IKAnalyzer 中文分词器
V2012 使用手册

目录

1.IK Analyzer 2012 介绍

IK Analyzer 是一个开源的，基于 java 语言开发的轻量级的中文分词工具包。从 2006 年 12 月推出 1.0 版开始， IKAnalyzer 已经推出了 4 个大版本。最初，它是以开源项目 Luence 为应用主体的，结合词典分词和文法分析算法的中文分词组件。从 3.0 版本开始，IK 发展为面向 Java 的公用分词组件，独立于 Lucene 项目，同时提供了对 Lucene 的默认优化实现。在 2012 版本中，IK 实现了简单的分词歧义排除算法，标志着 IK 分词器从单纯的词典分词向模拟语义分词衍化。

1.1 IK Analyzer 2012 结构设计

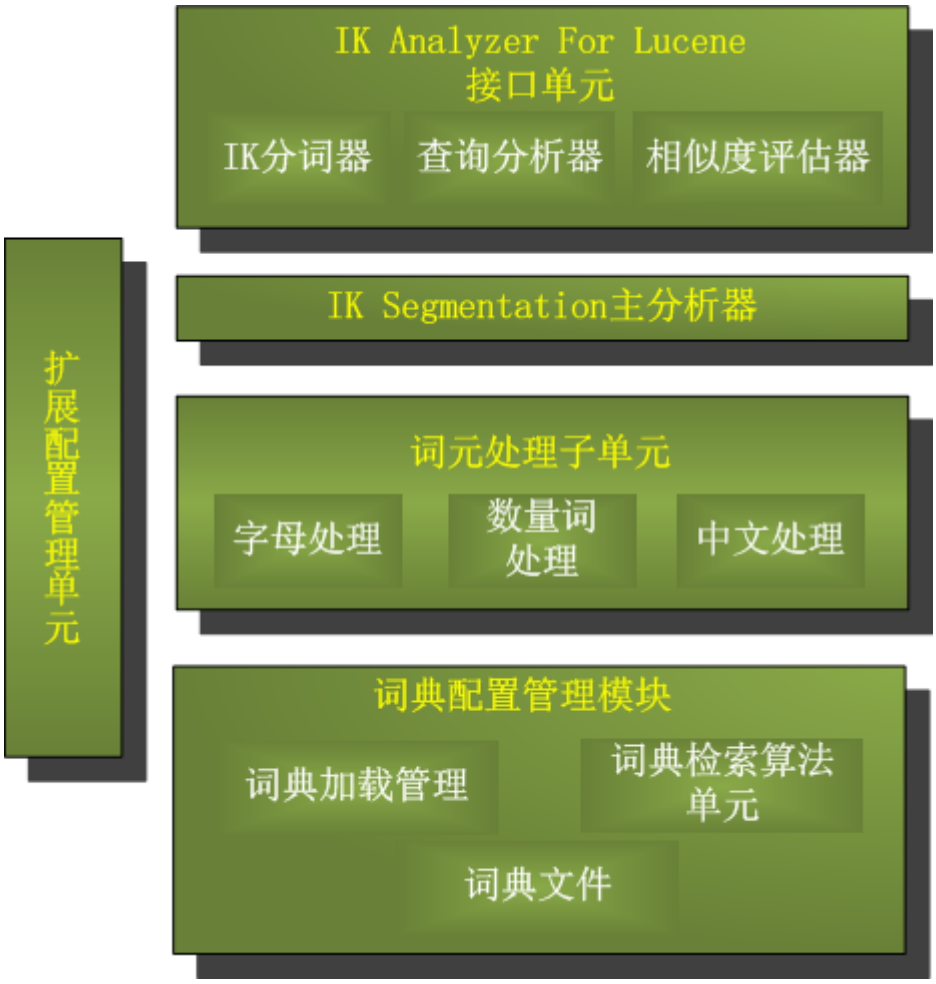

1.2 IK Analyzer 2012 特性

- 采用了特有的“正向迭代最细粒度切分算法“，支持细粒度和智能分词两种切分模式；
- 在系统环境：Core2 i7 3.4G 双核，4G 内存，window 7 64 位， Sun JDK 1.6_29 64 位 普通 pc 环境测试，IK2012 具有 160 万字/秒（3000KB/S）的高速处理能力。
- 2012 版本的智能分词模式支持简单的分词排歧义处理和数量词合并输出。
- 采用了多子处理器分析模式，支持：英文字母、数字、中文词汇等分词处理，兼容韩文、日文字符
- 优化的词典存储，更小的内存占用。支持用户词典扩展定义。特别的，在 2012 版本，词典支持中文，英文，数字混合词语。

1.3 分词效果示例

IK Analyzer 2012 版本支持 **细粒度切分** 和 **智能切分**，以下是两种切分方式的演示样例。

文本原文 1:

IKAnalyzer 是一个开源的，基于 java 语言开发的轻量级的中文分词工具包。从 2006 年 12 月推出 1.0 版开始， IKAnalyzer 已经推出了 3 个大版本。

- 智能分词结果:

ikanalyzer | 是 | 一个 | 开源 | 的 | 基于 | java | 语言 | 开发 | 的 | 轻量级 | 的 | 中文 | 分词 | 工具包 | 从 | 2006年 | 12月 | 推出 | 1.0版 | 开始 | ikanalyzer | 已经 | 推 | 出了 | 3个 | 大 | 版本

- 最细粒度分词结果:

ikanalyzer | 是 | 一个 | 一 | 个 | 开源 | 的 | 基于 | java | 语言 | 开发 | 的 | 轻量级 | 量级 | 的 | 中文 | 分词 | 工具包 | 工具 | 包 | 从 | 2006 | 年 | 12 | 月 | 推出 | 1.0 |

版 | 开始 | ikanalyzer | 已经 | 推出 | 出了 | 3 | 个 | 大 | 版本

文本原文 2:

张三说的确实在理

- 智能分词结果:

张三 | 说的 | 确实 | 在理

- 最细粒度分词结果:

张三 | 三 | 说的 | 的确 | 的 | 确实 | 实在 | 在理

文本原文 3

公路局正在治理解放大道路面积水问题

- 智能分词结果:

公路局 | 正在 | 治理 | 解放 | 大道 | 路面 | 积水 | 问题

- 最细粒度分词结果:

公路局 | 公路 | 路局 | 正在 | 治理 | 理解 | 解放 | 放大 | 大道 | 道路 | 路面 | 面积 | 积水 | 问题

文本原文 4

据路透社报道，印度尼西亚社会事务部一官员星期二(29 日)表示，日惹市附近当地时间 27 日晨 5 时 53 分发生的里氏 6.2 级地震已经造成至少 5427 人死亡，20000 余人受伤，近 20 万人无家可归。

- 智能分词结果:

据 | 路透社 | 报道 | 印度尼西亚 | 社会 | 事务部 | 一 | 官员 | 星期二 | 29 日 | 表示 | 日 | 惹 | 市 | 附近 | 当地时间 | 27 日 | 晨 | 5 时 | 53 分 | 发生 | 的 | 里氏 | 6.2 级 | 地震 | 已经 | 造成 | 至少 | 5427 人 | 死亡 | 20000 | 余人 | 受伤 | 近 | 20 | 万人 |

无家可归

- 最细粒度分词结果:

据 | 路透社 | 路透 | 社 | 报道 | 印度尼西亚 | 印度 | 尼 | 西亚 | 社会事务 | 社会 | 事务部 | 事务 | 部 | 一 | 官员 | 星期二 | 星期 | 二 | 29 | 日 | 表示 | 日 | 惹 | 市 | 附近 | 当地时间 | 当地 | 时间 | 27 | 日 | 晨 | 5 | 时 | 53 | 分发 | 分 | 发生 | 发 | 生 | 的 | 里氏 | 6.2 | 级 | 地震 | 已经 | 造成 | 至少 | 5427 | 人 | 死亡 | 20000 | 余人 | 受伤 | 近 | 20 | 万人 | 万 | 人 | 无家可归

2.使用指南

2.1 下载地址

GoogleCode 开源项目　　：http://code.google.com/p/ik-analyzer/

GoogleCode 下载：http://code.google.com/p/ik-analyzer/downloads/list

2.2 与相关项目的版本兼容

IK 分词器版本	Lucene 版本	Solr 版本
3.1.3GA 及先前版	兼容 2.9.1 及先前版本	没有 solr 接口
3.1.5GA	兼容 2.9.1 及先前版本	对 solr1.3 提供接口实现
3.1.6GA	兼容 2.9.1 及先前版本	对 solr1.3、solr1.4 提供接口实现
3.2.x	兼容 Lucene2.9 及 3.0 版本 不支持 Lucene2.4 及先前版本	仅对 solr1.4 提供接口实现

2.3 安装部署

IK Analyzer 安装包包含：

1. 《IKAnalyzer 中文分词器 V2012 使用手册》（即本文档）
2. IKAnalyzer2012.jar（主 jar 包）
3. IKAnalyzer.cfg.xml（分词器扩展配置文件）
4. stopword.dic（停止词典）
5. LICENSE.TXT；NOTICE.TXT （apache 版权申明）

它的安装部署十分简单，将 IKAnalyzer2012.jar 部署于项目的 lib 目录中；IKAnalyzer.cfg.xml 与 stopword.dic 文件放置在 class 根目录（对于 web 项目，通常是 WEB-INF/classes 目录，同 hibernate、log4j 等配置文件相同）下即可。

2.4 Lucene 用户快速入门

代码样例

IKAnalyzerDemo

```
/**
 * IK 中文分词  版本 5.0
 * IK Analyzer release 5.0
 *
 * Licensed to the Apache Software Foundation (ASF) under one or more
 * contributor license agreements.  See the NOTICE file distributed with
 * this work for additional information regarding copyright ownership.
 * The ASF licenses this file to You under the Apache License, Version
2.0
 * (the "License"); you may not use this file except in compliance with
```

```
 * the License.  You may obtain a copy of the License at
 *
 *     http://www.apache.org/licenses/LICENSE-2.0
 *
 * Unless required by applicable law or agreed to in writing, software
 * distributed under the License is distributed on an "AS IS" BASIS,
 * WITHOUT WARRANTIES OR CONDITIONS OF ANY KIND, either express or implied.
 * See the License for the specific language governing permissions and
 * limitations under the License.
 *
 * 源代码由林良益(linliangyi2005@gmail.com)提供
 * 版权声明 2012，乌龙茶工作室
 * provided by Linliangyi and copyright 2012 by Oolong studio
 *
 *
 */
package org.wltea.analyzer.sample;

import java.io.IOException;

import org.apache.lucene.analysis.Analyzer;
import org.apache.lucene.document.Document;
import org.apache.lucene.document.Field;
import org.apache.lucene.index.CorruptIndexException;
import org.apache.lucene.index.IndexReader;
import org.apache.lucene.index.IndexWriter;
import org.apache.lucene.index.IndexWriterConfig;
import org.apache.lucene.index.IndexWriterConfig.OpenMode;
import org.apache.lucene.queryParser.ParseException;
import org.apache.lucene.queryParser.QueryParser;
import org.apache.lucene.search.IndexSearcher;
import org.apache.lucene.search.Query;
import org.apache.lucene.search.ScoreDoc;
import org.apache.lucene.search.TopDocs;
import org.apache.lucene.store.Directory;
import org.apache.lucene.store.LockObtainFailedException;
import org.apache.lucene.store.RAMDirectory;
import org.apache.lucene.util.Version;
import org.wltea.analyzer.lucene.IKAnalyzer;


/**
 * IKAnalyzer 示例
 * 2012-3-2
```

```
 *
 * 以下是结合Lucene3.4 API的写法
 *
 */
public class IKAnalyzerDemo {
    public static void main(String[] args){
        //Lucene Document的域名
        String fieldName = "text";
         //检索内容
        String text = "IK Analyzer是一个结合词典分词和文法分词的中文分词开源工具包。它使用了全新的正向迭代最细粒度切分算法。";

        //实例化IKAnalyzer分词器
        Analyzer analyzer = new IKAnalyzer();



        Directory directory = null;
        IndexWriter iwriter = null;
        IndexReader ireader = null;
        IndexSearcher isearcher = null;
        try {
            //建立内存索引对象
            directory = new RAMDirectory();

            //配置IndexWriterConfig
            IndexWriterConfig iwConfig = new
IndexWriterConfig(Version.LUCENE_34 , analyzer);
            iwConfig.setOpenMode(OpenMode.CREATE_OR_APPEND);
            iwriter = new IndexWriter(directory , iwConfig);
            //写入索引
            Document doc = new Document();
            doc.add(new Field("ID", "10000", Field.Store.YES,
Field.Index.NOT_ANALYZED));
            doc.add(new Field(fieldName, text, Field.Store.YES,
Field.Index.ANALYZED));
            iwriter.addDocument(doc);
            iwriter.close();


            //搜索过程**********************************
            //实例化搜索器
            ireader = IndexReader.open(directory);
            isearcher = new IndexSearcher(ireader);
```

```
            String keyword = "中文分词工具包";
            //使用QueryParser查询分析器构造Query对象
            QueryParser qp = new QueryParser(Version.LUCENE_34,
fieldName, analyzer);
            qp.setDefaultOperator(QueryParser.AND_OPERATOR);
            Query query = qp.parse(keyword);

            //搜索相似度最高的5条记录
            TopDocs topDocs = isearcher.search(query , 5);
            System.out.println("命中: " + topDocs.totalHits);
            //输出结果
            ScoreDoc[] scoreDocs = topDocs.scoreDocs;
            for (int i = 0; i < topDocs.totalHits; i++){
                Document targetDoc = isearcher.doc(scoreDocs[i].doc);
                System.out.println("内容: " + targetDoc.toString());
            }

        } catch (CorruptIndexException e) {
            e.printStackTrace();
        } catch (LockObtainFailedException e) {
            e.printStackTrace();
        } catch (IOException e) {
            e.printStackTrace();
        } catch (ParseException e) {
            e.printStackTrace();
        } finally{
            if(ireader != null){
                try {
                    ireader.close();
                } catch (IOException e) {
                    e.printStackTrace();
                }
            }
            if(directory != null){
                try {
                    directory.close();
                } catch (IOException e) {
                    e.printStackTrace();
                }
            }
        }
    }
}
```

执行结果：

命中：1
内容：Document<stored/uncompressed,indexed,tokenized<text:IK Analyzer是一个结合词典分词和文法分词的中文分词开源工具包。它使用了全新的正向迭代最细粒度切分算法。>>

2.5 关键 API 说明

（注：本文档只列出常用的、主要的 API 说明，有可能因为版本变更而与实际代码产生不一致情况，因此最准确的说明请参看 Java API DOC）

类 org.wltea.analyzer.lucene.IKAnalyzer

说明：IK 分词器的主类，是 IK 分词器的 Lucene Analyzer 类实现。

该类使用方法请参考 “代码样例”章节

- public IKAnalyzer()

  说明：构造函数，默认实现最细粒度切分算法

- public IKAnalyzer(boolean useSmart)

  说明：构造函数

  参数 1 ：boolean useSmart， 当为 true 时，分词器采用智能切分 ；当为 false 时，分词器进行最细粒度切分。

类 org.wltea.analyzer.core.IKSegmenter

说明： 这是 IK 分词器的核心类。它是独立于 Lucene 的 Java 分词器实现。当您需要在 Lucene 以外的环境中单独使用 IK 中文分词 组件时，IKSegmenter 正是您要找的。

- public IKSegmenter(Reader input , boolean useSmart)

说明：IK 主分词器构造函数

参数 1：Reader input，字符输入读取

参数 2 : boolean useSmart，是否采用智能切分策略。true 使用智能切分，false 使用最细粒度切分。

- public IKSegmentation(Reader input , Configuration cfg)

说明：IK 主分词器新构造函数

参数 1：Reader input，字符输入读取

参数 2：Configuration cfg，分词器配置。用户可以定制自己的 Configuration 类，来改变词典配置。

- public synchronized Lexeme next()throws IOException

说明：读取分词器切分出的下一个语义单元，如果返回 null，表示分词器已经结束。

返回值：Lexeme 语义单元对象，即相当于 Lucene 的词元对象 Token

类 org.wltea.analyzer.core.Lexeme

说明： 这是 IK 分词器的语义单元对象，相当于 Lucene 中的 Token 词元对象。由于 IK 被设计为独立于 Lucene 的 Java 分词器实现，因此它需要 Lexeme 来代表分词的结果。

- public int getBeginPosition()

  说明：获取语义单元的起始字符在文本中的位置

  返回值：int ， 语义单元相对于文本的绝对起始位置

- public int getEndPosition()

  说明：获取语义单元的结束字符的下一个位置

  返回值：int ， 语义单元相对于文本的绝对终止位置的下一个字符位置

- public int getLength()

  说明：获取语义单元包含字符串的长度

  返回值：int ， 语义单元长度 = getEndPosition – getBeginPosition

- public String getLexemeText()

  说明：获取语义单元包含字符串内容

  返回值：String， 语义单元的实际内容，即分词的结果

2.6 IKQueryPaser 与 IK 简单搜索表达式说明

在 IK2012 版本之前，由于分词器没有处理歧义分词的能力，才使用了 IKQueryParser 来解决搜索时的歧义冲突问题。随着 2012 版本的推出，用户已经不再需要使用 IKQueryParser 来解决这样的问题。直接使用 Lucene 的 QueryParser 即可。

3.词表扩展

目前 ,IK 分词器自带的主词典拥有 27 万左右的汉语单词量。由于作者个人的精力有限，并没有对搜集到的词库进行全范围的筛选、清理。此外，对于分词组件应用场景所涉及的领域的不同，也需要各类专业词库的支持。为此，IK 分词器提供了对词典的扩展支持。

在 IK 分词器 3.1.3 以上版本，同时提供了对用户自定义的停止词（过滤词）的扩展支持。

3.1 基于 API 的词典扩充

IK 分词器支持使用 API 编程模型扩充您的词典和停止词典。如果您的个性化词典是存储于数据库中，这个方式应该对您适用。API 如下：

- 类 org.wltea.analyzer.dic.Dictionary

  说明： IK 分词器的词典对象。它负责中文词汇的加载，内存管理和匹配检索。

  - public static Dictionary initial(Configuration cfg)

    说明：初始化字典实例。字典采用单例模式，一旦初始化，实例就固定.

    PS:注意该方法只能调用一次。

    参数 1：Configuration cfg ， 词典路径配置

    返回值：Dictionary IK 词典单例

  - public static Dictionary getSingleton()

    说明：获取初始化完毕的字典单例

    返回值：Dictionary IK 词典单例

  - public void addWords(Collection<String> words)

    说明：加载用户扩展的词汇列表到 IK 的主词典中，增加分词器的可识别词语。

    参数 1：Collection<String> words ， 扩展的词汇列表

    返回值：无

  - public void disableWords(Collection<String> words)

    说明：屏蔽词典中的词元

    参数 1：Collection<String> words， 待删除的词列表

    返回值：无

3.2 基于配置的词典扩充

IK 分词器还支持通过配置 IKAnalyzer.cfg.xml 文件来扩充您的专有词典以及停止词典（过滤词典）。

1. 部署 IKAnalyzer.cfg.xml

IKAnalyzer.cfg.xml 部署在代码根目录下（对于 web 项目，通常是 WEB-INF/classes 目录）同 hibernate、log4j 等配置文件相同。

2. 词典文件的编辑与部署

分词器的词典文件格式是无 BOM 的 UTF-8 编码的中文文本文件，文件扩展名不限。词典中，每个中文词汇独立占一行，使用\r\n 的 DOS 方式换行。（注，如果您不了解什么是无 BOM 的 UTF-8 格式， 请保证您的词典使用 UTF-8 存储，并在文件的头部添加一空行）。您可以参考分词器源码 org.wltea.analyzer.dic 包下的.dic 文件。

词典文件应部署在 Java 的资源路径下，即 ClassLoader 能够加载的路径中。（推荐同 IKAnalyzer.cfg.xml 放在一起）

3. IKAnalyzer.cfg.xml 文件的配置

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE properties SYSTEM "http://java.sun.com/dtd/properties.dtd">
<properties>
    <comment>IK Analyzer 扩展配置</comment>
    <!--用户可以在这里配置自己的扩展字典  -->
    <entry key="ext_dict">/mydict.dic;
/com/mycompany/dic/mydict2.dic;</entry>

     <!--用户可以在这里配置自己的扩展停止词字典-->
    <entry key="ext_stopwords">/ext_stopword.dic</entry>
</properties>
```

在配置文件中，用户可一次配置多个词典文件。文件名使用“;”号分隔。文件路径为相对 java 包的起始根路径。

4.针对 solr 的分词器应用扩展

IK 分词器 3.2.0 以上版本从 API 层面提供了对 solr 中 BaseTokenizerFactory 接口的扩展实现。

4.1 solr 的 TokenizerFactory 接口实现

- 类 org.wltea.analyzer.solr.IKTokenizerFactory

  说明：该类继承与 solr 的 BaseTokenizerFactory，是 IK 分词器对 solr 项目 BaseTokenizerFactory 接口的扩展实现。

  属性：useSmart。该属性决定分词器是否采用智能切分。

4.2 solr1.4 配置样例

使用 IKAnalyzer 的配置

```
<schema name="example" version="1.1">

  ……

  <fieldType name="text" class="solr.TextField">
     <analyzer class="org.wltea.analyzer.lucene.IKAnalyzer"/>
  </fieldType>

  ……

</schema>
```

使用IKTokenizerFactory的配置

```
<fieldType name="text" class="solr.TextField" >
    <analyzer type="index">
    <tokenizer class="org.wltea.analyzer.solr.IKTokenizerFactory"
useSmart ="false"/>

  ……


    </analyzer>
    <analyzer type="query">
```

```
    <tokenizer class="org.wltea.analyzer.solr.IKTokenizerFactory"
useSmart ="false"/>

    ......

    </analyzer>
</fieldType>
```

5.关于作者

Blog ： linliangyi2007.javaeye.com

Email： linliangyi2005@gmail.com

（全文终）