Gromoteur 软件使用手册

Gromoteur 软件是由巴黎第三大学 Kim Gerdes 教授开发的一款集数据统计、词性标注、语义划分于一身的语料处理软件，为方便大家使用此软件，灿灿和九菊特做此使用手册，供大家参阅。

1. 语料格式

该软件支持格式为 UTF-8，具体转换方式为：

1) 首先，将 Word 格式另存为 TXT 格式，在转换前注意将 word 中所有文字合并为一段（此方法适用于做单个语料研究）。如果想对比两个或以上语料，则只需要将每段开始的空格去掉，将需要对比的语料单独成段即可，见下图。

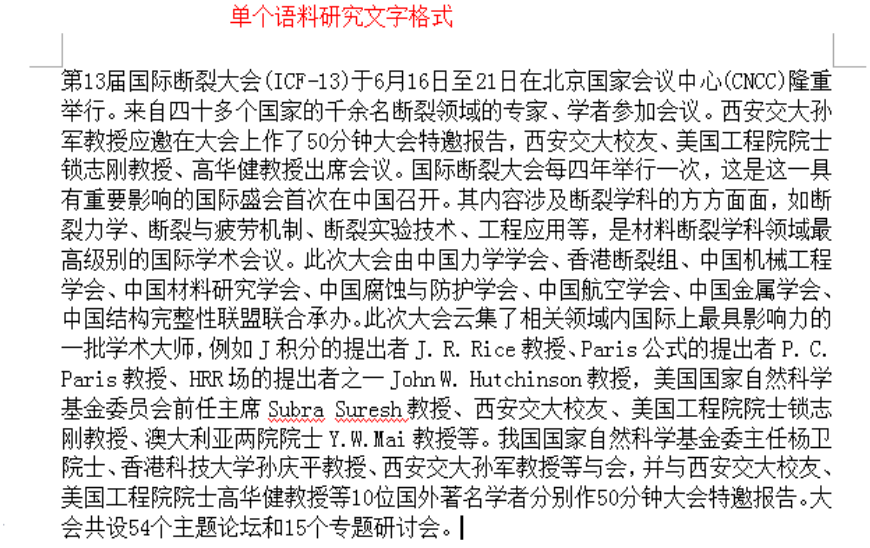

两个语料的对比研究

第13届国际断裂大会(ICF-13)于6月16日至21日在北京国家会议中心(CNCC)隆重举行。来自四十多个国家的千余名断裂领域的专家、学者参加会议。西安交大孙军教授应邀在大会上作了50分钟大会特邀报告，西安交大校友、美国工程院院士锁志刚教授、高华健教授出席会议。国际断裂大会每四年举行一次，这是这一具有重要影响的国际盛会首次在中国召开。其内容涉及断裂学科的方方面面，如断裂力学、断裂与疲劳机制、断裂实验技术、工程应用等，是材料断裂学科领域最高级别的国际学术会议。此次大会由中国力学学会、香港断裂组、中国机械工程学会、中国材料研究学会、中国腐蚀与防护学会、中国航空学会、中国金属学会、中国结构完整性联盟联合承办。
此次大会云集了相关领域内国际上最具影响力的一批学术大师，例如 J 积分的提出者 J. R. Rice 教授、Paris 公式的提出者 P. C. Paris 教授、HRR 场的提出者之一 John W. Hutchinson 教授，美国国家自然科学基金委员会前任主席 Subra Suresh 教授、西安交大校友、美国工程院院士锁志刚教授、澳大利亚两院院士 Y.W.Mai 教授等。我国国家自然科学基金委主任杨卫院士、香港科技大学孙庆平教授、西安交大孙军教授等与会，并与西安交大校友、美国工程院院士高华健教授等10位国外著名学者分别作50分钟大会特邀报告。大会共设54个主题论坛和15个专题研讨会。

2) 将处理好的 word 文档转换为 TXT 文档后，将 TXT 文档另存为 UTF-8 格式（具体方法如下）。

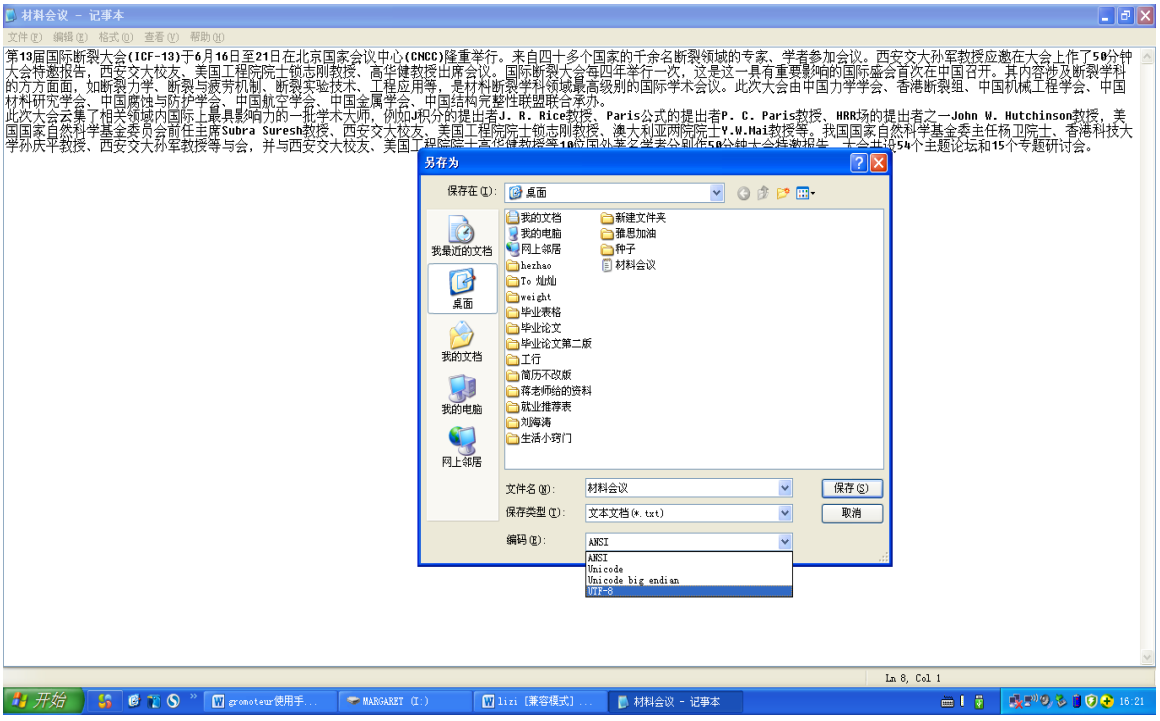

2. 软件使用

2.1 软件基本操作

该软件只能在电脑的 C 盘中运行，所以切记将软件考入 C 盘，并且不能重命名文件夹或者再添加新的文件夹

1）双击 g 图标，打开软件。

点击工具栏第一个按钮，将会弹出一个对话框，根据自己需要，进行重命名，选择 OK，此时该软件将为用户自动建立起一个语料库，接下来用户所有产出的数据和图表将存在该库中（可重复建多个不同的语料库），具体见下图。

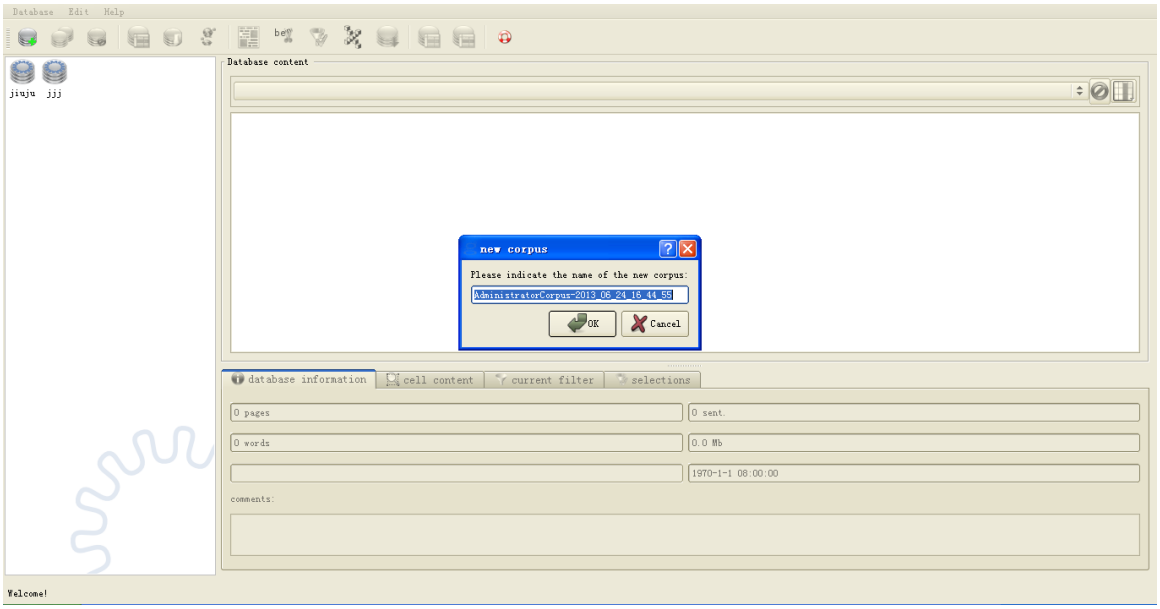

2）点击工具栏中第四个按钮，导入处理好的语料。

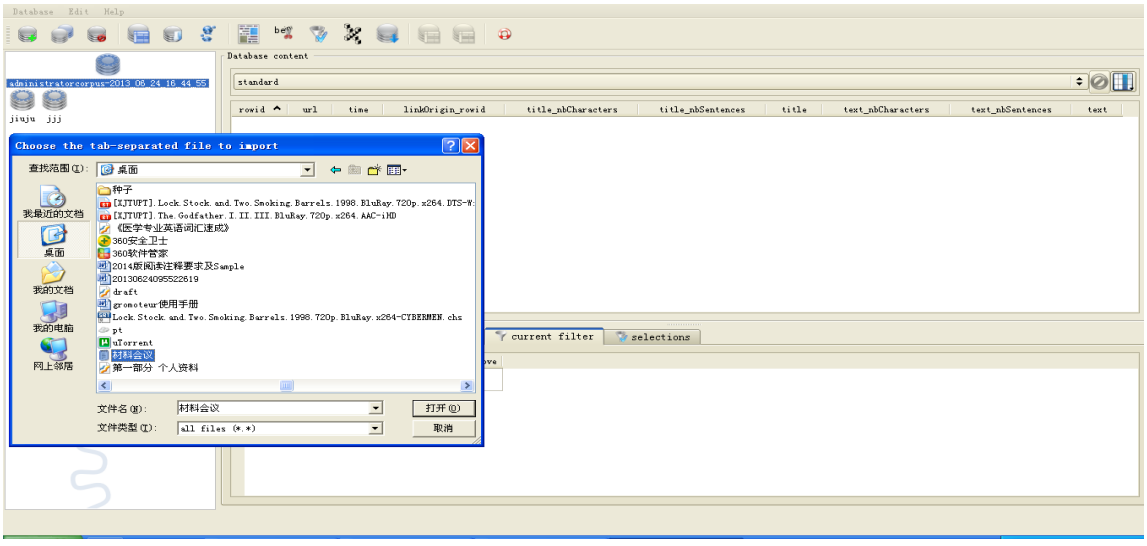

3）软件将显示以下状态

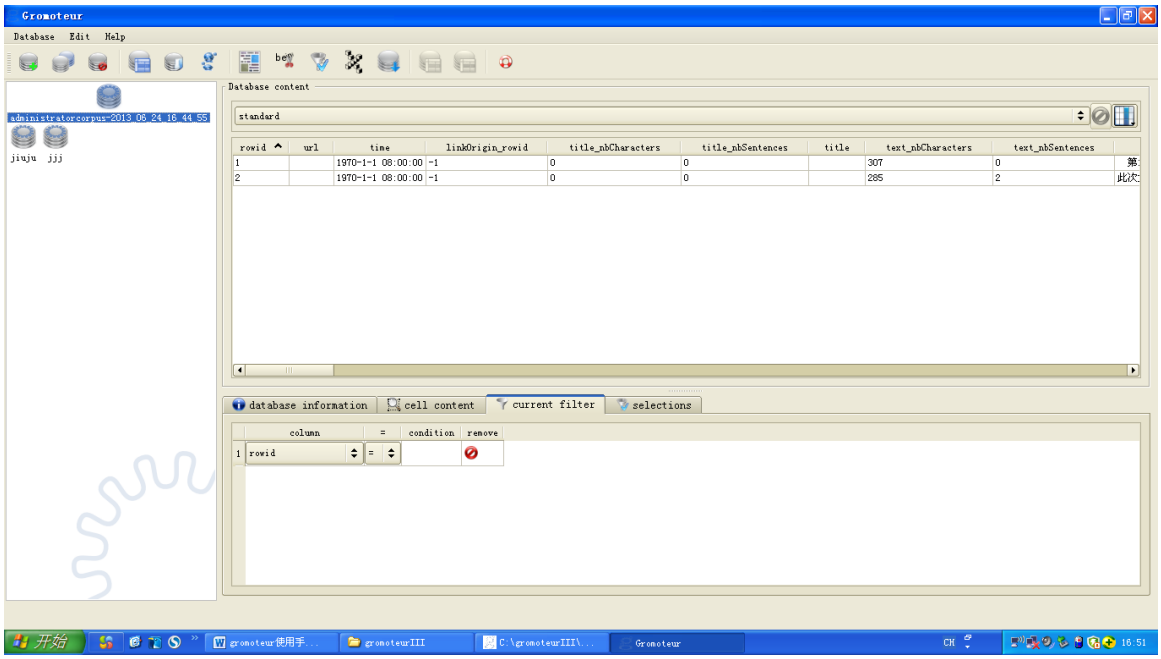

因为我们之前导入的语料为分段语料，所以在上图右边将会出现 2 个栏目。

4）点击工具栏最右边九宫格图表（该图标显示的是图表中包括的各项信息，包括编号、标题、字数、句子等信息，用户可根据自己的需要自行选择），选择 text 选项，具体操作为：点来九宫格图表 ⟹ 点击“text”选项 ⟹ 点击“invert selection”，此时将出现下图：

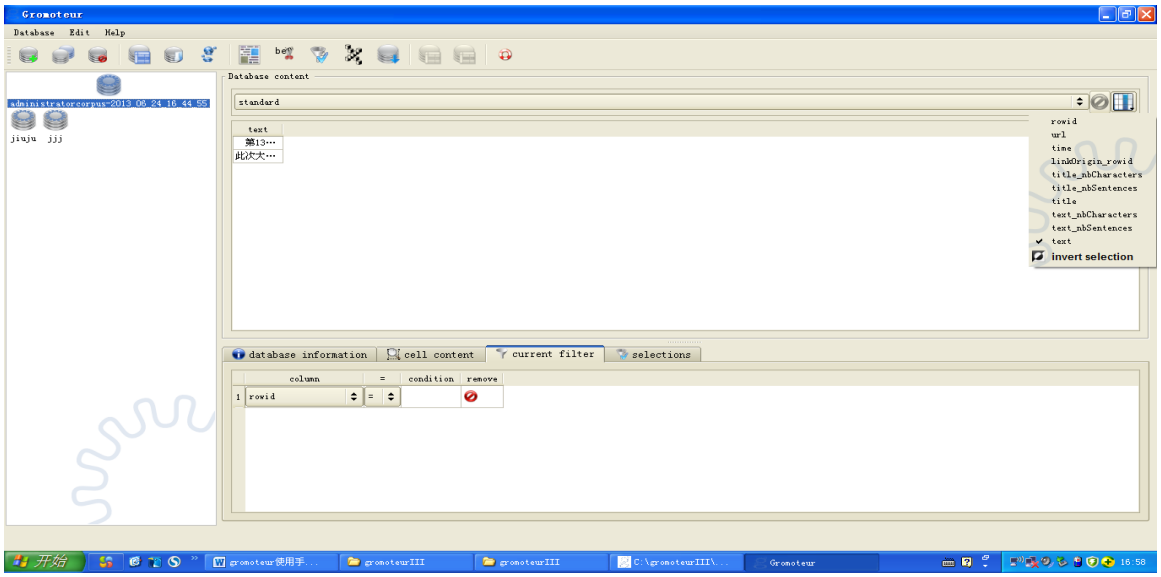

这样，我们的前期工作就做好了，接下来，我们将进行语义划分（segmentation）和词性标注（tag）的操作。

2.2 语义划分及标注

2.2.1 语义划分：

在九宫格中选定 Text，点击工具栏中第 8 个“be in”按钮，在弹出的对话框中选择“word segmenter”下的“urheen segmenter”选项，此选项将进行 segmentation，见下图（urheen segmenter 只进行 segmentation，urheen segpos 能同时 segmentation 和 tagging，大家可以根据自己需要自行选择）。

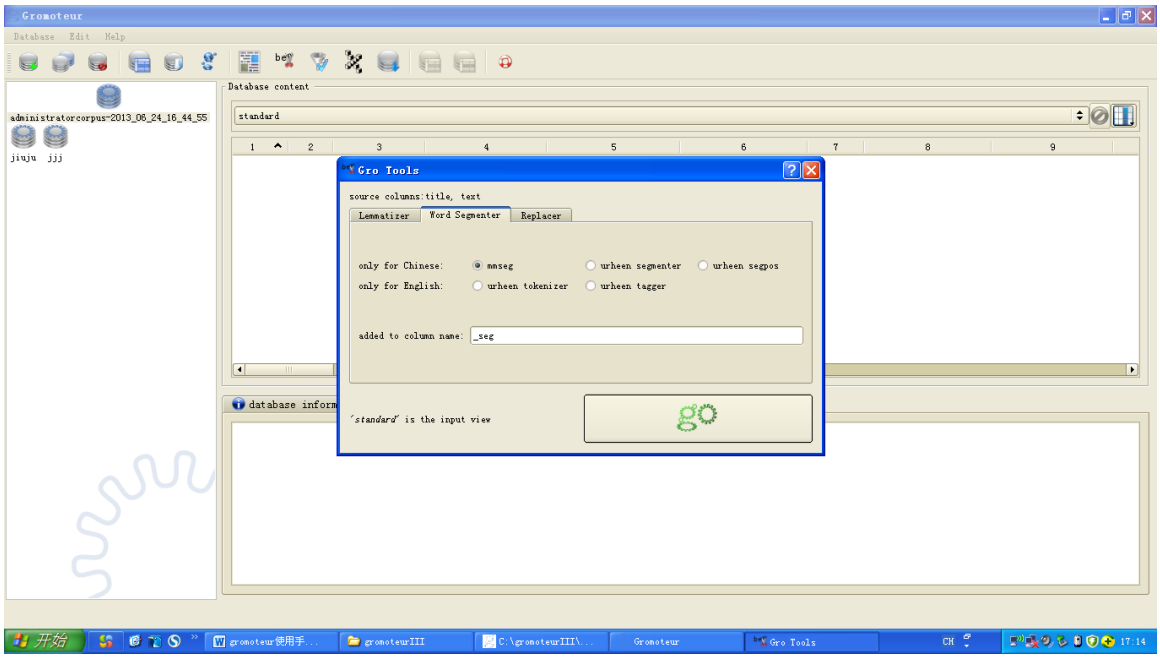

点击 go 按钮，将会出现如下结果（注意要将中间的进度条拉至最右，也可以通过右边的九宫格选择 text-seg 项）。

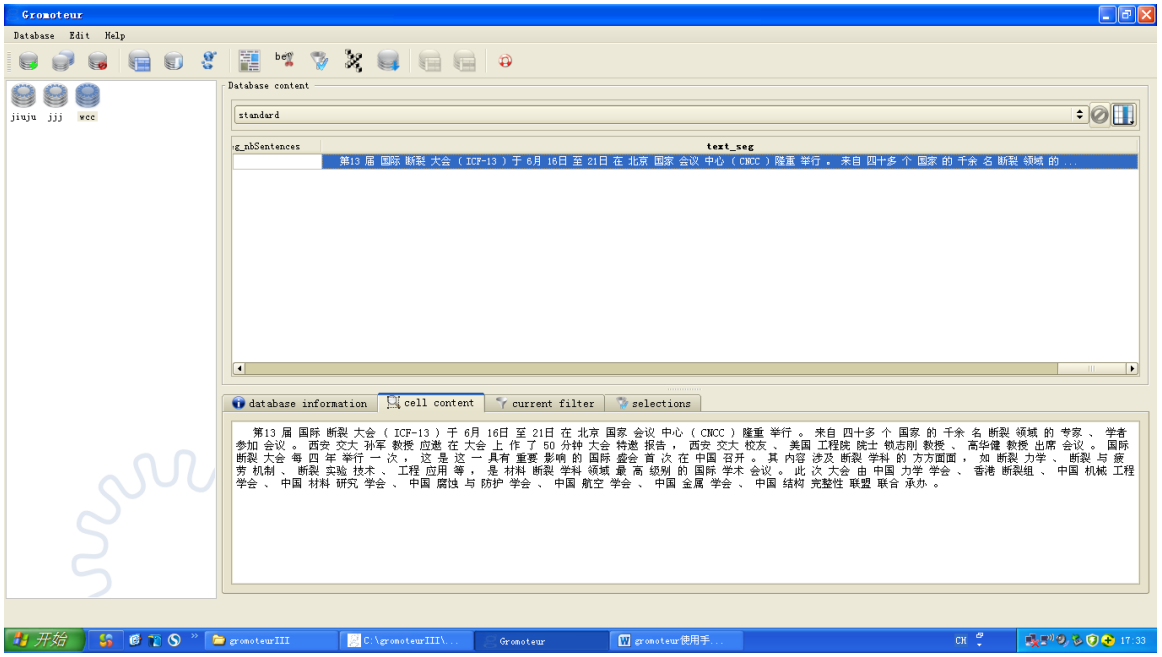

2.2.2 词性标注：

如果想进行 tag 过程，则点击工具栏中第 8 个“be in”按钮，在弹出的对话框中选择“word segmenter”下的“urheen segpos”选项,点击 go 就可以进行 tag，结果如下图：

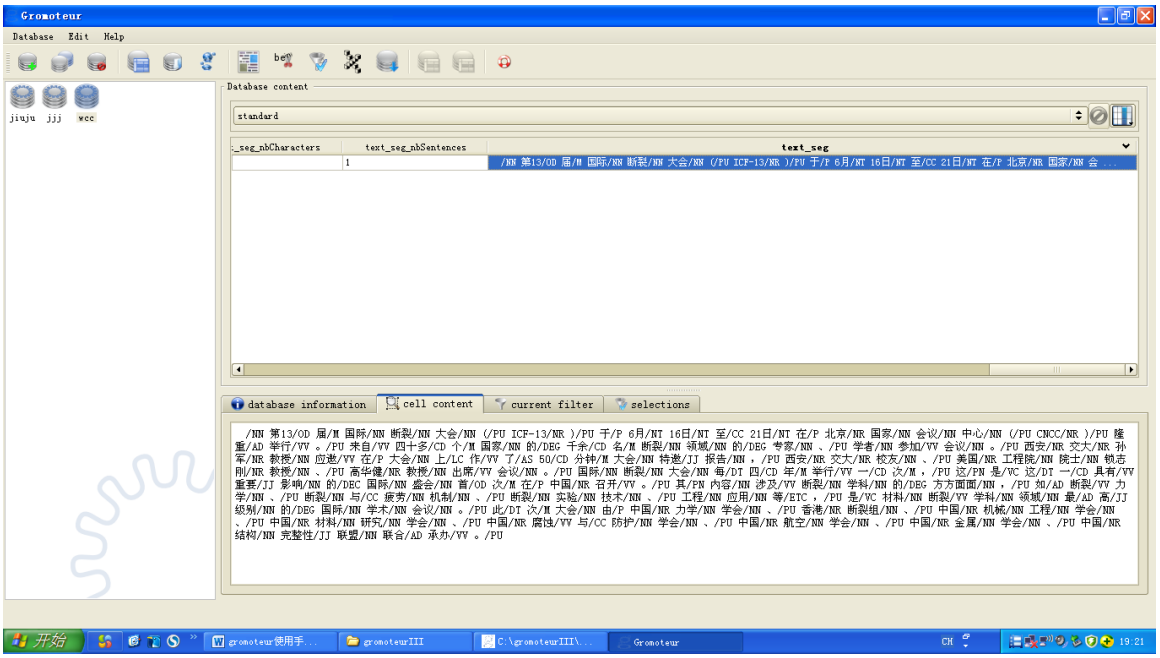

2.2.3 数据分析

该软件同样支持数据分析。接着上面的操作，在九宫格中选定 text-seg 项，点击上方第十个按钮，statistical analysis，进行数据分析。结果如下图所示：

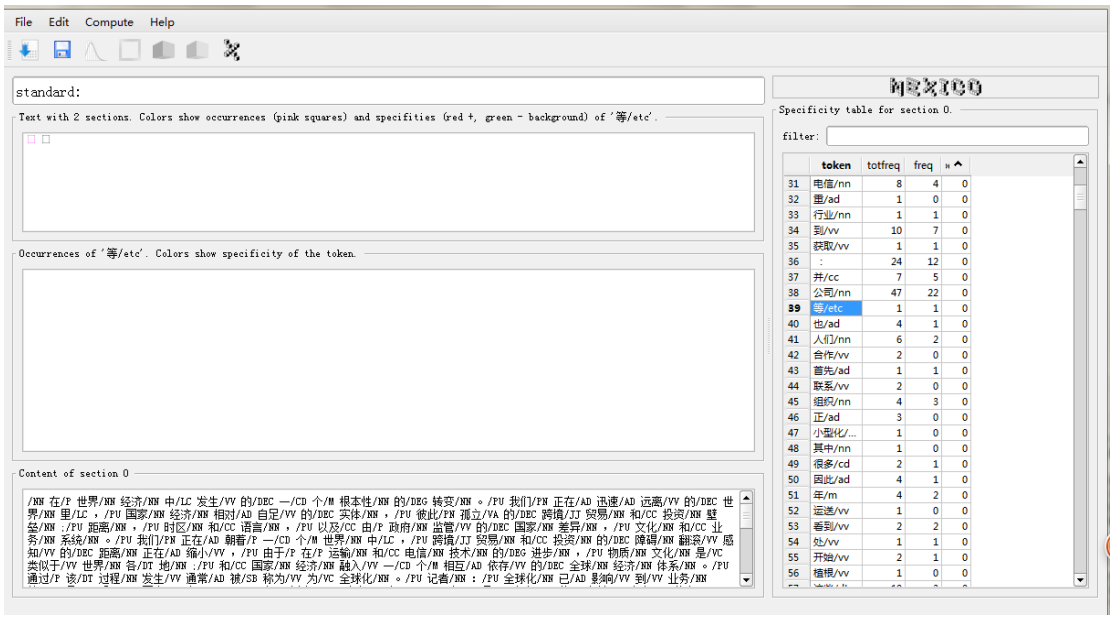

图表中，Total frequency 指的是该词在整个语料中所出现的次数，frequency 指的是该词在选定的文本中出现的次数。如图中，“到”在整个语料中出现 8 次，在第一部分（即第一个小方框）出现 7 次。最后一组数据 specificity 指的是前两项分布出现的概率，即 SP=$\frac{1}{10^{x}}$。大多数情况下，这个数据为 0，即出现的概率为 100%，当出现 1 以上或是负数时，便是值得深究的点。

2.3 结果导出：

我们以词性标注后的结果导出为例子，给大家展示如何将标注好的结果进行导出。

首先，点击工具栏中第 11 个选项 “export current view to file”。便

会出现对话框，如下图：

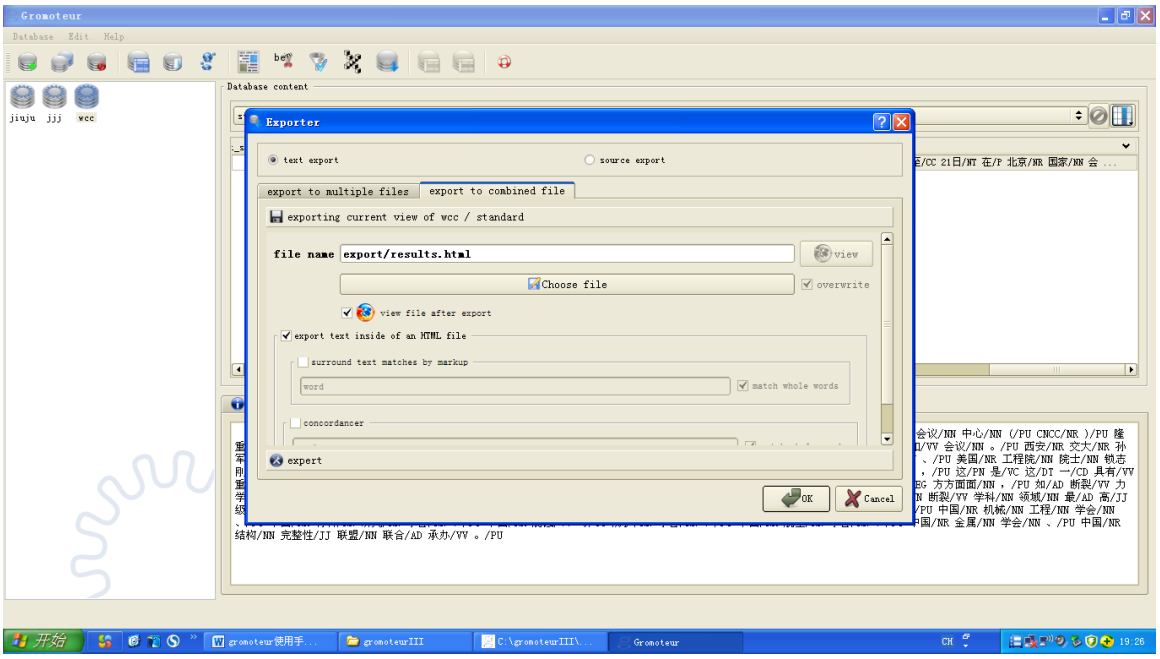

然后，将 file name 格中的名字全部删除，自己命名，并将下方“export text inside of an HTML file”前的小箭头去掉，然后点击 expert，下方会出现一系列选项卡，如下图：

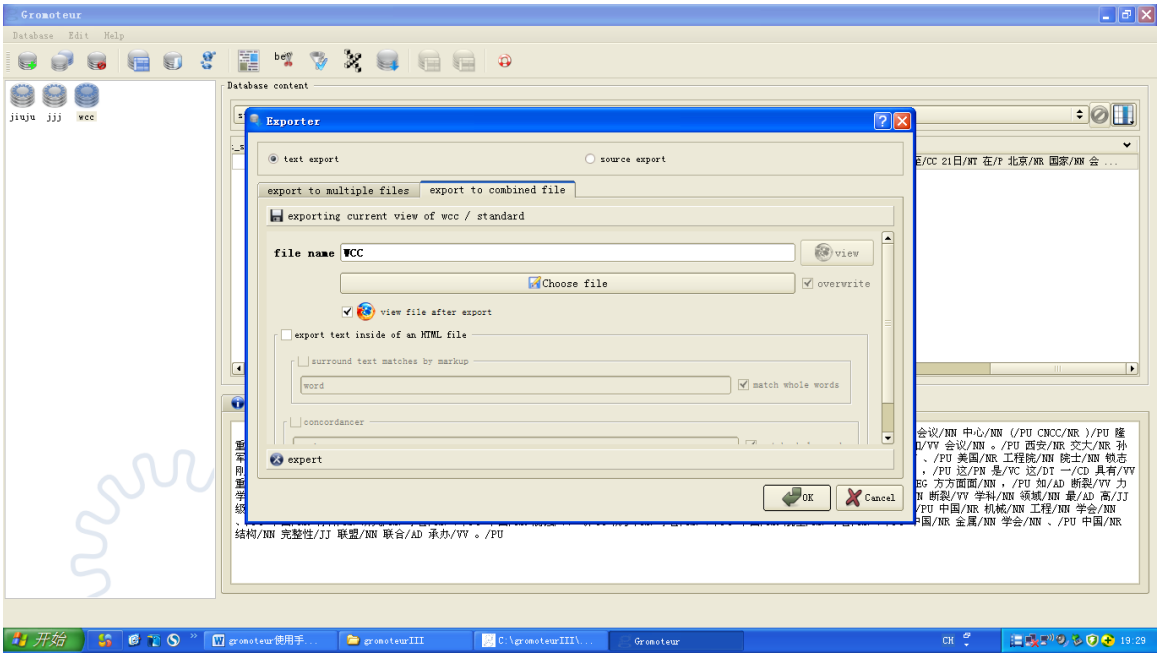

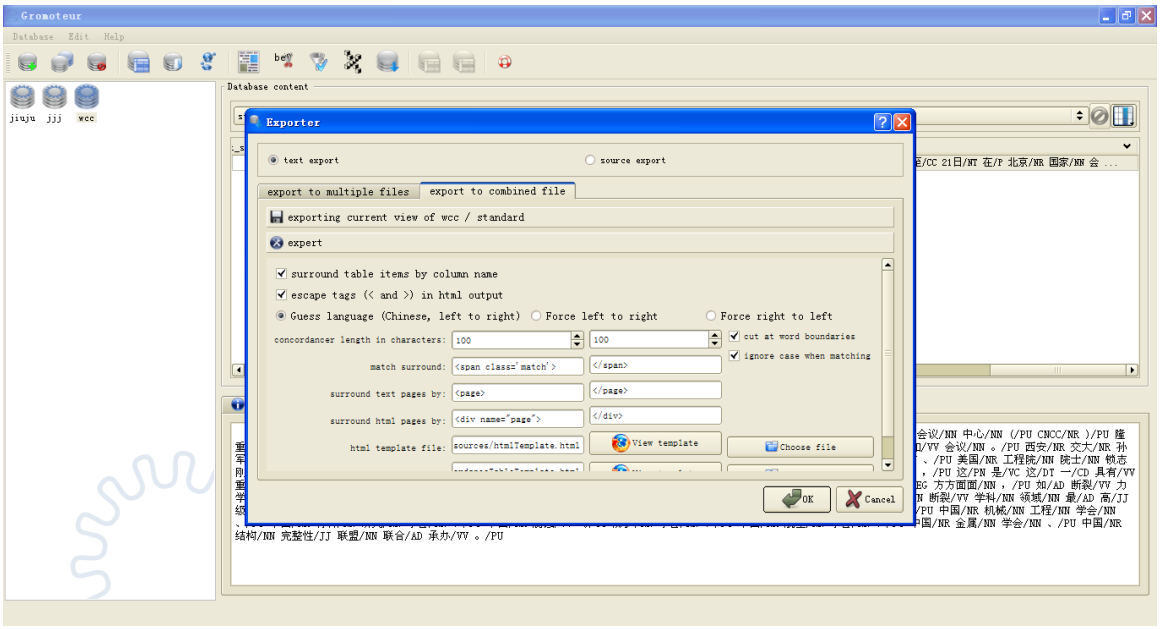

我们可以根据自己需要选择，一般我们会将 match surround, surround text pages by, 和 surround HTML pages by 这三个选项后的 6 个空格清空，然后点击 ok，处理好的文件会自动弹出打开，结果如此下图:

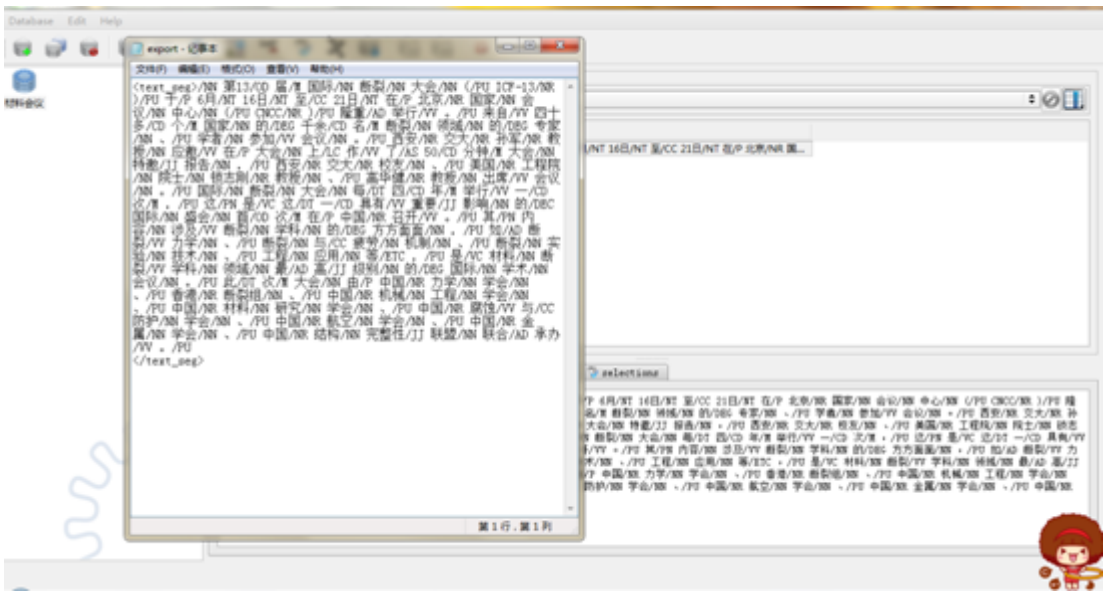

处理好的文件就在 gromoteur 文件夹中，根据自己当时的命名找到对应文件，或者直接将弹出的文件“另存为”，方便寻找。

后续的画树需要将此时导出的文件上传到 Arborator（这是专门用于画树的在线资源，其使用方法后续会给大家介绍）上进行画树。如下图：