



# 华为云-云搜索服务Elasticsearch实践

胡斐然

华为，云服务技术总监



战略级赞助商 HUAWEI

钻石级赞助商 普翔

白金级赞助商 华夏博格

神州数码  
Digital China

金牌级赞助商 iData API

合作伙伴

开源中国  
oschina.net

掘金

谱时

IT大咖说

Otpub

Broadview  
[www.broadview.com.cn](http://www.broadview.com.cn)

百格活动  
[bagevent.com](http://bagevent.com)

MAXHUB  
高效会议平台



# 华为云-云搜索服务Elasticsearch实践

2018.11



站内搜索

智能分词

越搜越准

多媒体

协同搜图

音乐检索

日志&指标

数据协同

内核增强

运维

服务化

专业看护

# 智能分词

商品检索

坐席知识库

自动对话服务

- 新词或特有名词无法搜索
- 短语问题
- 多租户的支持

## 泊松分词器

- 支持未登录词识别
- 对英文更友好
- 支持多租户，对每个Index分别设定词库
- 支持多粒度分词，对每个词进粗细粒度的控制
- 支持简繁体、拼音分词
- 支持同义词

## 问题一：新词或者特有名词无法搜索

举例：李世石是人名

lk\_max\_word:

李/世/石/是/人/人名/名

lk\_smart:

李/世/石/是/人名


poission hmm:

李世石/是/人名

说明：

默认词库中没有的人名、地名、特有名词不能准确分词

解决思路：



使用华为  
积累的知  
识库、论  
坛语料训  
练出来基  
础模型

使用隐马尔可夫模型

观察态：字符

隐藏态：BMES

## 问题二：英文短语

举例：windows system

```
1 GET _analyze
2 {
3     "analyzer": "ik_max_word",
4     "text": ["windows system"]
5 }
6
7 GET _analyze
8 {
9     "analyzer": "ik_smart",
10    "text": ["windows system"]
11 }
12
13
14
15
16
17 ]
```



说明：

IK分词器中对英文是按照空格切分的，即便是在词库中配置windows system，也无法当做短语来识别

解决思路：

自定义词库文件中，一个词一行，空格识别为普通字符

```
1 GET token_test1/_analyze
2 {
3     "analyzer": "my_analyzer",
4     "text": ["windows system"]
5 }
```

```
1 GET token_test1/_analyze
2 {
3     "tokens": [
4         {
5             "token": "windows system",
6             "start_offset": 0,
7             "end_offset": 14,
8             "type": "word",
9             "position": 0
10 },
11         {
12             "token": "Windows",
13             "start_offset": 0,
14             "end_offset": 7,
15             "type": "word",
16             "position": 0
17 },
18         {
19             "token": "system",
20             "start_offset": 8,
21             "end_offset": 14,
22             "type": "word",
23             "position": 1
24 }]
```

## 问题三：词库无法在索引上单独配置，全局词库有干扰

举例：

有两个词库文件A.dict/B.dict，想在索引A中使用A.dict，索引B中使用B.dict。

IK分词器配置 IKAnalyzer.cfg.xml：

```
<properties>
  <comment>IK Analyzer 扩展配置</comment>
  <entry key="ext_dict">/path/A.dict; /path/B.dict</entry>
</properties>
```

说明：

IK分词器的词库配置在配置文件中，属于全局配置，和索引没有产生任何联系。因此，任何词库都是全局生效的，无法达到想要的结果。

解决思路：

建立索引的时候在setting中配置

```
PUT A
{
  "settings": {
    "analysis": {
      "tokenizer": {
        "my_tokenizer_index": {
          "type": "poisson_index",
          "poisson_dict": ["资源管理器", "P20 pro", "喜大普奔"],
          "poisson_dict_path": "A.dict , A1.dict",
          "poisson_stopword_dict_path": "stopwordA.dict"
        },
        "analyzer": {
          "my_analyzer_index": {
            "tokenizer": "my_tokenizer_index"
          }
        }
      }
    }
  }
}
```

# 智能搜索（越搜越准）

传统搜索引擎都是基于文本匹配的算法来打分排序，没有考虑其它因素，比如搜索内容的热度等。华为云云搜索服务提供基于用户历史数据提升搜索排序的功能，可以提高此类场景的用户体验。




## 适用场景：

- **帖子搜索**
- **新闻搜索**
- **视频摘要搜索**
- **内容推荐**

## 根据历史数据训练模型进行重排序——方案

搜索内容	点击文档	Index	点击时间	原始排序
华为	华为Mate 20发布会	product	2018-10-11 12:24:00	6



## 越搜越准训练模型后重排序——效果

### 原始搜索

```
: {  
  "query": {  
    "match": {  
      "desc": "华为"  
    }  
  }  
}
```

文档	score
探访华为总部：华为大学开2500门课	0.7911257
华为Mate 20发布会	0.5753642
华为技术逆天！每年跟苹果收几十亿专利费	0.5753642

### 越搜越准模型搜索：

```
{  
  "query": {  
    "match": {  
      "value": "华为"  
    }  
  },  
  "rescore": {  
    "window_size": 10,  
    "poisson_rank": {  
      "keyword": "华为",  
      "boost": 4,  
      "total_match": 0  
    }  
  }  
}
```

效果：重打分后历史被点击的越多的记录排序越靠前

文档	score
华为Mate 20发布会	1.5241129
华为技术逆天！每年跟苹果收几十亿专利费	1.0712540
探访华为总部：华为大学开2500门课	0.7925697

# 协同搜图

## 以文搜图



鲜花预定\_厦门鲜花店送花 ...  
[xm.hua.com](http://xm.hua.com)

## 以图搜图



## 协同搜图




“2018 感冒药”

## 适用场景：

- 图像版权
- AR呈现
- 商品检索
- 素材检索

## 协同搜图——方案

云搜索服务在elasticsearch基础上增加向量检索的能力，和elasticsearch已有的检索能力相融合



### 支持的向量表达方式

- 原始浮点向量
- 乘积向量
- 局部性Hash
- 混合

### 支持的距离函数

- 欧式距离
- 点积
- 夹角
- 混合

## 协同搜图——效果



南瓜的做法\_健康饮食\_疾病网



南瓜- Danbaoli blog Danbaoli blog



南瓜(南瓜葫芦科植物)\_百度百科




+万圣节+绿叶



协同搜图场景：亿级图片，毫秒级完成查询，准确率99%

# 音频检索


通过一段音频片段，检索出音频库中相似的音频内容



适应场景：

- 音频、音乐版权
- 第二屏关联
- 旋律找歌
- 媒资管理
- 媒体去重

## 音频检索——问题



[ $\text{SHA1}(P, P, dt), \text{SHA1}(P, P, dt), \dots$ ] [874dae83e3805c3bdd7d, e99eef00f40c704f620c, ...]

业界普遍的做法，是将一段波形通过频谱变换找到一些高能量的点，然后将高能量点序列组成音频中的指纹。所以，音频检索的问题在于：  
**如何在大量音频内容高效的找到尽可能多的匹配指纹？**

# 音频检索——方案

**Query :**

[874dae83,e99eef00f,.....]


**Documents**

[874dae83,e99eef00f, 472109cbf, 50df37991, e96671e0,.....]

[2d60780, 762a9d162, 4bffaf125, bac5fa18, 8831d37a5,.....]

[5e0bad6c, 3dccda461, 472109cbf, 627404b84, c7af515c,.....]

.....




## 音频检索——效果

音乐库大小	ES检索
5万首音乐	100ms
20万首音乐	200ms
100万首音乐	230ms



经过验证，Elasticsearch的索引机制天然适合音频的检索模型，通过将音频转换为指纹组成的文档。能够非常好的处理音频检索问题

# 数据协同——云搜索服务日志解决方案案例



# 内核优化——基于运维应用的优化案例


需求：时间戳、主机名、当前内存占用量，收集周期为每分钟收集一次，统计当前集群的占用内存总量



## 服务化相关的相关改进

### 痛点：


- 集群部署
- 多集群管理
- 节点扩容
- 磁盘扩容
- 监控告警
- 数据备份与恢复
- 集群状态诊断分析



### 解决方案：

- 一键部署，15分钟内完成100节点的部署
- 提供openAPI管理多集群
- 一键扩容节点，不中断现网业务
- 一键扩容磁盘，不中断现网业务
- 基于华为云监控告警平台及云监控服务
- 基于OBS可配置的手动和定时备份任务
- 集群监控指标的统计分析


# 专业看护——华为云的运维看护流程



# 吃自己的狗粮

## 自建ES集群运维ES集群


- 收集服务管理面和业务面日志，日志可视化、统计分析、搜索定位
- 收集ES集群状态、监控统计指标，定制界面呈现并可转告警通知



日志监控可视化

业务指标监控可视化

# 什么是云搜索服务



云搜索服务是一个**基于Elasticsearch且完全托管的在线分布式搜索服务**，为用户提供结构化、非结构化文本的多条件检索、统计、报表。完全兼容开源Elasticsearch软件原生接口。

它可以帮助网站和APP**搭建搜索框**，提升用户寻找资料和视频的体验；还可以**搭建日志分析平台**，在运维上进行行业务日志分析和监控，在运营上进行流量分析等等。



# Thank You.

**Copyright©2018 Huawei Technologies Co., Ltd. All Rights Reserved.**

The information in this document may contain predictive statements including, without limitation, statements regarding the future financial and operating results, future product portfolio, new technology, etc. There are a number of factors that could cause actual results and developments to differ materially from those expressed or implied in the predictive statements. Therefore, such information is provided for reference purpose only and constitutes neither an offer nor an acceptance. Huawei may change the information at any time without notice.