7. Big Data und NoSQL-Datenbanken

- Motivation Big Data
  - Herausforderungen
  - Einsatzbereiche
- Systemarchitekturen für Big Data Analytics
  - Analyse-Pipeline
  - Hadoop, MapReduce, Spark/Flink
- NoSQL-Datenbanken
  - Eigenschaften
  - Document Stores (MongoDB)
  - Graph-Datenbanken (neo4J)
- parallele/verteilte Graphanalysen / Gradoop

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}),
  - …
- bis 2020 werden ca 40 ZB jährlich erzeugt

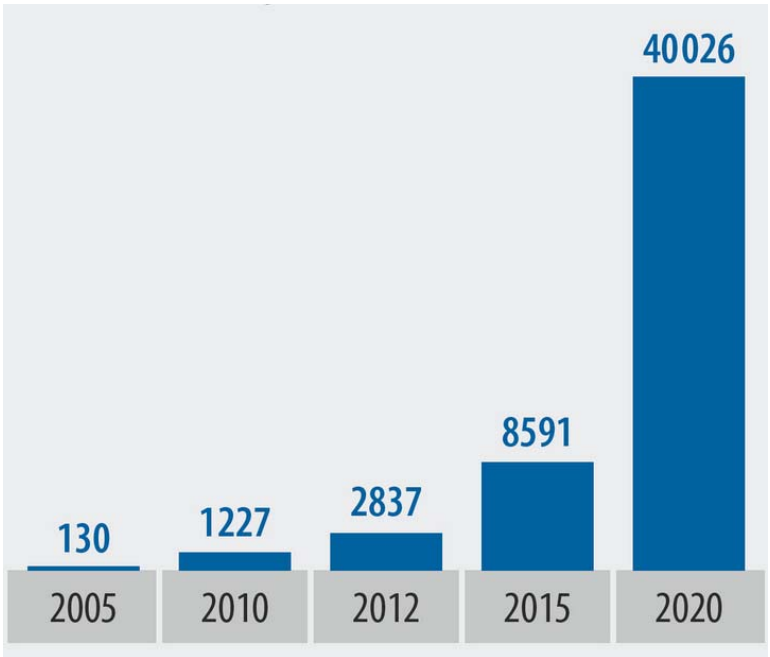

Quelle: IDC

Welche Art von Daten?

- mobile Endgeräte (Smartphones, Watches, …):
  Multimedia-Daten (Fotos, Videos), Bewegungsdaten, Nachrichten …
- 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
- wissenschaftliche Daten zB in Klimaforschung, Experimentalphysik, Lebenswissenschaften und Sozialwissenschaften (Digital Humanities)
- Sensor-Daten / eingebettete Systeme
  - vernetzte Produktion/Fertigung (Industrie 4.0)
  - „intelligentes“ Haus, Verkehrsüberwachung, …

Datenzunahme

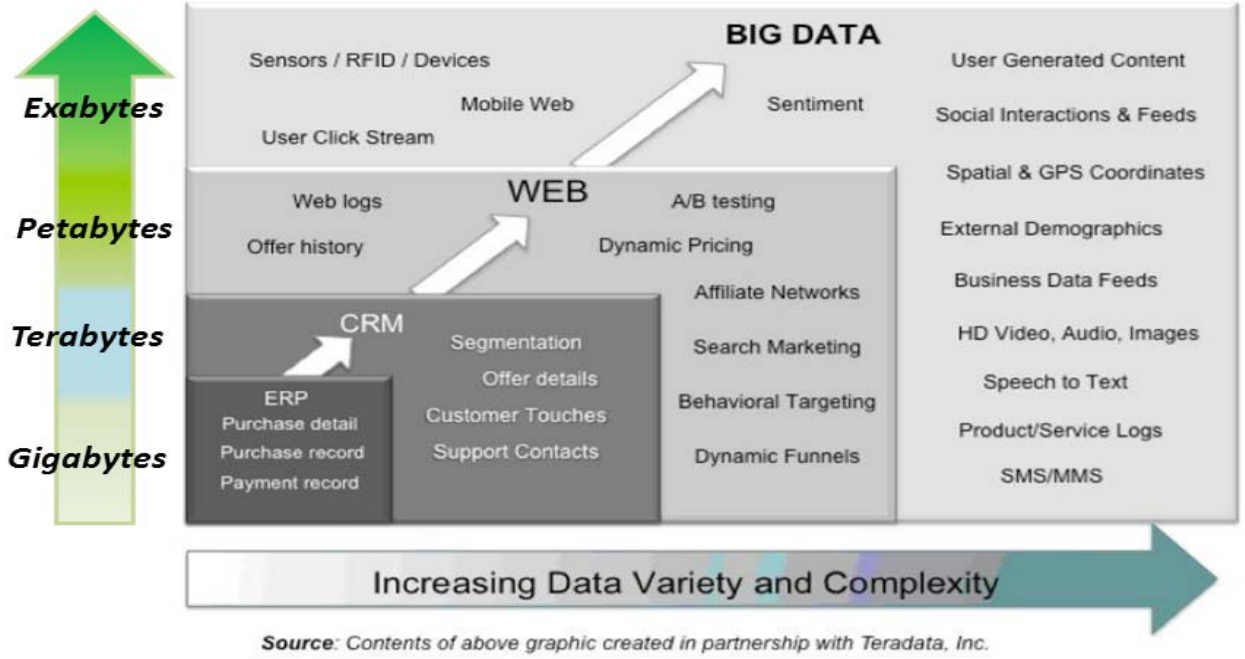

***Source**: Contents of above graphic created in partnership with Teradata, Inc.*

Data Center

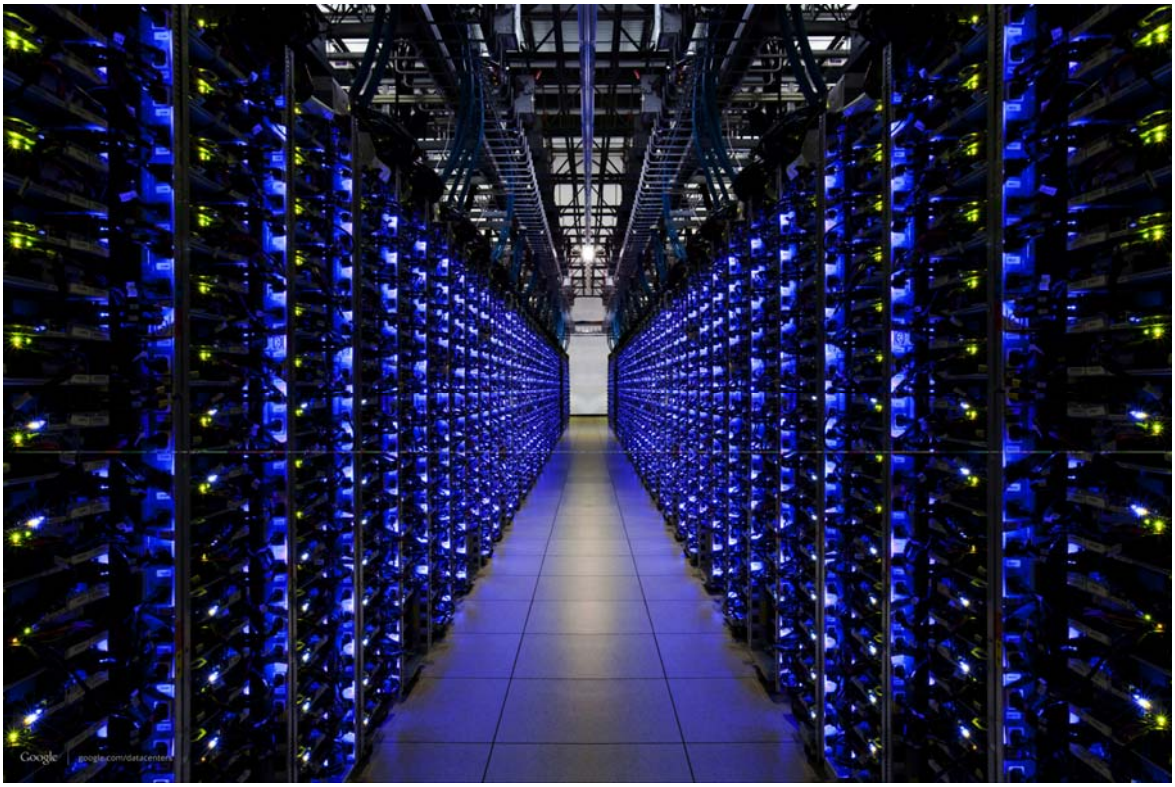

Source: Google Inc.

Big Data Challenges

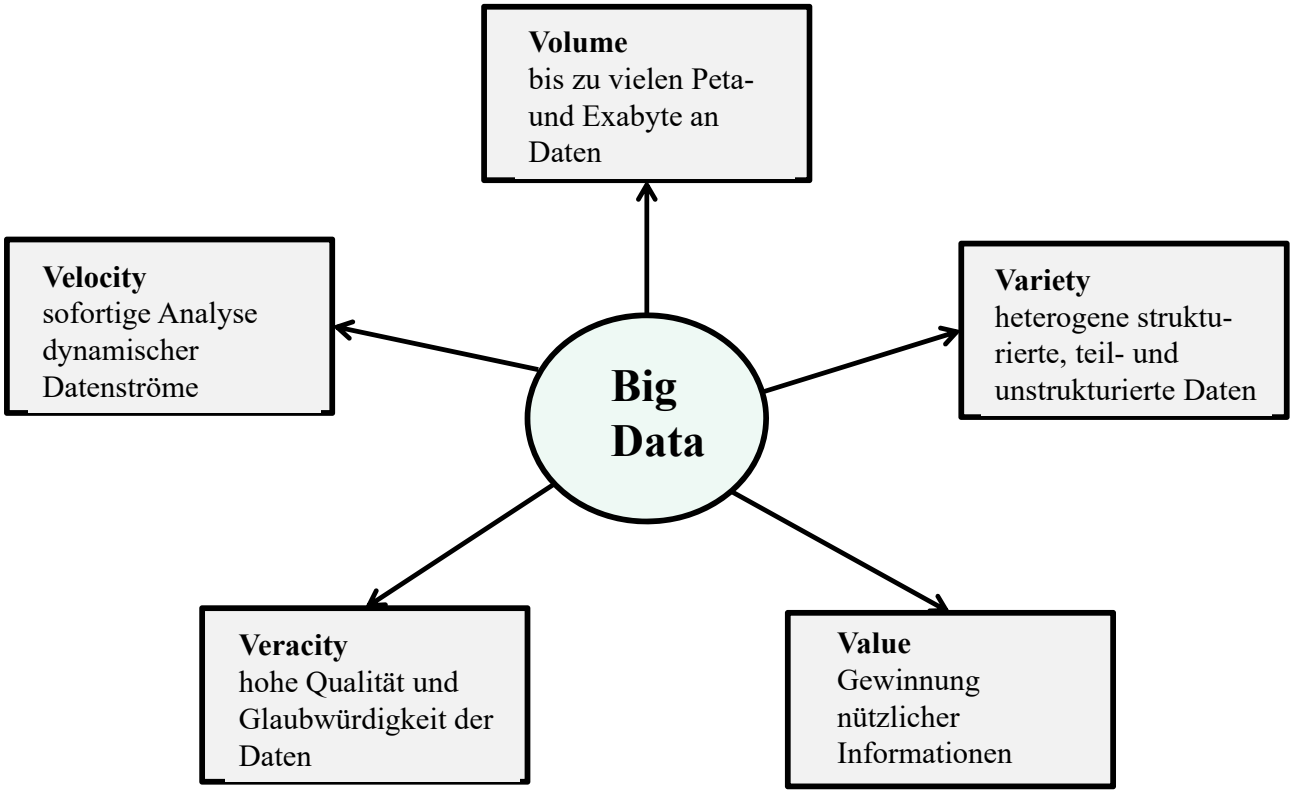

Potenziale für Big-Data-Technologien

- Daten sind Produktionsfaktor: „data is the new oil“
  - ähnlich Betriebsmitteln und Beschäftigten
  - essenziell für viele Branchen und Wissenschaftsbereiche
- valide Grundlage für zahlreiche Entscheidungsprozesse
  - Vorhersage/Bewertung/Kausalität von Ereignissen
- kurzfristige Analysen von Realdaten im Geschäftsleben
  - Empfehlungsdienste (Live Recommendations)
  - Analyse/Optimierung von Produktionsprozessen, Lieferketten, etc.
- verbesserte Analysen in zahlreichen wissenschaftlichen Anwendungen

Anwendungsdomänen für Big Data Analytics

Smarter Healthcare

Multi-channel sales

Finance

Log Analysis

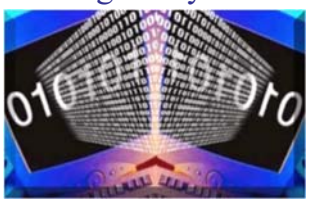

Homeland Security

Traffic Control

Telecom

Search Quality

Manufacturing

Trading Analytics

Fraud and Risk

Retail: Churn, NBO

Big Data Analyse-Pipeline

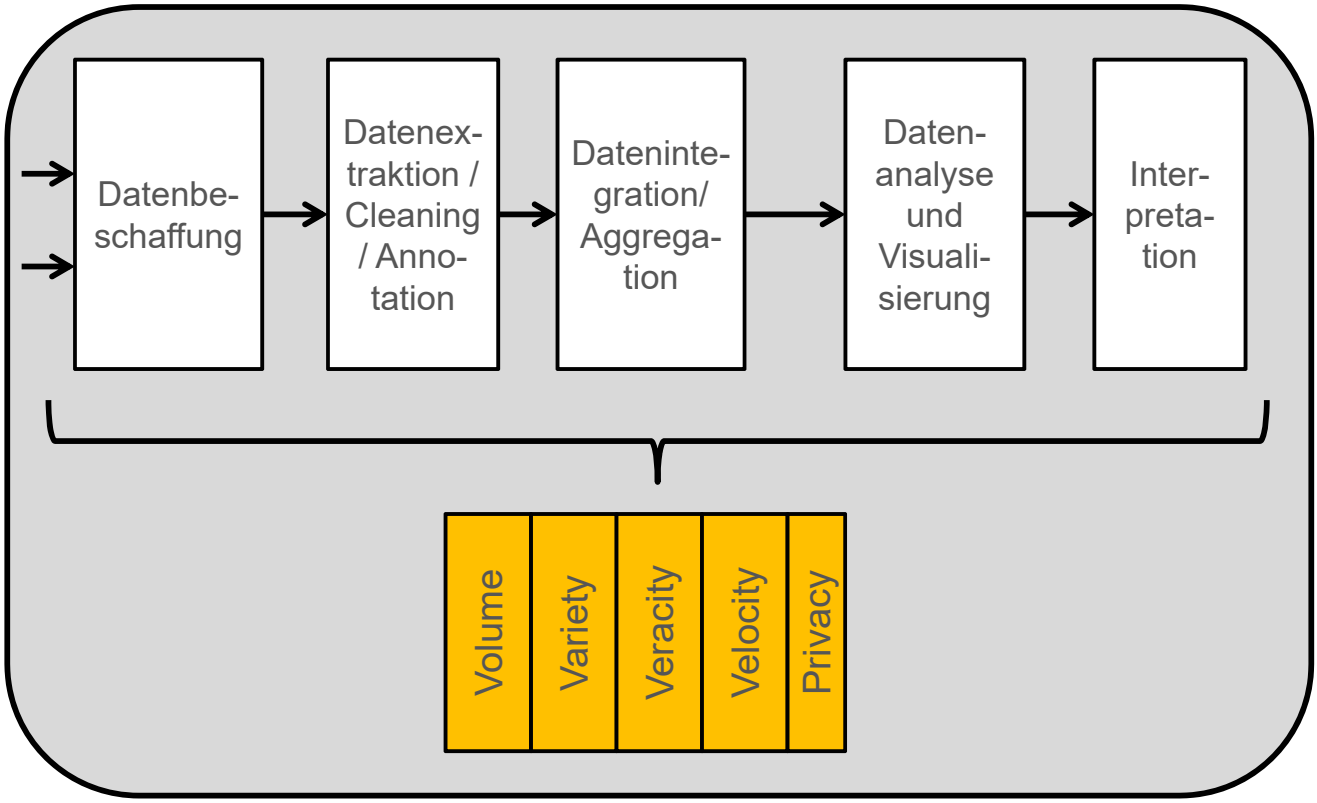

Technologie-Trends

- 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
- Nutzung v.a. zur Verarbeitung riesiger Mengen teilstrukturierter Daten in einem verteilten Dateisystem
  - *Konstruktion Suchmaschinenindex*
  - *Clusterung von News-Artikeln*
  - *Spam-Erkennung …*

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

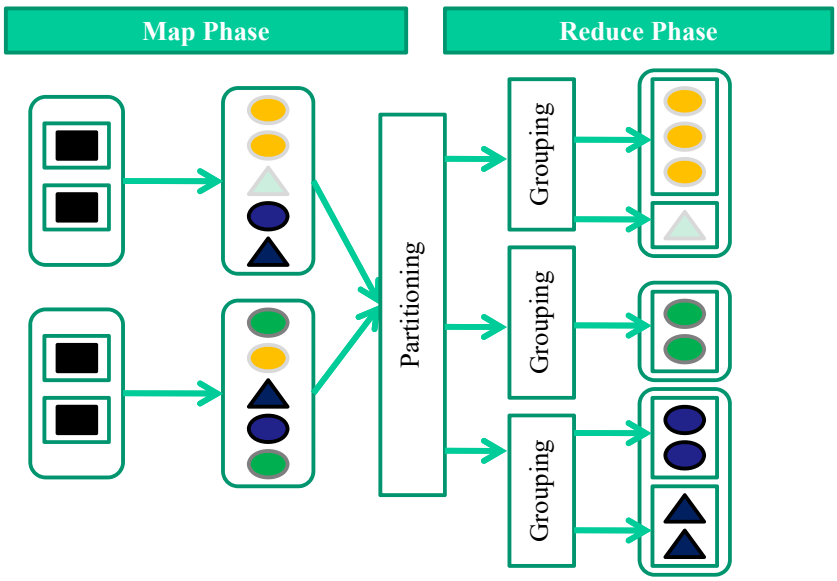

MR-Beispiel: Generierung Text-Index

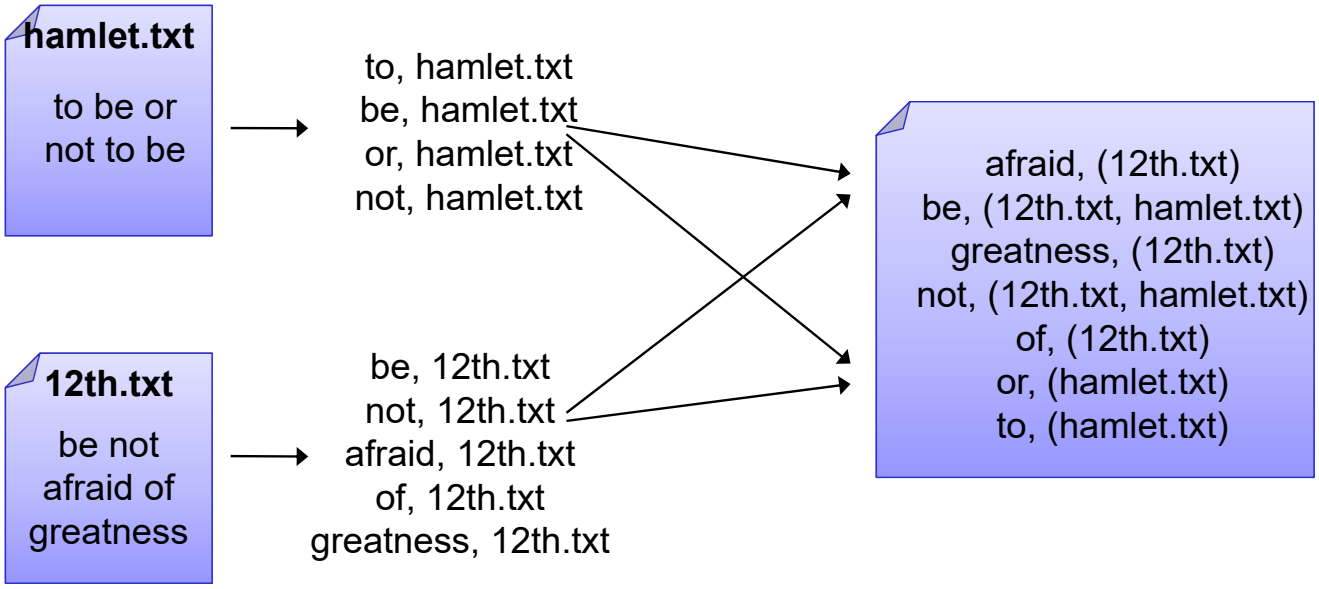

Hadoop-Ökosystem für Big Data

Hadoop 1.0

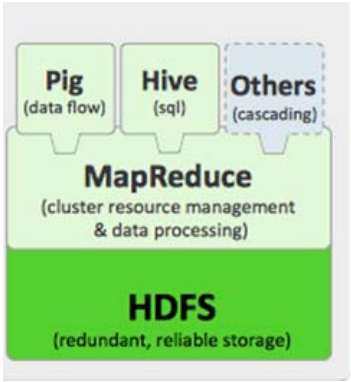

Hadoop 2.x

Spark vs Flink

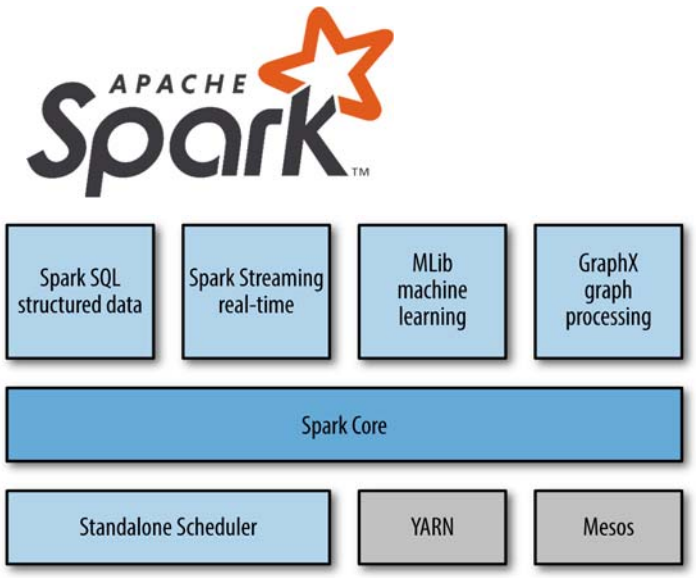

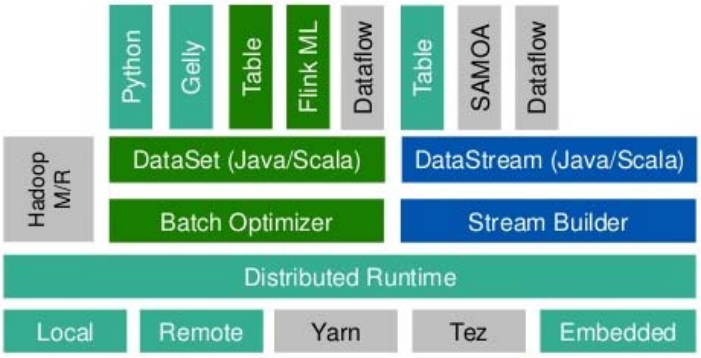

NoSQL-Datenbanken

Relationale Datenbanken: Pros and Cons

- universelle Verbreitung und auf absehbare Zeit ungefährdet für die meisten DB-Anwendungen
  - SQL: mächtige, standardisierte, mächtige (deklarative) Query-Sprache
  - ACID
  - reife Technologie
  - automatische Parallelisierung ...
- Schema-getrieben
  - 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

- Definition von ***www.nosql-database.org***

  Datenbanken der nächsten Generation die meist
  - nicht-relational
  - verteilt,
  - open-source und
  - horizontal (auf große Datenmengen) skalierbar sind
- ursprünglicher Fokus: moderne "web-scale" Datenbanken
- Entwicklung seit ca. 2009
- weitere Charakteristika:
  - schema-frei, Datenreplikation, einfache API,
  - eventually consistent / BASE (statt ACID)
- Koexistenz mit SQL
  - "NoSql" wird als "Not only Sql" 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 BigData / Hbase, Hypertable, Cassandra …
  - Tabellen-basierte 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

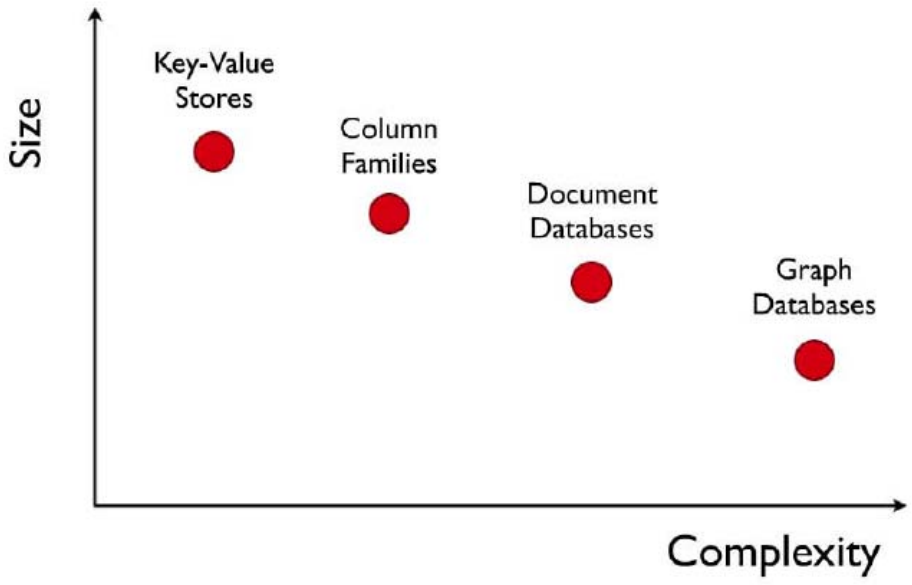

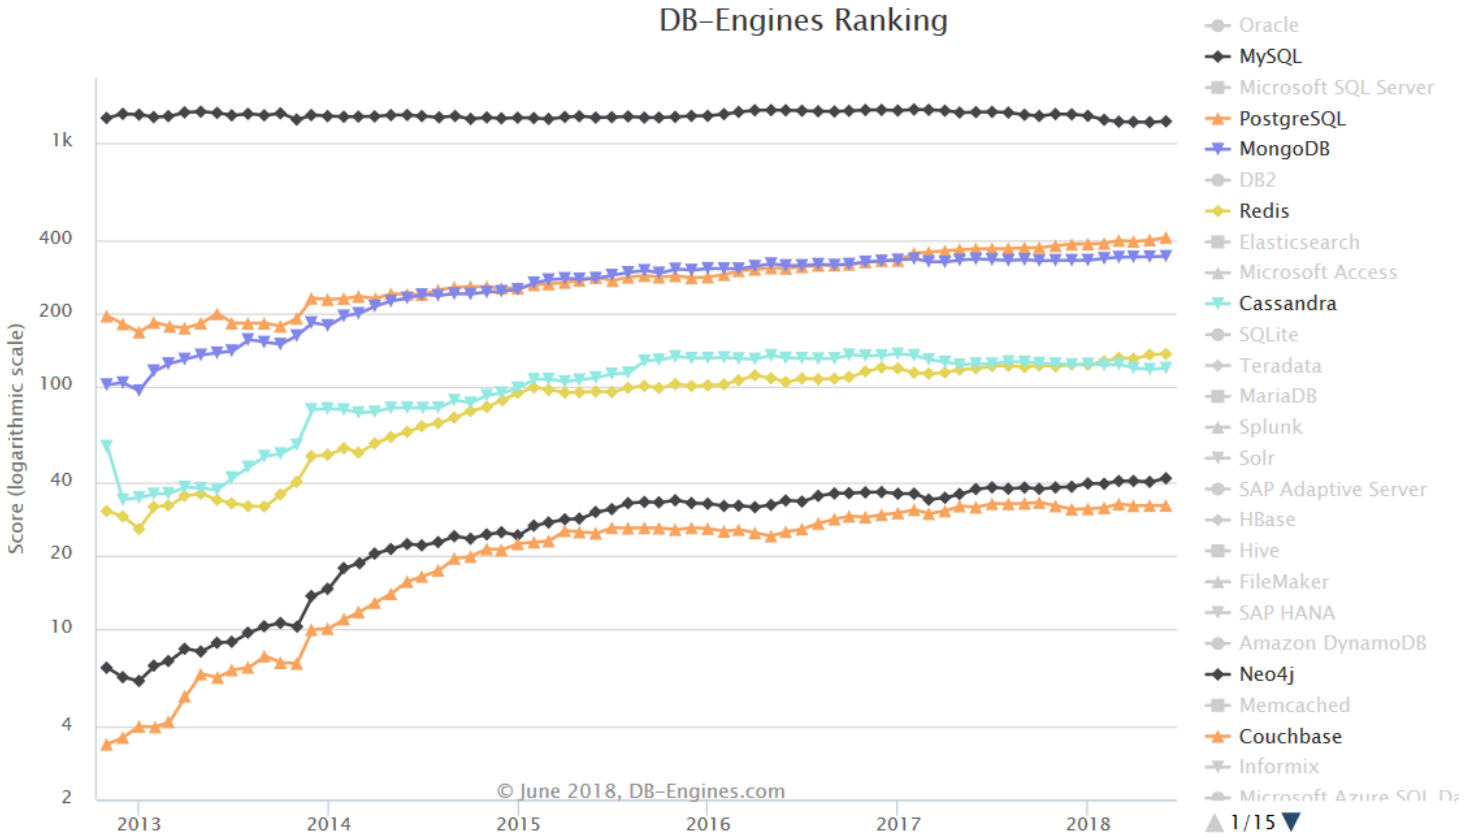

https://db-engines.com/en/ranking_trend

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

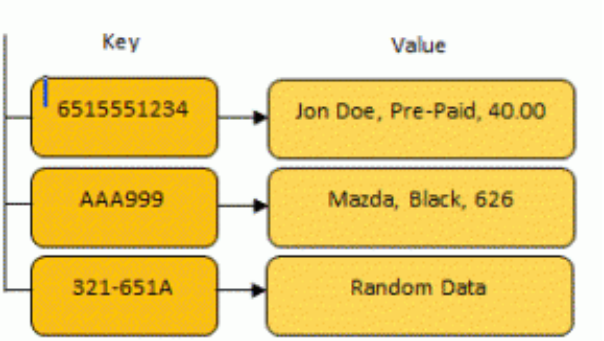

- schnelle Lese/Schreibzugriffe über Schlüssel
  - put (key, value)
  - get (key)
- keine komplexen Queries (z.B. Bereichsabfragen)

Spaltenorientierte Key-Value Stores

- 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

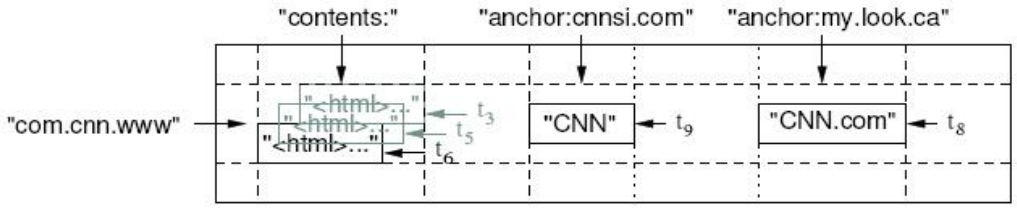

Row Key	Time Stamp	Column ***contents***	Column Family ***anchor***	
"com.cnn.www"	T9		anchor:cnnsi.com	CNN
	T8		anchor:my.look.ca	CNN.COM
	T6	"<html>.. "		
	T5	"<html>.. "		

Spaltenorientierte Key-Value Stores (2)

- weiteres Beispiel

Row Key	Column Family: "User"	Column Family: "Article"
"userid1"	name: Username, value: uname1 name: Email, value: uname1@abc.com name: Tel, value: 123-4567	
"userid2"	name: Username, value: uname2 name: Email, value: uname2@abc.com name: Tel, value: 123-4568	name: ArticleId, value:userid2-1 name: ArticleId, value:userid2-2 name: ArticleId, value:userid2-3
"userid3"	name: Username, value: uname3 name: Email, value: uname3@abc.com name: Tel, value: 123-4569	

- hochskalierbar, replizierte Speicherung
- einfache Get/Put-Operationen mit schnellen Zugriffszeiten (Hashing)

MongoDB

- zunehmend Verbreitung findender Dokumenten-Store
  - 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 Partitionierung der Dokumentenkollektionen unter vielen Knoten ("Sharding")
  - automatische Replikation mit Konsistenzwahrung
- kein ACID, z.B bzgl Synchronisation
  - Änderungen nur bzgl einzelner Dokumente atomar

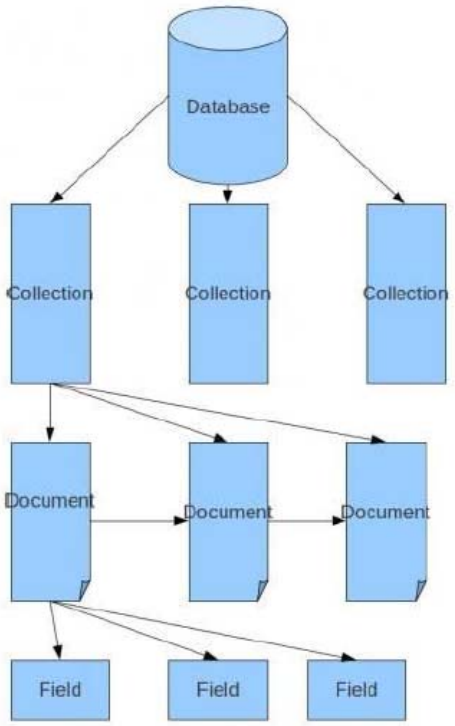

Beispiel: relational vs. dokumentenorientiert

RDB:

STUDENTS

sno	name
1	Peter
2	Tom

POSTS

postID	topic	pdate
p1	NoSQL	01-09-2012
p2	RelationalDB	02-09-2012

COMMENTS

commentID	postID	sno	content	cdate
c1	p1	1	Excellent	02-09-2012
c2	p1	2	I do not understand.	03-09-2012
c3	p1	1	This is a good idea!	04-09-2012

MongoDB:

```
{topic: 'NoSQL',
pdate: 01-09-2012,
comments: {{name: 'Peter',
           content: 'Excellent',
           cdate: 02-09-2012},
           {name: 'Tom',
           content: 'I do not understand.',
           cdate: 03-09-2012},
           {name: 'Peter',
           content: 'This is a good idea!',
           cdate: 04-09-2012}}
}
```

- keine Beziehungen zwischen Dokumenten (-> keine Joins) sondern geschachtelte Komponenten (ähnlich NF2, jedoch ohne Schemazwang)
  - Redundanz bei n:m-Beziehungen

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“)

Neo4J

- 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

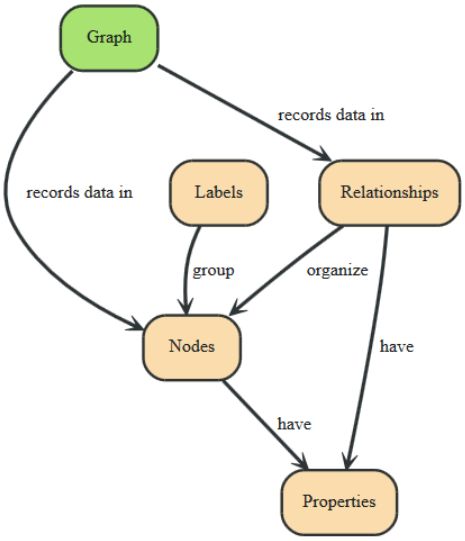

Property-Graphen

- mehrere, gerichtete Kanten zwischen zwei Knoten möglich (gerichteter „Multigraph“)
  - Labels für Knoten/Kanten
  - Properties für Knoten/Kanten

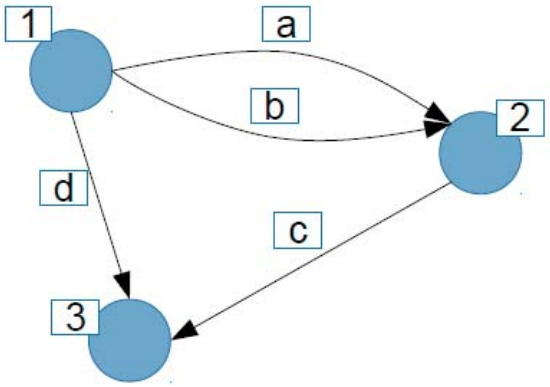

- konstanter Aufwand zur Traversierung zu Nachbarknoten (statt Join im RM)

Query-Sprache Cypher

- 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

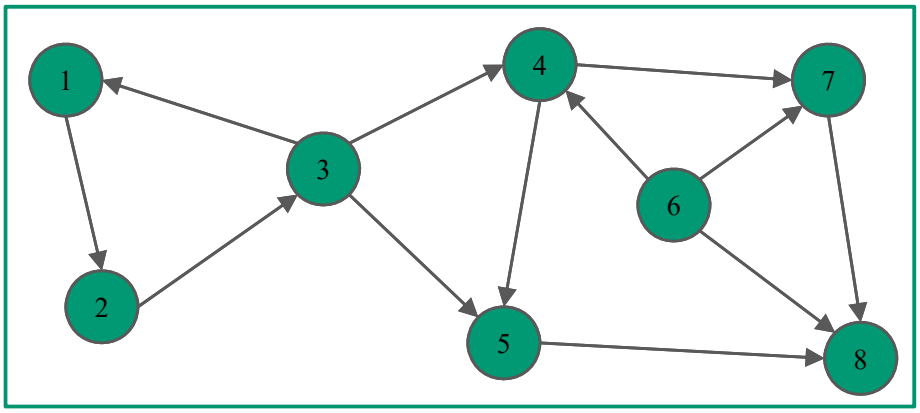

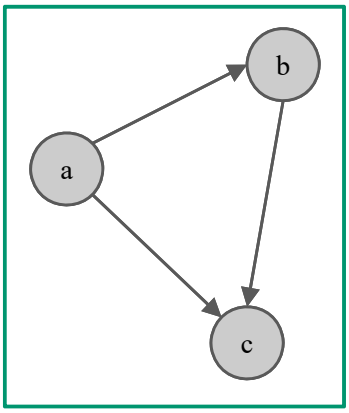

Neo4j: Cypher (3)

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

c
3
4
5
2

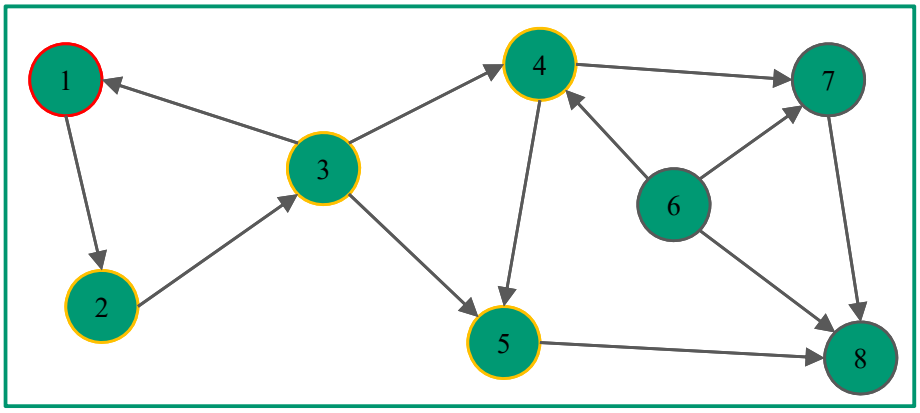

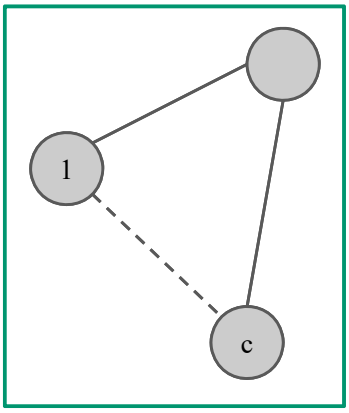

Neo4j: Cypher (4)

```
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

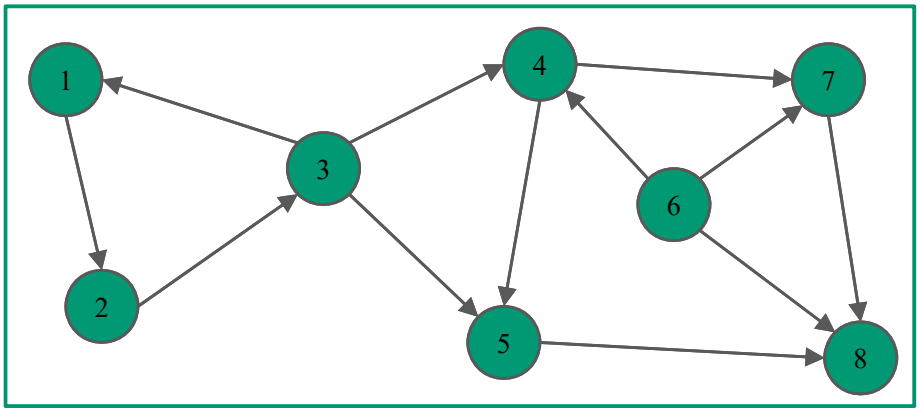

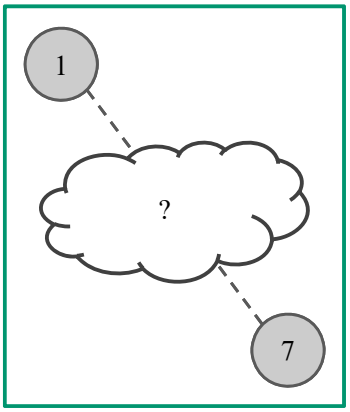

Neo4j: Cypher (5)

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

length	cnt
4	4
3	1

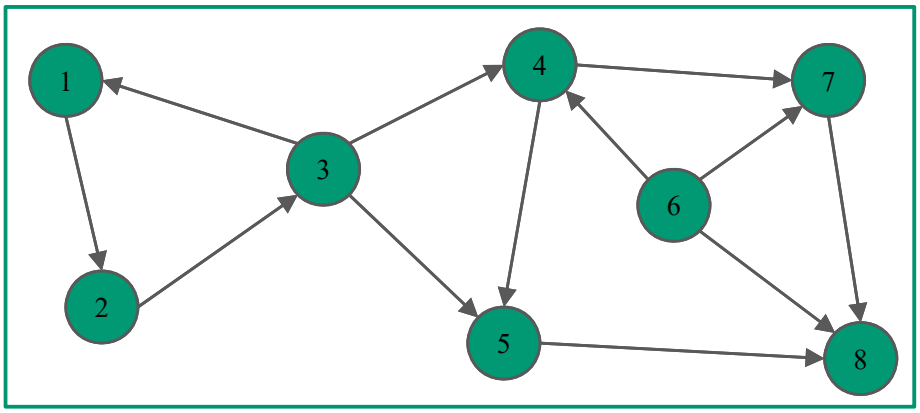

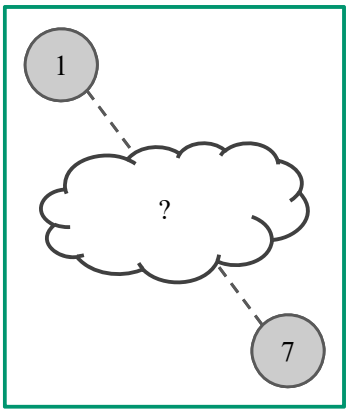

Neo4j: Cypher (6)

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

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

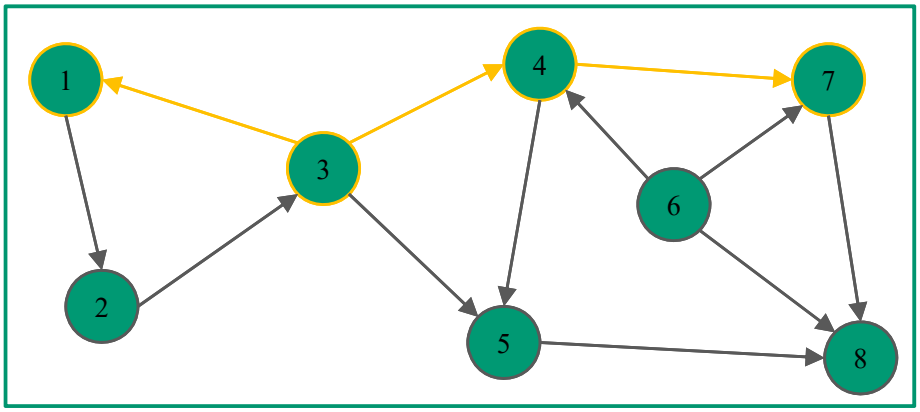

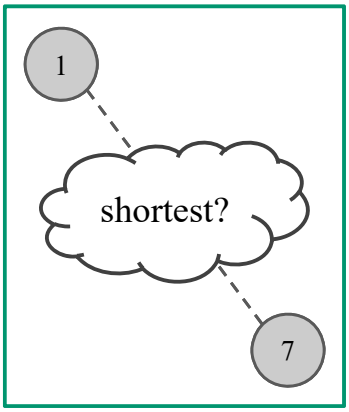

Neo4j: Cypher (7)

```
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

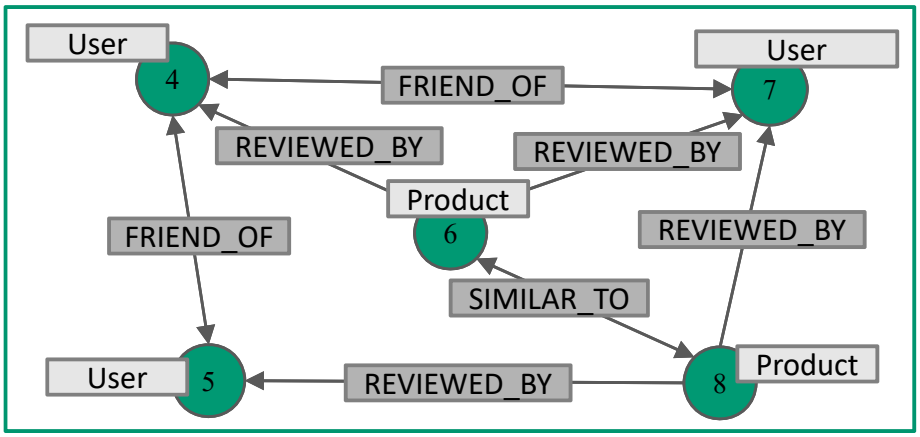

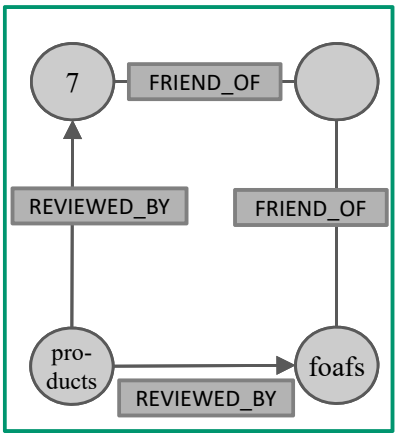

Analyse sehr großer Graphen (Big Graph Data)*

- 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)
  - effiziente, verteilte Verwaltung und Analyse großer Mengen von Graphdaten
  - erweitertes Property-Graph Datenmodell (EPGM) mit mächtigen Operatoren (Graph Grouping, Pattern Matching, …)
  - hoch-skalierbar basierend auf Hadoop / Flink
  - www.gradoop.org

* Junghanns, M.; Petermann, A.; Neumann, M.; Rahm, E.: *Management and Analysis of Big Graph Data: Current Systems and Open Challenges*. In: Handbook of Big Data Technologies, Springer 2017

Ansätze zur Graphanalyse

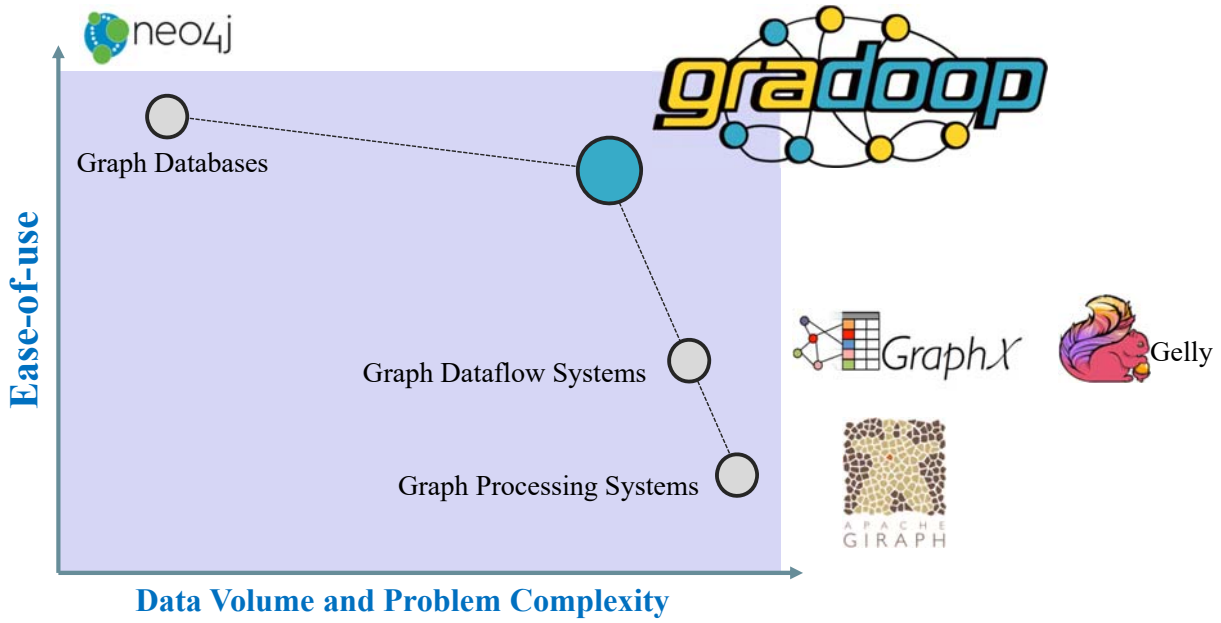

Gradoop-Architektur

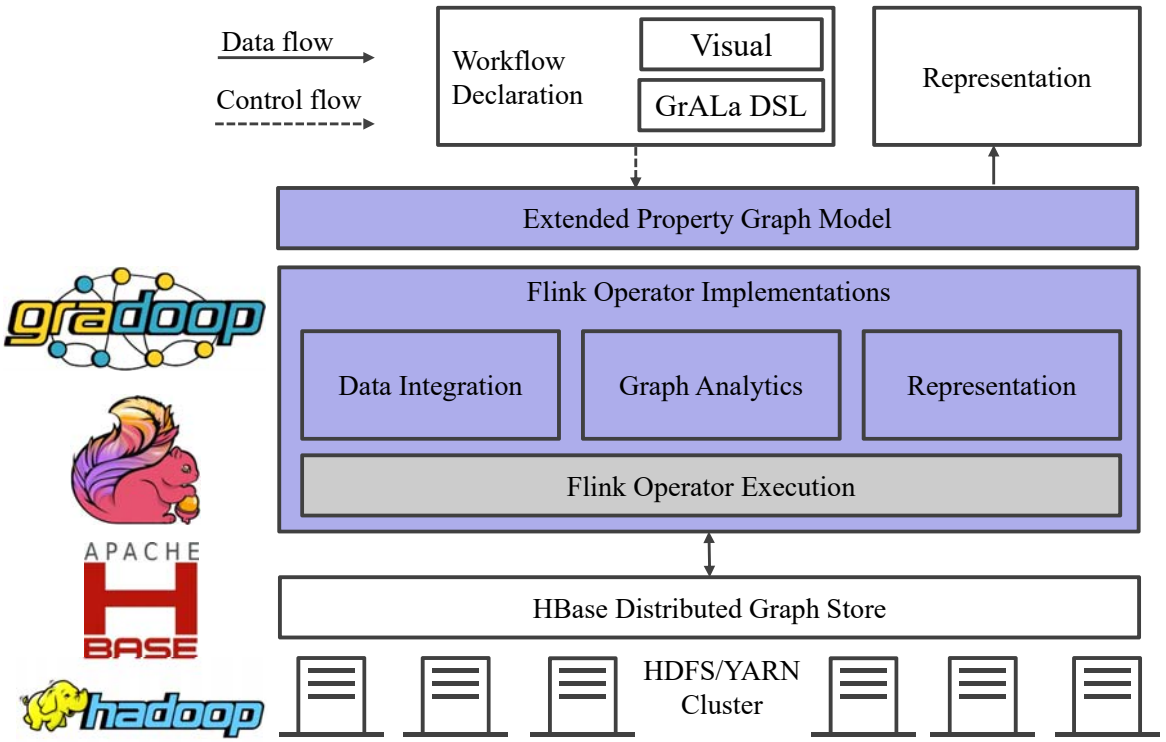

Gradoop Beispielgraph

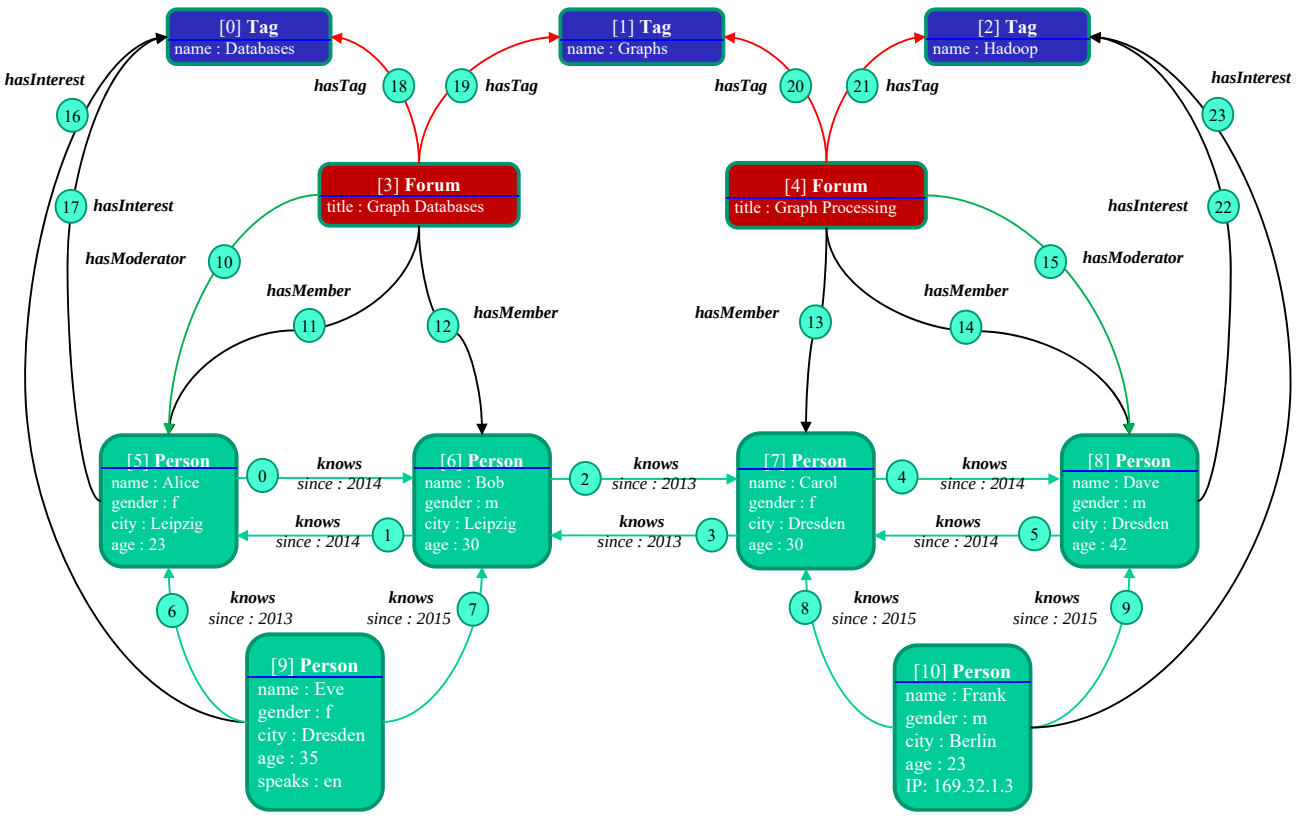

Gradoop-Operatoren

	Operators		Algorithms
	Unary	**Binary**	
Logical Graph	Aggregation	Combination	Gelly Library
	Pattern Matching	Overlap	BTG Extraction
	Transformation	Exclusion	Adaptive Partitioning
	Grouping	Equality	
	Subgraph		
	Call *		
Graph Collection	Selection	Union	Frequent Subgraphs
	Distinct	Intersection	
	Sort	Difference	
	Limit	Equality	
	Apply *		
	Reduce *		
	Call *		

* auxiliary

Gradoop Grouping: Typ-Ebene *(Schema Graph)*

```
vertexGrKeys = [:label]
edgeGrKeys   = [:label]
sumGraph     = databaseGraph.groupBy(vertexGrKeys, [COUNT()], edgeGrKeys, [COUNT()])
```

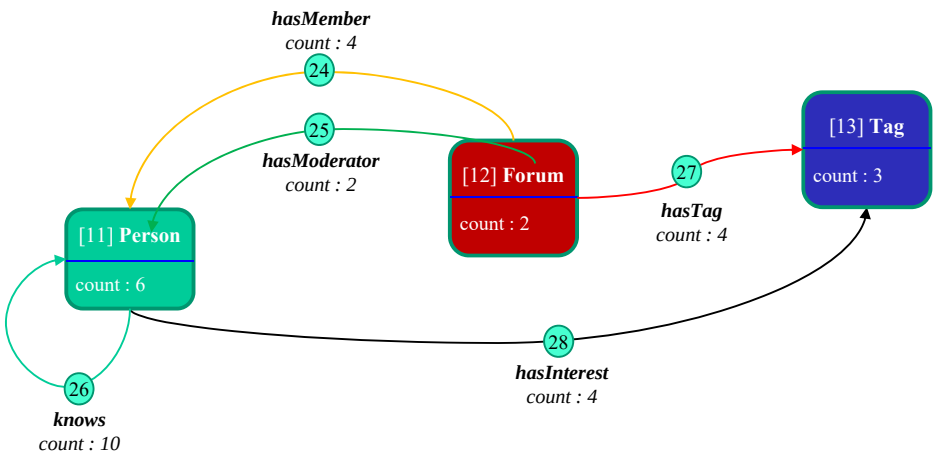

Grouping (2): Property-spezifisch

```
personGraph   = databaseGraph.subgraph((vertex => vertex[:label] == 'Person'),
                                       (edge => edge[:label] == 'knows'))
vertexGrKeys = [:label, "city"]
edgeGrKeys    = [:label]
sumGraph      = personGraph.groupBy(vertexGrKeys, [COUNT()], edgeGrKeys, [COUNT()])
```

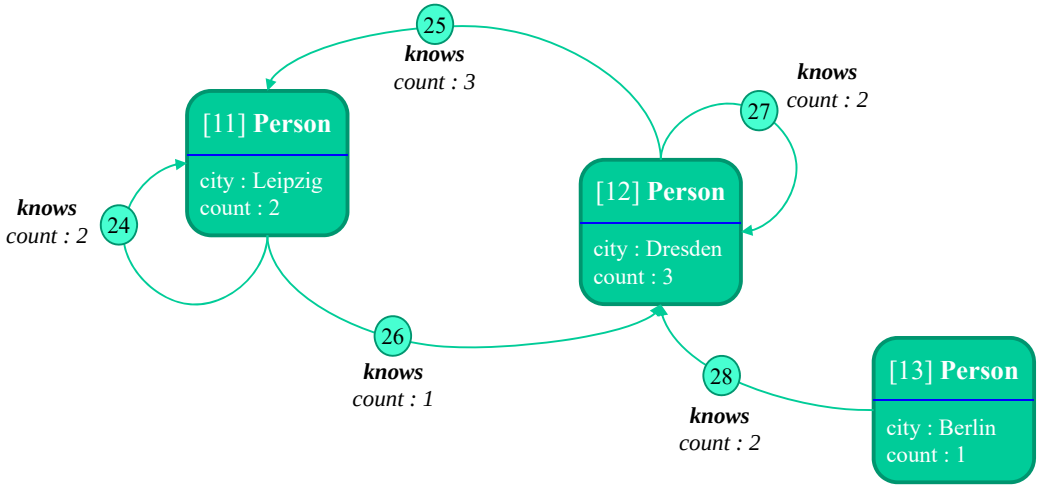

Vergleich

	Graph-Datenbanken, z.B. Neo4j	Graph Processing Systems (z.B. Giraph)	Distributed Dataflow Systems (Flink Gelly, Spark GraphX)	gradoop
Datenmodell	PGM	generische Graphen	generische Graphen	Extended PGM
Fokus	Queries	Analyse/Mining	Analyse/Mining	Analyse/Mining
Query-Sprache	ja	nein	nein	(ja)
Skalierbarkeit	vertikal	horizontal	horizontal	horizontal
Workflows	nein	nein	ja	ja
Dynamische Graphen / Versionierung	nein	nein	nein	nein
Visualisierung	(ja)	nein	nein	in Arbeit
Datenintegration	nein	nein	nein	in Arbeit

Zusammenfassung

- Big Data Herausforderungen
  - Volume, Variety, Velocity, Veracity, Privacy
  - skalierbare Analysen / Machine Learning
- unterschiedliche Architekturen: Cloud/Hadoop-Cluster, In-Memory Warehouses, hybride Lösungen
- 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