	-0,61	+9,55
14.	↑ 15.	↑ 18.	MariaDB +	Relational DBMS	64,56	+1,45	+15,83
15.	↓ 14.	↓ 14.	Solr	Suchmaschine	63,21	-1,60	-1,16
16.	16.	↓ 13.	SAP Adaptive Server +	Relational DBMS	61,63	-0,99	-5,83
17.	17.	↓ 15.	HBase +	Wide Column Store	59,69	-1,24	+1,22
18.	18.	↑ 20.	Hive +	Relational DBMS	57,40	+0,39	+15,75
19.	19.	↓ 16.	FileMaker	Relational DBMS	55,00	-0,12	-2,17
20.	20.	↓ 19.	SAP HANA +	Relational DBMS	48,90	+0,37	+0,75
21.	21.	↑ 22.	Amazon DynamoDB +	Multi-Model ⓘ	43,14	+0,69	+11,08
22.	22.	↓ 21.	Neo4j +	Graph DBMS	40,90	-0,00	+5,99

Staatliche BS1 Ingolstadt



Vergleichen Sie die Konsistenzmodelle ACID (RDBMS) und BASE (noSQL).

RDBMS

A: atomicity

C: consistency

I: isolation

D: durability

B: basically

A: available

S: soft state

E: eventually consistent

No SQL

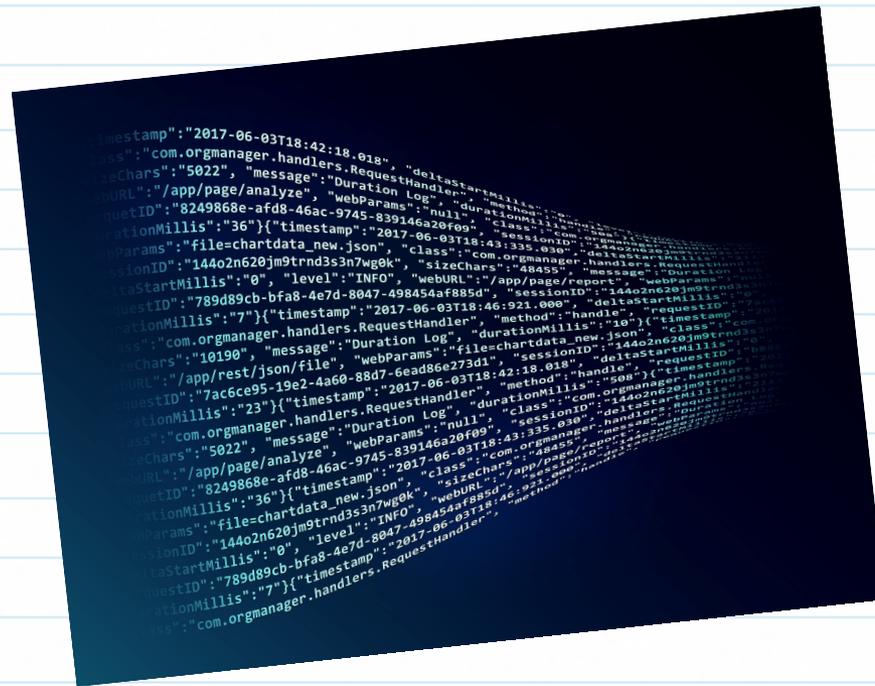
Konsistenz
(pessimistisch)

Verfügbarkeit
(optimistisch)



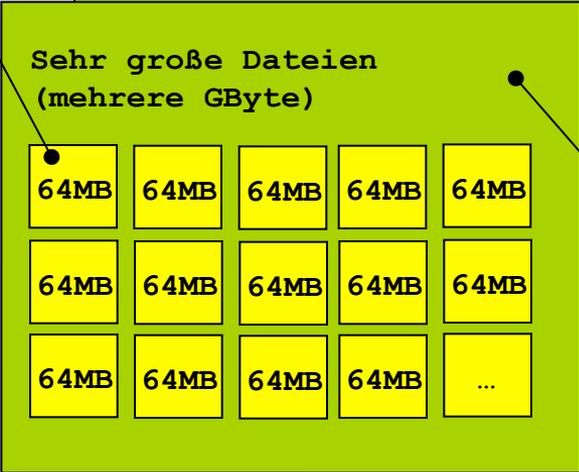
Teil 2:

Big Data - Konzepte

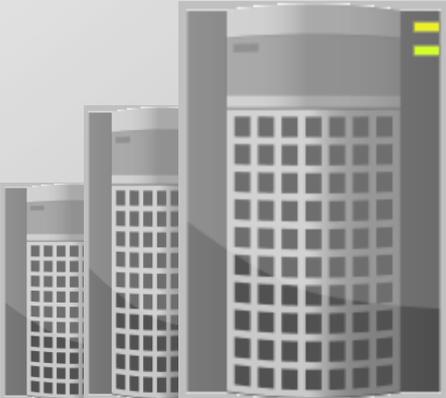


Erklären Sie den Begriff **horizontale Skalierung** am Beispiel des GFS.

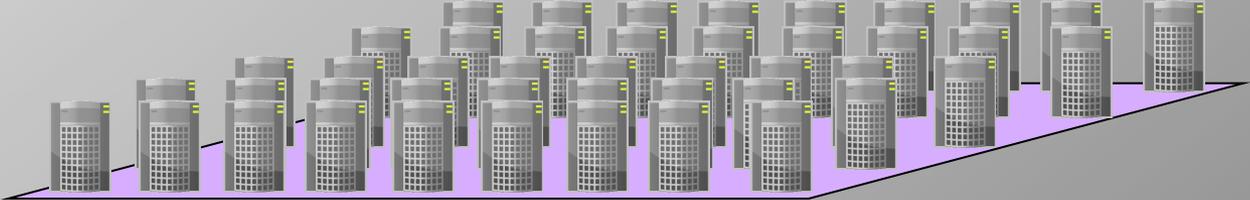
64 MB Chunks mit
64 Bit Kennzeichnung



Datei wird mind.
3 mal pro Cluster
gespeichert.



1 Master
(Meta-Daten)



Cluster mit vielen Chunkserver

„heart-beat messages“



Erläutern Sie die Notwendigkeit von Map-Reduce-Algorithmen in einem verteilten Dateisystem.

Inspiziert
von IBM

Reduce

Shuffle

MAP



Erläutern Sie den Map-Reduce-Algorithmen anhand eines Beispiels.

Daten

.....
081520171
123420183
081520181
123420182
471120184
.....

MAP

(....., .)
(2017, 1)
(2018, 3)
(2018, 1)
(2018, 2)
(2018, 4)
(....., .)

Shuffle

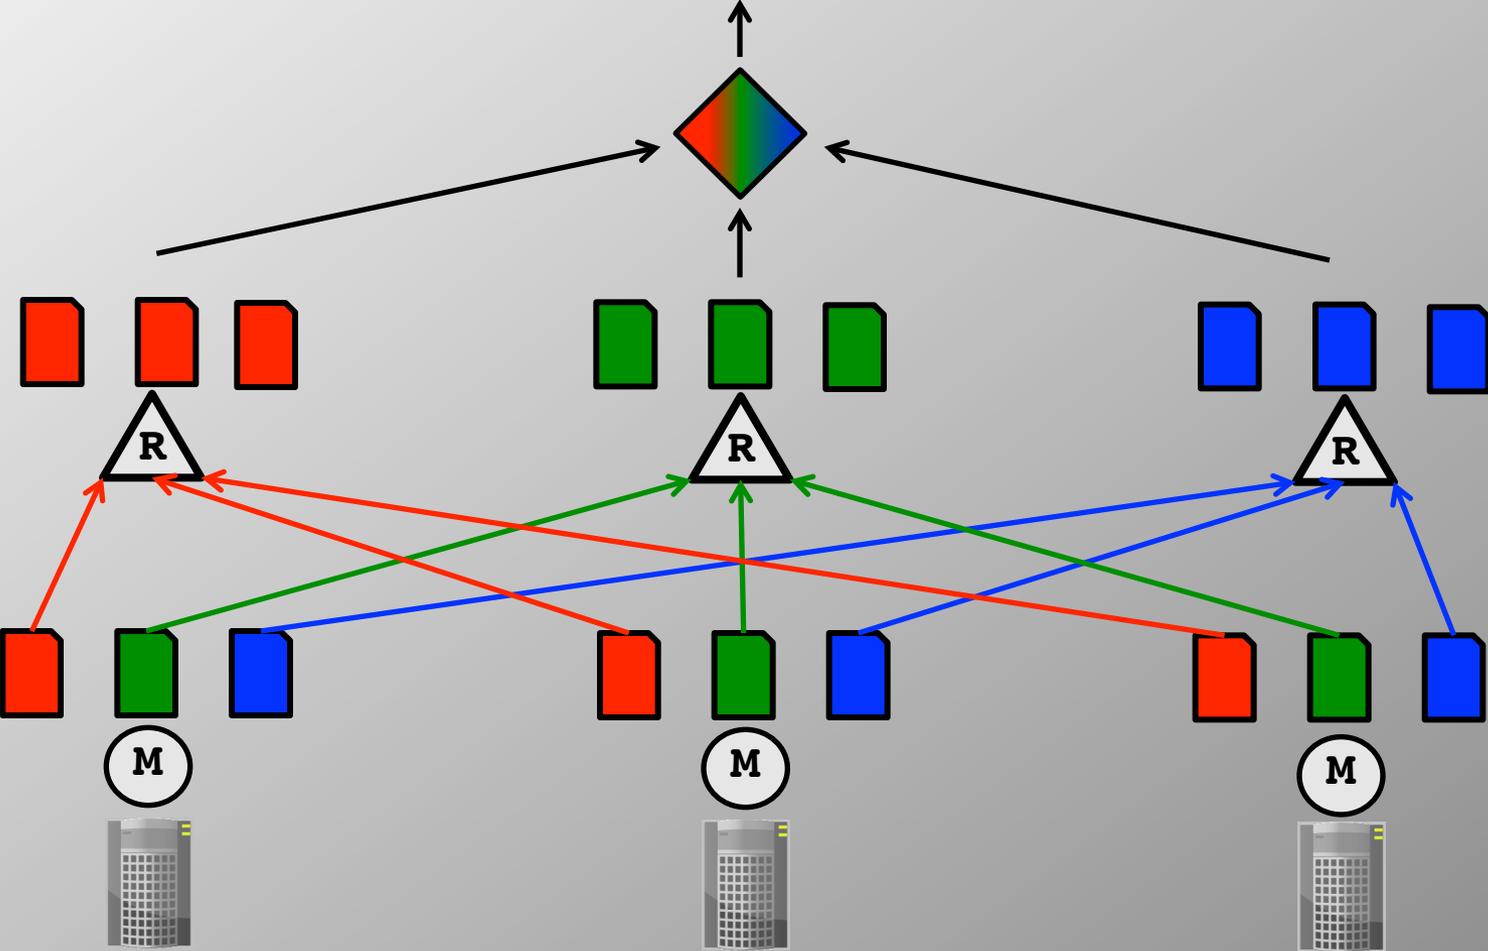
(....., .)
(2017, 1)
(2018, [3, 1, 2, 4])
(....., .)

Reduce

(....., .)
(2017, 1.0)
(2018, 2.5)
(....., .)

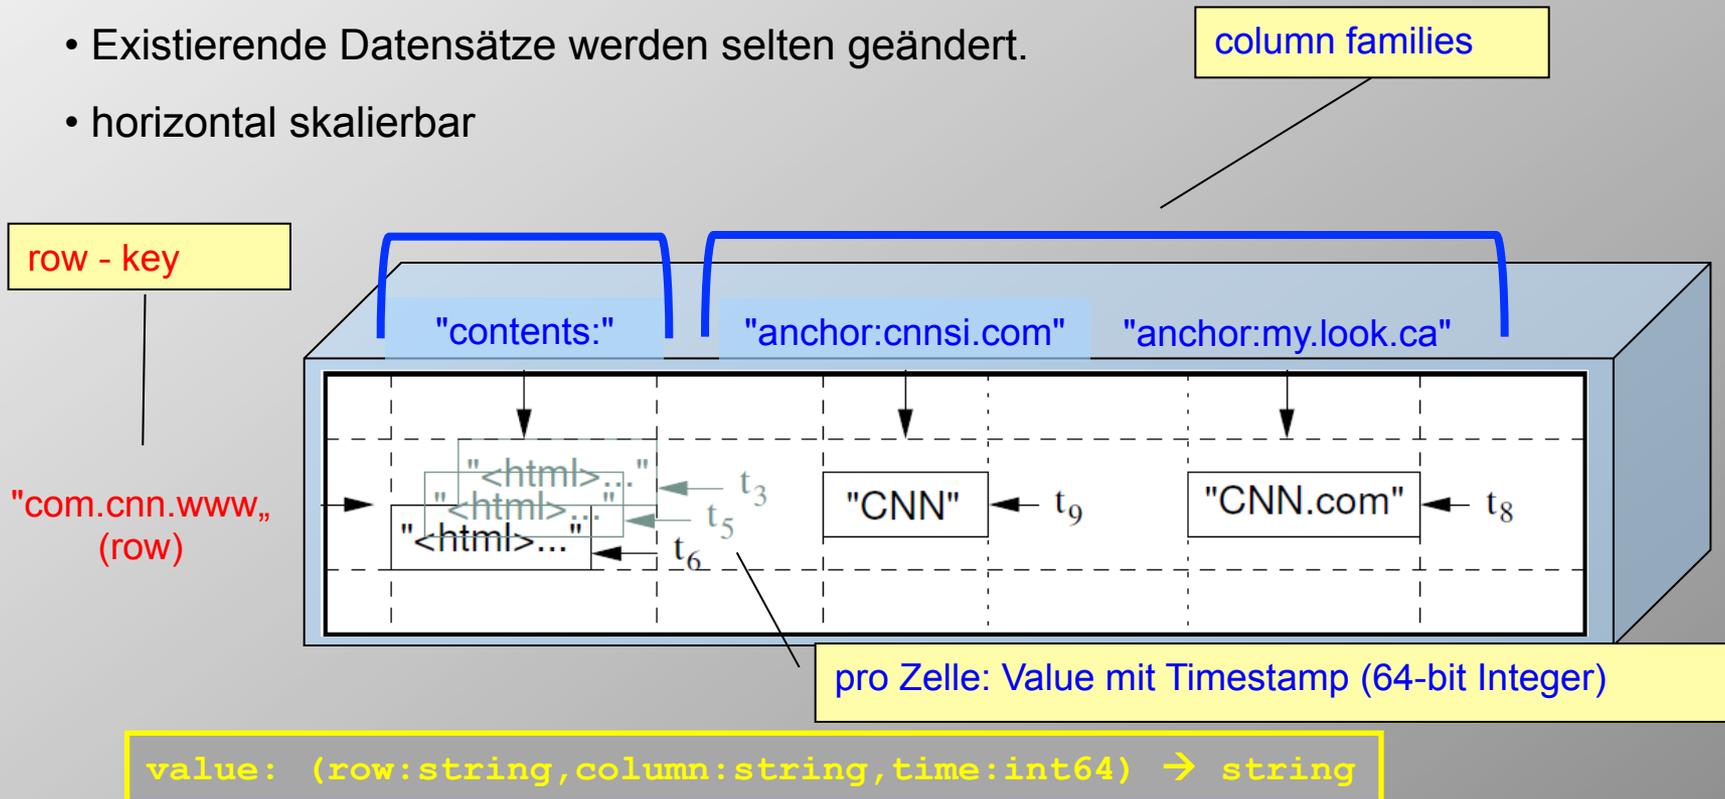


Map-Reduce-Algorithmen in verteilten Dateisystemen



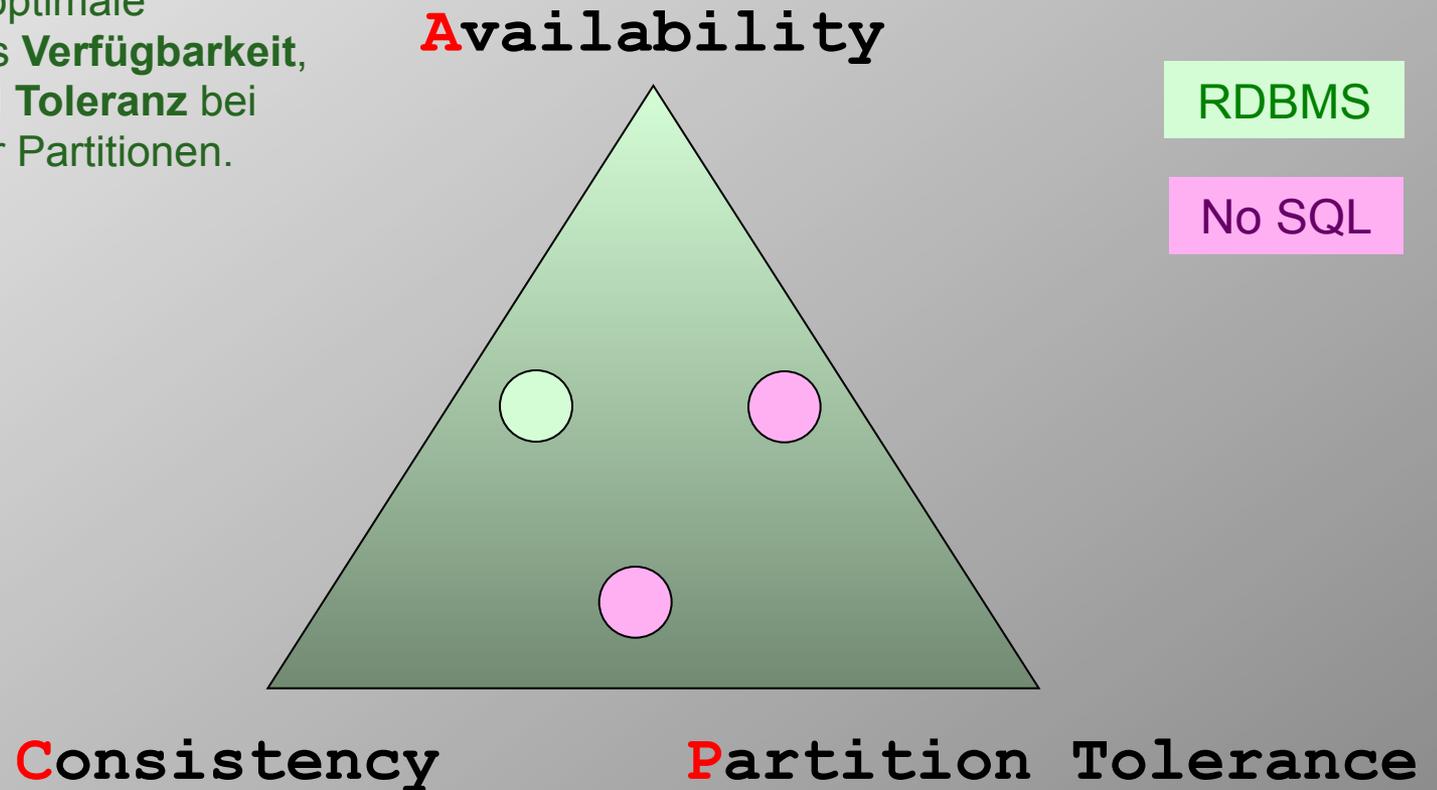
Erläutern Sie das Konzept von Googles **Big Table**.

- Datensätze werden oft hinzugefügt.
- Existierende Datensätze werden selten geändert.
- horizontal skalierbar



Erklären Sie das CAP-Theorem von Eric Brewer im Zusammenhang mit relationalen und noSQL Datenbanken.

Das Ziel ist die optimale Kombination aus **Verfügbarkeit**, **Konsistenz** und **Toleranz** bei Ausfall einzelner Partitionen.

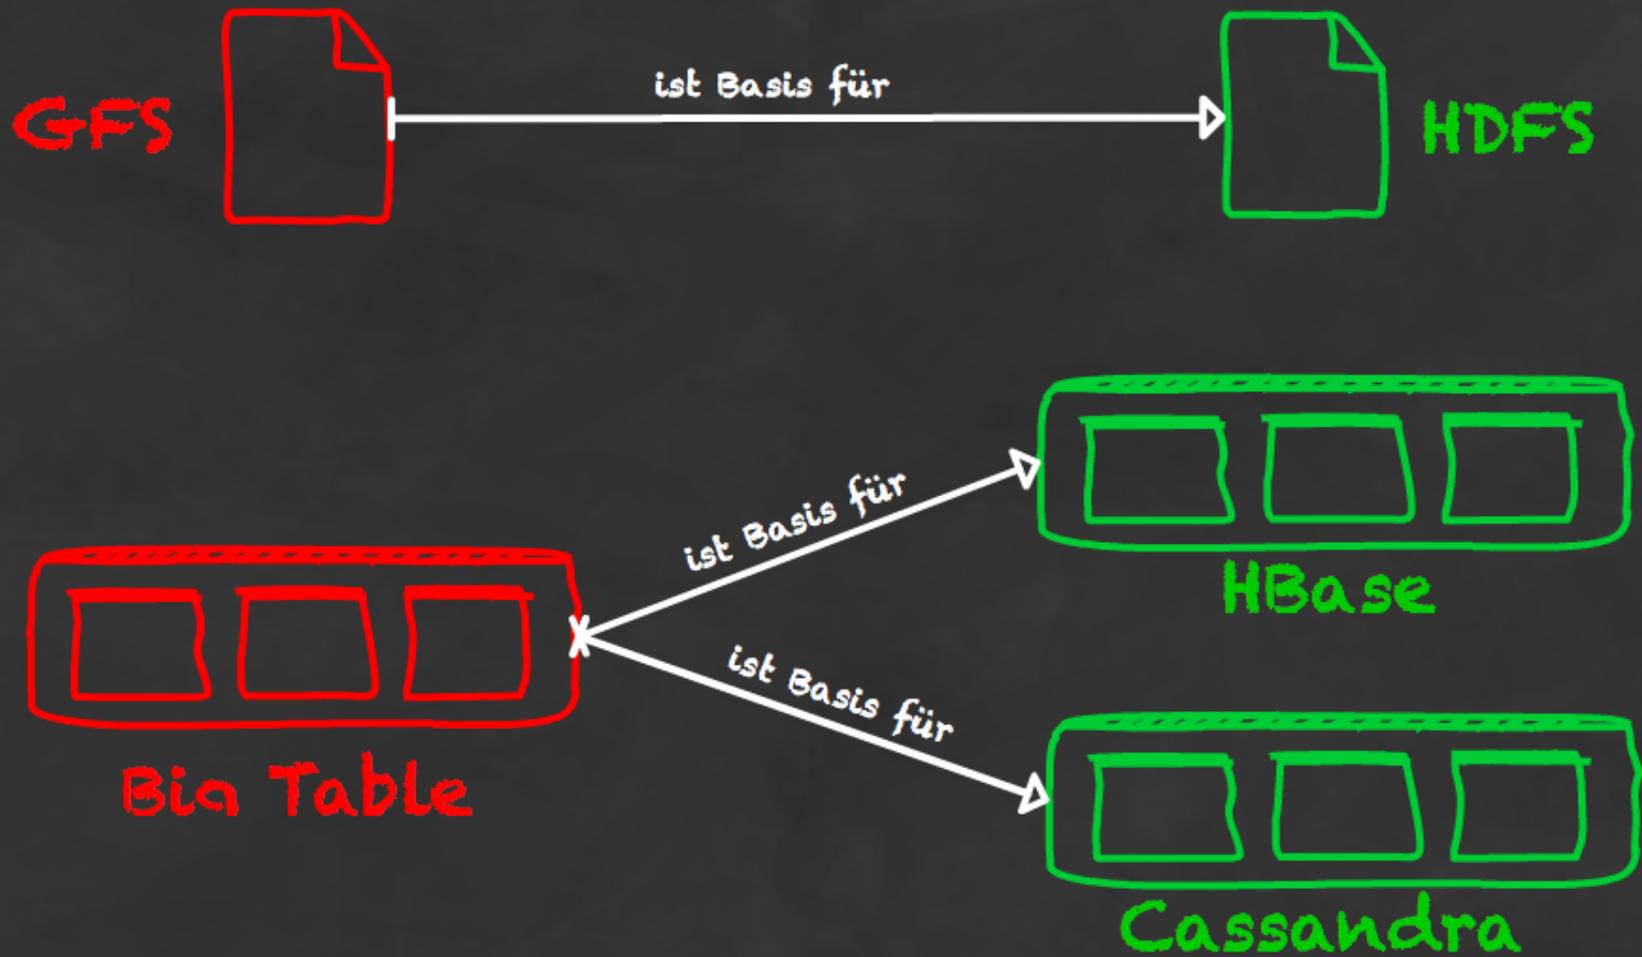




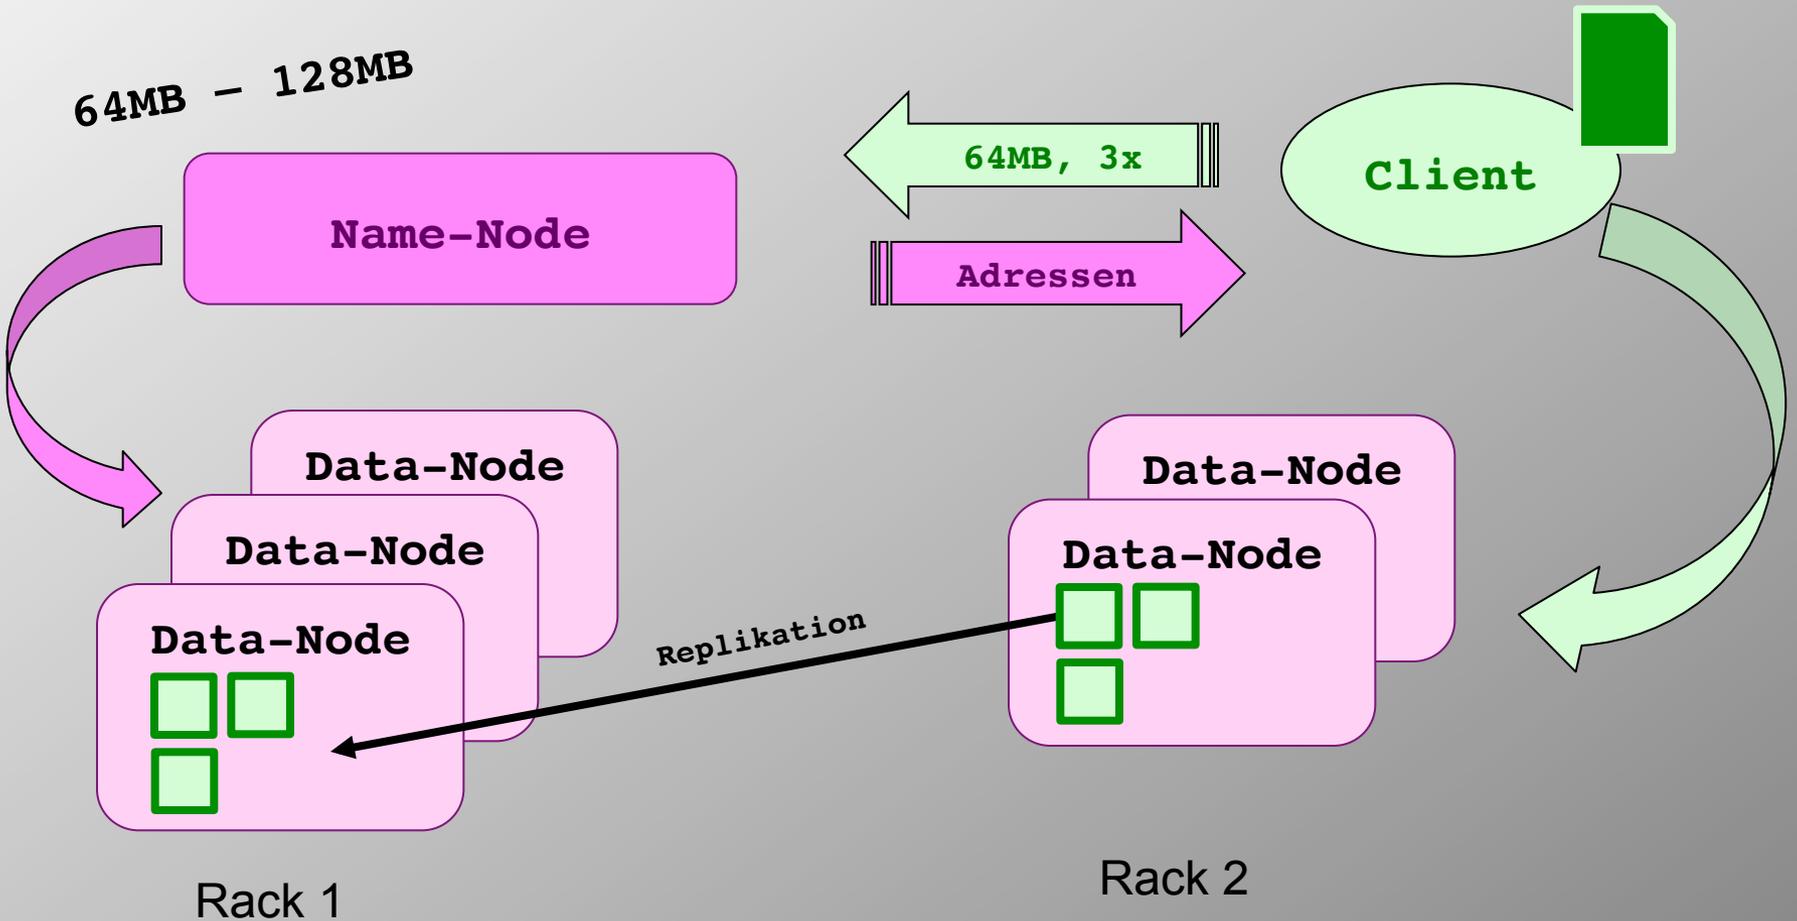
proprietär



Open Source



Wie wird die Idee des GFS im **Hadoop-Distributed-File-System** umgesetzt?



HADOOP - Eco-System

Integration

- Atlas
- Falcon
- Sqoop
- Flume
- Kafka

Werkzeuge

- Zeppelin
- Ambari
- DSX

Datenzugriff

- Map Reduce
- Pig
- Hive
- HBase
- Storm
- Solr
- Spark

YARN

Data Management

- HDFS

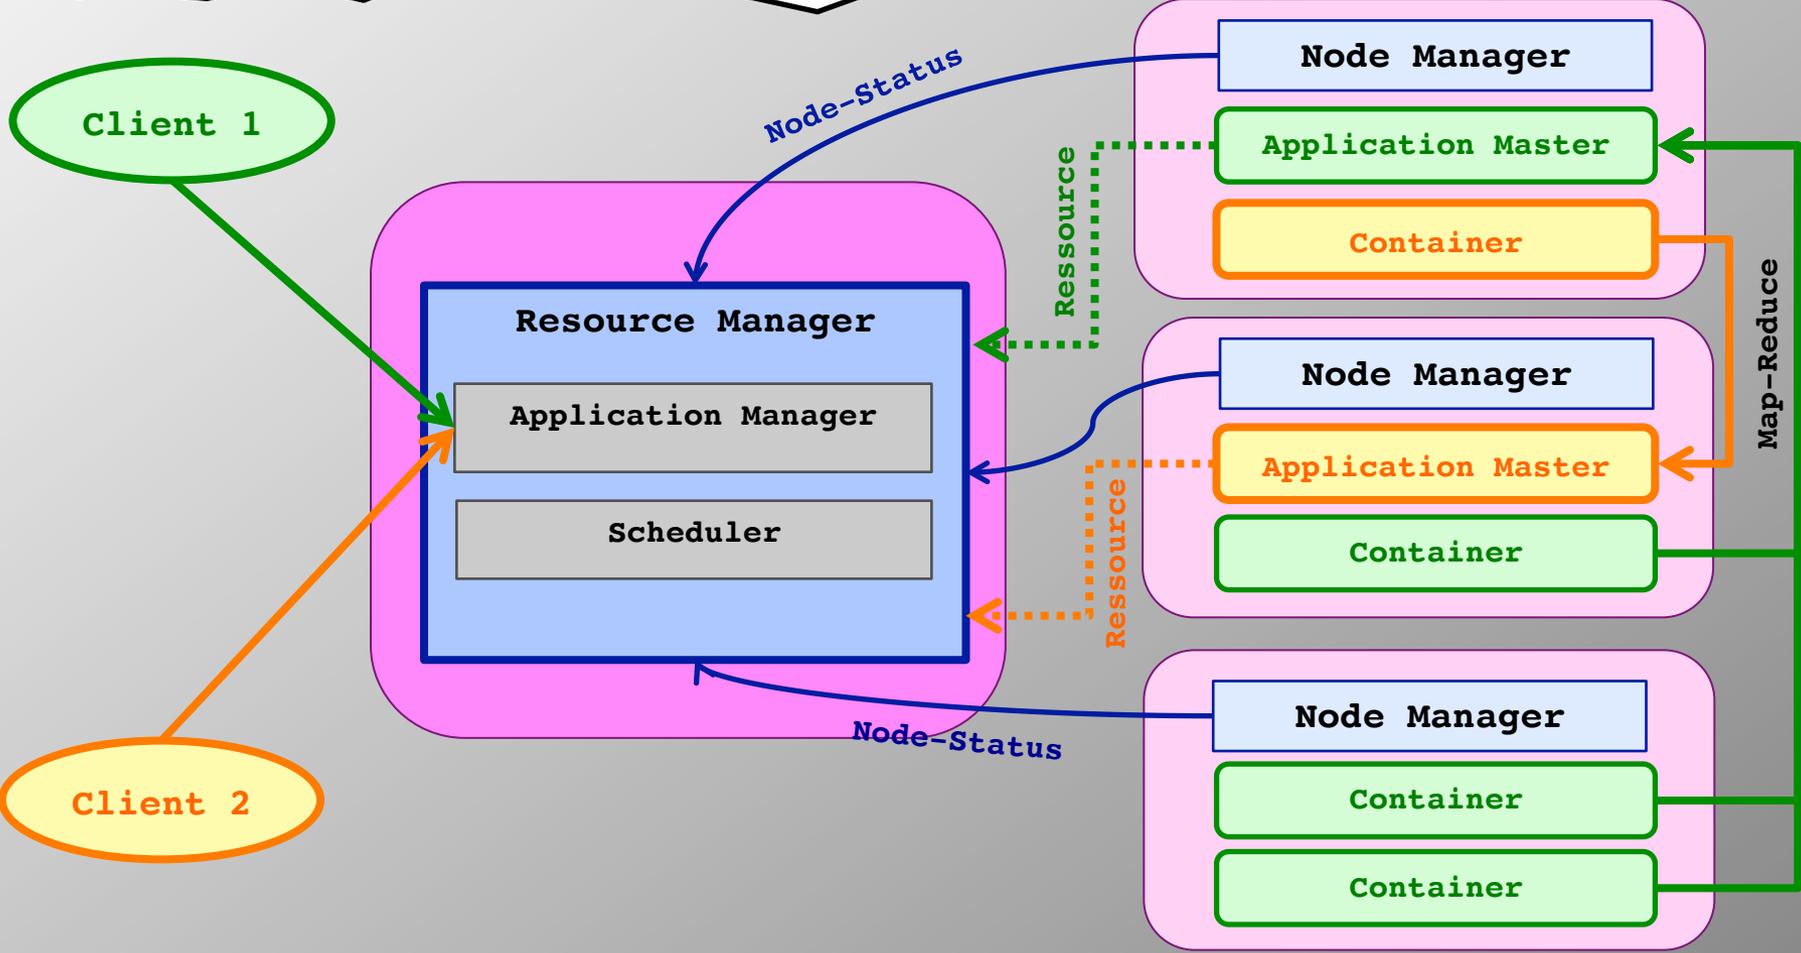
Sicherheit

- Ranger
- Knox
- HDFS Encryption

Betrieb

- Ambari
- Cloudbreak
- ZooKeeper
- Oozie

Erläutern Sie die Aufgabe von **YARN** als Bindeglied zwischender Daten-Management-Schicht und der Datenzugriffsschicht einer HDFS-Anwendung.





Cassandra

- Flexibilität und Skalierbarkeit durch Key / Value
- vertraute Schemasicherheit
- verteilte Architektur

über den Tellerand...

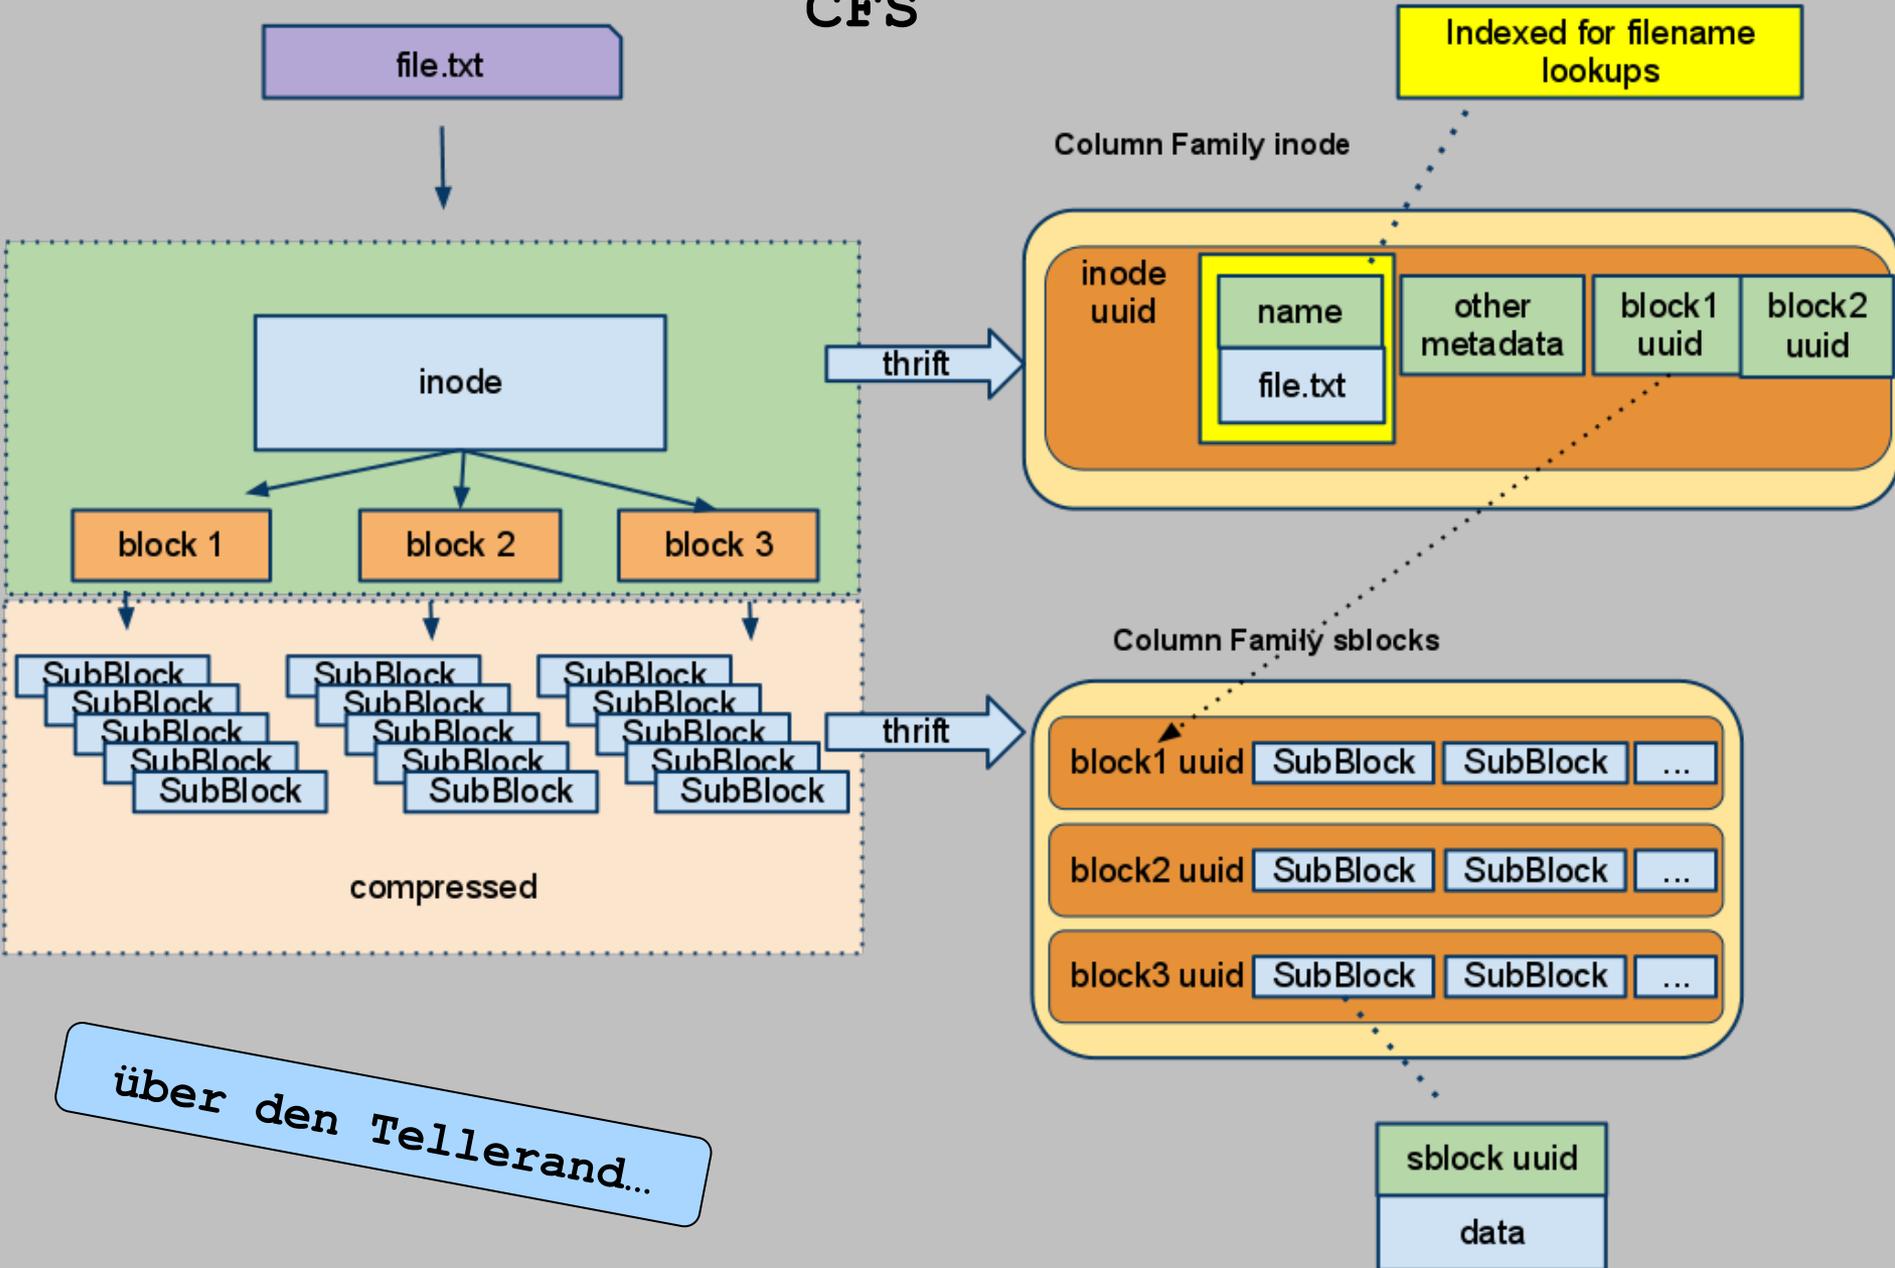
Key / Value	
Wide Column Stores	Graphdatenbanken

Keyspace: WildWest				
CF: Users				
	"Jim"	„reactivity“: "2"		
	"Joe"	„reactivity“: "9"	„nick_name“: "Little Joe"	
CF: Horses				
	"Kelly"	"color": "white"	"owner": "Jim"	
CF: Weapons				
	"Colt"	"ammo": "15"	"owner": "Joe"	
CF: Duels				
	"high_noon"	"player_1": "Jim"	"player_2": "Joe"	"winner": "Joe"
CF: Messages				
	"high_noon_1"	"from": "Joe"	"to": "Jim"	"text": "Loooser!"

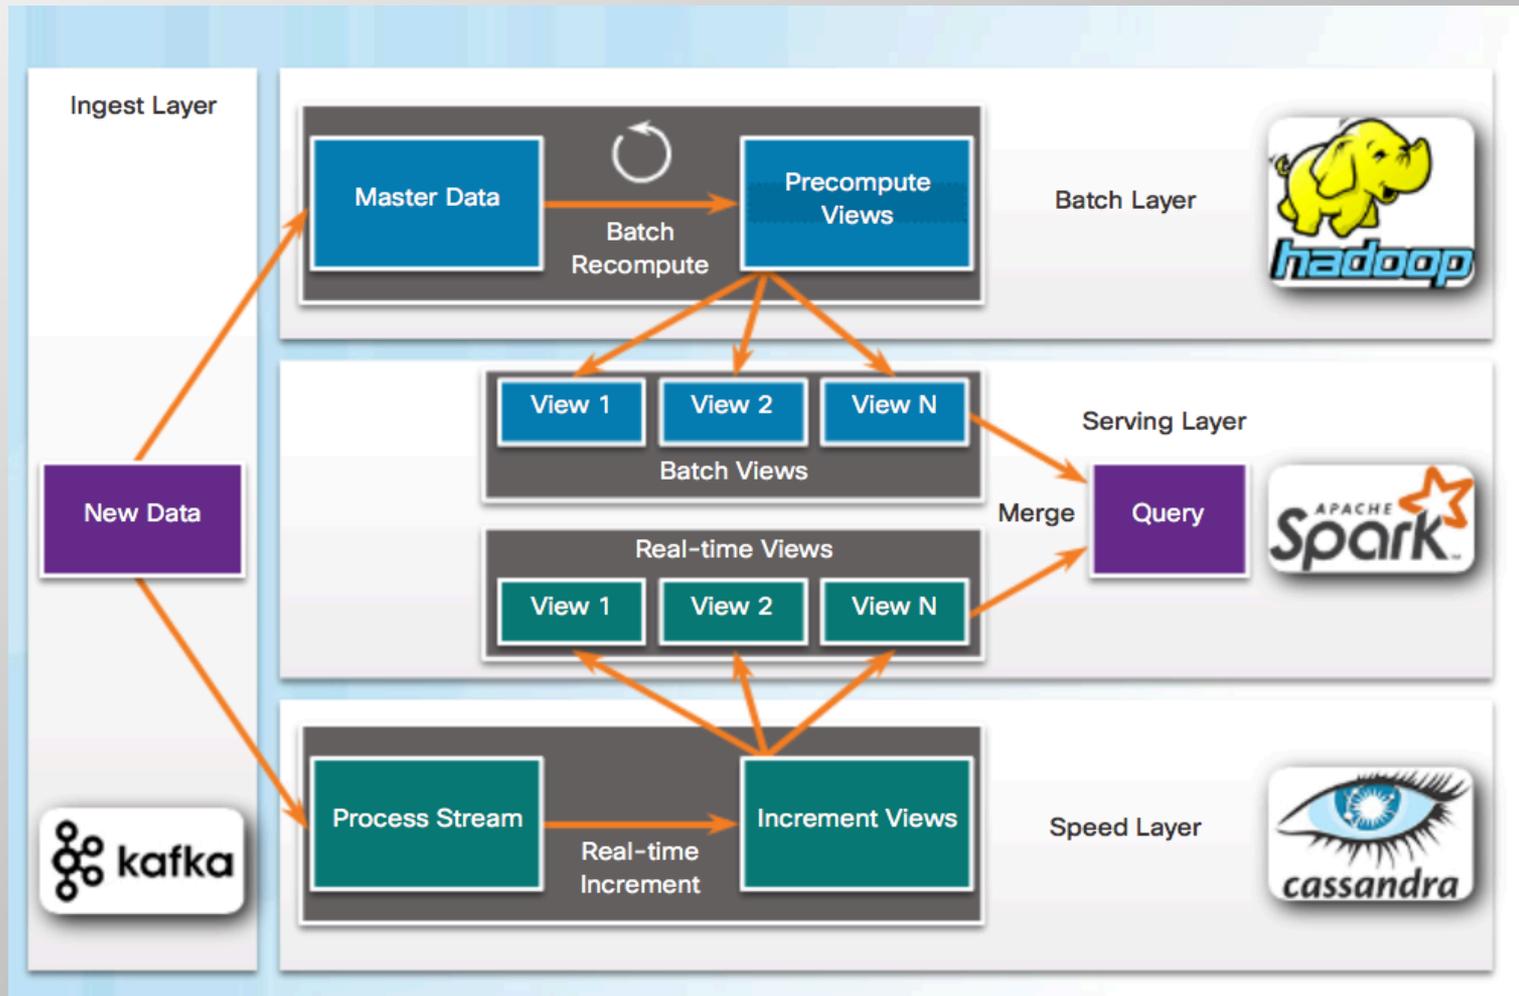
Abbildung 3.2.1 Cassandra-Zustand nach ersten Inserts



CFS



Aus welchen Komponenten besteht eine **Lambda-Architektur**? Skizzieren Sie die Komponenten...



Teil 4:

Big Data im Unterricht

**Big Data ist
fachübergreifend!!!**



1. AJ

JAVA Basics

Packet Tracer,
OSI Modell,
vernetzte Systeme

2. AJ

JAVA OOP,
Android

UML

RDBMS

Packet Tracer,
Protokolle,
CCNA Sem. 1,
Raspberry Pi,
Sensoren,
Virtualisierung

3. AJ

RDBMS - SQL

Big Data Basics

IoT + PT

Python Basics

WANN?



Geführtes Selbststudium & Aufgaben

Big Data & Analytics

Chapter 0

Course Introduction

Chapter 1

Data and the Internet of Things

Chapter 2

Fundamentals of Data Analysis

Chapter 3

Data Analysis

Chapter 4

Advanced Data Analytics and Machine Learning

Chapter 5

Storytelling with Data

Chapter 6

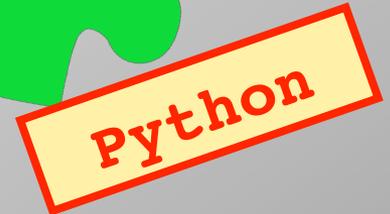
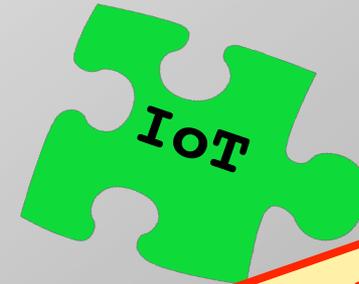
Architecture for Big Data and Data Engineering

WIE?

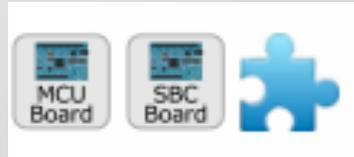
8 Blöcke
mit
je 3 Std.



Ein Packet Tracer, viele Möglichkeiten...



Boards



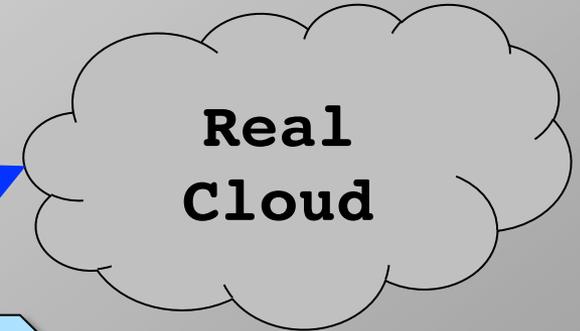
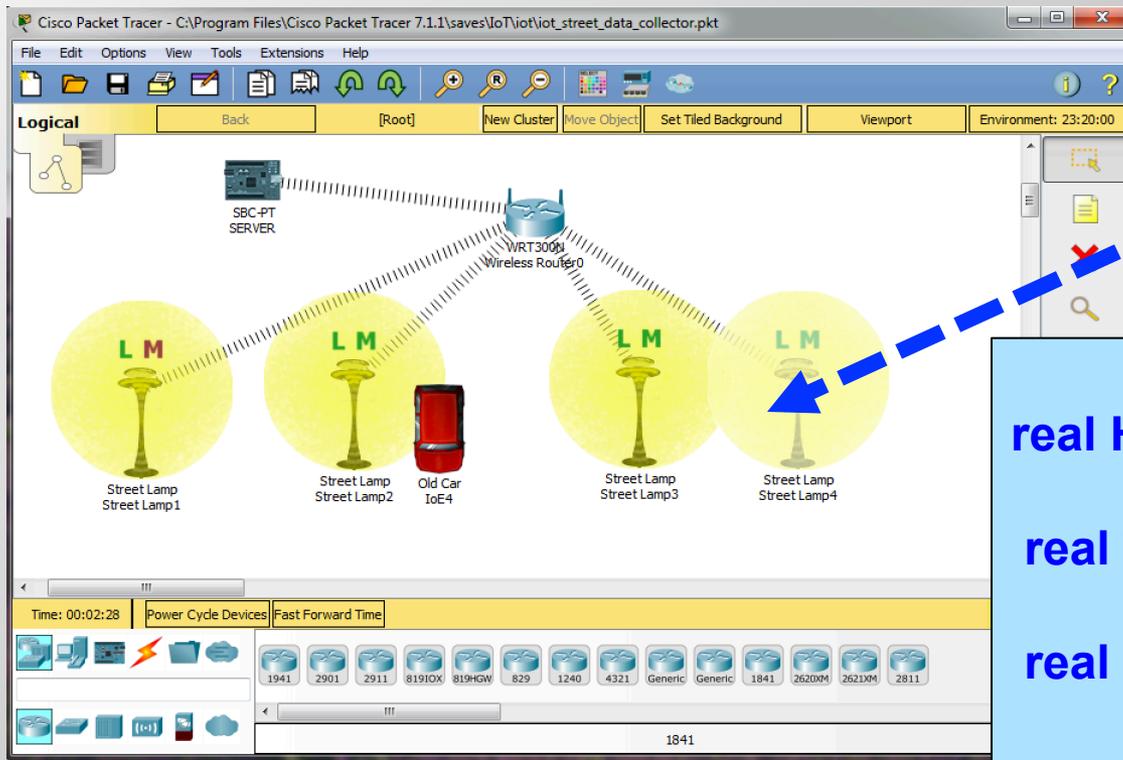
Aktoren



Sensoren



Packet Tracer mit Cloud-Anbindung



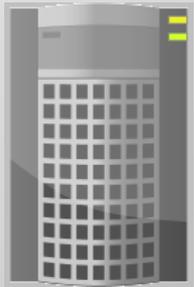
**real HTTP,
real TCP,
real UDP**



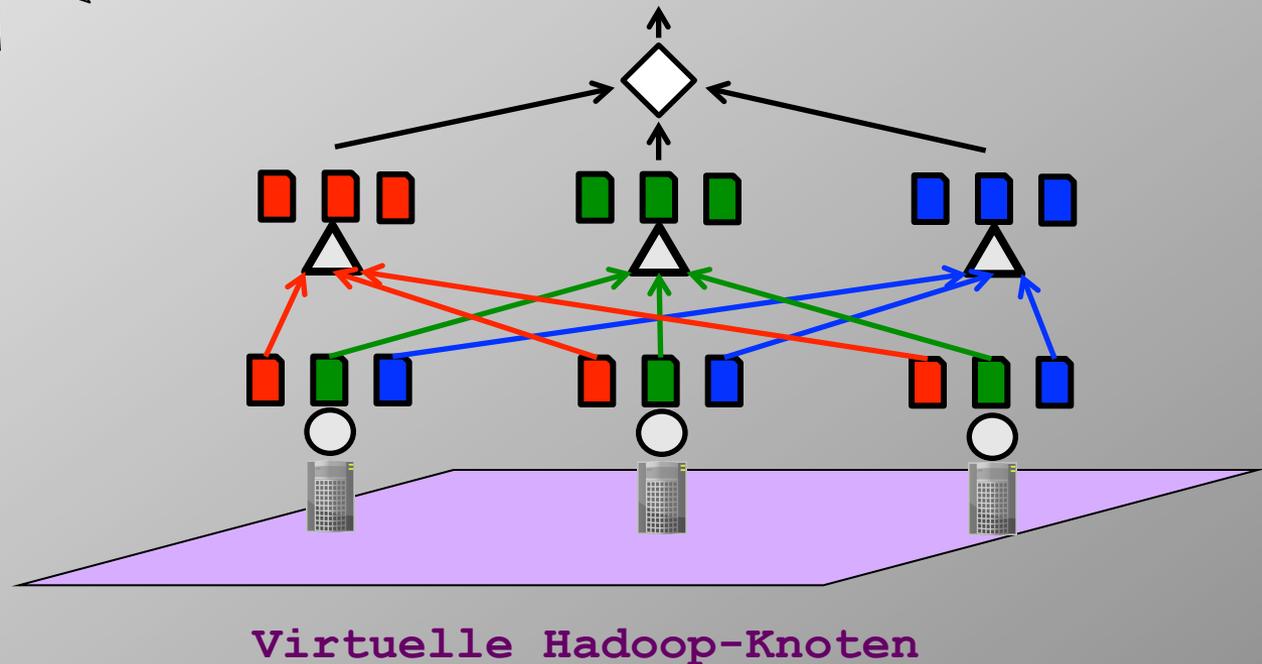
Virtueller Hadoop-Cluster mit Yarn, Map-Reduce im Klassenraum



Primzahlen
Zwischen
1 und 300.000



Hadoop
Master



Auszug aus dem Lehrplan...

ANWENDUNGSENTWICKLUNG/PROGRAMMIERUNG

Jahrgangsstufe 12

Fachrichtung: Systemintegration

Lernfeld

77 Std.

**Entwickeln und Bereitstellen von Anwendungssystemen –
Schwerpunkt: Datenbankanwendungen**

ANWENDUNGSENTWICKLUNG/PROGRAMMIERUNG

Jahrgangsstufe 12

Fachrichtung: Anwendungsentwicklung

Lernfeld

165 Std.

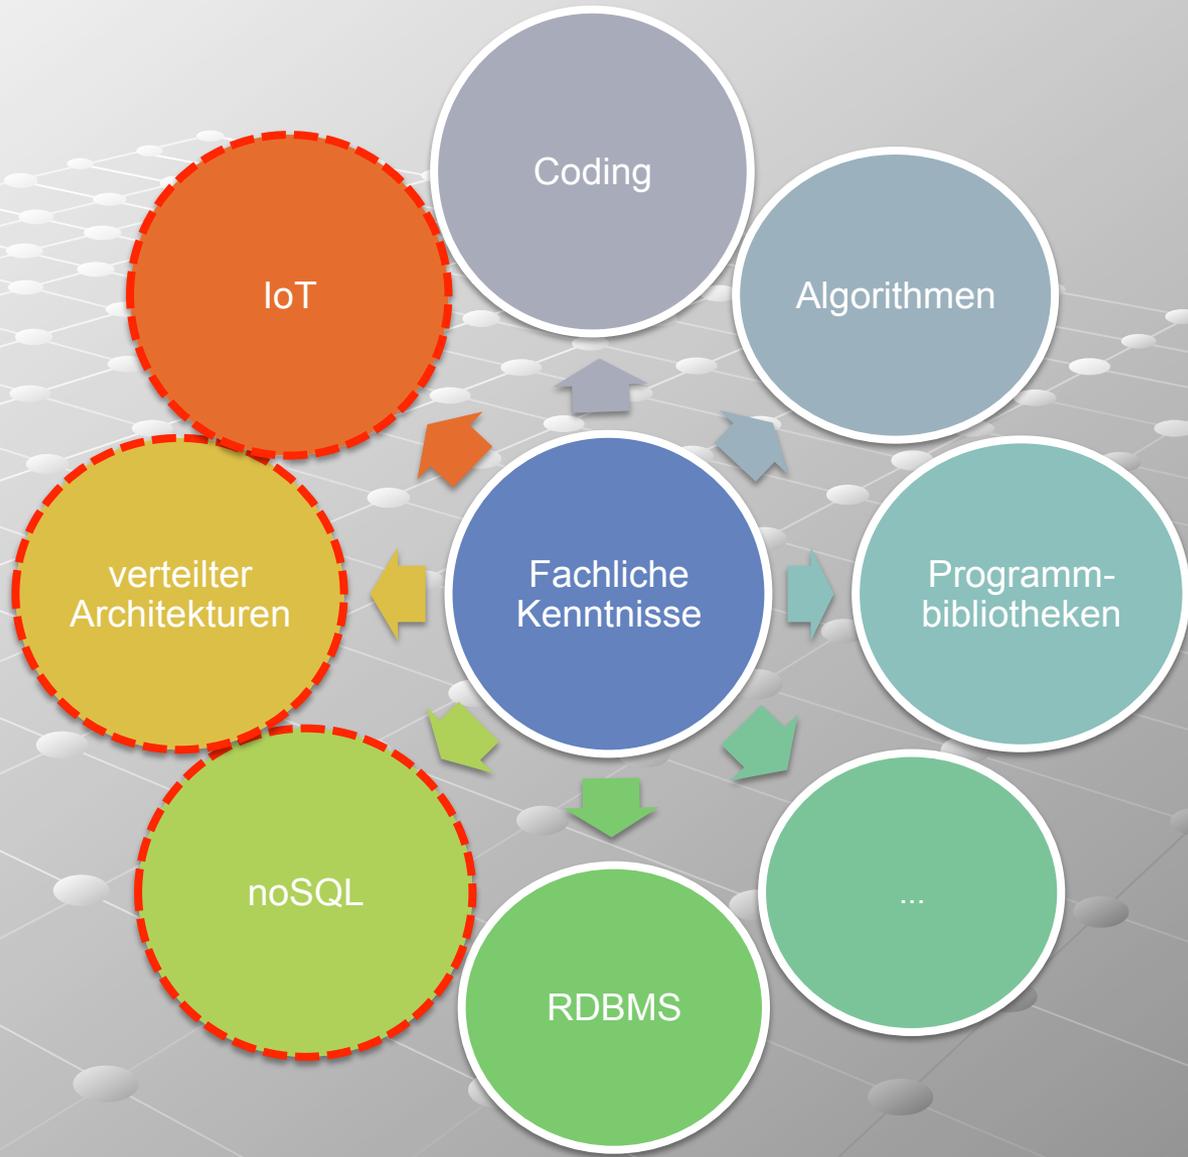
**Entwickeln und Bereitstellen von Anwendungssystemen –
Schwerpunkt: Programmentwicklungsmethoden, Programmierung
und Datenbankkonzepte**

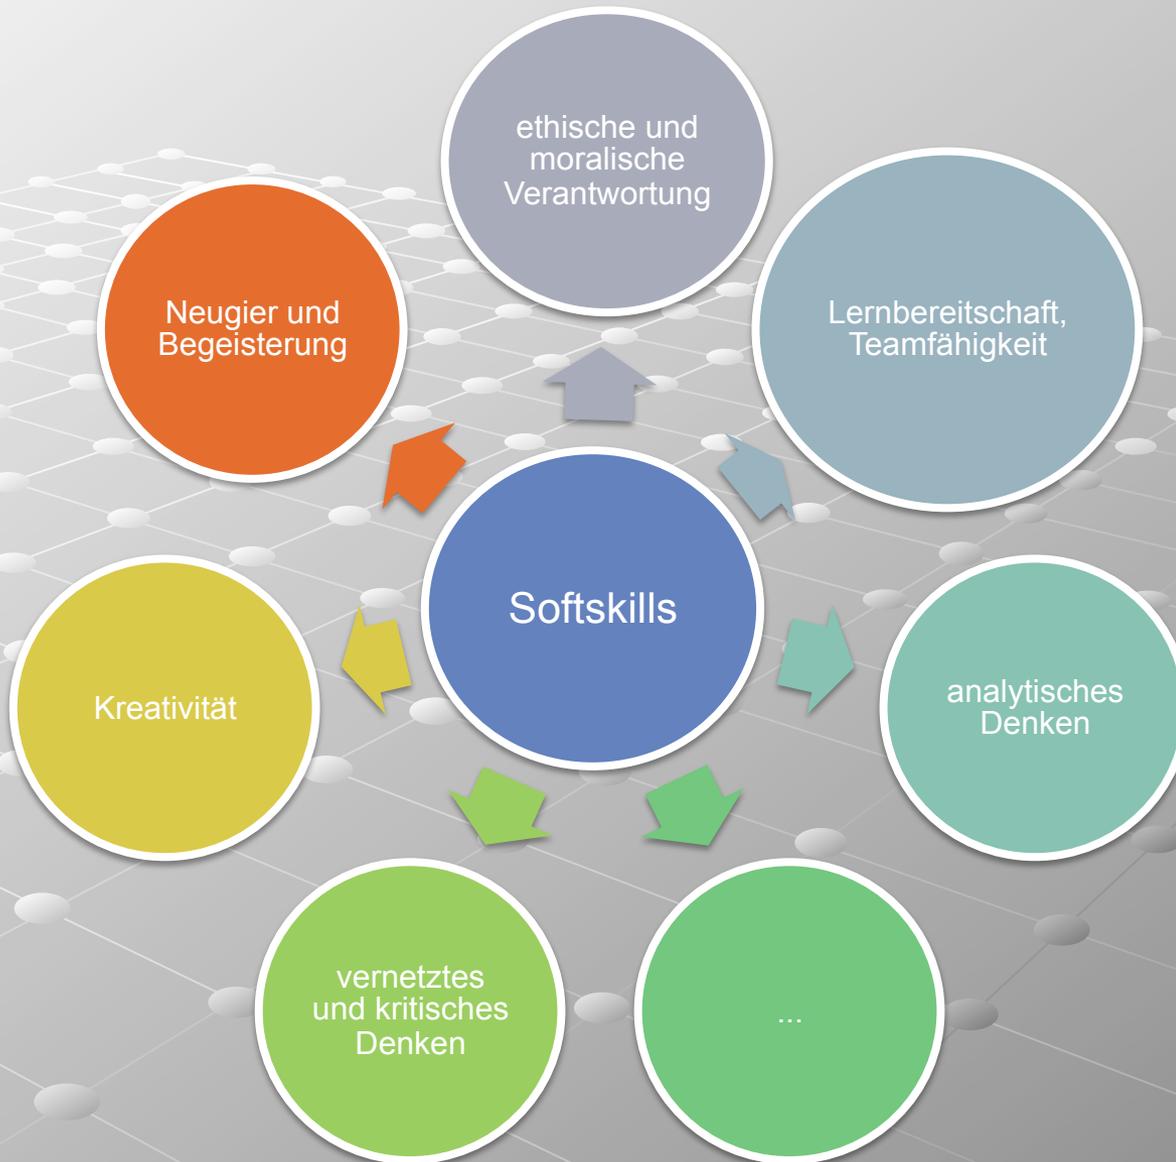
Ziele

Die Schülerinnen und Schüler wenden für das Entwickeln von Anwendungssystemen eine Programmierungsmethode an und erstellen die (Anwendungs-)Programme auf der

n eine
kanter
ng an
eise zu
ines
an-







Appendix A:

**Big Data Analyse, Daten-
auswertung, Visualisierung**

Today: out of scope



Datenanalyse und Visualisierung

Grundlagen

- Was ist Datenanalyse
- Big Data verarbeiten
- unterschiedliche Datenquellen
- Daten verarbeiten
- ethische Verantwortung und Bedenken

Datenanalyse

- Statistik
- Verteilungen und Merkmale von Daten
- beschreibende Statistik
- Korrelationen

Machine Learning

- Vorhersagen
- Modell-Abschätzungen

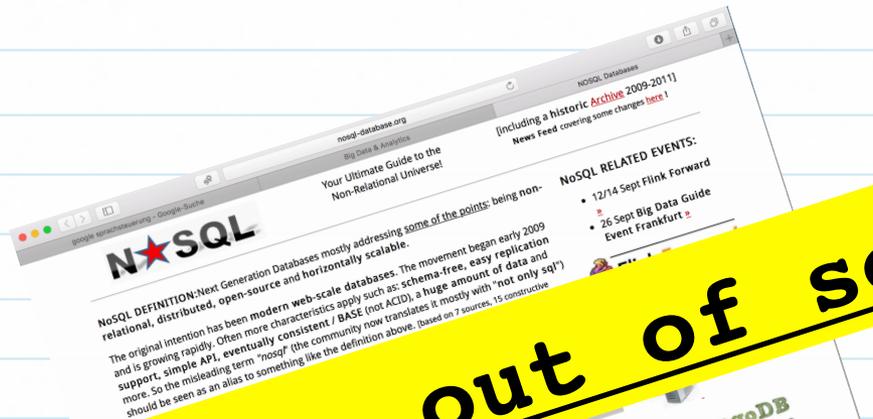
Storytelling mit Daten

- Hypothesen und Nachweise
- Visualisierungs-Werkzeuge
- geeignete Visualisierungen



Appendix B:

noSQL – Datenbanken



Today: out of scope

Hadoop / HBase APL Java / any writer, Protocol: any write call, Query Method: MapReduce java / any exec, Replication: HDFS replication, Written in: Java, Concurrency: ?, Misc Links: 3 Books [1, 2, 3], Article >>

MapR, Hortonworks, Cloudera Hadoop Distributions and professional services.

Cassandra massively scalable, partitioned row store, masterless architecture, linear scale performance, no single points of failure, read/write support across multiple data centers & cloud availability zones, API / Query Method: CQL and Thrift, replication: peer-to-peer, written in: Java, Concurrency: tunable consistency, Misc: built-in data compression, MapReduce support, primary/secondary indexes, security features. Links: [Documentation](#), [Planet](#), [Company](#).

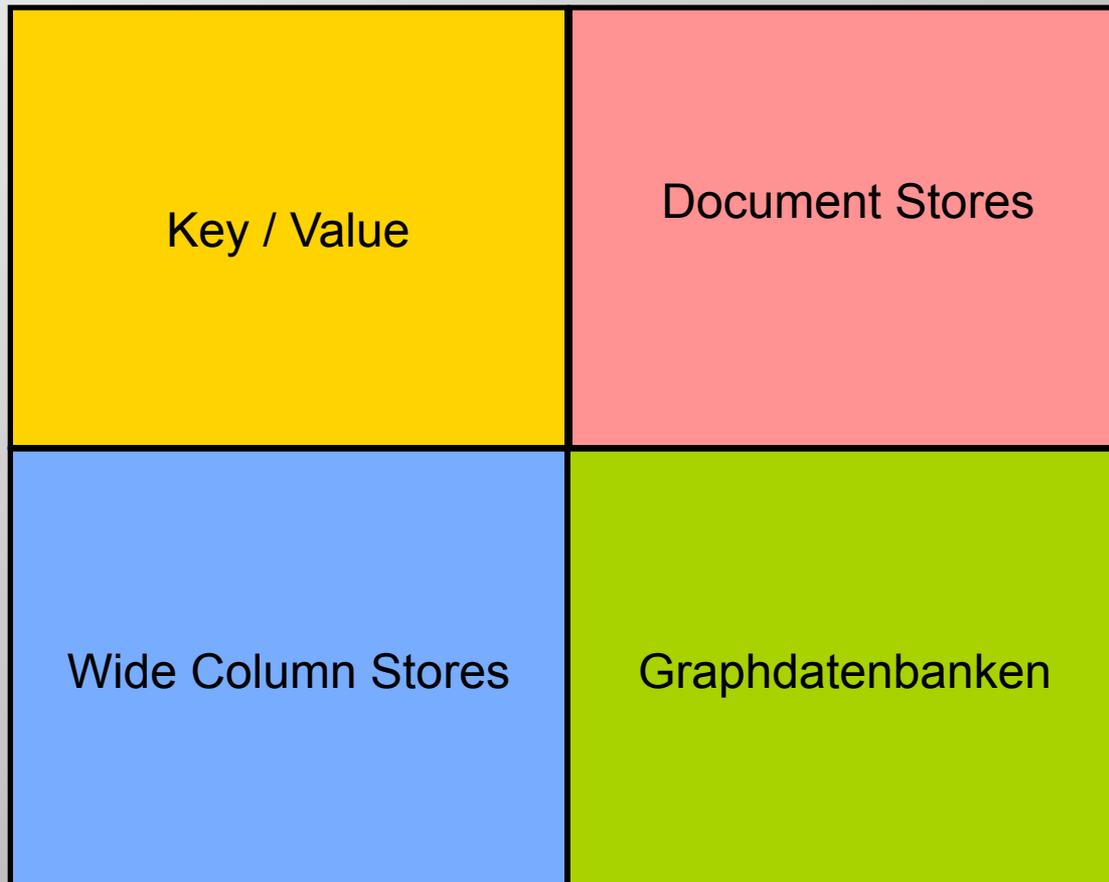
ArangoDB
the multi-model NoSQL DB

NoSQL FORUMS

- Global NoSQL Forum
- Forum Berlin
- Forum France



In welche vier Kategorien werden NoSQL – Kernsysteme eingeteilt?



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value	Document Stores
Wide Column Stores	Graphdatenbanken

- **Daten:** Schlüssel / Wert - Paare
- **Schlüssel sind:** Datenbanken, Namensräume, Attribute
- **Werte :** Zeichenketten aber auch Hashes, Listen oder Mengen
- **Vorteil:** einfaches Datenmodell
- **Nachteil:** Mächtigkeit der Abfragesprache oft gering (hier muss man sich auf die API verlassen)



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value	Document Stores
Wide Column Stores	Graphdatenbanken

```
SET server:name "bs1in"
```

```
GET server:name => "bs1in"
```

```
RPUSH friends "Tom"
```

```
RPUSH friends "Bob"
```

```
LPUSH friends "Sam"
```

```
LRANGE riends 1 2 => ["Tom","Bob"]
```

```
LLEN friends => 3
```

```
LPOP friends => "Sam"
```

```
RPOP friends => "Bob"
```

```
LLEN friends => 1
```

...ein kleines API
Beispiel...



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value	Document Stores
Wide Column Stores	Graphdatenbanken

- **Daten:** Informationen werden als Dokument abgelegt.
- **Dokument:** Strukturierte Datensammlung JSON, BSON, YAML, RDF (**R**essource **D**escription **F**ramework).
- **Identifizierung:** Jedes Dokument erhält eine ID.
- **Vorteil:** Die Verantwortung für das Dokumenten-Schema liegt in der Anwendung. Erweiterungen sind kein Problem.
- **Nachteil:** keine referenzielle Integrität, keine Normalisierung.



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value

Document Stores

RavenDB

Wide Column Stores

Graphdatenbanken

Java **S**cript **O**bject **N**otation

```
{  
  "Performers": ["Rebekka Bakken"],  
  "Composers": [],  
  "Title": "If Only",  
  "Album": "Art of How to Fall",  
  "Duration": "00:03:42.574000",  
  "Genre": "Pop"  
};
```



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value

Document Stores

Wide Column Stores

Graphdatenbanken

- **Daten:** spaltenorientiert, d.h. pro Attribut wird eine Tabelle verwendet.
- **Vorteil:** gute Analyse und einfache Aggregation der Daten, Verwendung in OLAP- und Data-Warehouse-Umgebungen.
- **Nachteil:** Suche und das Einfügen von Daten ist aufwendiger.



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value

Document Stores

Wide Column Stores

Graphdatenbanken

- Speicherung von Informationen erfolgt in **Knoten** und **Kanten**
- **Property-Graphen** bieten die Möglichkeit, Knoten und Kanten mit Eigenschaften zu versehen.
- **Anwendungsbereiche**: Graphen, semantische Netzwerke und Location Bases Services (Smartphones)



Beschreiben Sie die genannten NoSQL-Kategorien.

Key / Value	Document Stores
Wide Column Stores	Graphdatenbanken

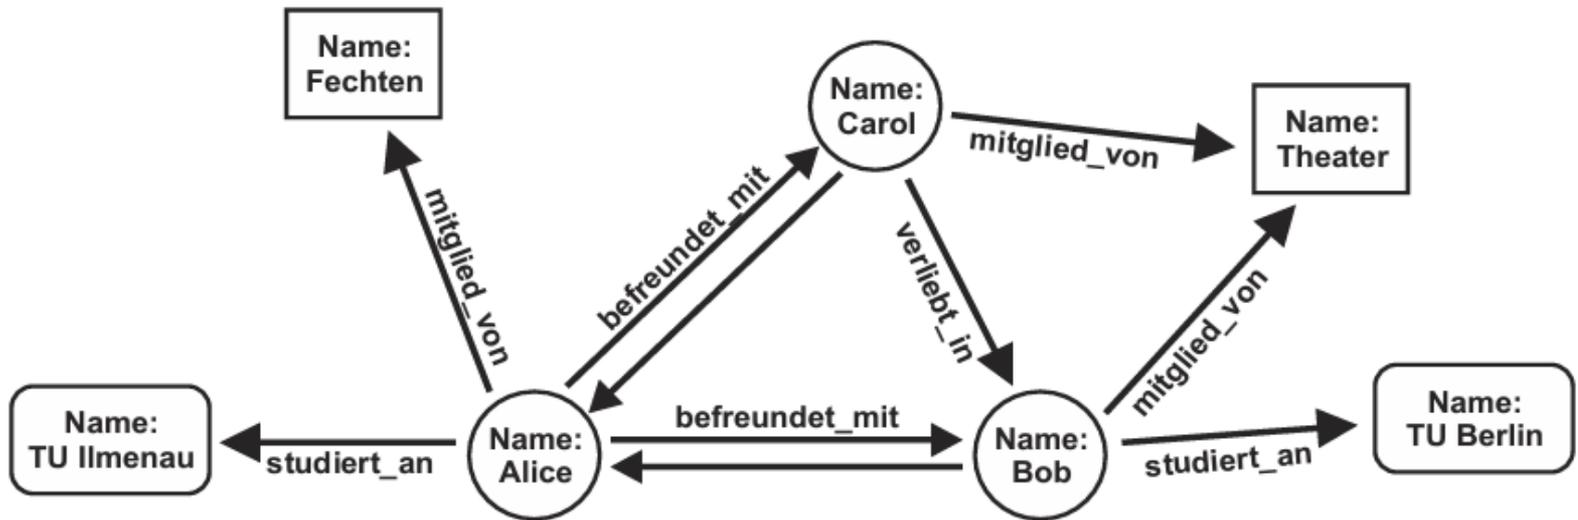
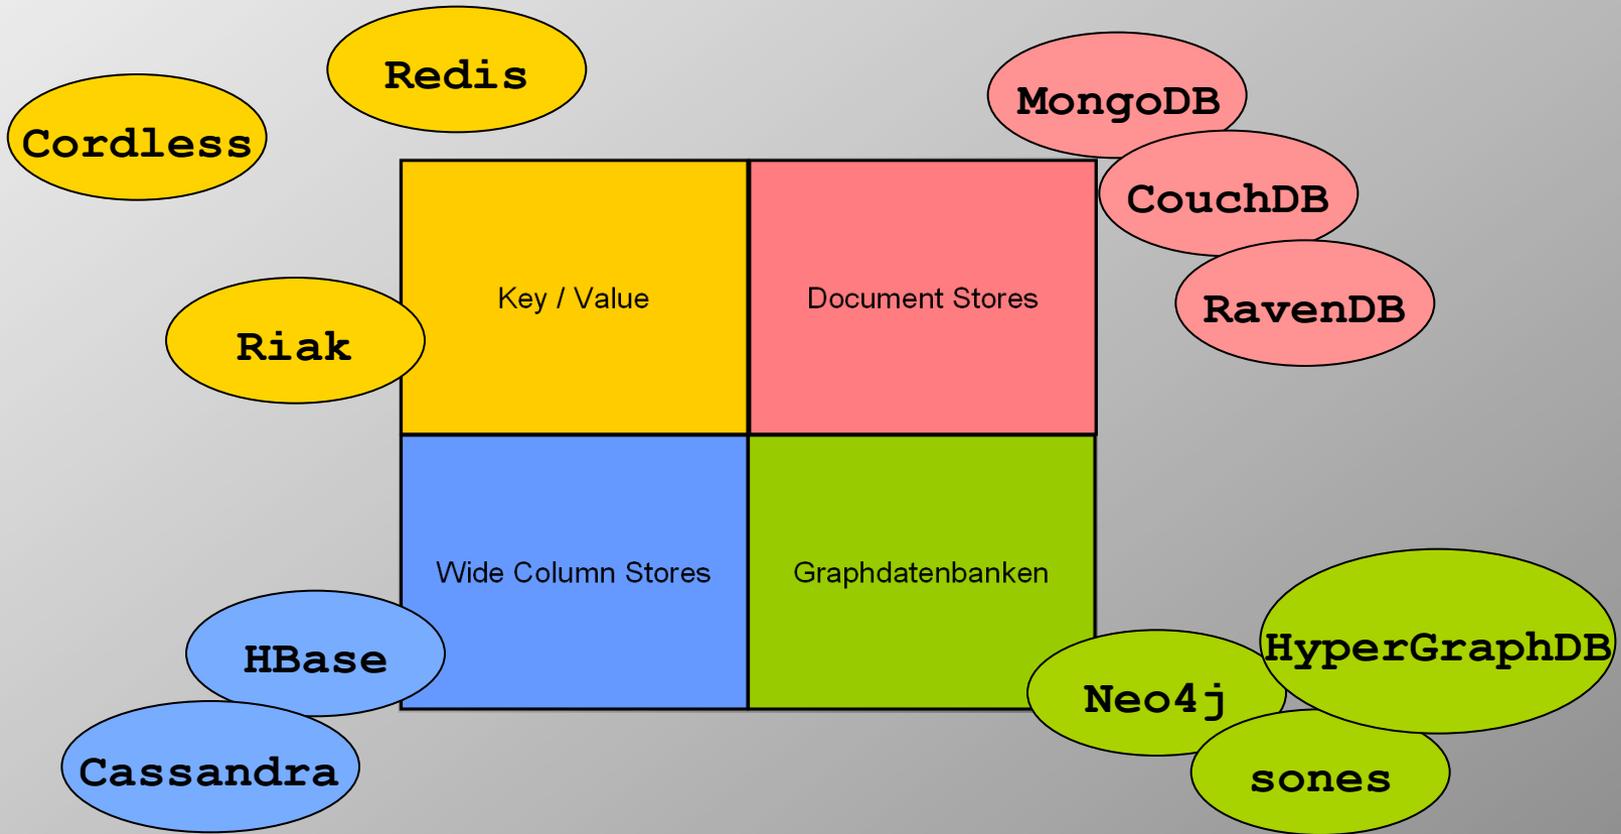


Abbildung 6.1.3 Beispiel eines Property-Graphen anhand eines „sozialen Netzes“

[sones GraphDB VisualGraph Tool](#)



Ordnen Sie wichtige NoSQL-Datenbanken den Kategorien zu.



Welche Konzepte stehen bei NoSQL-Datenbanksystemen im Vordergrund? Erklären Sie in diesem Zusammenhang den Begriff BASE.



Datenmodell ist nicht relational

Keine Speicherung in herkömmlichen Tabellen

Datenbank ist schemafrei

oder hat nur schwächere Schemarestriktionen

verteilte Systeme

einfache Replikationsmechanismen

horizontale Skalierbarkeit

Server-Cluster

einfache API

Open Source



Vergleichen Sie die Konsistenzmodelle ACID (RDBMS) und BASE (noSQL).

A: atomicity

C: consistency

I: isolation

D: durability

B: } basically

A: } available

S: soft state

E: eventually consistent

Konsistenz
(pessimistisch)

Verfügbarkeit
(optimistisch)



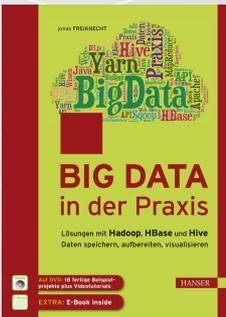


Big Data

Entwicklung und Programmierung von Systemen für große Datenmengen und Einsatz der Lambda-Architektur

[Nathan Marz](#), [James Warren](#)

mitp Professional



Big Data in der Praxis

Lösungen mit Hadoop, HBase und Hive. Daten speichern, aufbereiten, visualisieren

[Jonas Freiknecht](#)

Hanser



NoSQL

Einstieg in die Welt nichtrelationaler Web2.0 Datenbanken

[Stefan Edlich](#), [Achim Friedland](#), [Jens Hampe](#), [Benjamin Brauer](#)

Hanser



research.google.com

[google bigTable](#)

[google file system](#)

Apache Hadoop

[hadoop.apache.org](#)

Hadoop Ecosystem

[de.hortonworks.com](#)

Big Data im Web

[Big Data auf Wikipedia](#)

NoSQL im Web

[www.nosql-database.org](#)

DB-Engines

[db-engines.com](#)



**Vielen Dank für Ihre
Aufmerksamkeit**

