


NoSQL & MongoDB




Grundlagen Datenbanken


- ✓ Wozu Datenbanken?
- ✓ Relationales Datenbankmodell

NoSQL

- ✓ Grundlagen
- ✓ Grundlegende Einteilung
- ✓ CAP-Theorem
- ✓ SQL vs. NoSQL
- ✓ Der Weg zur richtigen DB
- ✓ MongoDB

Zusammenfassung





- Zentrale Speicherung von Daten
 - Konsistenz (Consistency)
 - Verringerung von Redundanz
 - Gleichzeitige Verfügbarkeit für mehrere Benutzer (Concurrency)
- Permanente Datensicherung (Fault-Tolerance)
- Suchanfragen + Query (Indexierung)
- Datenmanipulation
- Verarbeitung großer Datenmengen

Datenbank = Daten + Verknüpfungen (entscheidend für DB-Modell)

ID	User	OS	Last Login
123	Batman	Linux	10.01.18
342	Spiderman	Linux	(null)
425	Superman	Windows	(null)
774	Iron Man	Linux	12.03.18

- **Prinzip:** Organisation von Daten in Tabellen
 - Tabelle: Relation (z.B. Konsument, Produkt)
 - Spalten: Attribute
 - Zeilen: Instanzen
 - Zeilen-ID: Primary Key
 - Übergreifende Verknüpfungen: Foreign Keys
- **Datenmodell** festgelegt durch (vordefiniertes) Schema
- **ACID**
 - Atomizität: "All or nothing" bei Transaktionen
 - Consistency: Transaktionen bewahren Datenkonsistenz in DB
 - Isolation: Keine Interferenz bei parallel gestarteten Transaktionen
 - Durable: Datenänderungen werden permanent geschrieben
- **Vertreter:** Oracle (1980), MySQL (1995), SQL Server (1989), PostgreSQL (1997)

- NoSQL: steht für „Not Only SQL“
- Kennzeichen
 - Keine vordefinierten Tabellenschema
 - BASE („Basically Available Soft state Eventual consistency“)
 - Designprinzip, welches absolute Konsistenz (zwischen verteilten Systemen) aufgibt
 - (+) Erhöhte Verfügbarkeit des Systems
 - (-) System-Zustand zeitweise undefiniert
 - Wordplay: „ACID“ (Säure) und „BASE“ (Base)
- NoSQL umfasst mehr als 200 verschiedene Datenbanken (<http://nosql-database.org>)
- Grundlegende Einteilung
 - Schlüssel/Wert-DB (Key/Value)
 - Spalten-DB (Wide-Column)
 - Dokumenten-DB (Document)
 - Graphen-DB (Graph)

Grundlegende Einteilung

Key/Value DB

Key	Value
"Batman"	{"Bruce Wayne", "Gotham City"}
"Spiderman"	{"Peter Parker", "New York City"}
"Superman"	{"Clark Kent", "Metropolis"}
"Iron Man"	{"Tony Stark", "Malibu"}

- **Prinzip:**
Hash-Tables mit Schlüssel/Wert-Paaren
- **Datenmodell:** Planar
- **Use Cases:**
 - URL-Kürzungsdienst
 - Kurzlebige Daten (z.B. Logfiles, Session-Daten, Cache, Queues)
- **Wichtigste Vertreter:**
Memcached (2003), Redis (2009)

Grundlegende Einteilung

Wide-Column DB

Row Key	Column/ Key 1	Column/ Key 2	Column/ Key 3	Column/ Key 4
"Batman"	First Name	Last Name	Residence	SavedEarth
	Bruce	Wayne	Gotham	Yes
"Superman"	First Name	Last Name	Residence	SavedEarth
	Clark	Kent	Metropolis	Yes
"Iron Man"	First Name	Last Name	Residence	SavedEarth
	Tony	Stark	Malibu	Yes
"The Avengers"			Residence	SavedEarth
			New York	Yes


- **Prinzip:** Daten-Speicherung in Spalten
 - Column Family = Row key + Column keys + Values
- **Datenmodell:** Linear (für ein Objekt)
- **Use Cases:**
 - User-Profil Attribute
 - Metadaten (z.B. Songs, Künstler)
 - Real-Time Analytics
- **Wichtigste Vertreter:**
Cassandra (2008), HBase (2008)

```
{  
  Group_name: "The Avengers",  
  Residence: "New York",  
  Superheroes: [  
    {Name: "Tony Stark", Alias: "Iron  
      Man"},  
    {Name: "Bruce Banner", Alias: "Hulk"},  
    {Name: "Thor Odinson", Alias: "Thor"},  
    ... ]  
}
```

- **Prinzip:**
Collections von Key/Value-Paaren in
Dokumenten-Struktur (XML, JSON, BSON)
- **Datenmodell:** Strukturiert
- **Use Cases:**
 - Historische Daten bzw. Archivierung
 - Single Views
 - Produkt Katalog bzw. Warenkorb
 - Benutzer-generierter Content (z.B. Blogs)
 - Real-Time Analytics
- **Wichtigste Vertreter:**
MongoDB (2009), Couchbase (2011)

Grundlegende Einteilung


Graph DB



- **Prinzip:**
Daten werden in Knoten + Linien (Verknüpfungen) gespeichert
- **Datenmodell:** Netzwerk
- **Use Cases:**
 - Produkt- oder Freundschafts-Empfehlungen
 - optimale Routen („Problem des Handlungsreisenden“)
- **Wichtigste Vertreter:**
Neo4j (2007)

CAP-Theorem


Consistency



- **Consistency (Konsistenz): Geschriebene Daten sind für alle Benutzer gleich**
- Availability (Verfügbarkeit): DB-System ist für jeden jederzeit verfügbar
- Partition tolerance: Kommunikationsfehler zwischen Komponenten stören nicht die Funktionsweise des Gesamtsystems

CAP-Theorem


Availability



- Consistency (Konsistenz): Geschriebene Daten sind für alle Benutzer gleich
- Availability (Verfügbarkeit): **DB-System ist für jeden jederzeit verfügbar**
- Partition tolerance: Kommunikationsfehler zwischen Komponenten stören nicht die Funktionsweise des Gesamtsystems

CAP-Theorem


Partition tolerance



- Consistency (Konsistenz): Geschriebene Daten sind für alle Benutzer gleich
- Availability (Verfügbarkeit): DB-System ist für jeden jederzeit verfügbar
- **Partition tolerance: Kommunikationsfehler zwischen Komponenten stören nicht die Funktionsweise des Gesamtsystems**

CAP-Theorem

Gesamtdarstellung




- Consistency (Konsistenz): Geschriebene Daten sind für alle Benutzer gleich
- Availability (Verfügbarkeit): DB-System ist für jeden jederzeit verfügbar
- Partition tolerance: Kommunikationsfehler zwischen Komponenten stören nicht die Funktionsweise des Gesamtsystems

CAP-Theorem: Wenn P auftritt, sind C und A nicht gleichzeitig erfüllbar

Anmerkung: Konsistenz und Verfügbarkeit haben eine andere Bedeutung als bei ACID

CAP-Theorem

DB-Ausprägungen



SQL

- Optimiert für zentralisierte Datenbanken (vertical scaling)
- Gewährt strenge Transaktions-Sicherheit (ACID)
- Festes, logisch-konsistentes, nicht-redundantes Datenmodell
- SQL ist high-level Query-Sprache

Probleme

- Skalierung (z.B. bei Performance-Problemen)
- Statistisches Datenmodell & Schema-Erweiterung
 - Workarounds zerstören oftmals die Konsistenz des DB-Modells

Use Cases

- Nur eine Datenquelle
- Systeme mit wenig Benutzern
- Strukturierte Daten
- Komplexe Transaktionen

NoSQL

- Optimiert für verteilte Datenbanken (horizontal scaling)
- Hohe Verfügbarkeit & einfache Skalierbarkeit (Sharding)
- Flexibles, agiles Datenmodell
- Bessere Lese- und Schreib-Performance für große Datenmengen

Probleme


- Transaktions-Sicherheit
- Umstrukturierungen des DB-Modells (z.B. neue Relationen)
- Keine einheitliche Technologie

Use Cases

- Verschiedene Datenquellen
- Systeme mit vielen Benutzern & Cloud Computing
- Semi-Strukturierte, verschachtelte Daten
- Einfache Transaktionen

- Skalierung (horizontal/vertikal oder Cloud) & Performance
- Datenquellen (wenige/viele)
- Datenmodell klassifizieren (strukturierte/unstrukturierte Daten)
- Transaktionen (einfach/komplex)
- Popularität (z. B. <https://db-engines.com>)
- Legacy/Neu-Anwendung
 - Möglichkeiten für Legacy-Anwendungen
 - Migration des Datenmodell
 - Polyglot persistence: Kombination verschiedener Datenbanken-Technologien

- Name abgeleitet von “humongous” (engl.): “gigantisch”
- Geschrieben in C++
- BSON-Basiert (Binary JSON)
- Varianten
 - Open Source: GNU AGPL v3.0
 - Kommerziell: "MongoDB Enterprise Advanced "
 - Tools (Ops Manager, MongoDB Compass)
 - Commercial development license
 - Zusätzliche Sicherheits-Features: Kerberos/LDAP-Authentifizierung, Auditing
 - In-Memory storage engine
- Plattformunabhängig (Windows, Linux, OS X, Solaris)
- GridFS (“Grid File System”) für Dateien größer als 16 MB (maximale Dokumentengröße)



■ Datenorganisation

- SQL-Table: Collection von JSON-Dokumenten
- SQL-Row: Document
 - Aufbau: Key : Value
 - Eindeutigkeit durch `_id` (ObjectId)

■ Zugriff auf MongoDB

- Code: JavaScript, Java, Python, Scala
- GUI-Tools: MongoDB Compass, Robot 3T
- DB-Shell: `mongo`
 - Interaktives JavaScript Interface
 - Kann JS-Skripts ausführen:
`mongo <JS-File>`

```
> show dbs
admin 0.000GB
config 0.000GB
local 0.000GB
> use foo
switched to db foo
> db.stats()
{
  "db" : "foo",
  "collections" : 0,
  "views" : 0,
  "objects" : 0,
  "avgObjSize" : 0,
  "dataSize" : 0,
  "storageSize" : 0,
  "numExtents" : 0,
  "indexes" : 0,
  "indexSize" : 0,
  "fileSize" : 0,
  "fsUsedSize" : 0,
  "fsTotalSize" : 0,
  "ok" : 1
}
```

```
> db.createCollection("MyTestCollection")
{ "ok" : 1 }
> db.fooTest.createIndex({"testIdx":1})
{
  "createdCollectionAutomatically" : false,
  "numIndexesBefore" : 3,
  "numIndexesAfter" : 4,
  "ok" : 1
}
> db.dropDatabase()
{ "dropped" : "foo", "ok" : 1 }
```

System

- Hilfe: `db.help()`
- Show database: `show dbs`
- Create/Switch to DB: `use <database>`
- Show statistics: `db.stats()`

Basics

- Create collection:
`db.createCollection(<name>, <options>)`
- Create Index:
`db.<collection>.createIndex( {y:1} )`
- Create view: `db.createView(<view>, <source>, <pipeline>, <collation> )`
- Drop database: `db.dropDatabase()`

Allgemeines Kommando-Prinzip: `db.<collection>.<command>( JSON )`

JSON: strukturiert durch Operatoren (`$and`, `$or`, `$gt`, `$in`, ...), `<keys>` und `<values>`

- Create

- Prinzip: `db.<collection>.insert(<document>)`

- Bsp.: `db.heroes.insertOne({ Name: "Bruce Wayne", Alias: "Batman", Age: 35 })`

- Read

- Prinzip: `db.<collection>.find(<query criteria><projections>)`

- Projections: Selektive Darstellung von gewünschten Feldern

- Bsp.:

- `db.heroes.find({ Age: { $gt: 18 } }, { Name: 0 } ).limit(5)`

- `db.heroes.find({ Name: { $in: [ "Bruce Wayne", "Clark Kent" ] } })`

- `db.heroes.find({ $or: [ { Alias: "Batman" }, { Age: 40 } ] })`

- Update

- Prinzip: `db.<collection>.update(<update filter>,<updated action>)`

- Bsp.: `db.heroes.updateOne({ Name: "Bruce Wayne" }, { $set: { Name: "B. W." } } )`

- Delete

- Prinzip: `db.<collection>.deleteOne(<delete filter>)`

- Bsp.: `db.heroes.deleteOne({ Age: 35 })`

Siehe "SQL to MongoDB Mapping Chart" (MongoDB Manual)

- Zwei Zugriffsmöglichkeiten
 - MongoTemplate
 - MongoClient: Interface between Java und MongoDB (connect to db, create collection, ...)
 - Bsp.: `mongoTemplate.insert(new Address(), "Address");`
 - MongoRepository
 - Bsp.: `mongoTemplate.insert(new Address(), "Address");`
- MongoConverter
 - Mapping of Java Objekt → Dokument
 - Möglichkeiten
 - Direkt (Annotations-Basiert): `@Document`, `@ID`, ...
 - Custom MongoConverter-Implementation
- MongoTemplate hat Methoden für fundamentale DB-Operationen
 - z.B. `createCollection()`, `mapReduce()`, ...
 - vgl. mit Relationaler DB (JDBC): Execute SQL-Query
- Spring Boot 2: Reactive MongoDB (Zugriff gemäß Publisher-Subscriber Pattern)

```
@Document
public class Person {

    @Id
    private String id;

    @Field("fName") //Mapping to MongoDB-Field "vName"
    private String firstName;

    @Indexed
    private String surName;

    private int age;

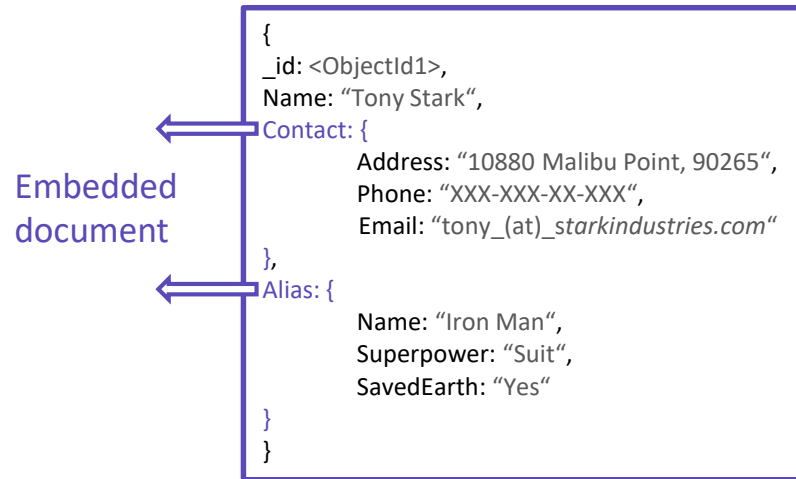
    @Transient //Feld wird bei dem Mapping ignoriert
    private int size;

    @PersistenceConstructor
    public Person(String firstName, String surName, int age) {
        this.firstName = firstName;
        this.surName = surName;
        this.age = age;
    }

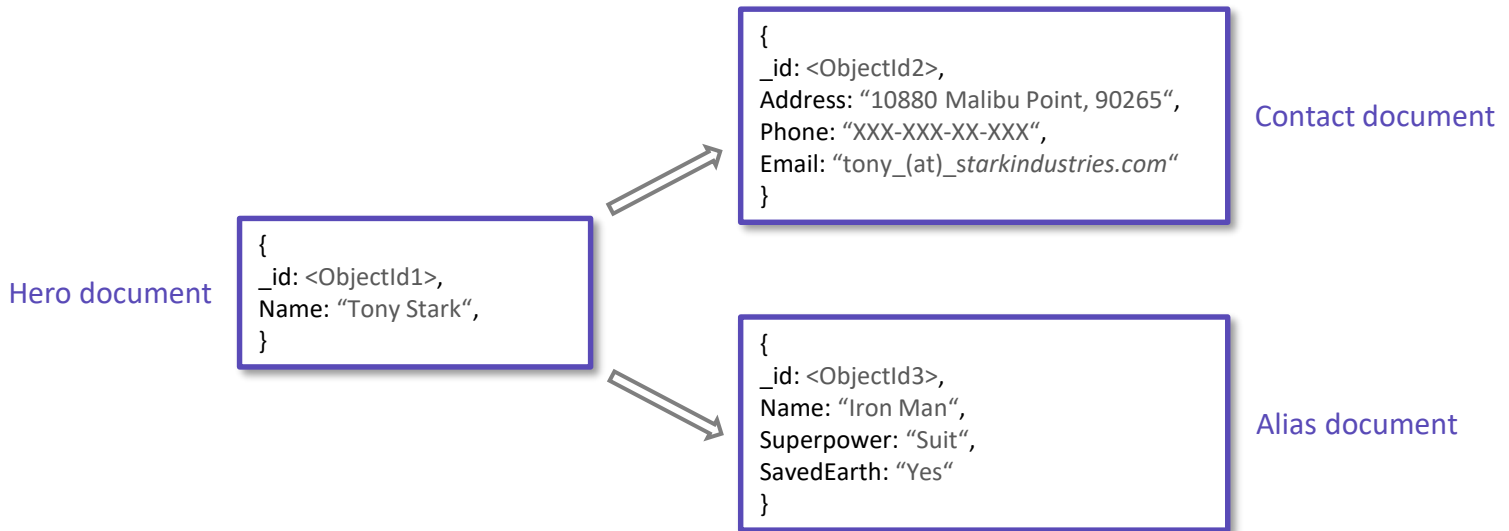
    public String getId() {
        return id;
    }

    //...
}
```


- **Prinzip:** flexibles Schema
 - Optionale Dokumenten-Validierung (bei update/insert) ist möglich
- **Schlüsselfaktoren**
 - Atomicity: Transaktions-Sicherheit (derzeit) nur auf Dokumenten-Ebene
 - Use Cases der Datenverarbeitung in der Anwendung (Queries, Updates,...)
 - Dokumentenstruktur
 - **Embedded documents:** für "contains- " & "one-to-many relationships" (1 Haupt-Dokument greift immer auf viele Unter-Dokumente zu)
 - Referenzen: für komplexe " many-to-many relationships"



- **Prinzip:** flexibles Schema
 - Optionale Dokumenten-Validierung (bei update/insert) ist möglich
- **Schlüsselfaktoren**
 - Atomicity: Transaktions-Sicherheit (derzeit) nur auf Dokumenten-Ebene
 - Use Cases der Datenverarbeitung in der Anwendung (Queries, Updates,...)
 - Dokumentenstruktur
 - Embedded documents: für "contains- " & "one-to-many relationships" (1 Haupt-Dokument greift immer auf viele Unter-Dokumente zu)
 - **Referenzen:** für komplexe " many-to-many relationships"



```
db.heroes.aggregate([
  $match stage → { $match: { Status: "X" } },
  $group stage → { $group: { _id: "$Name", total: { $sum: "$Income" } } }
])
```



■ Prinzip


- Gruppierere Werte aus verschiedenen Dokumenten
- Führe Operationen durch
- Reduziere auf einziges Ergebnis

■ Möglichkeiten

- **Aggregation pipeline**
- Map-Reduce Funktion
- Single-Purpose Aggregation-Methoden

siehe "SQL to Aggregation Mapping Chart" (MongoDB Manual)


```
db.heroes.mapReduce(  
  map →      function() { emit( this.Name, this.Income ); },  
  reduce →   function(key, values) { return Array.sum(values) },  
  
  query →    { Status: "X" },  
  output →   out: "result"  
  })
```



■ Prinzip


- Gruppierere Werte aus verschiedenen Dokumenten
- Führe Operationen durch
- Reduziere auf einziges Ergebnis

■ Möglichkeiten

- Aggregation pipeline
- Map-Reduce Funktion**
- Single-Purpose Aggregation-Methoden

siehe "SQL to Aggregation Mapping Chart" (MongoDB Manual)

```
db.heroes.distinct( "Name" )
```




■ Prinzip

- Gruppriere Werte aus verschiedenen Dokumenten
- Führe Operationen durch
- Reduziere auf einziges Ergebnis

■ Möglichkeiten


- Aggregation pipeline
- Map-Reduce Funktion
- **Single-Purpose Aggregation-Methoden**

siehe "SQL to Aggregation Mapping Chart" (MongoDB Manual)



- **Prinzip:** Gruppe von `mongod`-Instanzen
 - 1 Primary: empfängt alle Write-Operationen
 - N Secondary: replizieren von Primary
- **Failover-Prozess**
 - Wenn Primary nicht erreichbar
 - Auswahlverfahren zwischen den Secondaries
 - Wahl eines neuen Primary
 - Schiedsrichter (engl. „Arbiter“): Instanz ohne Daten

- **Prinzip:** Verteilung von Daten auf mehrere Maschinen (gemäß "horizontal scaling")
- **Komponenten**
 - Query router (Mongos)
 - Shards: Sub-Set der Daten
 - Config Server: Metadaten & Konfiguration
- **Shard Key**
 - Schlüssel, der die Partitionierung in Chunks bestimmt
 - Index-Feld (einzeln, Compound), dass in jedem Dokument existiert
 - Wird beim "Sharden" der Collection festgelegt und kann dann nicht mehr geändert werden
 - Hat Auswirkung auf die Performance, Effizienz und Skalierbarkeit des Sharded Clusters



- NoSQL erweitert die Datenbank-Landschaft
- Grundlegende Einteilung: Key/Value-, Wide-Column-, Document-, Graph-DB
- MongoDB
 - Ist eine dokumentenbasierte Datenbank mit Zugriffsmöglichkeiten über (Mongo-)Shell, GUI-Tools & Code
 - Programmiersprachen-Treiber (z.B. Java) erlauben das komplette DB-Design & Entwicklung
 - Horizontale Skalierung wird durch Sharding erreicht
- Schema-Design (vergleichbar mit Hausbau)
 - Relationale Datenbank: Fertighaus (Einrichtung gemäß fester Vorgaben?)
 - NoSQL-Datenbank: klassischer Hausbau (Wie bleibt Haus stabil?)

