MATHEMA campus 2014

Kein blasses Schema?
NoSQL und Big Data mit Hibernate OGM

Thomas Much

thomas@muchsoft.com
www.muchsoft.com

NoSQL und Big Data …

- Herzlich Willkommen in der NoSQL-Welt!

NoSQL und Big Data …

- NoSQL
  - nicht-relationale Datenbanken, verteilt, skalierbar
  - oft Schema-frei

    ⇒ „Structured Storage“
  - oft keine ACID-Transaktionen

    ⇒ „weak consistency“, „eventual consistency“ (BASE) o.ä.

Besser „NoREL“?

- Big Data
  - Datenmengen: Terabyte 10^{12}, Petabyte 10^{15}, Exabyte 10^{18}
  - Algorithmen wie MapReduce

NoSQL und Big Data …

- Vier Arten von NoSQL-Datenbanken (YMMV):
  - **Document**
    - CouchDB, MongoDB, …, Lucene, …
  - **Graph**
    - Neo4j, …
  - **Key-Value**
    - Redis, Infinispan, EhCache, …
  - **Column**
    - BigTable, HBase, Cassandra, …

NoSQL und Big Data …

- Vier Arten von NoSQL-
  - **Document**
    - CouchDB, MongoD
  - Graph
    - Neo4j, …
  - Key-Value
    - Redis, Infinispan, EhCache, …
  - Column
    - BigTable, HBase, Cassandra, …

```
{"id": "1234",
 "name": "Thomas Much",
 "adressen": [
  {"prio": "1",
   "email": "info@muchsoft.com"},
  {"prio": "2",
   "email": "much@me.com"}
 ]
}
```

NoSQL und Big Data …

- Vier Arten von NoSQL-Datenbanken (YMMV):
  - Document
    - CouchDB, MongoD
  - **Graph**
    - Neo4j, …
  - Key-Value
    - Redis, Infinispan, E
  - Column
    - BigTable, HBase, Cassandra, …

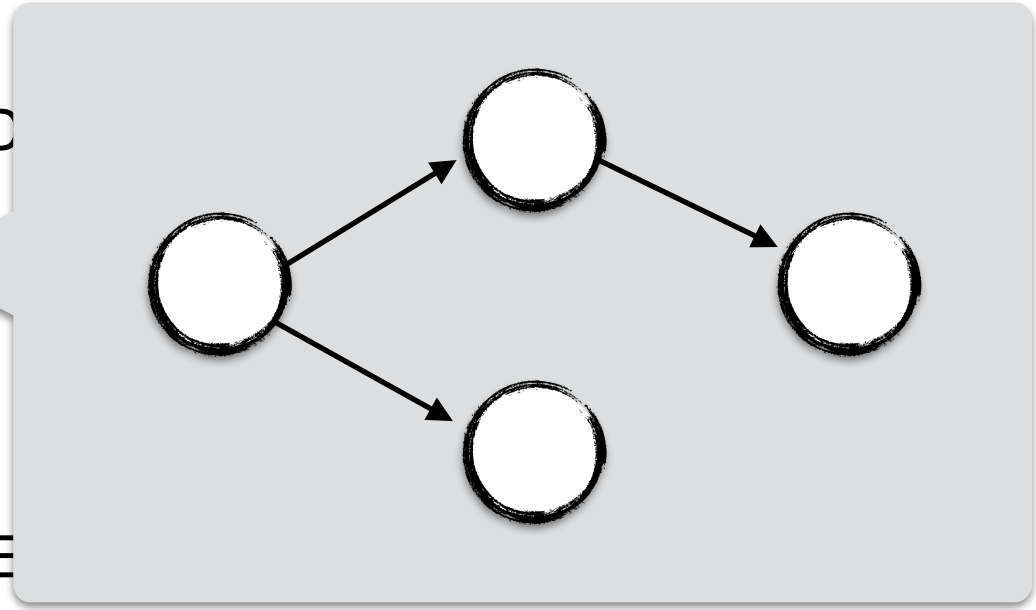

NoSQL und Big Data …

- Vier Arten von NoSQL-Datenbanken (YMMV):
  - Document
    - CouchDB, MongoDB, Lucene
  - Graph
    - Neo4j, …
  - **Key-Value**
    - Redis, Infinispan, E
  - Column
    - BigTable, HBase, C

Key	Value
123	„Thomas“
124	„info@muchsoft.com“
250	„“
1000	1,95583

NoSQL und Big Data …

- Vier Arten von NoSQL-Datenbanken (YMMV):
  - Document
    - CouchDB, MongoDB, Lucene
  - Graph
    - Neo4j, …
  - Key-Value
    - Redis, Infinispan, E
  - **Column**
    - BigTable, HBase, C

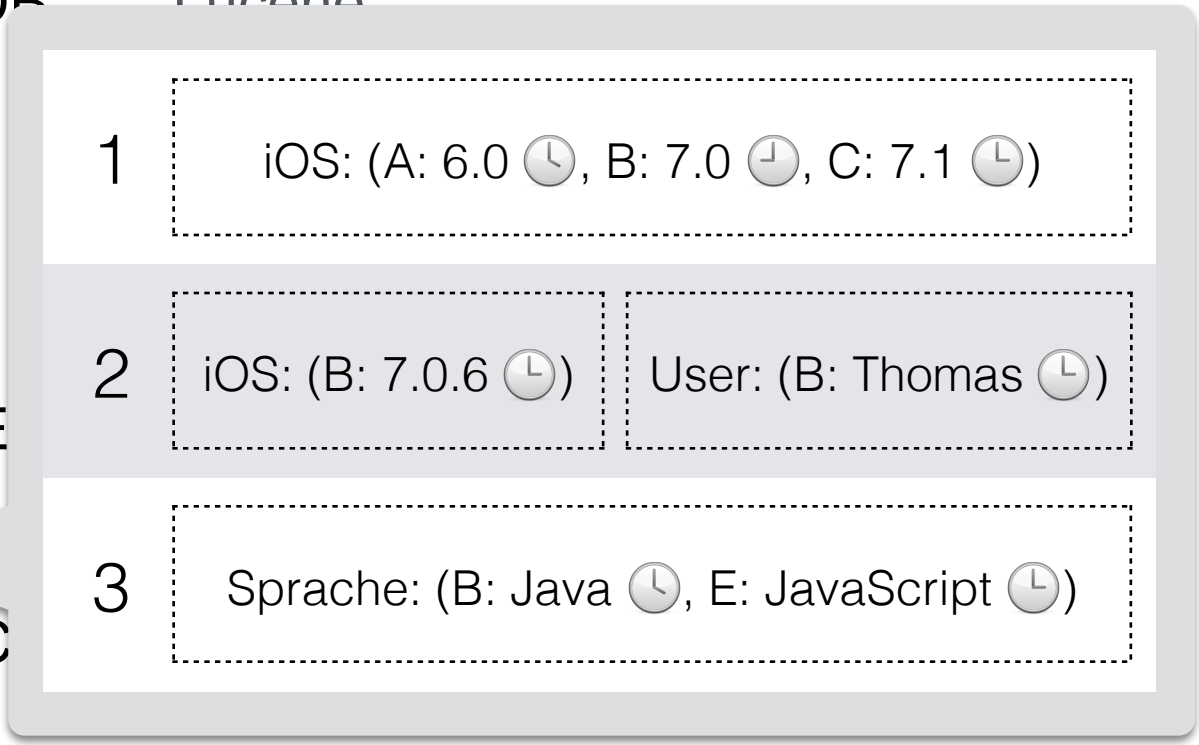

NoSQL und Big Data …

- Kein JDBC, kein SQL
- Kein festes Schema, unterschiedlichste Datenmodelle
- Keine garantierten Transaktionen
- Hohe Performance-Anforderungen

- Das macht NoSQL-Datenbanken zum perfekten Backend für…

NoSQL und Big Data …

Ähem.

NoSQL und Big Data …

Hibernate ? ? ?

Hibernate?

- **Hibernate ORM** (Object Relational Mapping) ≈ „Hibernate“
- Bildet *Domänenmodelle* auf relationale Datenbanken ab; benötigt JDBC(-Treiber) und SQL
- Version 1.0 schon 2002
  Referenzimplementation für JPA 1.0 (2006)
  Unterstützt JPA 2.0 seit 3.5 (2010), JPA 2.1 seit 4.3 (2013)
- De-facto-Standard für ORM in Java
  mit *Hibernate-API* bzw. mit *Java-Persistence-API*

- Neben ORM gibt es weitere Hibernate-Projekte:
  Search, Validator, OGM …

Hibernate OGM!

- **Hibernate OGM** („Object Grid Mapping“)
  - wegen „Data Grids“ als eine der NoSQL-Kategorien

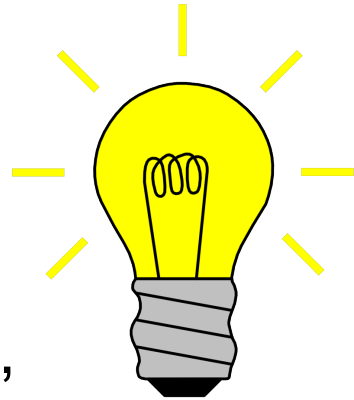

- Idee:
  ORM-Kern verwenden (Entity-Mapping, Abfragen etc.),
  aber auf NoSQL-Datenbanken abbilden
- Vorteil:
  Standard- (JPA) oder zumindest bekannte (Hibernate) API

- Seit 2011 in der Entwicklung
- Aktuelle Version 4.1-Beta (bisher noch kein Final-Release)

Achtung, Beta!

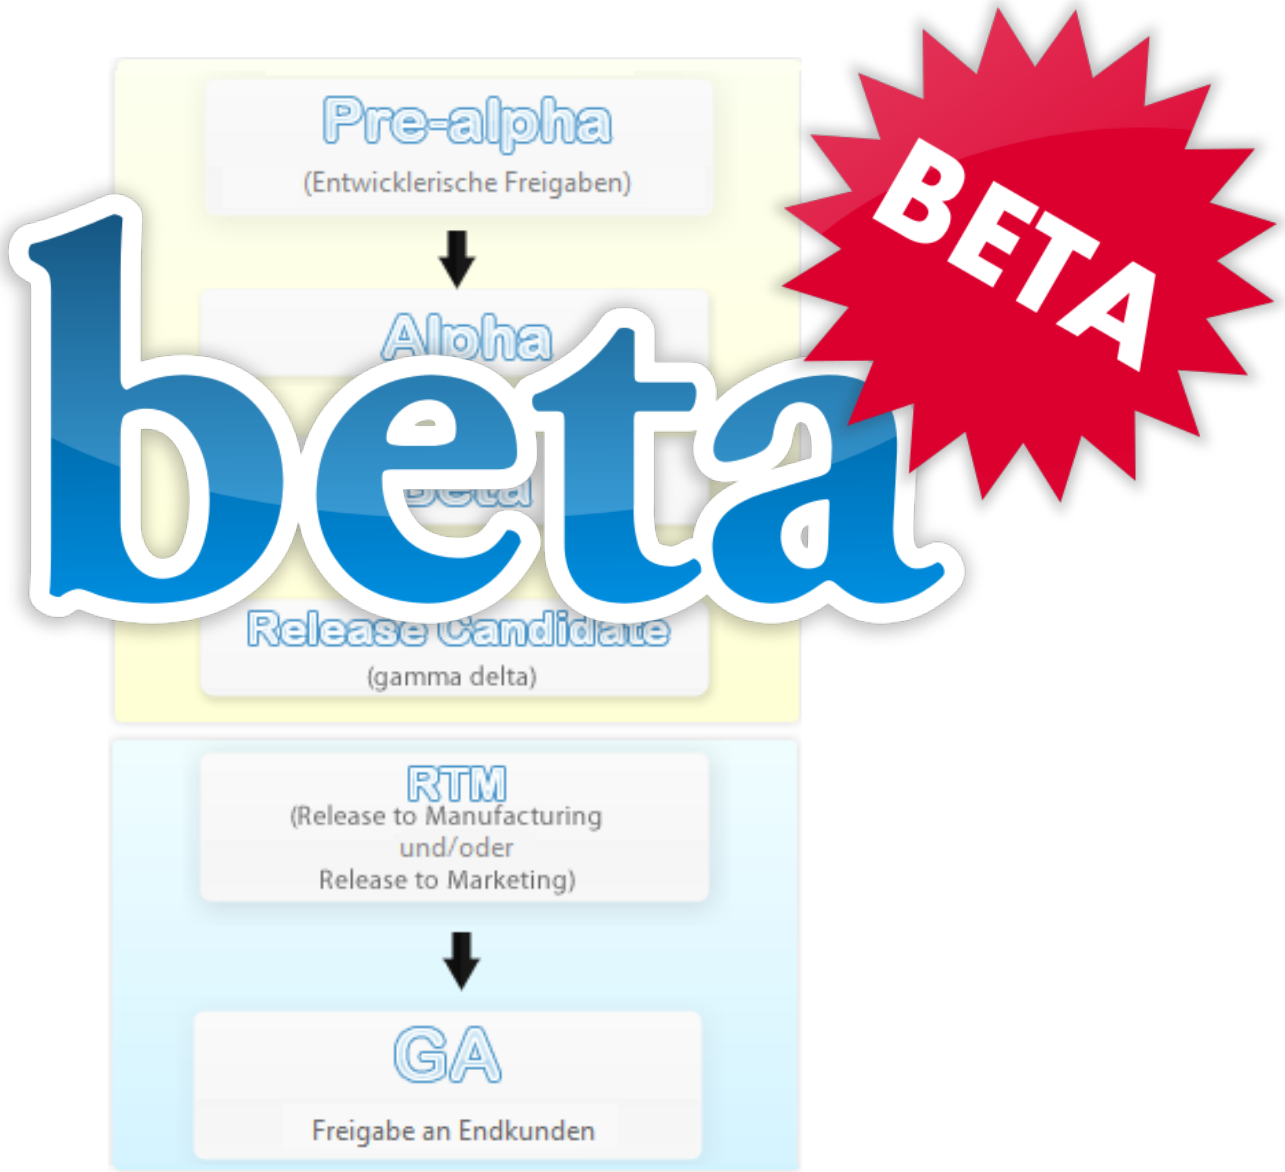

http://de.wikipedia.org/wiki/Entwicklungsstadium_(Software)#Beta-Version

Beta – aber bereits Frontpage-Projekt

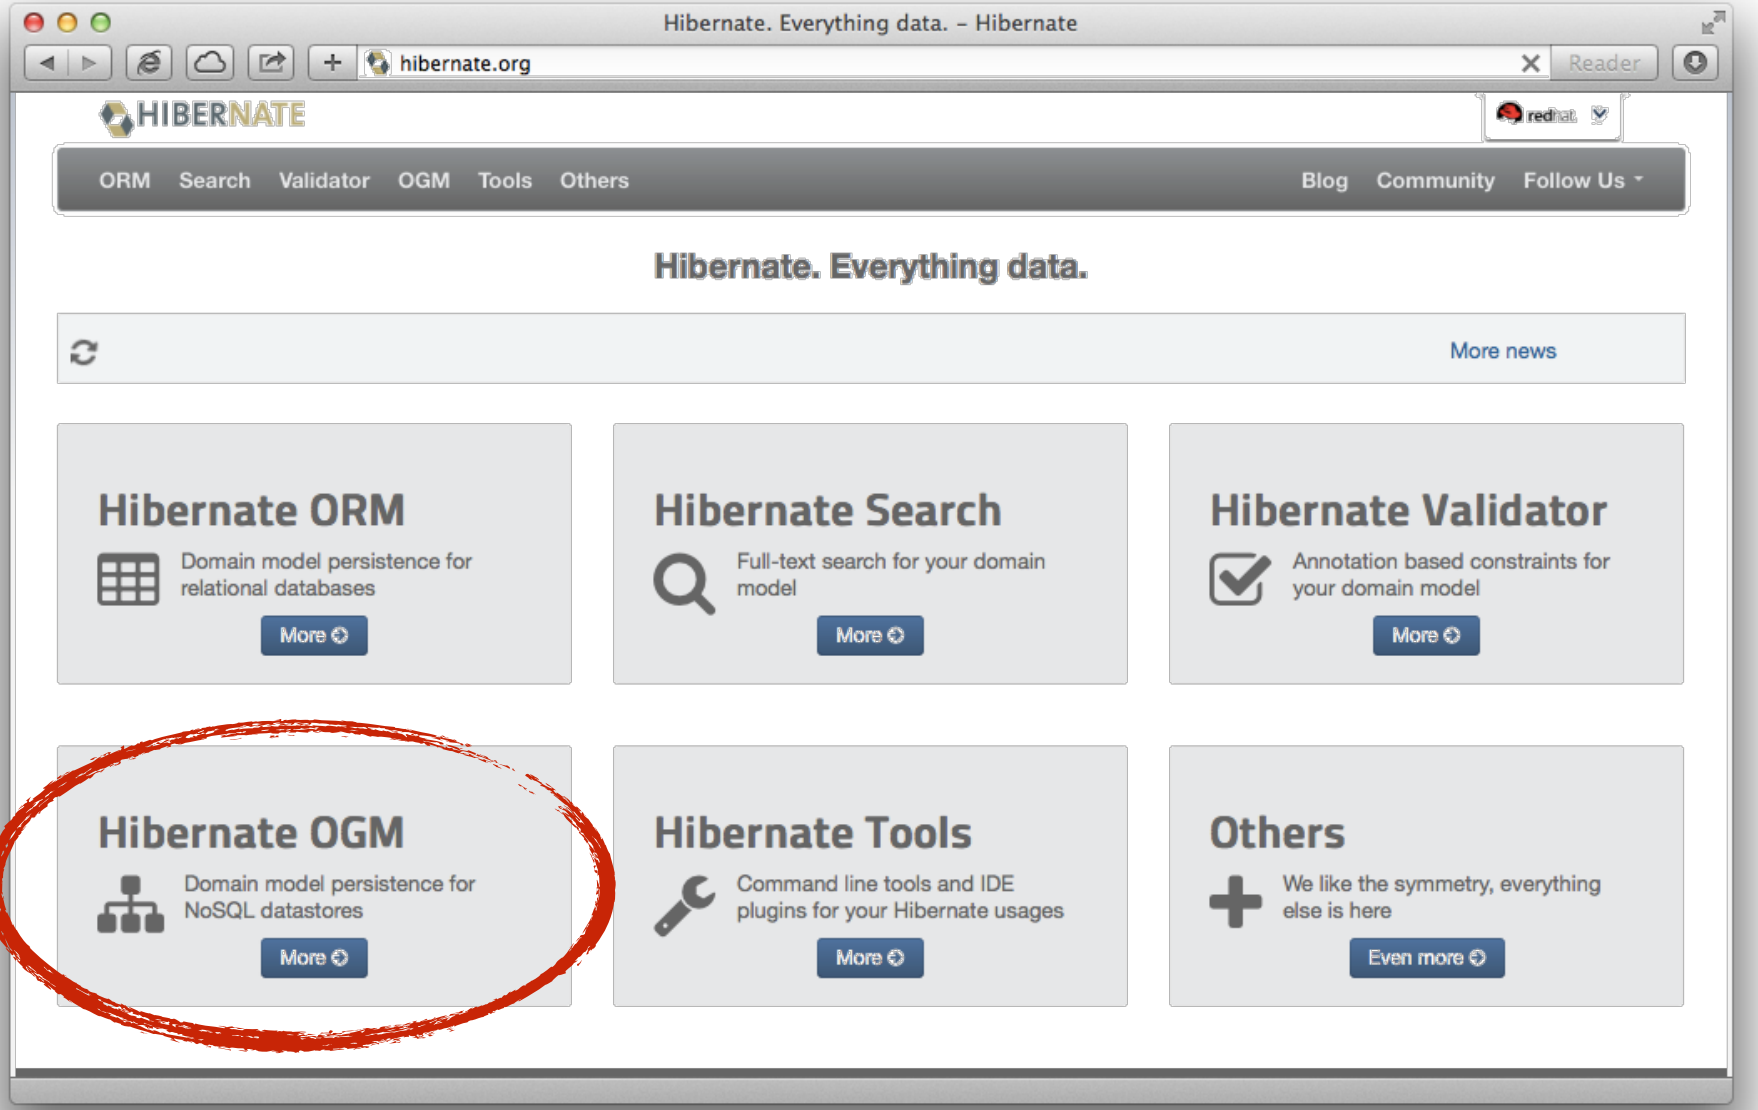

Unterstützte NoSQL-Datenbanken

- Derzeit

- Geplant

Hibernate OGM – Features

- Anbindung diverser NoSQL-Produkte über *Dialekte*
  - auch gleichzeitig in einer Anwendung
  - auch gemischt mit SQL-Datenbanken
- Abfragen (Queries)
  - JPQL (wird in native Abfragen konvertiert)
  - Native Queries
  - Volltext-Abfragen (mittels Hibernate Search)
- Produkt(familien)-spezifische API (ergänzend zu JPA)

JPA und NoSQL – passt das?

- JPA = *Java Persistence* (nicht „Java Relational Persistence“)
  - auch wenn der Standard derzeit nur relationale DBs behandelt
- Viele Konzepte passen:
  `@Embeddable` (Komponenten), `@ElementCollection`
- Vieles lässt sich ohne große Verrenkungen abbilden:
  Assoziationen, Unterklassen
- Voraussetzung: Domänenmodell
  - ähnliche Abwägung wie bei JPA vs. JDBC

NoSQL mit JPA-Entites

```
@Entity
@Table(name = "artikel")
public class Artikel {
    @Id @GeneratedValue(generator = "uuid")
    @GenericGenerator(name = "uuid", strategy = "uuid2")
    private String id;

    private String name;
    private String beschreibung;
    private Double preis;

    @ManyToOne
    private Farbe farbe;
```

Getter/Setter etc. ausgelassen

JPA und NoSQL – passt das?

- Vorteile:
  - Abstraktion auf Entity-Klassen-Ebene
    (zur Laufzeit viele Optimierungen durch Hibernate möglich)
  - Bekannte API + Semantik
  - Späte Wahl des konkreten NoSQL-Produkts möglich!
- Nachteile:
  - Abstraktion (Performance?)
- Ähnliche Diskussion wie bei pro/contra Hibernate (JPA)

Hibernate OGM – Architektur

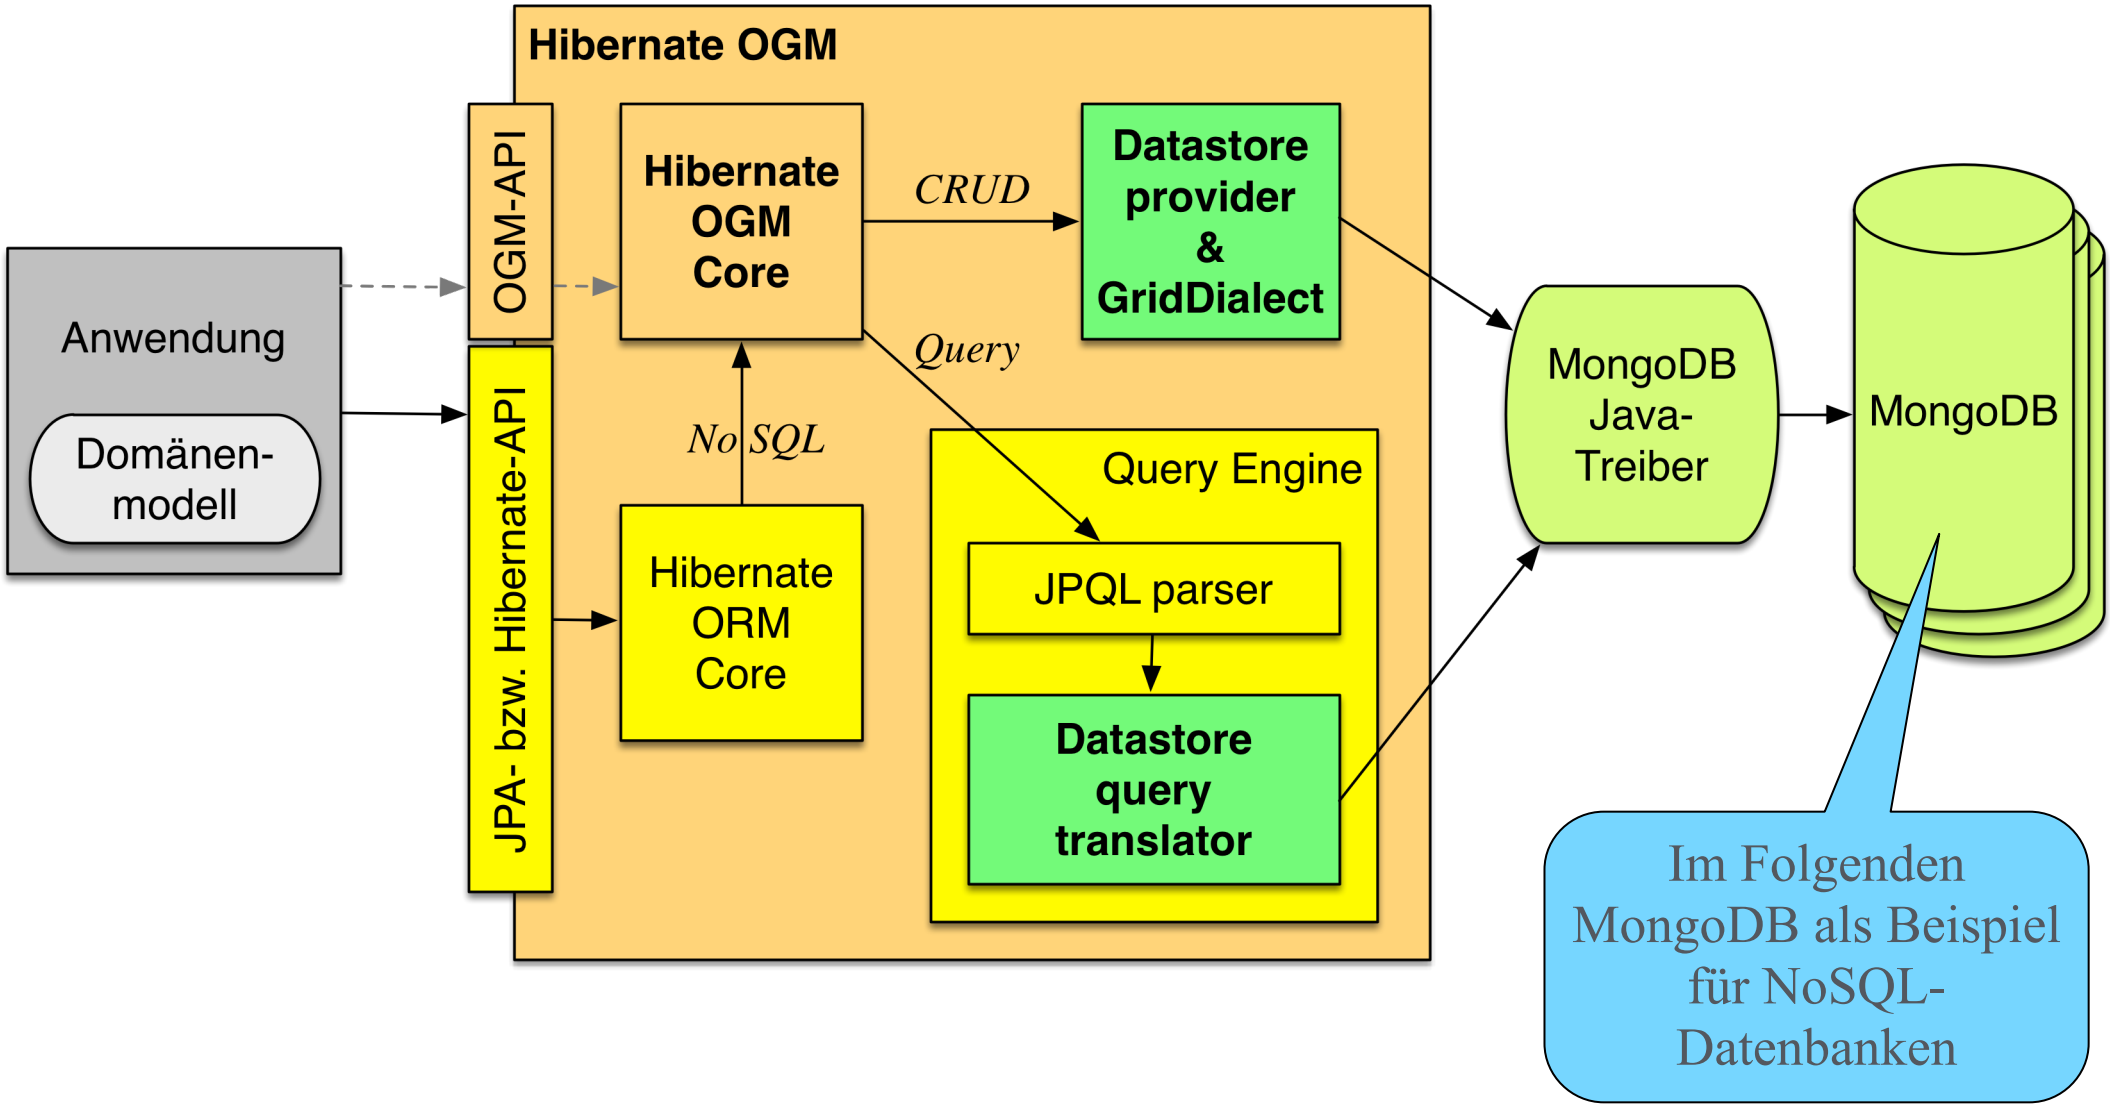

Hibernate OGM – Architektur

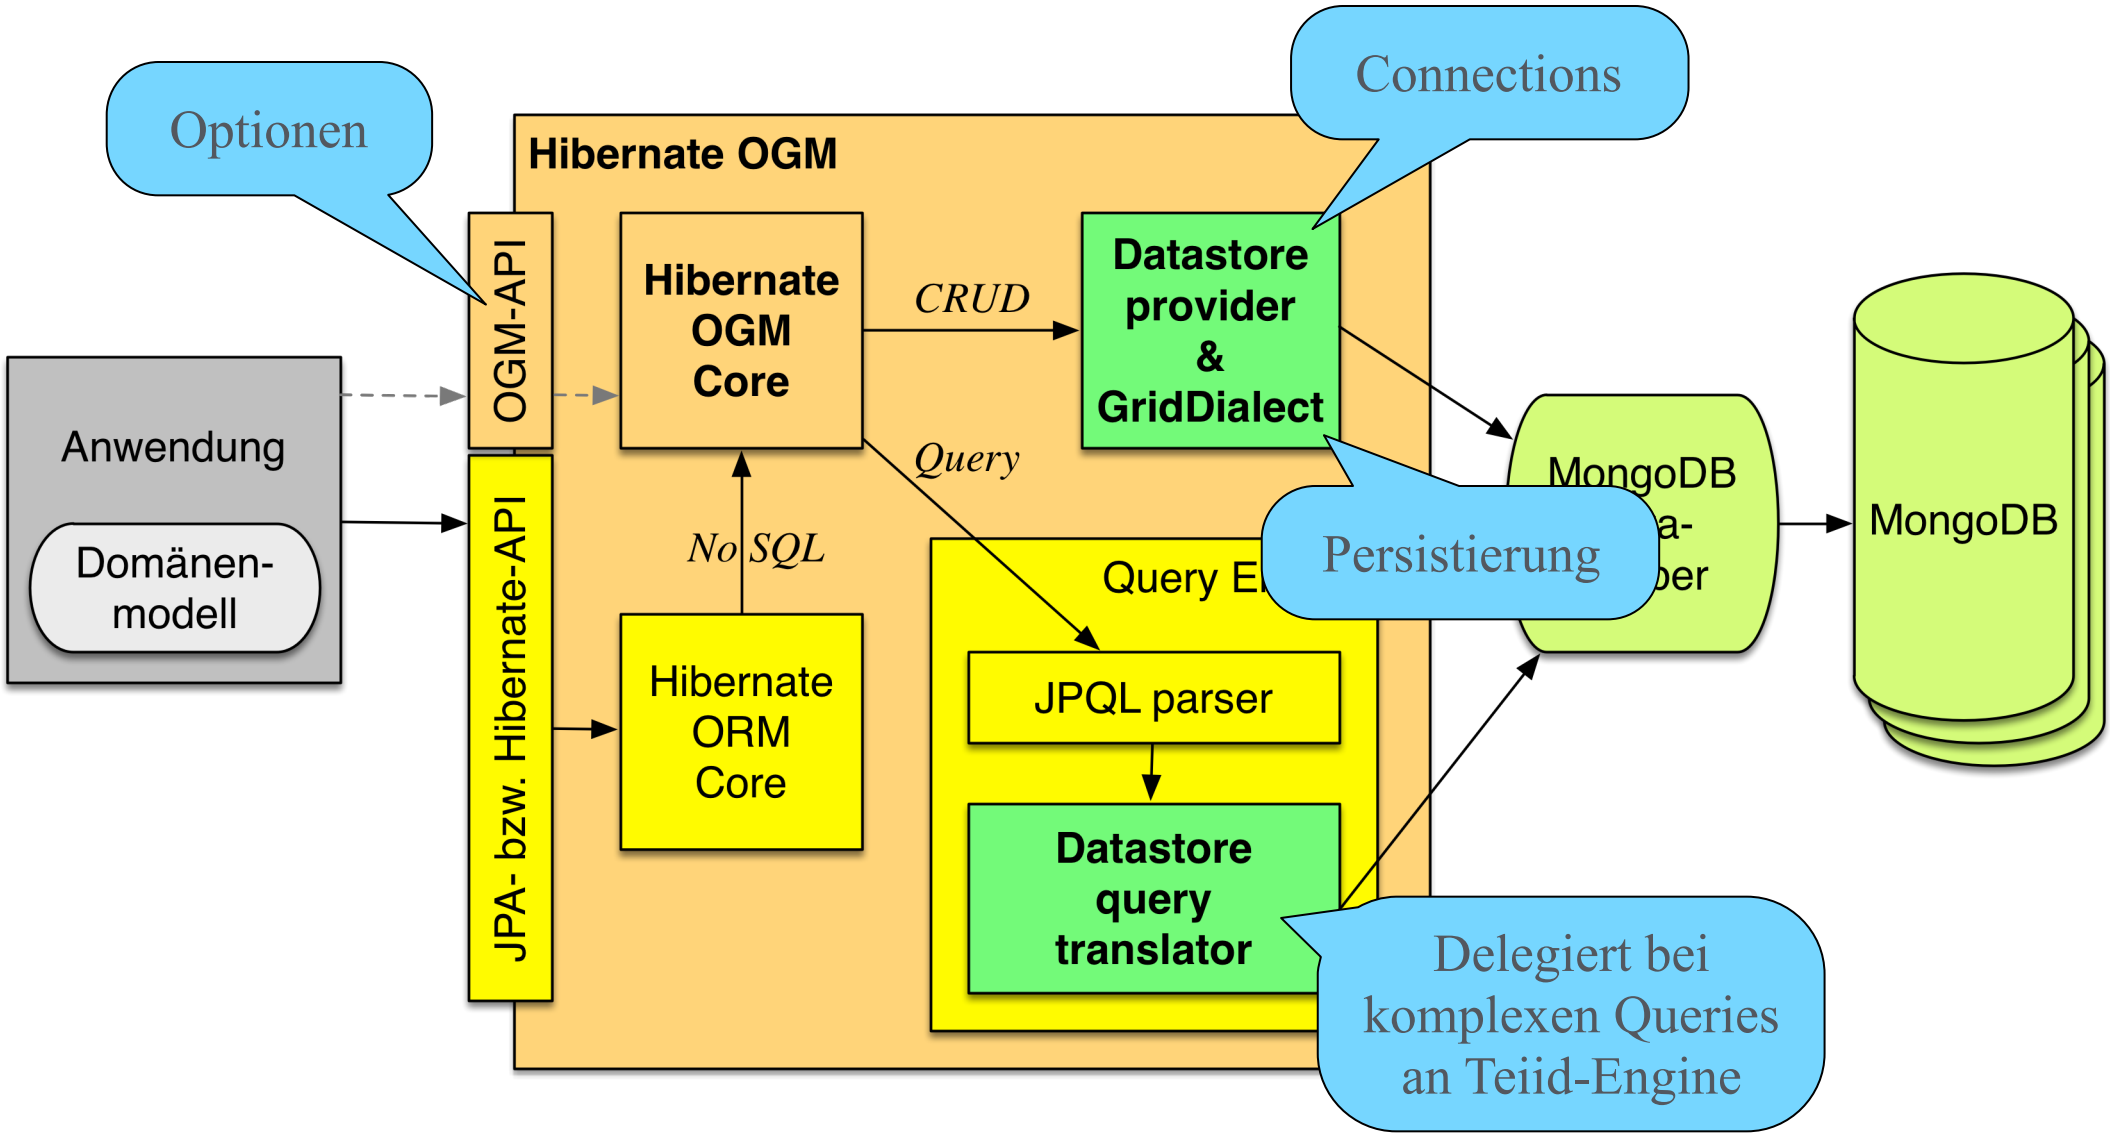

Entities persistieren…

```
EntityManagerFactory emf =
   Persistence.createEntityManagerFactory("meine-mongodb-pu");

TransactionManager transactionManager =
   com.arjuna.ats.jta.TransactionManager.transactionManager();

transactionManager.begin();

EntityManager em = emf.createEntityManager();


Artikel artikel = new Artikel("iMac",
            "iMac 27\", 16 GB RAM, 1 TB Fusion Drive", 2999.0);

em.persist( artikel );


em.flush();

transactionManager.commit();

em.close();
```

… mit Transaktionen???

- MongoDB unterstützt keine TAs (so wie viele NoSQL-DBs)
  - Atomarität nur auf Dokument-Ebene
- JPA-TA-Klammer trotzdem empfohlen!
  (Aber nicht erzwungen)
- Relevant für die NoSQL-Datenbanken, die Transaktionen unterstützen (z.B. Neo4j mit ACID-TAs)
- Bei MongoDB für automatisches Flush beim TA-Commit
  - Rollback hier aber nicht möglich

Konfiguration in persistence.xml (1)

```
<?xml version="1.0"?>
<persistence xmlns="http://java.sun.com/xml/ns/persistence"
   xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
   xsi:schemaLocation="http://java.sun.com/xml/ns/persistence"
   http://java.sun.com/ xml/ns/persistence/persistence_2_0.xsd"
   version="2.0">

   <persistence-unit name="meine-mongodb-pu" transaction-type="JTA">

      <provider>
         org.hibernate.ogm.jpa.HibernateOgmPersistence
      </provider>

      <jta-data-source>java:/DefaultDS</jta-data-source>


      <properties> … </properties>

   </persistence-unit>
</persistence>
```

Nur im Java-EE-Container

Konfiguration in persistence.xml (2)

```
<properties>

   <property name="hibernate.transaction.jta.platform"
             value="org.hibernate...JBossStandAloneJtaPlatform" />


   <property name="hibernate.ogm.datastore.provider"
             value="mongodb" />

   <property name="hibernate.ogm.datastore.database"
             value="test" />


   <property name="hibernate.ogm.datastore.host" value="127.0.0.1"/>
   <property name="hibernate.ogm.datastore.port" value="27017" />

   <!-- username, password, connection_timeout ... -->

</properties>
```

MongoDB

much — mongod — 95×19

```
StraylightMBA:~ much$ mongod
mongod --help for help and startup options
Fri Mar 14 12:31:26.052 [initandlisten] MongoDB starting : pid=1564 port=27017 dbpath=/data/db/
 64-bit host=StraylightMBA.local
Fri Mar 14 12:31:26.052 [initandlisten]
Fri Mar 14 12:31:26.052 [initandlisten] ** WARNING: soft rlimits too low. Number of files is 25
6, should be at least 1000
Fri Mar 14 12:31:26.052 [initandlisten] db version v2.4.9
Fri Mar 14 12:31:26.052 [initandlisten] git version: 52fe0d21959e32a5bdbecdc62057db386e4e029c
Fri Mar 14 12:31:26.052 [initandlisten] build info: Darwin bs-osx-106-x86-64-2.10gen.cc 10.8.0
Darwin Kernel Version 10.8.0: Tue Jun  7 16:32:41 PDT 2011; root:xnu-1504.15.3~1/RELEASE_X86_64
 x86_64 BOOST_LIB_VERSION=1_49
Fri Mar 14 12:31:26.052 [initandlisten] allocator: system
Fri Mar 14 12:31:26.052 [initandlisten] options: {}
Fri Mar 14 12:31:26.053 [initandlisten] journal dir=/data/db/journal
Fri Mar 14 12:31:26.053 [initandlisten] recover : no journal files present, no recovery needed
Fri Mar 14 12:31:26.082 [websvr] admin web console waiting for connections on port 28017
Fri Mar 14 12:31:26.083 [initandlisten] waiting for connections on port 27017
```

much — mongo — 73×14

```
StraylightMBA:~ much$ mongo
MongoDB shell version: 2.4.9
connecting to: test
Server has startup warnings:
Fri Mar 14 12:31:26.052 [initandlisten]
Fri Mar 14 12:31:26.052 [initandlisten] ** WARNING: soft rlimits too lo
 Number of files is 256, should be at least 1000
> show dbs
local   0.078125GB
test    (empty)
> use test
switched to db test
> show collections
>
```

Artikel speichern …

```
@Entity
@Table(name = "artikel")
public class Artikel {
    @Id @GeneratedValue(generator = "uuid")
    @GenericGenerator(name = "uuid", strategy = "uuid2")
    private String id;

    private String name;
    private String beschreibung;
    private Double preis;

    public Artikel() {}
    public Artikel(String name, String beschreibung, Double preis)…
```

… Mongo-Shell …

JPA-Entity

```
> db
test

> show collections
artikel
system.indexes

> db.artikel.find()
{ "_id" : "bf391a40-b1a3-4b7f-a92b-f5aa8fbbd155",
"preis" : 876.54, "name" : "iPhone 6",
"beschreibung" : "256 GB, Farbe: Blue Dalmatian" }
{ "_id" : "ae5b8cf9-3a3b-45ff-b763-9f7f1c254af4",
"preis" : 2999, "name" : "iMac", "beschreibung" :
"iMac 27\", 16 GB RAM, 1 TB Fusion Drive" }

> db.artikel.findOne()
{
    "_id" : "bf391a40-b1a3-4b7f-a92b-f5aa8fbbd155",
    "preis" : 876.54,
    "name" : "iPhone 6",
    "beschreibung" : "256 GB, Farbe: Blue Dalmatian"
}
```

… Artikel laden (mit JPQL)

```
transactionManager.begin();
EntityManager em = emf.createEntityManager();

TypedQuery<Artikel> q =
    em.createQuery("select a from Artikel a", Artikel.class);

List<Artikel> artikelListe = q.getResultList();

for (Artikel a : artikelListe) { … }

em.flush();
transactionManager.commit();
em.close();
```

Datensätze ohne OGM / JPA

```
> art = { name: "iTV", preis: 1499.9 }
{ "name" : "iTV", "preis" : 1499.9 }

> db.artikel.insert( art )

> db.artikel.find()
{ "_id" : "bf391a40-b1a3-4b7f-a92b-f5aa8fbbd155", "preis" :
876.54, "name" : "iPhone 6", "beschreibung"
Blue Dalmatian" }
{ "_id" : "ae5b8cf9-3a3b-45ff-b763-9f7f1c25
2999, "name" : "iMac", "beschreibung" : "iM
1 TB Fusion Drive" }
{ "_id" : ObjectId("5329fa368b95bcac0b9e729e"), "name" : "iTV",
"preis" : 1499.9 }
```

MongoDB-ObjectId kann beim Laden von OGM nicht gemappt werden…

Exception in thread "main" javax.persistence.PersistenceException: org.hibernate.PropertyAccessException: could not set a field value by reflection setter of model.Artikel.id

Caused by: java.lang.IllegalArgumentException: Can not set java.lang.String field model.Artikel.id to org.bson.types.ObjectId

Produktspezifische Abfragen

```
Query q = em.createNativeQuery("{name:'iMac'}", Artikel.class);

Query q = em.createNativeQuery(
   "{$and: [ {name:'iMac'}, {preis:2999} ]}", Artikel.class);

Query q = em.createNativeQuery(
   "{$query: {name:'iMac'}, $orderby: {name:1}}", Artikel.class);

Query q = em.createNamedQuery("alleImacs");


Artikel imac = (Artikel) q.getSingleResult();
```

```
@Entity
@Table(name = "artikel")
@NamedNativeQuery(
  name = "alleImacs",
  query = "{$query: {name:'iMac'}, $orderby: {name:1}}",
  resultClass = Artikel.class)
public class Artikel { ... }
```

Hibernate OGM / Search – Architektur

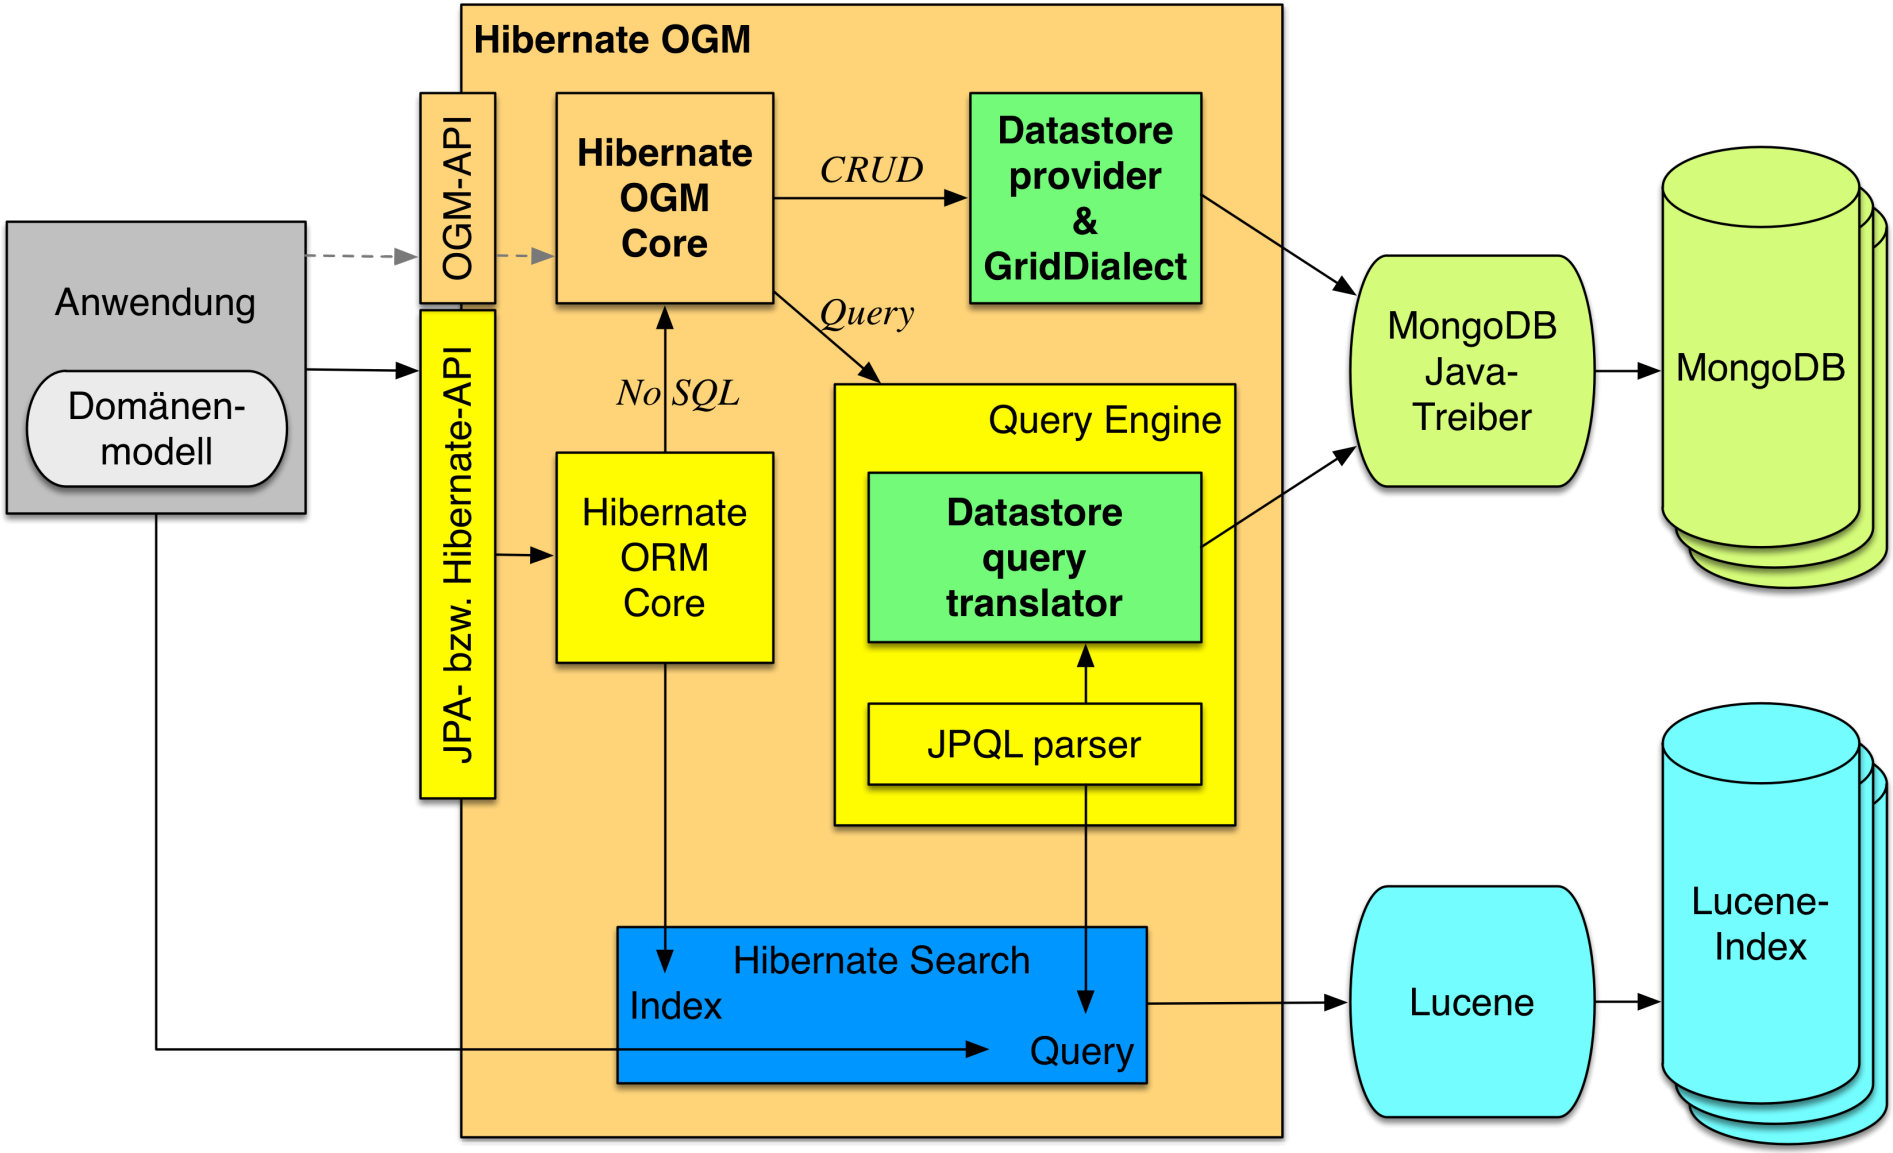

Volltext-Index mit Hibernate Search

```
@Indexed
@Entity
public class Artikel {

    @Id ... private String id;

    @Field(analyze = Analyze.NO)
    private String name;

    @Field(analyze = Analyze.YES)
    private String beschreibung;

    …
}
```

```
<property
   name="hibernate.search.default.directory_provider"
   value="filesystem" />
<property
   name="hibernate.search.default.indexBase"
   value="/data/search" />
```

- Damit ist bereits die JPQL-Suche in NoSQL-Datenbanken möglich, die keine eigene Abfragesprache besitzen!

Abfragen mit Hibernate Search

```
EntityManager em = …;

FullTextEntityManager ftem =
    Search.getFullTextEntityManager( em );

QueryBuilder b =
    ftem.getSearchFactory().buildQueryBuilder()
        .forEntity(Artikel.class).get();

Query luceneQuery =
    b.keyword().onFields("name", "beschreibung")
     .matching("imac").createQuery();


FullTextQuery ftQuery =
    ftem.createFullTextQuery(luceneQuery, Artikel.class);

ftQuery.initializeObjectsWith(ObjectLookupMethod.SKIP,
                    DatabaseRetrievalMethod.FIND_BY_ID);

List<Artikel> artikelListe = ftQuery.getResultList();
…
```

Etwas mehr Mapping, bitte

- Eingebettete Komponenten
- Listen von Werten / Komponenten
- Assoziationen
- Vererbung

- Im Folgenden: Entity mit Mapping & JSON in der Datenbank

Eingebettete Komponenten…

```
@Entity
@Table(name = "artikel")
public class ArtikelMitVariante {
    @Id … uuid …
    private String id;

    private String name;
    private String beschreibung;
    private Double preis;

    @Embedded
    private Variante variante;
    …
```

Mongo-Shell (JSON)

```
@Embeddable
public class Variante {
  private String groesse;
  private String farbe;
  …
}
```

… Eingebettete Komponenten

```
> db.artikel.find()
{ "_id" : "bf391a40-b1a3-4b7f-a92b-f5aa8fbbd155",
"preis" : 876.54, "name" : "iPhone 6",
"beschreibung" : "256 GB, Farbe: Blue Dalmatian" }
…
{ "_id" : "df40aa17-005e-4915-a83b-63617ada831f",
"beschreibung" : "Schönes T-Shirt", "name" : "T-
Shirt", "preis" : 19.95, "variante" : { "farbe" :
"orange", "groesse" : "S" } }
```

JPA-Entity

```
> db.artikel.findOne( {name:"T-Shirt"} )
{
    "_id" : "df40aa17-005e-4915-a83b-63617ada831f",
    "beschreibung" : "Schönes T-Shirt",
    "name" : "T-Shirt",
    "preis" : 19.95,
    "variante" : {
        "farbe" : "orange",
        "groesse" : "S"
    }
}
```

Collection als Artikel laden?

Listen von Werten / Komponenten…

```
@Entity
@Table(name = "artikel")
public class ArtikelMitGroessen {
    @Id … uuid …
    private String id;

    private String name;
    private String beschreibung;
    private Double preis;

    @ElementCollection
    private List<String> groessen = new ArrayList<>();
    …
```

… Listen von Werten / Komponenten

```
> db.artikel.findOne( {name:"Poloshirt"} )
{
    "_id" : "710b2cf5-9463-4243-bd93-86163b387903",
    "beschreibung" : "Buntes Poloshirt",
    "groessen" : [
        {
            "groessen" : "M"
        },
        {
            "groessen" : "L"
        },
        {
            "groessen" : "XL"
        },
        {
            "groessen" : "S"
        }
    ],
    "name" : "Poloshirt",
    "preis" : 14.95
}
```

JPA-Entity

Assoziationen…

```
@Entity
@Table(name = "artikel")
public class ArtikelMitFarbe {
    @Id … uuid …
    private String id;

    private String name;
    private String beschreibung;
    private Double preis;

    @ManyToOne(cascade = CascadeType.PERSIST)
    private Farbe farbe;
    …
```

```
@Entity
@Table(name = "farben")
public class Farbe {
   @Id
   private String name;
   …
}
```

… Assoziationen

JPA-Entities

```
> db.artikel.find()

{ "_id" : "1ea30dc7-005b-4eaf-a325-d6df08059501",
"farbe_name" : "rot", "preis" : 9.95, "name" : "T-
Shirt 1a", "beschreibung" : "Rotes T-Shirt" }

{ "_id" : "fbe4b0cb-d6c7-4d50-a890-9c25cc9d70fc",
"farbe_name" : "rot", "preis" : 17.95, "name" : "T-
Shirt 1b", "beschreibung" : "Rotes T-Shirt" }

{ "_id" : "44c543a8-d8e4-4de4-8066-753fa5e4949b",
"farbe_name" : "grün", "preis" : 19.95, "name" : "T-
Shirt 2", "beschreibung" : "Grünes T-Shirt" }
```

```
> db.farben.find()

{ "_id" : "rot" }

{ "_id" : "grün" }
```

(MongoDB-)spezifische Konfiguration

- Verknüpfungsinformationen für Assoziationen werden standardmäßig in der Entity abgelegt.
- Optional in separater Assoziations-Kollektion:

```
import org.hibernate.ogm.datastore.document.options.*;
import org.hibernate.ogm.datastore.mongodb.options.*;

@Entity
@Table(name = "artikel")
@AssociationStorage(
    AssociationStorageType.ASSOCIATION_DOCUMENT)
@AssociationDocumentStorage(
    AssociationDocumentType.COLLECTION_PER_ASSOCIATION)
public class ArtikelMitFarbe { … }
```

- Konfiguration alternativ über Properties oder mit der Options-API.

Vererbung…

```
@Entity
@Table(name = "artikel")
@Inheritance(strategy = InheritanceType.TABLE_PER_CLASS)
public class Artikel { ... }
```

Andere Vererbungs-Strategien werden *nicht* unterstützt

```
@Entity
public class ArtikelMitDatum extends Artikel {

   private Date datum;

   …
}
```

Mongo-Shell (JSON)

… Vererbung

JPA-Entities

```
> show collections

ArtikelMitDatum
artikel

> db.artikel.find()

{ "_id" : "7a6cc2d4-85db-44cf-afa2-847a155aec10",
"preis" : 876.54, "name" : "iPhone 6",
"beschreibung" : "256 GB, Farbe: Blue Dalmatian" }

{ "_id" : "8036b24a-37aa-43e8-9306-b558a5f4d8e3",
"preis" : 2999, "name" : "iMac", "beschreibung" :
"iMac 27\", 16 GB RAM, 1 TB Fusion Drive" }

> db.ArtikelMitDatum.find()

{ "_id" : "5500c09d-d611-4f4c-99bc-7cfb5549880d",
"preis" : 19.95, "name" : "T-Shirt", "beschreibung" :
"Schönes T-Shirt", "datum" :
ISODate("2014-03-20T20:48:15.543Z") }
```

Hibernate-API

- Anstelle der Java-Persistence-API kann auch die proprietäre Hibernate-API verwendet werden
  - Bitte nur in gut begründeten Fällen…

```
Configuration cfg = new OgmConfiguration();

cfg.setProperty("hibernate.ogm.datastore.provider", "mongodb");
…

cfg.addAnnotatedClass( … );

SessionFactory sf = cfg.buildSessionFactory();

…
```

Andere NoSQL-Datenbanken

- Map – für Unit-Tests
- Infinispan – (sehr) gute Unterstützung, JTA
- EhCache – gute Unterstützung, (derzeit) keine TA-Nutzung
- Neo4J – experimentell, JTA / ACID
- CouchDB – experimentell, keine TA

- Zur Konfiguration der unterstützten NoSQL-Datenbanken stehen spezielle Properties (und teilweise auch Annotationen) zur Verfügung.

Ausblick / Roadmap nach OGM 4.1

- Hibernate OGM 4.2
  - benutzerdefinierte Typen
  - gleichzeitiges Schreiben in mehrere Backends (No+SQL)
  - Cassandra? HBase?
  - Anpassung an Hibernate ORM 5
- Hibernate OGM 4.3
  - „Polyglotte Persistenz“
  - Queries verbessern (Joins, Map/Reduce)
- danach
  - (Nicht-)Schema-Migrationen (mit Annotationen und/oder API)

Hibernate OGM – Fazit (1)

- Hibernate OGM übernimmt relationale Konzepte, sofern sie sinnvoll für NoSQL-Datenbanken sind:
  - Domänenmodell als Struktureinheit
  - Primärschlüssel
  - „Fremdschlüssel“ für Verbindungen zwischen Entities
- Mit diesen Konzepten hat das relationale Modell vor über 30 Jahren die damalige Datenbank-Welt vereinheitlicht
  - bei OGM aber ohne strenge Konsistenzprüfungen
  - „Convention over Constraints“ 😉

Hibernate OGM – Fazit (2)

- Derzeit können JPA-Entities schon gut in NoSQL-Datenbanken gespeichert werden
  - in einem Format, das auch für andere (Nicht-OGM-) Anwendungen gut lesbar ist
- Das Einlesen beliebiger fremd-geschriebener NoSQL-Datenbanken klappt dagegen nicht immer
- teilweise noch buggy, Features teilweise noch unvollständig
- Performance gut testen
  - ist bei großen Assoziationen derzeit nicht wirklich gut

Hibernate OGM – Fazit (3)

- Spannende – weil erstaunlich gut passende – Verwendung von vorhandener Standard-API (JPA) für aktuellen NoSQL-Trend
- Trotz Beta schon einen Blick wert!
  - auch wenn bis zur Final noch viel zu tun ist (mitmachen! 😊)
- Produktiveinsatz muss derzeit noch sehr gut geprüft werden
  - evtl. sind die proprietären APIs derzeit noch geeigneter / stabiler
- Guter (einfacher!) Einstieg in die NoSQL-Welt
  - gerade auch für Unternehmen mit etwas „traditionellerer“ IT

Fragen?

Vielen Dank! 😊

thomas.much@muchsoft.com