

8. Big Data und NoSQL-Datenbanken

■ Einleitung Big Data

- Herausforderungen
- Analyse-Pipeline
- Einsatzbereiche

■ Systemarchitekturen für Big Data Analytics

- Hadoop, MapReduce, Spark/Flink

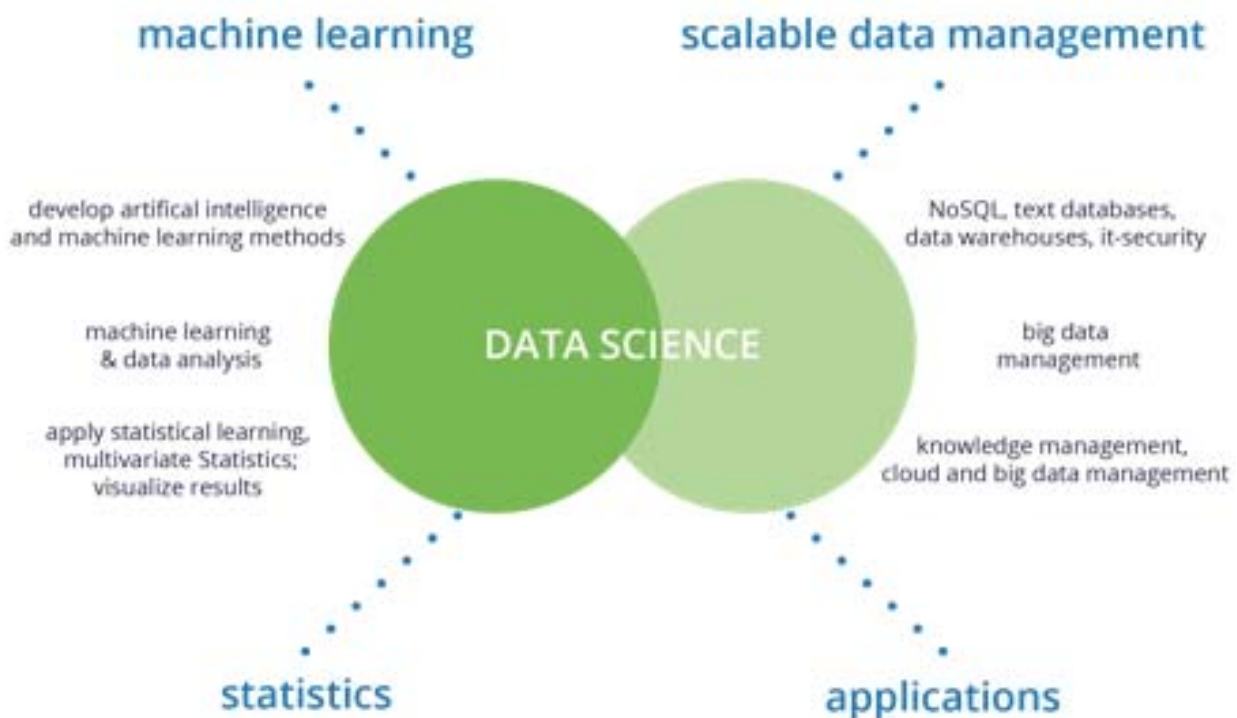
■ NoSQL-Datenbanken

- Eigenschaften
- Document Stores (MongoDB)
- Graph-Datenbanken (neo4J)

■ parallele/verteilte Graphanalysen / Gradoop




DATA SCIENCE



Wie groß ist Big Data?

■ Big wandelt sich schnell

- Gigabytes,
- Terabytes (10^{12}),
- Petabytes (10^{15}),
- Exabytes (10^{18}),
- **Zettabytes (10^{21})**,
- Yottabytes (10^{24}),
- Brontobytes (10^{27}),
- ...



geschätztes Datenaufkommen in Zettabytes

Quelle: Statista



Welche Art von Daten?

■ Unternehmensdaten

- strukturierte Daten (Datenbanken, Data Warehouses) mit Angaben zu Personal, Kunden, Bestellungen, Rechnungen ...
- Dokumente, E-Mails

■ Web-Daten

- Web-Seiten + Multimedia-Inhalte (Videos, Fotos, ...)
- Click Logs

■ soziale Netzwerke / Kommunikationsplattformen (Facebook, Twitter, LinkedIn, ...)

- Nutzer, Beziehungen, Nachrichten, Multimedia-Inhalte

■ Sensor-Daten / eingebettete Systeme

- vernetzte Produktion/Fertigung (Industrie 4.0)
- „intelligentes“ Haus, Verkehrsüberwachung, ...

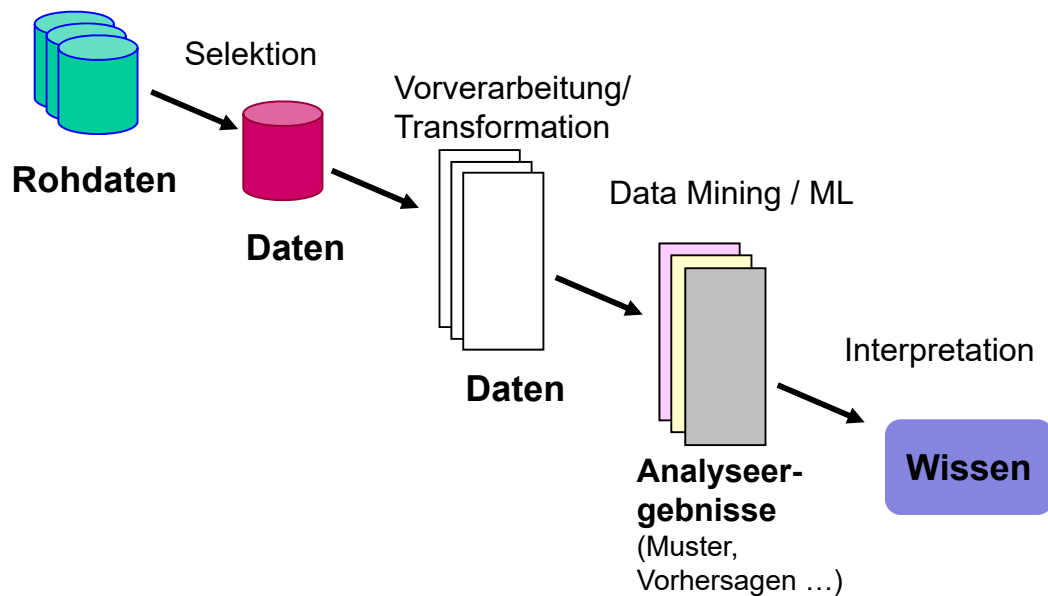
■ umfangreiche und unterschiedliche wissenschaftliche Daten

- z.B. in Klimaforschung, Experimentalphysik, Lebenswissenschaften/Medizin (genetische Daten, Patientendaten mit Röntgen/MRT-Aufnahmen etc.), Sozialwissenschaften (Digital Humanities)

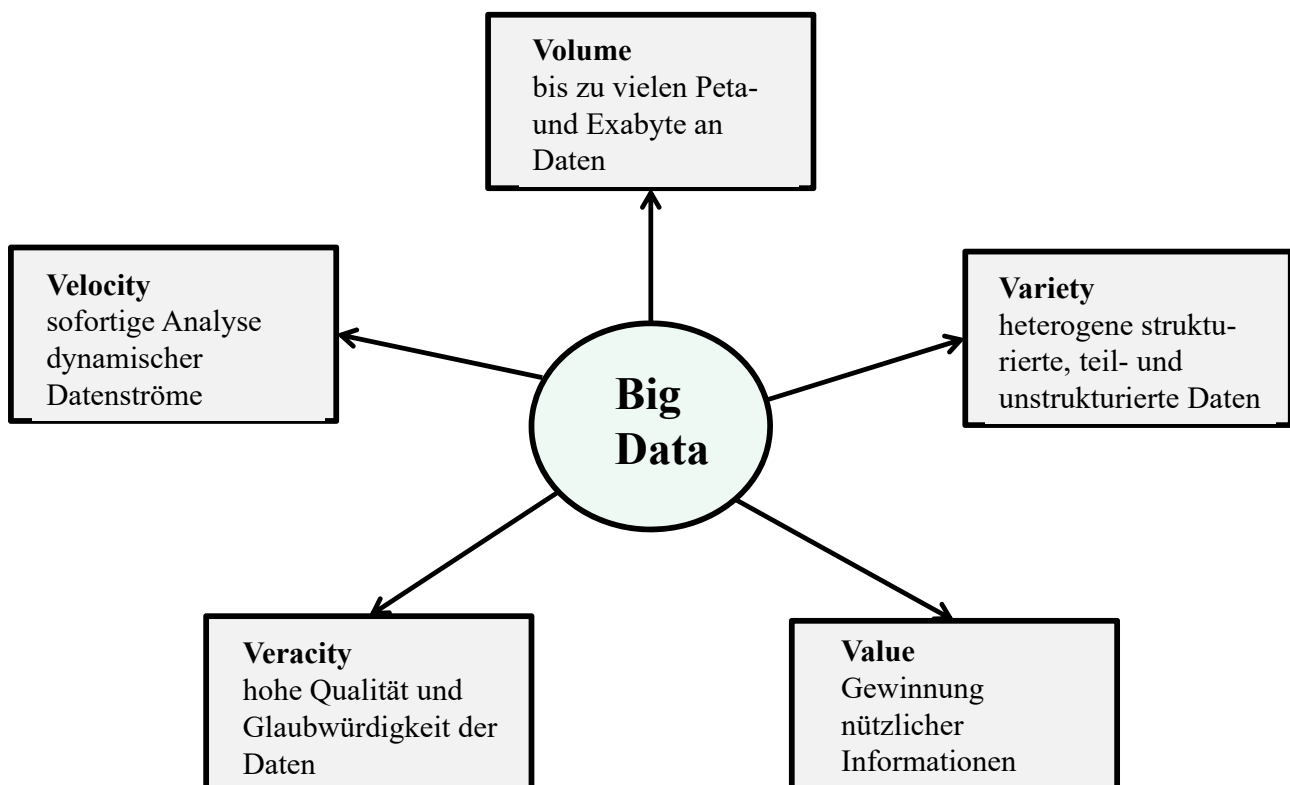


DATENANALYSE / KNOWLEDGE DISCOVERY

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



Big Data Challenges



Potenziale für Big-Data/ML

- Daten sind Produktionsfaktor: „data is the new oil“
 - ähnlich Betriebsmitteln und Beschäftigten
- valide Grundlage für zahlreiche Entscheidungsprozesse
 - Vorhersage/Bewertung/Kausalität von Ereignissen
- verbesserte Analysen / Vorhersagen in zahllosen Anwendungen und Domänen
 - intelligente Werbung und Empfehlungen, Analyse/Optimierung von Produktionsprozessen, Lieferketten, etc.
 - Entdecken krimineller Aktivitäten (Kreditkartenmissbrauch, Hackerangriffe ...)
 - verbesserte/personalisierte Therapien ...
 - Klimavorhersagen ...



Plattformen für Big Data Analytics

- massiv skalierbare Cloud-Architekturen (Shared Nothing)
- Frameworks zur automatischen Parallelisierung datenintensiver Aufgaben (Hadoop, MapReduce, Apache Spark/Flink)



- Parallelverarbeitung auf unterschiedlichen Stufen
 - Data Center (Cluster)
 - Multi-core server
 - Spezialprozessoren: GPUs /FPGAs
- In-Memory Datenbanken / Data Warehouses
- Spezialsysteme für Streaming-Daten, Graph-Daten, ...

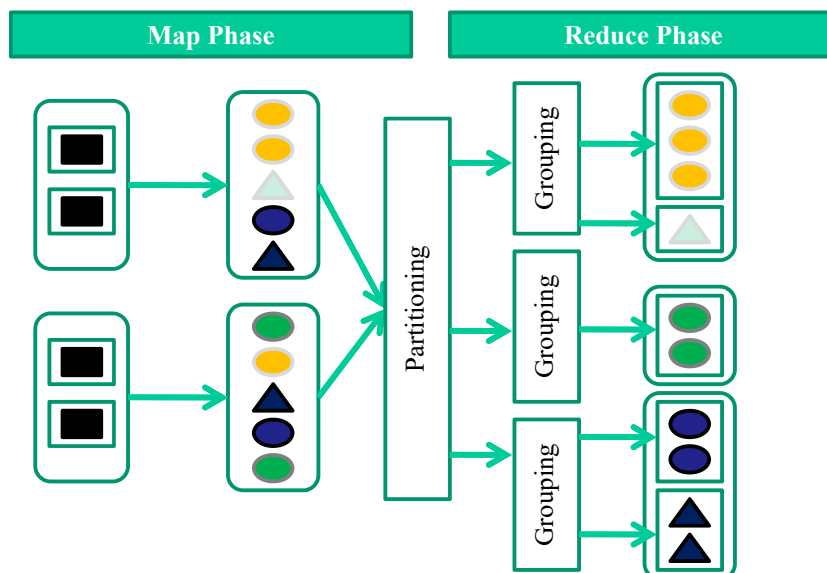


MapReduce

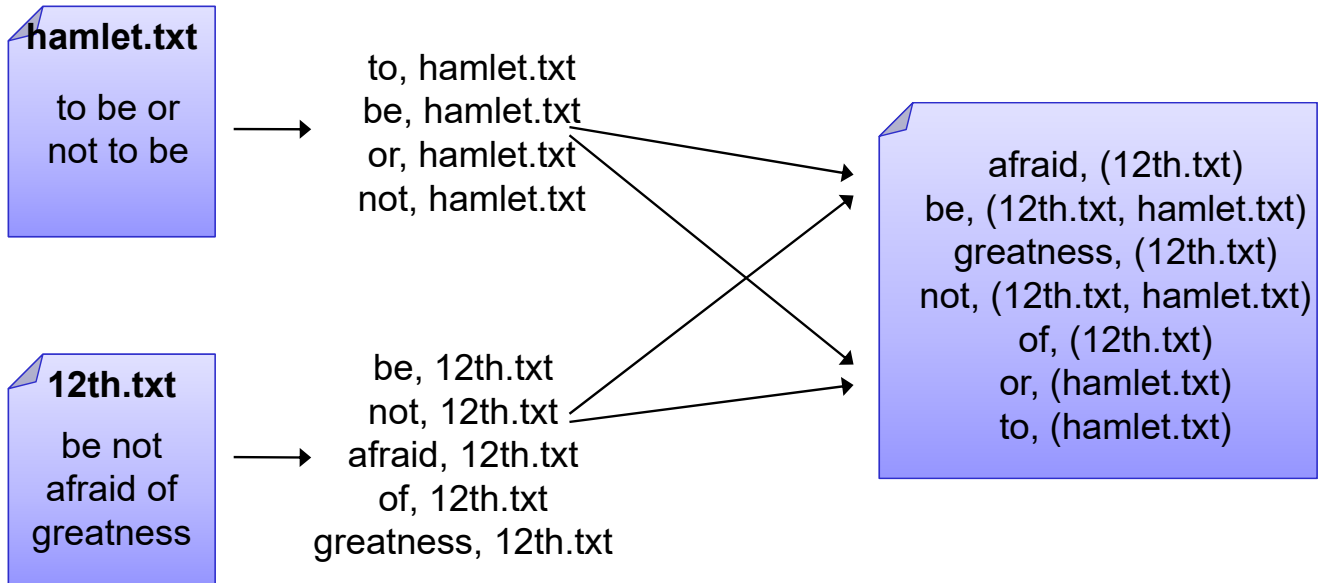
- Framework zur automatischen Parallelisierung von Auswertungen auf großen Datenmengen
 - Entwicklung bei Google
 - populäre Open-Source-Implementierung: Hadoop (seit 2006)
- Nutzung v.a. zur Verarbeitung riesiger Mengen teilstrukturierter Daten in einem verteilten Dateisystem
 - *Konstruktion Suchmaschinenindex*
 - *Clusterung von News-Artikeln*
 - *Spam-Erkennung ...*
- Fokus auf Batch-Verarbeitung

MapReduce

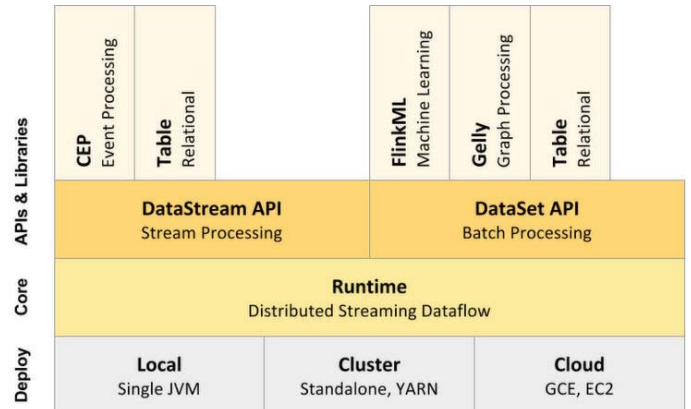
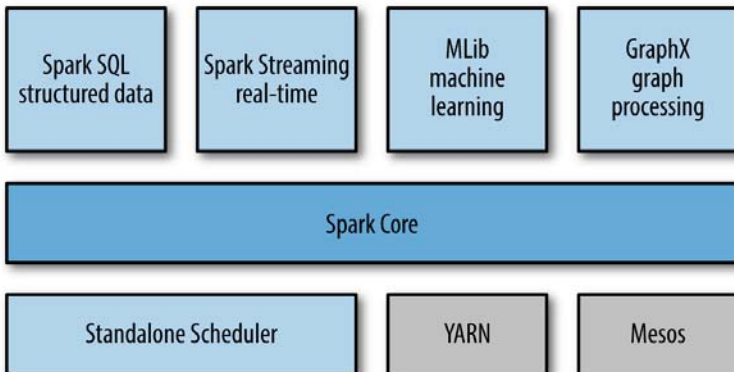
- Verwendung zweier Funktionen: **Map** und **Reduce**
- **Map**-Anwendung pro Eingabeobjekt zur Erzeugung von Key-value Paaren
 - jedes Key-Value-Paar wird einem Reduce-Task zugeordnet
- **Reduce**-Anwendung für jede Objektgruppe mit gleichem Key



MR-Beispiel: Generierung Text-Index



Spark vs Flink



8. Big Data und NoSQL-Datenbanken

■ Einleitung Big Data

- Herausforderungen
- Analyse-Pipeline
- Einsatzbereiche

■ Systemarchitekturen für Big Data Analytics

- Hadoop, MapReduce, Spark/Flink

■ NoSQL-Datenbanken

- Eigenschaften
- Document Stores (MongoDB)
- Graph-Datenbanken (neo4J)

■ parallele/verteilte Graphanalysen / Gradoop



NoSQL-Datenbanken

Not
Only SQL



Relationale Datenbanken: Pros and Cons

- universelle Verbreitung und auf absehbare Zeit ungefährdet für die meisten DB-Anwendungen
 - SQL: standardisierte, mächtige (deklarative) Query-Sprache
 - ACID
 - reife Technologie
 - automatische Parallelisierung ...
- schema-getrieben (“schema first”)
 - weniger geeignet für semi-strukturierte Daten
 - zu starr für irreguläre Daten, häufige Änderungen
- relativ hohe Kosten, v.a. für Parallele DBS (kein Open-Source System)
- Skalierbarkeitsprobleme für Big Data (Web Scale)
 - Milliarden von Webseiten
 - Milliarden von Nutzern von Websites und sozialen Netzen
- ACID / strenge Konsistenz nicht immer erforderlich



NoSQL-Datenbanken

- Entwicklung seit ca. 2009
 - ursprünglicher Fokus: moderne “web-scale” Datenbanken
- Merkmale
 - nicht-relational
 - verteilt,
 - open-source und
 - horizontal (auf große Datenmengen) skalierbar sind
- weitere Charakteristika:
 - schema-frei
 - Datenreplikation
 - einfache API
 - statt ACID nur BASE (**B**asic **A**vailability, **S**oft state, **E**ventually consistent)
- Koexistenz mit SQL
 - “NoSql” wird als “**N**ot **o**nly **S**ql“ interpretiert



Arten von NoSQL-Systemen

■ Key Value Stores

- Amazon Dynamo, Voldemort, Membase, Redis ...
- Speicherung eines Werts (z.B. BLOB) pro nutzer-definiertem Schlüssel bzw. Speicherung von Attribut/Wert-Paaren
- nur einfache key-basierte Lookup/Änderungs-Zugriffe (get, put)

■ erweiterte Record-Stores / Wide Column Store

- Google BigTable / Hbase, Cassandra, Accumulo ...
- tabellenbasierte Speicherung mit flexibler Erweiterung um neue Attribute

■ Dokument-Datenbanken


- CouchDB, MongoDB ...
- Speicherung semistrukturierter Daten als Dokument (z.B. JSON)

■ Graph-Datenbanken

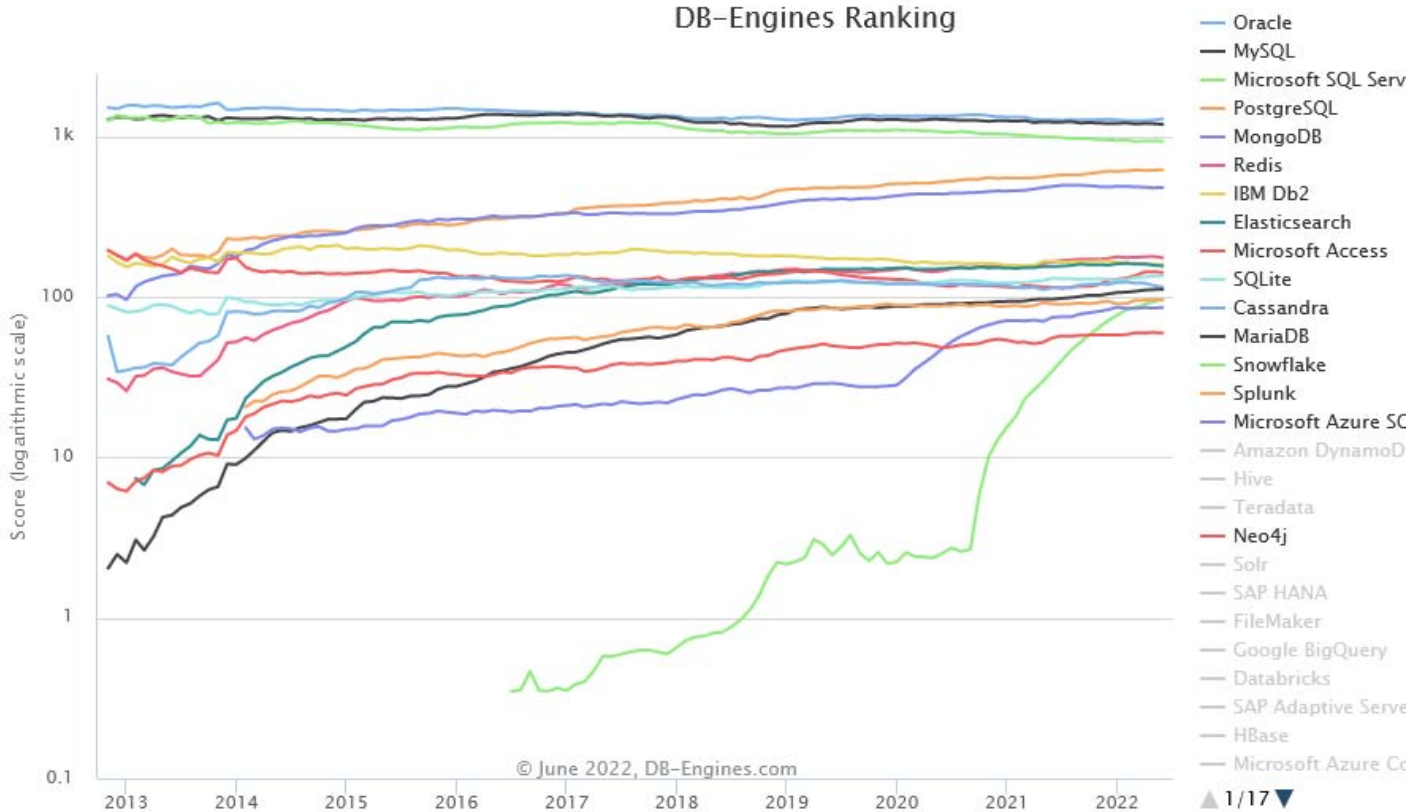
- Neo4J, OrientDB ...
- Speicherung / Auswertung großer Graph-Strukturen



Grobeinordnung NoSQL-Systeme



DB-Engines Ranking




https://db-engines.com/en/ranking_trend



Key-Value Stores

■ Speicherung von Schlüssel-Werte-Paaren

- im einfachsten Fall bleiben Werte systemseitig uninterpretiert (BLOBs)
- flexibel, kein Schema
- günstig für wenig strukturierte Inhalte bzw. stark variable Inhalte, z.B. Twitter-Nachrichten, Webseiten etc.
- keine Verwaltung von Beziehungen



■ schnelle Lese/Schreibzugriffe über Schlüssel


- put (key, value)
- get (key)

■ keine komplexen Queries (z.B. Bereichsabfragen)



Erweiterbare Record Stores

- spaltenorientierte Key-Value Stores mit Erweiterbarkeit über Spaltenfamilien
- Vorbild: Google BigTable
 - Clones: HBase, Cassandra, ...
- Ziele (BigTable):
 - Milliarden von Zeilen, Millionen von Spalten, Versionierung (z.B. für Web-Seiten)
 - einfache Erweiterbarkeit um Spalten (innerhalb vordefinierter *Spaltenfamilien*)
 - mehrdimensionale Keys: Zeilen- und Spalten-Schlüssel, Versionsnr




Row Key	Time Stamp	Column <i>contents</i>	Column Family <i>anchor</i>	
"com.cnn.www"	T9		anchor:cnnsi.com	CNN
	T8		anchor:my.look.ca	CNN.COM
	T6	"<html>.. "		
	T5	"<html>.. "		



MongoDB



- **Dokumenten-Store** mit bereits hoher Verbreitung
 - open source-Version verfügbar
 - JSON-Dokumente, gespeichert als BSON (Binary JSON)
- DB besteht aus Kollektionen von Dokumenten
- einfache Anfragesprache
 - Indexierung von Attributen möglich
 - Map/Reduce-Unterstützung
- Skalierbarkeit und Fehlertoleranz
 - Skalierbarkeit durch horizontale Verteilung der Dokumentkollektionen unter vielen Knoten ("Sharding")
 - automatische Replikation mit Konsistenzwahrung
- kein ACID, z.B. bzgl Synchronisation
 - Änderungen nur bzgl einzelner Dokumente atomar



Beispiel: relational vs. dokumentenorientiert

Relational

STUDENTS	
sno	name
1	Peter
2	Tom

POSTS		
postID	topic	pdate
p1	NoSQL	01-09-2021
p2	RelationalDB	02-09-2021

COMMENTS				
commentID	postID	sno	content	cdate
c1	p1	1	Excellent	02-09-2021
c2	p1	2	I do not understand.	03-09-2021
c3	p1	1	This is a good idea!	04-09-2021

MongoDB (JSON)

```
{topic: 'NoSQL',
pdate: 01-09-2021,
comments : {{name: 'Peter',
content: 'Excellent',
cdate: 02-09-2021},
{name: 'Tom',
content: 'I do not understand.',
cdate: 03-09-2021},
{name: 'Peter',
content: 'This is a good idea!',
cdate: 04-09-2021}}
}
```

- geschachtelte Komponenten (ähnlich XML)
 - keine Beziehungen zwischen Dokumenten (-> keine Joins)
 - Redundanz bei n:m-Beziehungen
 - schemaflexibel



MongoDB: Operationen

RDB		MongoDB
SELECT * FROM students;	↔	db.students.find();
INSERT INTO students ...;	↔	db.students.insert(...);
UPDATE students ...;	↔	db.students.update(...);
DELETE FROM students ...;	↔	db.students.remove(...);
...	↔	...

■ Beispiele:

```
> db.students.insert({sno: 1, name: 'Peter'});
```

```
> db.posts.insert({topic: 'NoSQL', pdate: ...});
```

```
student_a={sno:731, name:'Irving Bonce', address:
```

```
{street:'38 Glenpark Ave',
city:'Dunedin',
phone:4535467}};
```

```
> db.students.save(student_a);
```

```
> db.students.find();
```

```
{_id:1, sno:731, name:'Irving Bonce', address:
{street:'38 Glenpark Ave',
city:'Dunedin',
phone:4535467}}
```



MongoDB: Operationen (2)

```
# find the student whose name is "Stephen Hong"
> db.students.find({name: 'Stephen Hong'});

# find all students whose last name is 'Hong'
> db.students.find({name: /Hong$/});

# find all students who live in Canberra
> db.students.find({address.city: 'Canberra'});

# count the number of students
> db.students.count();

# find all students who enrolled courses either "SP03" or "SP04"
> db.students.find({courses: {$in: ['SP03', 'SP04']}},
                  {sno: 1, name: 1});

# find all students whose ages are below 20
> db.students.find({age: {$lt: 20}});
```



Graph-Datenbanken

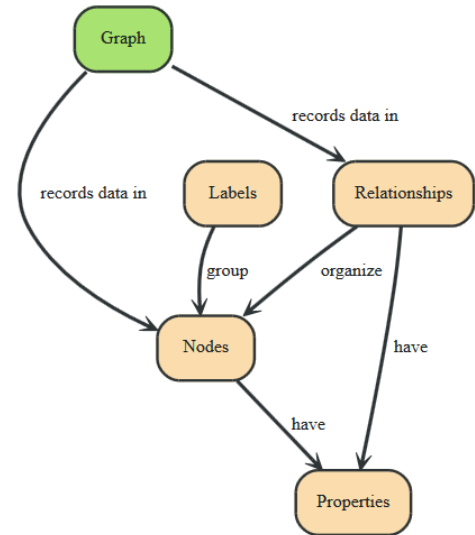
- bessere Unterstützung stark vernetzter Daten als mit Relationenmodell
 - soziale Netzwerke
 - Protein-Netzwerke
 - stark vernetzte Webdaten / Unternehmensdaten / ...
- Graph-Verwaltung im Relationenmodell oft nicht ausreichend schnell
 - viele Tabellen, viele Joins
 - langsame Traversierung von Kanten
 - langsame Umsetzung von Graph-Algorithmen
- Graph-Datenbanken
 - Graph-Datenmodell mit Gleichbehandlung von Entities und Relationships
 - Graph-Anfragesprachen
 - optimierte Graph-Operationen (z.B. finde „friends of friends“)



- native Graph-Datenbank von Neo Technology
 - Community Edition (open-source) + kommerzielle Varianten
 - in Java realisiert , Unterstützung weiterer Sprachen (Ruby, Python)
 - ACID-Unterstützung
 - Skalierbarkeit durch Datenreplikation


■ zentrale Datenstruktur: Property-Graphen

- Knoten/Kanten haben Label (Id bzw. Typ))
- Knoten und Kanten können Properties haben
- Property: Key-Value-Paar (Key ist vom Typ String)
- gerichtete Kanten



Property-Graphen

- mehrere, gerichtete Kanten zwischen zwei Knoten möglich (gerichteter „Multigraph“)
 - Labels für Knoten/Kanten
 - Properties für Knoten/Kanten
-
- konstanter Aufwand zur Traversierung zu Nachbarknoten (statt Join im RM)



■ Merkmale

- Pattern Matching
- OLTP-artige Lese/Änderungsoperationen
- schnelle Traversierungen
- ACID-basierte Updates

■ Klauseln:

- **START**: Starting points in the graph.
- **MATCH**: The graph pattern to match.
- **WHERE**: Filtering criteria.
- **RETURN**: What to return.
- **CREATE**: Creates nodes and relationships.
- **DELETE**: Removes nodes, relationships and properties.
- **SET**: Set values to properties.
- **FOREACH**: Performs updating actions once per element in a list.
- **WITH**: Divides a query into multiple, distinct parts.





Neo4j: Cypher (2)

```
MATCH (a)-->(b)-->(c),
      (a)-->(c)
RETURN a,b,c
```

```
MATCH (a)-->(b)-->(c)<--(a)
RETURN a,b,c
```

a	b	c
3	4	5
6	4	7
6	7	8





Neo4j: Cypher (3)

```

MATCH (a)--()->(c)
WHERE a.id = 1
RETURN c.id AS c
    
```

c
3
4
5
2





Neo4j: Cypher (4)

```

MATCH p=(a)-[*1..4]->(b)
WHERE a.id = 1 AND b.id = 7
RETURN nodes(p), length(p)
    
```

nodes(p)	length(p)
(1,2,3,4,7)	4
(1,3,4,7)	3
(1,3,4,6,7)	4
(1,3,5,8,7)	4
(1,3,5,4,7)	4





Neo4j: Cypher (5)

```

MATCH p=shortestPath((a)-[*..4]-(b))
WHERE a.id = 1 AND b.id = 7
RETURN nodes(p)
    
```

nodes(p)
(1,3,4,7)




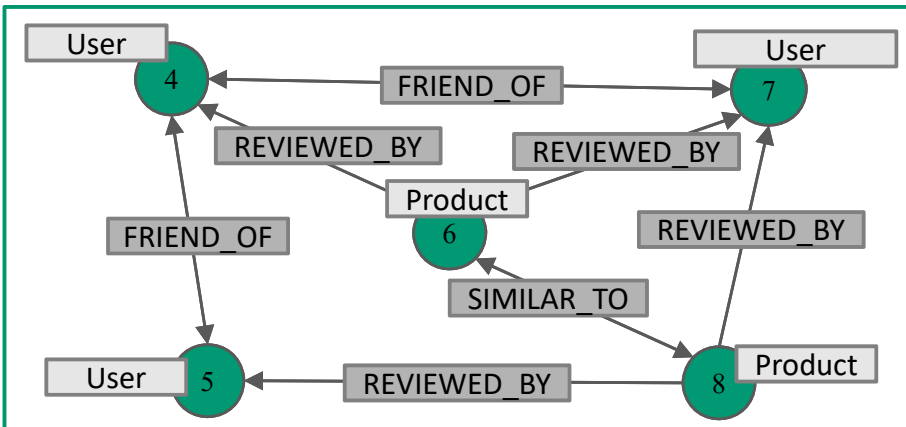
Neo4j: Cypher (6)

Freundesfreunde von Nutzern, die das selbe Produkt wie ein Nutzer bewertet haben

```

MATCH (u:User)-[:FRIEND_OF*2..2]-foafs,
foafs<-[:REVIEWED_BY]-products,
products-[:REVIEWED_BY]->(u)
WHERE u.id = 7
AND NOT u-[:FRIEND_OF]-foafs
RETURN foafs, products
    
```

foafs	products
5	8



Analyse sehr großer Graphen (Big Graph Data)*

- oft riesige Graphdatenmengen (soziale Netze, Web, wissenschaftliche Netze)
 - Milliarden von Knoten und Kanten
 - aufwändige Mining-Verfahren (frequent patterns, Cluster-Verfahren, Vorhersagen)
- Graph-DBS fokussieren auf einfachere Auswertungen (OLTP, Queries)
 - (relativ) ausdrucksstarkes Graphdatenmodell: Property-Graphen
 - Skalierbarkeitsprobleme
 - nur begrenztes Graph Mining
- *Graph Processing Frameworks* (Apache Giraph, Spark GraphX, Flink Gelly, ...)
 - parallele/skalierbare Verarbeitung von sehr großen In-Memory-Graphen
 - nur generische Graphen, keine Query-Sprache
- neuer Forschungsansatz **Gradoop** (UL, ScaDS.AI)
 - effiziente, verteilte Verwaltung und Analyse großer Mengen von Graphdaten
 - erweitertes Property-Graph Datenmodell (EPGM) mit mächtigen Operatoren
 - hoch-skalierbar basierend auf Hadoop / Flink
 - open-source (www.gradoop.org)

• Rost, C; Gomez, K; Taeschner, M; Fritzsche, P; Schons, L; Christ, L; Adameit, T; Junghanns, M; Rahm, E:
Distributed temporal graph analytics with GRADOOP. VLDB Journal 2022



Zusammenfassung

- Big Data Herausforderungen
 - Volume, Variety, Velocity, Veracity, Privacy
 - skalierbare Analysen / Machine Learning
- skalierbare Cluster-Architekturen auf Basis von Hadoop mit Framework wie Apache Spark / Flink
- NoSQL
 - Auslöser: webskalierbares Datenmanagement
 - semistrukturierte schemafreie Daten
 - Verzicht auf SQL/ACID
- unterschiedliche Systemarten
 - Key/Value-Stores, erweiterte Record-Stores (Spaltenfamilien)
 - Dokumenten Stores
 - Graph-Datenbanken
- Hauptproblem für NoSQL: fehlende Standards
- skalierbare Graphanalysen: Queries und Mining auf verteilten Plattformen

