

# Search Evolution – von Lucene zu Solr und ElasticSearch



**Florian Hopf**

**@fhopf**

**<http://www.florian-hopf.de>**



## Das Programm der BED-Con 2013 in der Übersicht

Haben Sie Fragen zum Programm? Bitte schreiben Sie eine E-Mail an uns [michael.schuetz {at} bed-con \(dot\) org](mailto:michael.schuetz@bed-con.org). Bei gegebenem Anlass können noch kurzfristig Änderungen im Programm erfolgen.

### Donnerstag, 04. April 2013

| Zeit          | Hörsaal 1  | Hörsaal 2  | Seminarraum 1  | Seminarraum 2   |
|---------------|--|--|--|---|
| ab 08:00      | Einlass  |  |  |   |
| 09:00 – 10:00 | <b>JavaScript + Java EE = ♥</b><br>Kris Borchers     | <b>OAuth 2.0 – Ein Standard wird erwachsen</b><br>Uwe Friedrichsen                               | <b>Search Evolution – Von Lucene zu Solr und ElasticSearch</b><br>Florian Hopf   | <b>Offline Strategien für HTML5 Web Applikationen</b><br>Stephan Hochdörfer |
| 10:00 – 10:15 | Pause  |  |  |   |
| 10:15 – 11:15 | <b>Java EE 7, the road ahead</b><br>David Delabassee | <b>Memory Management: TP, CMS und G1 – welche GC-Strategie ist die richtige?</b><br>Tobias Frech | <b>Kurzvortrag-Session</b><br><b>Guttenbase</b> Markus Dahm<br><b>DB versionieren</b> Niko Köbler<br><b>Togglz</b> Niko Köbler | <b>Spring Data Repositories unter der Lupe</b><br>Oliver Gierke             |
| 11:15 – 11:30 | Pause  |  |  |   |

## DB versionieren

Dein Quellcode ist versioniert im Repository abgelegt! Warum Deine **Datenbank** nicht?Jederzeit einen beliebigen Stand der **Datenbank** in der Entwickler-, Test- oder Produktions-Umgebung wiederherstellen? Machs doch einfach! Die Flyway-Bibliothek lässt sich nahtlos in jede Java-Anwendung und in den Build für agiles Continuous Delivery integrieren. Es war noch nie so einfach!

## Handling humongous data with NoSQL/MongoDB

Der Umgang mit schnell wachsenden Datenmengen, sich ändernden Strukturen sowie dem Wunsch nach Skalierbarkeit stellt herkömmliche RDBMS System vor neue Herausforderungen. Eine adäquate Lösung hierfür bieten mittlerweile NoSQL **Datenbanken**. MongoDB wird als prominenter Vertreter der Dokumentorientierten **Datenbanken** detailliert vorgestellt. Neben des Basics werden u.a. Sharding, Replica Sets, Map/Reduce und das Schema Design aufgegriffen.

## Guttenbase

Aus vielerlei Gründen müssen oft komplette **Datenbanken** kopiert oder migriert werden.Z.B., um lokal entwickeln zu können oder damit eine separate Anwendung mit den selben Datenarbeiten kann. Schwierig wird eine Migration insbesondere zwischen verschiedenen RDBMS.Bisherige Werkzeuge sind für diese Aufgaben oft unzureichend:Eine Lösung bietet das Framework "GuttenBase", mit dem man Datenmigrationen programmieren kann.Dies ist ein wesentlicher Unterschied zu bestehenden Werkzeugen

## Logdateien live und in Farbe

Wenn Log-Informationen in Dateien landen ist es meist ein Datenfriedhof. Spätestens bei der Fehlersuche in der Produktion zeigen sich die Grenzen, wenn die Logdateien über verschiedene Server verstreut, die Dateien groß sind, und der Weg über das Operating für den Zugriff lang ist.Ein Logserver bringt hier Ordnung: Historische Daten können in einer (No)SQL-**Datenbank** gespeichert und gefunden werden, Events können live und in Farbe am Bildschirm mitverfolgt werden, der Zugriff ist nach Anmeldung

## Haskell aus einer Java-Enterprise Perspektive

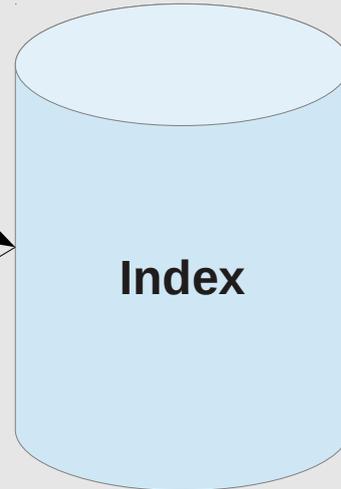
Die funktionale Programmiersprache Haskell ist über viele Jahre im akademischen Kontext entstanden und gereift. In der kommerziellen Geschäftswelt kam sie dagegen praktisch nie zum Einsatz. Nun hat sich in den letzten Jahren Haskell und insbesondere das begleitende Umfeld massiv gewandelt. Es ist nun möglich mit dem Benutzer zu interagieren, größere Projekte zu verwalten, **Datenbanken** anzusprechen und Webanwendungen zu erstellen. Dabei bleiben die Vorteile von Haskell als reine, also durchgehend

# Index

The screenshot shows the website for BED Berlin Expert Days 2013. The header includes navigation links: HOME, TICKETS, PROGRAMM, TALKS, NEWCOMER, KOMITEE, ORT, SPONSOREN/PARTNER, VEREIN, KONTAKT. The main content area is titled "Das Programm der BED-Con 2013 in der Übersicht" and includes a note about contacting Michael Schuetz for program questions. Below this, a section for "Donnerstag, 04. April 2013" features a table with columns for "Zeit", "Hörsaal 1", "Hörsaal 2", "Seminarraum 1", and "Seminarraum 2". The table lists various talks and seminars with their titles and speakers.

| Zeit          | Hörsaal 1                                       | Hörsaal 2   | Seminarraum 1  | Seminarraum 2  |
|---------------|---|---|--|--|
| ab 08:00      | Einlass   |   |  |  |
| 09:00 - 10:00 | JavaScript + Java EE - *<br>Kris Borchers       | OAuth 2.0 - Ein Standard wird erwachen<br>Uwe Freidrichsen                                  | Search Evolution - Von Lucene zu Solr und ElasticSearch<br>Florian Högler                        | Offline Strategien für HTML5 Web Applikationen<br>Stephan Hochdörfer |
| 10:00 - 10:15 | Pause   |   |  |  |
| 10:15 - 11:15 | Java EE 7, the road ahead<br>David DeMaesseneer | Memory Management: TR, CMS und G1 - welche GC-Strategie ist die richtige?<br>Tobias Fritsch | Konzepte: Session<br>Guttenbase: Markus Damm<br>DB versionieren: Niko Köber<br>Toggl: Niko Köber | Spring Data Repositories unter der Lupe<br>Oliver Gierke             |
| 11:15 - 11:30 | Pause   |   |  |  |

Indizieren



Suchen

The screenshot shows a search result page for the query "datenbank". It includes a search bar with the text "datenbank" and a "Suchen" button. The results are organized into sections with bold headings: "DB versionieren", "Handling humongous data with NoSQL/MongoDB", "Guttenbase", "Logdateien live und in Farbe", and "Haskell aus einer Java-Enterprise Perspektive". Each section contains a short paragraph of text.

datenbank

**DB versionieren**  
Den Quellcode ist versioniert im Repository abgelegt! Warum Deine **Datenbank** nicht jederzeit einen beliebigen Stand der **Datenbank** in der Entwickler-, Test- oder Produktions-Umgebung wiedermisteln? Machs doch einfach! Die Flyway-Bibliothek lässt sich nahtlos in jede Java-Anwendung und in den Build für agiles Continuous Delivery integrieren. Es war noch nie so einfach!

**Handling humongous data with NoSQL/MongoDB**  
Der Umgang mit schnell wachsenden Datenmengen, sich ändernden Strukturen sowie dem Wunsch nach Skalierbarkeit stellt herkömmliche RDBMS System vor neue Herausforderungen. Eine adäquate Lösung hierfür bieten mittlerweile NoSQL **Datenbanken**. MongoDB wird als prominenter Vertreter der Dokumentenorientierten **Datenbanken** detailliert vorgestellt. Neben den Basics werden u.a. Sharding, Replica Sets, Map/Reduce und das Schema Design aufgegriffen.

**Guttenbase**  
Aus vielerlei Gründen müssen oft komplette **Datenbanken** kopiert oder migriert werden. Z.B., um lokal entwickeln zu können oder damit eine separate Anwendung mit den selben Datenarbeiten kann. Schwierig wird eine Migration insbesondere zwischen verschiedenen RDBMS. Bisherige Werkzeuge sind für diese Aufgaben oft unzureichend. Eine Lösung bietet das Framework "GuttenBase", mit dem man Datenmigrationen programmieren kann. Dies ist ein wesentlicher Unterschied zu bestehenden Werkzeugen.

**Logdateien live und in Farbe**  
Wenn Log-Informationen in Dateien landen ist es meist ein Datenfresser. Spätestens bei der Fehlersuche in der Produktion zeigen sich die Grenzen, wenn die Logdateien über verschiedene Server verstreut, die Dateien groß sind, und der Weg über das Operating für den Zugriff lang ist. Ein Logviewer bringt hier Ordnung: Historische Daten können in einer (No)SQL-**Datenbank** gespeichert und gefunden werden, Events können live und in Farbe am Bildschirm mitverfolgt werden, der Zugriff ist nach Anmeldung.

**Haskell aus einer Java-Enterprise Perspektive**  
Die funktionale Programmiersprache Haskell ist über viele Jahre im akademischen Kontext entstanden und gereift. In der kommerziellen Geschäftswelt kam sie dagegen praktisch nie zum Einsatz. Nun hat sich in den letzten Jahren Haskell und insbesondere das begleitende Umfeld massiv gewandelt. Es ist nun möglich mit dem Benutzer zu interagieren, größere Projekte zu verwalten, **Datenbanken** anzusprechen und Webanwendungen zu erstellen. Dabei bieten die Vorteile von Haskell als reine, also durchgehend



# Analyzing



# Analyzing

Such  
Evolution -  
Von Lucene  
zu Solr und  
ElasticSearch

Verteiltes  
Suchen mit  
Elasticsearch

# Analyzing

Such  
Evolution -  
Von Lucene  
zu Solr und  
ElasticSearch

1. Tokenization →

| Term          | Document Id |
|---------------|-------------|
| Such          | 1           |
| Evolution     | 1           |
| Von           | 1           |
| Lucene        | 1           |
| zu            | 1           |
| Solr          | 1           |
| und           | 1           |
| ElasticSearch | 1           |
| Verteiltes    | 2           |
| Suchen        | 2           |
| mit           | 2           |
| Elasticsearch | 2           |

Verteiltes  
Suchen mit  
Elasticsearch

# Analyzing

Such  
Evolution -  
Von Lucene  
zu Solr und  
ElasticSearch

1. Tokenization →

2. Lowercasing →

| Term          | Document Id |
|---------------|-------------|
| such          | 1           |
| evolution     | 1           |
| von           | 1           |
| lucene        | 1           |
| zu            | 1           |
| solr          | 1           |
| und           | 1           |
| elasticsearch | 1,2         |
| verteiltes    | 2           |
| suchen        | 2           |
| mit           | 2           |

Verteiltes  
Suchen mit  
Elasticsearch

# Analyzing

Such  
Evolution -  
Von Lucene  
zu Solr und  
ElasticSearch

1. Tokenization →

2. Lowercasing →

3. Stemming →

| Term          | Document Id |
|---------------|-------------|
| such          | 1,2         |
| evolution     | 1           |
| von           | 1           |
| luc           | 1           |
| zu            | 1           |
| solr          | 1           |
| und           | 1           |
| elasticsearch | 1,2         |
| verteilt      | 2           |
| mit           | 2           |

Verteiltes  
Suchen mit  
Elasticsearch

*Lucerne*

# Inverted Index



# Analyzer



# Query Syntax

datenbank OR DB

title:elasticsearch

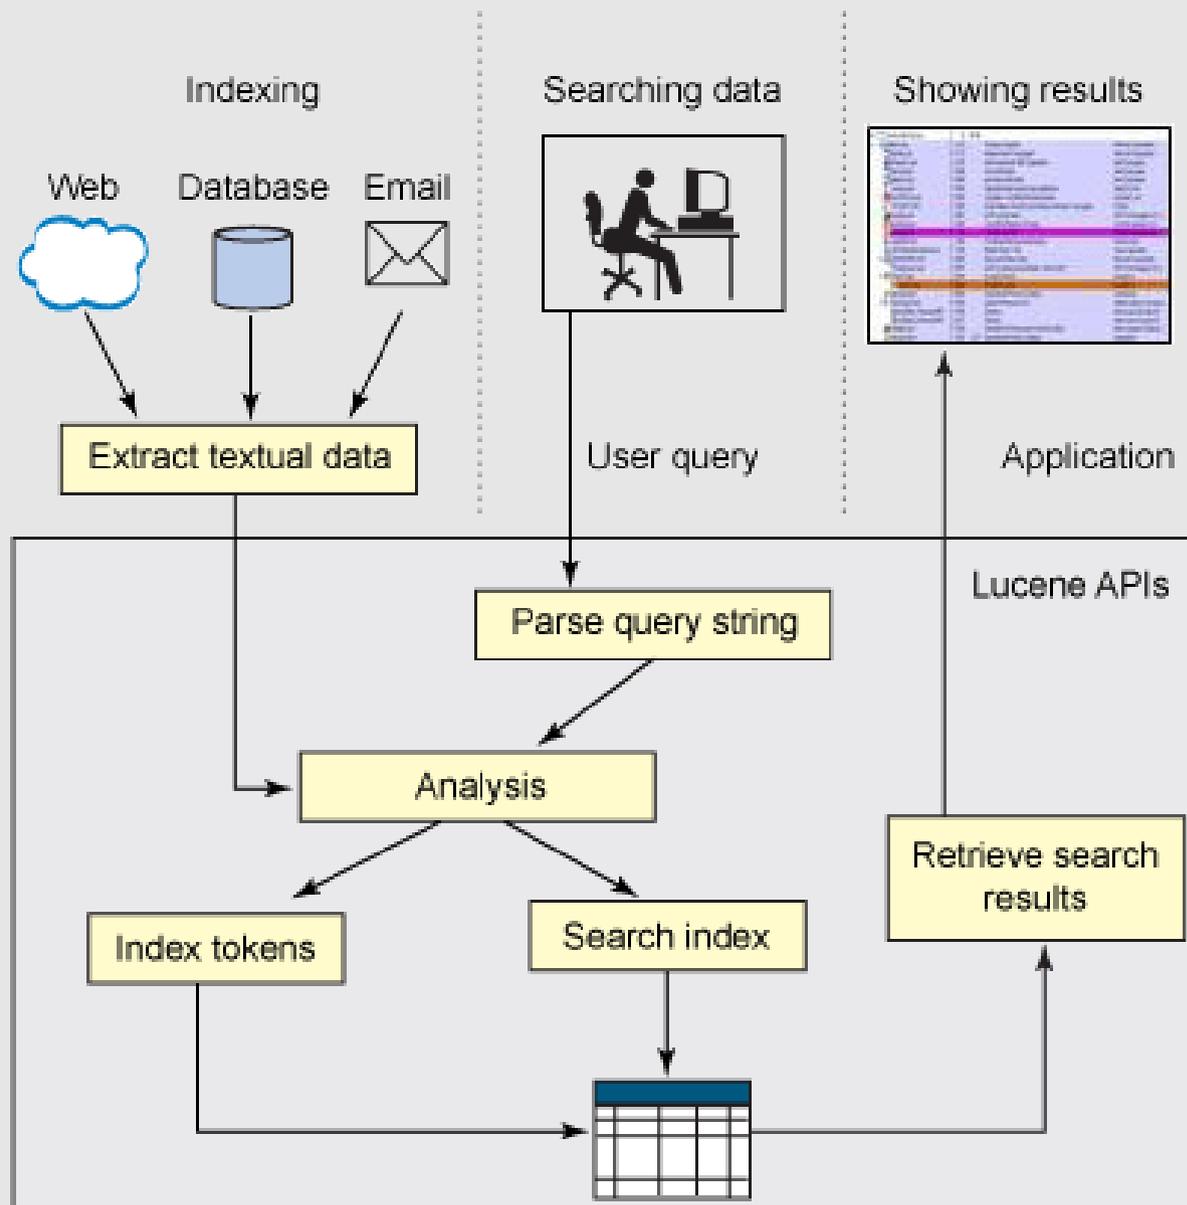
"apache lucene"

speaker:hopp~

elastic\* AND date:[20130101 TO 20130501]

# Relevance





<http://www.ibm.com/developerworks/java/library/os-apache-lucenesearch/>

# Documents

## Document

title

Verteiltes Suchen mit Elasticsearch

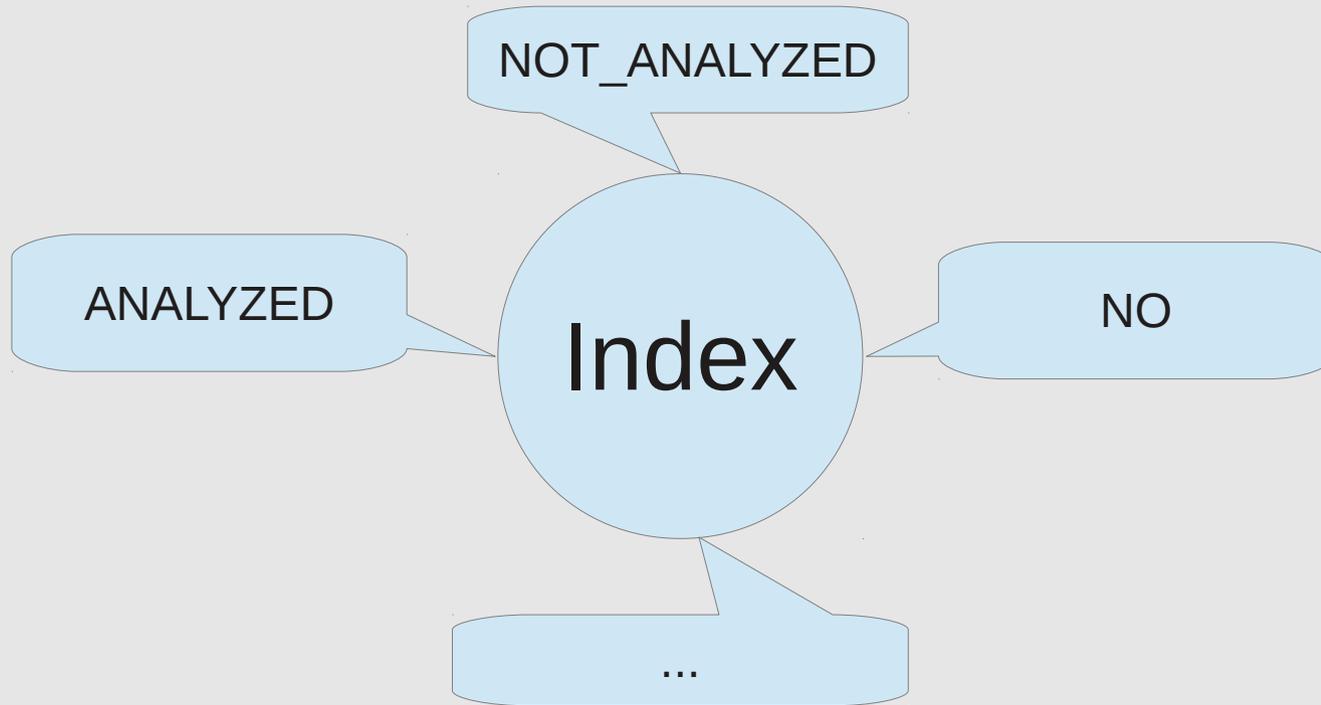
date

20130404

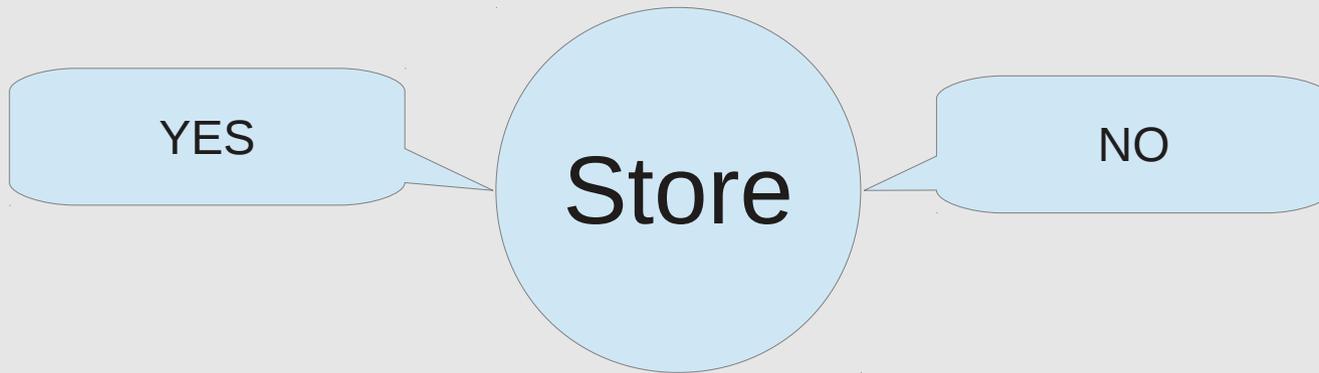
speaker

Dr. Halil-Cem Gürsoy

# Attributes



# Attributes



# Indexing

```
Document es = new Document();
es.add(new Field("title",
    "Verteiltes Suchen mit Elasticsearch",
    Field.Store.YES,
    Field.Index.ANALYZED));
es.add(new Field("date",
    "20130404",
    Field.Store.NO,
    Field.Index.ANALYZED));
es.add(new Field("speaker",
    "Dr. Halil-Cem Gürsoy",
    Field.Store.YES,
    Field.Index.ANALYZED));
```

# Indexing

```
Directory dir = FSDirectory.open(
    new File("/tmp/testindex"));
IndexWriterConfig config = new IndexWriterConfig(
    Version.LUCENE_36,
    new GermanAnalyzer(Version.LUCENE_36));
IndexWriter writer = new IndexWriter(dir, config);

writer.addDocument(es);

writer.commit();
```

# Searching

```
IndexReader reader = IndexReader.open(dir);
IndexSearcher searcher = new IndexSearcher(reader);
QueryParser parser = new QueryParser(
    Version.LUCENE_36,
    "title",
    new GermanAnalyzer(Version.LUCENE_36));
Query query = parser.parse("suche");

TopDocs result = searcher.search(query, 10);
assertEquals(1, result.totalHits);

int id = result.scoreDocs[0].doc;
Document doc = searcher.doc(id);
String title = doc.get("title");
assertEquals(
    "Verteiltes Suchen mit Elasticsearch",
    title);
```

## DB versionieren

Dein Quellcode ist versioniert im Repository abgelegt! Warum Deine **Datenbank** nicht?Jederzeit einen beliebigen Stand der **Datenbank** in der Entwickler-, Test- oder Produktions-Umgebung wiederherstellen? Machs doch einfach! Die Flyway-Bibliothek lässt sich nahtlos in jede Java-Anwendung und in den Build für agiles Continuous Delivery integrieren. Es war noch nie so einfach!

## Handling humongous data with NoSQL/MongoDB

Der Umgang mit schnell wachsenden Datenmengen, sich ändernden Strukturen sowie dem Wunsch nach Skalierbarkeit stellt herkömmliche RDBMS System vor neue Herausforderungen. Eine adäquate Lösung hierfür bieten mittlerweile NoSQL **Datenbanken**. MongoDB wird als prominenter Vertreter der Dokumentorientierten **Datenbanken** detailliert vorgestellt. Neben des Basics werden u.a. Sharding, Replica Sets, Map/Reduce und das Schema Design aufgegriffen.

## Guttenbase

Aus vielerlei Gründen müssen oft komplette **Datenbanken** kopiert oder migriert werden.Z.B., um lokal entwickeln zu können oder damit eine separate Anwendung mit den selben Datenarbeiten kann. Schwierig wird eine Migration insbesondere zwischen verschiedenen RDBMS.Bisherige Werkzeuge sind für diese Aufgaben oft unzureichend:Eine Lösung bietet das Framework "GuttenBase", mit dem man Datenmigrationen programmieren kann.Dies ist ein wesentlicher Unterschied zu bestehenden Werkzeugen

## Logdateien live und in Farbe

Wenn Log-Informationen in Dateien landen ist es meist ein Datenfriedhof. Spätestens bei der Fehlersuche in der Produktion zeigen sich die Grenzen, wenn die Logdateien über verschiedene Server verstreut, die Dateien groß sind, und der Weg über das Operating für den Zugriff lang ist.Ein Logserver bringt hier Ordnung: Historische Daten können in einer (No)SQL-**Datenbank** gespeichert und gefunden werden, Events können live und in Farbe am Bildschirm mitverfolgt werden, der Zugriff ist nach Anmeldung

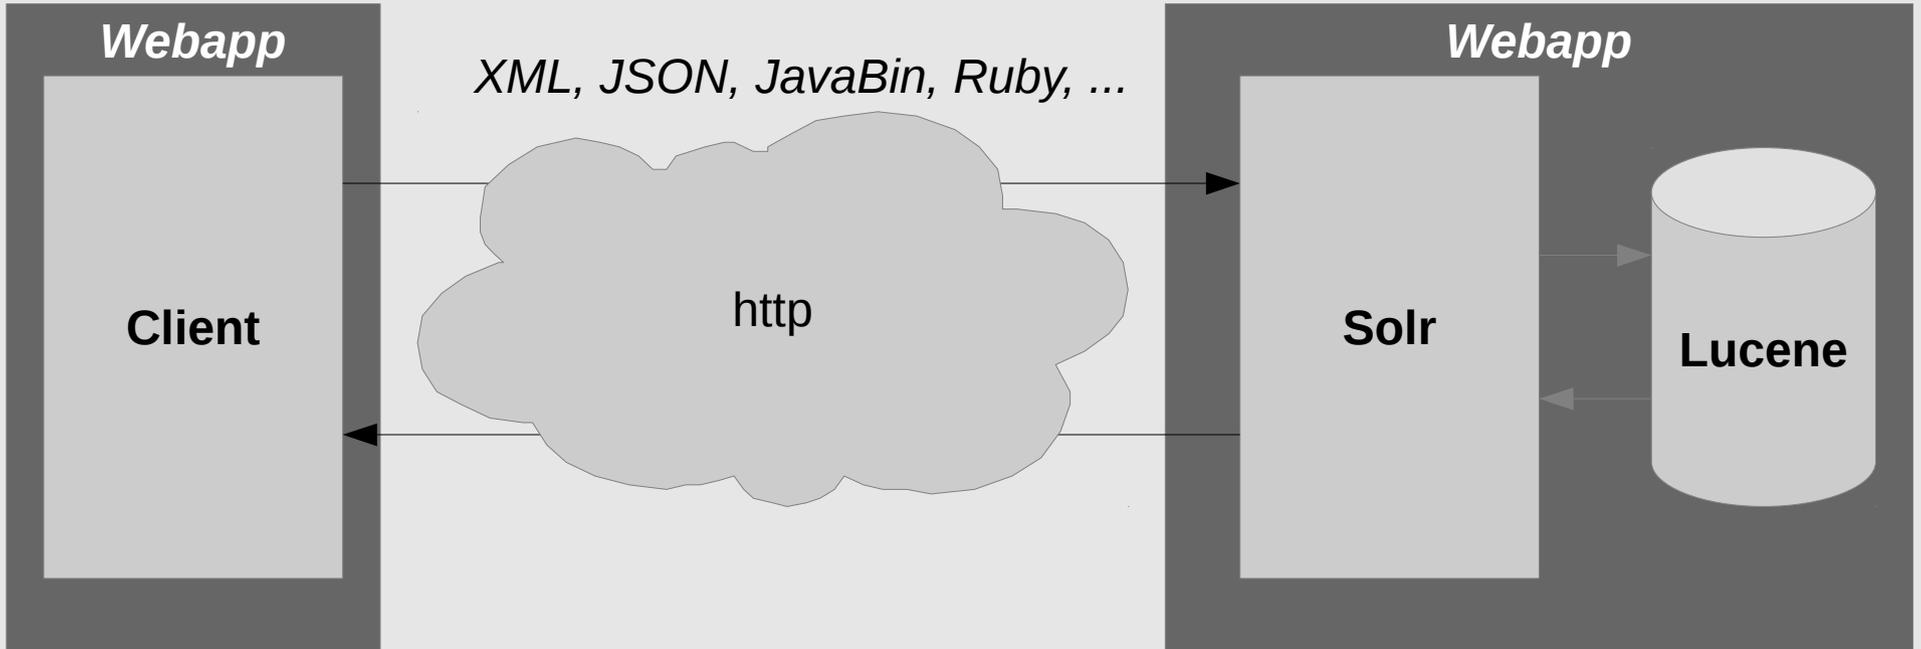
## Haskell aus einer Java-Enterprise Perspektive

Die funktionale Programmiersprache Haskell ist über viele Jahre im akademischen Kontext entstanden und gereift. In der kommerziellen Geschäftswelt kam sie dagegen praktisch nie zum Einsatz. Nun hat sich in den letzten Jahren Haskell und insbesondere das begleitende Umfeld massiv gewandelt. Es ist nun möglich mit dem Benutzer zu interagieren, größere Projekte zu verwalten, **Datenbanken** anzusprechen und Webanwendungen zu erstellen. Dabei bleiben die Vorteile von Haskell als reine, also durchgehend

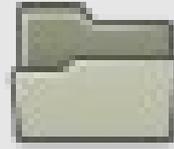
Apache

**Solr**





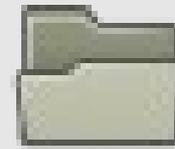
# Config



Solr Home



conf



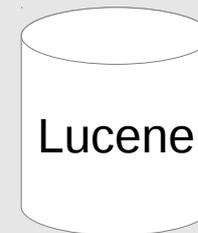
data



**schema.xml**



**solr-  
config.xml**



Lucene

# Schema

schema.xml

**Field Types**

**Fields**

# Schema

```
<fieldType name="text_de" class="solr.TextField">
  <analyzer>
    <tokenizer
      class="solr.StandardTokenizerFactory"/>
    <filter
      class="solr.LowerCaseFilterFactory"/>
    <filter
      class="solr.GermanLightStemFilterFactory"/>
  </analyzer>
</fieldType>
```

# Schema

```
<fields>
  <field name="title" type="text_de"
    indexed="true" stored="true"/>
  <field name="speaker" type="string"
    indexed="true" stored="true"
    multiValued="true"/>
  <field name="speaker_search" type="text_ws"
    indexed="true" stored="false"
    multiValued="true"/>
  [...]
</fields>

<copyField source="speaker" dest="speaker_search"/>
```

# Indexing

```
SolrInputDocument document =
    new SolrInputDocument();
document.addField("path",
    "/tmp/foo");
document.addField("title",
    "Verteiltes Suchen mit Elasticsearch");
document.addField("speaker",
    "Dr. Halil-Cem Gürsoy");

SolrServer server =
    new HttpSolrServer("http://localhost:8080");

server.add(document);
server.commit();
```

# Solrconfig

solrconfig.xml

**Lucene Config  
Caches**

**Request Handler**

**Search Components**

# Solrconfig

```
<requestHandler name="/bedcon"  
  class="solr.SearchHandler">  
  <lst name="defaults">  
    <int name="rows">10</int>  
    <str name="q.op">AND</str>  
    <str name="q.alt">*:*</str>  
    <str name="defType">edismax</str>  
    <str name="qf">  
      content  
      title^1.5  
      speaker_search  
    </str>  
  </lst>  
</requestHandler>
```

# Searching

```
SolrQuery solrQuery = new SolrQuery("suche");
solrQuery.setQueryType("/bedcon");

QueryResponse response = server.query(solrQuery);
assertEquals(1, response.getResults().size());

SolrDocument result = response.getResults().get(0);
assertEquals("Verteiltes Suchen mit Elasticsearch",
             result.get("title"));
assertEquals("Dr. Halil-Cem Gürsoy",
             result.getFirstValue("speaker"));
```

Nach Datum sortieren

#### Speaker:

- [Andreas Lüdeke](#) (1)
- [Claus Ibsen](#) (1)
- [David Delabasse](#) (1)
- [Jan Jongboom](#) (1)
- [Manuel Blechschmidt](#) (1)
- [Niko Köbler](#) (1)
- [Rene Groeschke](#) (1)
- [René Gröschke](#) (1)
- [Robert Schuster](#) (1)

#### Datum:

- [2012](#) (5)
- [2013](#) (4)

### Gradle wird den *Build* schon schaukeln ...

Gradle ist ein innovatives Open-Source-*Build*- und Automatisierungstool. Es verbindet die Vorzüge ...

### How to *build* a recommender system based on Mahout and Java EE ...

Speaker: Manuel Blechschmidt, Language: EnglishFolien: How to *build* a recommender system based on ...

### Gradle, der neue Stern am Himmel der Open-Source-*Build*-Systeme ...

Gradle ist der neue Stern am Himmel der Open-Source-*Build*-Systeme. In dieser Session wird anhand ...

### DB versionieren

doch einfach! Die Flyway-Bibliothek lässt sich nahtlos in jede Java-Anwendung und in den *Build* für ...

### Java EE 7, the road ahead

language. Long awaited Batch Processing API and Caching API are also getting added to *build* applications ...

### AngularJS made easy with Yeoman

implementierung auch eingefleischte JavaScript-Phobiker beeindruckt. Zusammen mit Yeoman als JS *Build* Tool haben ...

### Enterprise Integration Patterns and DSL with Apache Camel

Apache Camel, a very popular integration framework, *builds* on the principles of the EIPs ...

### Maven Packaging Plugin – Creating distribution packages for Java software artifacts

IPK-based GNU/Linux-distributions and integrates well with *build* servers such as Jenkins.The talk will ...

### JavaScript in the Cloud

it ourselves – *build* an IDE in the browser: Cloud9 IDE.In this talk I will describe the vision and ...

# Faceting

...

```
solrQuery.setFacet(true);
solrQuery.addFacetField("speaker");

QueryResponse response = server.query(solrQuery);
List<FacetField.Count> speakerFacet =
    response.getFacetField("speaker").getValues();
assertEquals(1, speakerFacet.get(0).getCount());
assertEquals("Dr. Halil-Cem Gürsoy",
    speakerFacet.get(0).getName());
```



elasticsearch.

# Indexing

```
curl -XPOST
  'http://localhost:9200/bedcon/talk/' -d '{
    "speaker" :
      "Dr. Halil-Cem Gürsoy",
    "date" :
      "2013-04-04T16:00:00",
    "title" :
      "Verteiltes Suchen mit Elasticsearch"
  }'

{"ok":true,"_index":"bedcon","_type":"talk",
"_id":"CeltdivQRGSvLY_dBZv1jw","_version":1}
```

# Mapping

```
curl -XPUT
  'http://host/bedcon/talk/_mapping' -d '{
"talk" : {
  "properties" : {
    "title" : {
      "type" : "string",
      "analyzer" : "german"
    }
  }
}
```

# Searching

```
curl -XGET
  'http://host/bedcon/talk/_search?q=elasticsearch'
{...},
"hits":{"total":1,"max_score":0.054244425,
  "hits":[{"
    :'',
    "_score":0.054244425,
    "_source" : {
      "speaker" :
        "Dr. Halil-Cem Gürsoy",
      "date" :
        "2013-04-04T16:00:00",
      "title":
        "Verteiltes Suchen mit Elasticsearch"
    }
  ]
}
```

# Searching

```
curl -XGET
'http://localhost:9200/bedcon/talk/_search' -d '{
  "query" : {
    "query_string" : {"query" : "elasticsearch"}
  },
  "facets" : {
    "tags" : {
      "terms" : {"field" : "speaker"}
    }
  }
}'
```

# Searching

```
SearchResponse response =
    esClient.prepareSearch("bedcon")
        .addFacet(
            FacetBuilders.termsFacet("speaker")
                .field("speaker"))
        .setQuery(
            QueryBuilders.queryString("elasticsearch"))
        .execute().actionGet();

assertEquals(1, response.getHits().getTotalHits());
```

# Verteilung

ElasticSearch

http://localhost:9201/

Connect

Watoomb

cluster health: green (2, 5)

Overview

Browser

Structured Query [+]

Any Request [+]

Cluster Overview

New Index

**bedcon**

size: 79.6kb (159.2kb)

docs: 20 (20)

Info ▾

Actions ▾

**Sphinx** K9Gt6H5CTxeeZ1NUc8-nGA

inet[/172.28.100.56:9200]

Info ▾

Actions ▾



**Watoomb** 4ILdbXKwS3CT6PBSaQyDzQ

inet[/172.28.100.56:9201]

Info ▾

Actions ▾



# Verteilung

ElasticSearch

http://localhost:9201/

Connect

Watoomb

cluster health: green (3, 5)

Overview

Browser

Structured Query [+]

Any Request [+]

Cluster Overview

New Index

**Dweller-in-Darkness** 27iedtOQSjWwBnCl\_ZRsDw  
inet[/172.28.100.56:9202]

Info Actions

**Sphinx** K9Gt6H5CTxeeZ1NUc8-nGA  
inet[/172.28.100.56:9200]

Info Actions

**Watoomb** 4lLdbXKwS3CT6PBSaQyDzQ  
inet[/172.28.100.56:9201]

Info Actions

**bedcon**

size: 79.6kb (159.2kb)  
docs: 20 (20)

Info Actions





<http://lucene.apache.org>  
<http://lucene.apache.org/solr/>  
<http://elasticsearch.org>  
<https://github.com/fhopf/lucene-solr-talk>

**@fhopf**  
**mail@florian-hopf.de**  
**<http://blog.florian-hopf.de>**

# Images

- <http://www.morguefile.com/archive/display/3470>
- <http://www.flickr.com/photos/quinnanya/5196951914/>  
Quinn Dombrowski
- <http://www.morguefile.com/archive/display/695239>
- <http://www.morguefile.com/archive/display/93433>
- <http://www.morguefile.com/archive/display/811746>
- <http://www.morguefile.com/archive/display/12965>
- <http://www.morguefile.com/archive/display/181488>