智分析使用手册

最新版请前往智分析官网—产品手册查看：https://saz.codeghub.com

目录

前言

智分析是一款基于自然语言处理技术的文本分析工具，同时通过可视化技术，大大减小了使用自然语言处理技术的门槛。

智分析主打傻瓜式、自动化，最大限度减少人工成本，完全不懂技术的用户也可以无障碍使用。

同时智分析秉着 “人工+智能=越用越智能” 的理念，使人工仅专注于领域内知识的刨析，相关技术性的东西可以完全交给智分析来处理，且人工也会使智分析更加的智能，分析得到更准确的结果

快速入门

四步开启您的智分析之旅

1. 登陆账号进入<我的项目>

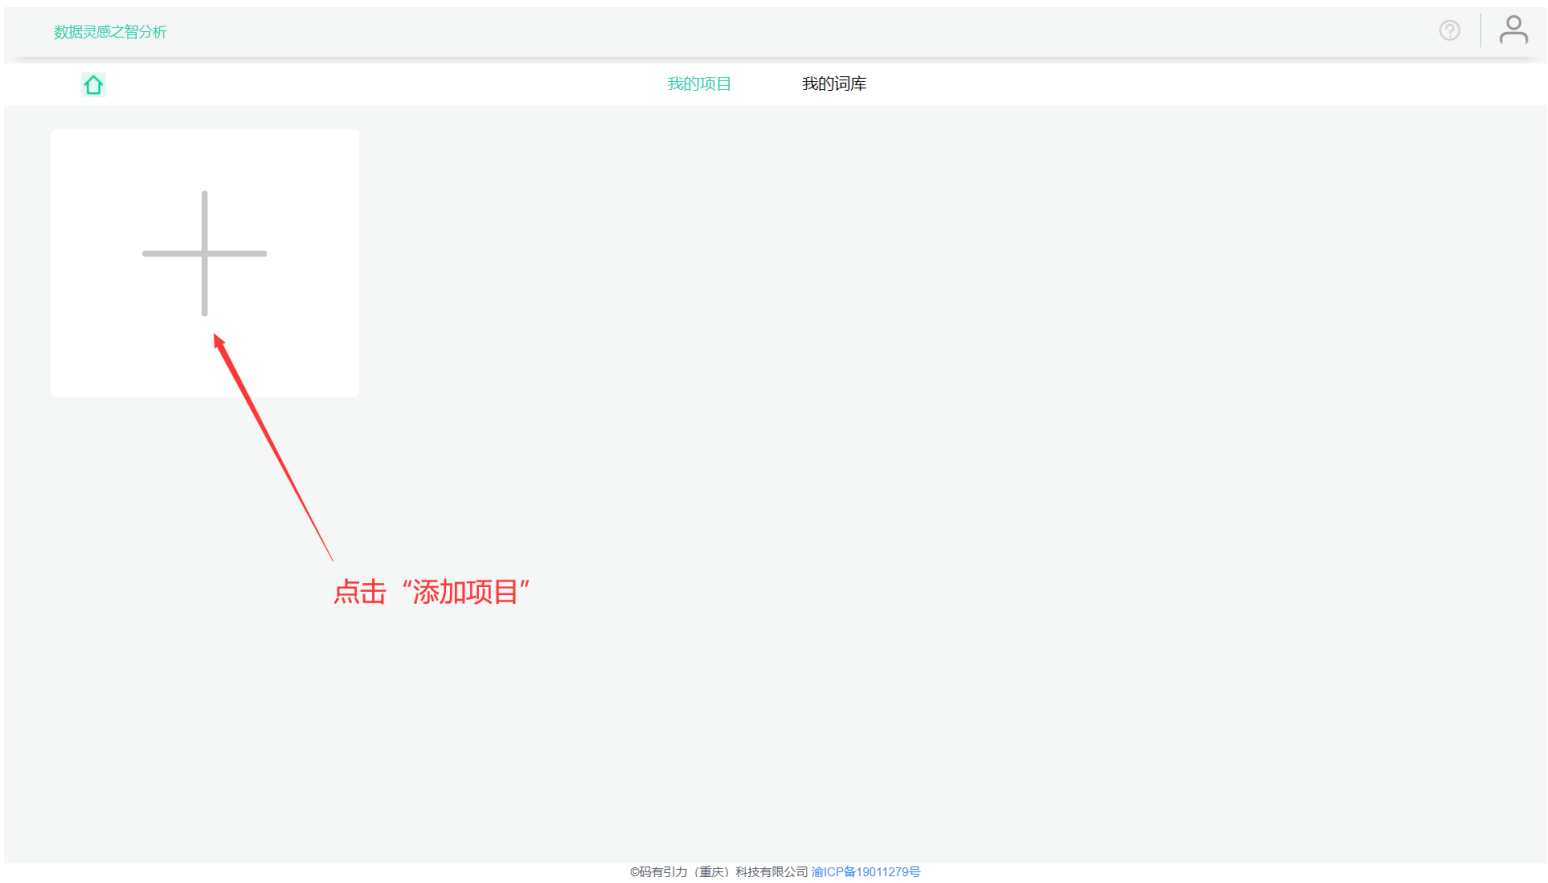

2. 点击“+”添加项目，输入项目名称并上传数据文件（数据文件暂支持excel、txt文件），点击新建项目完成项目创建

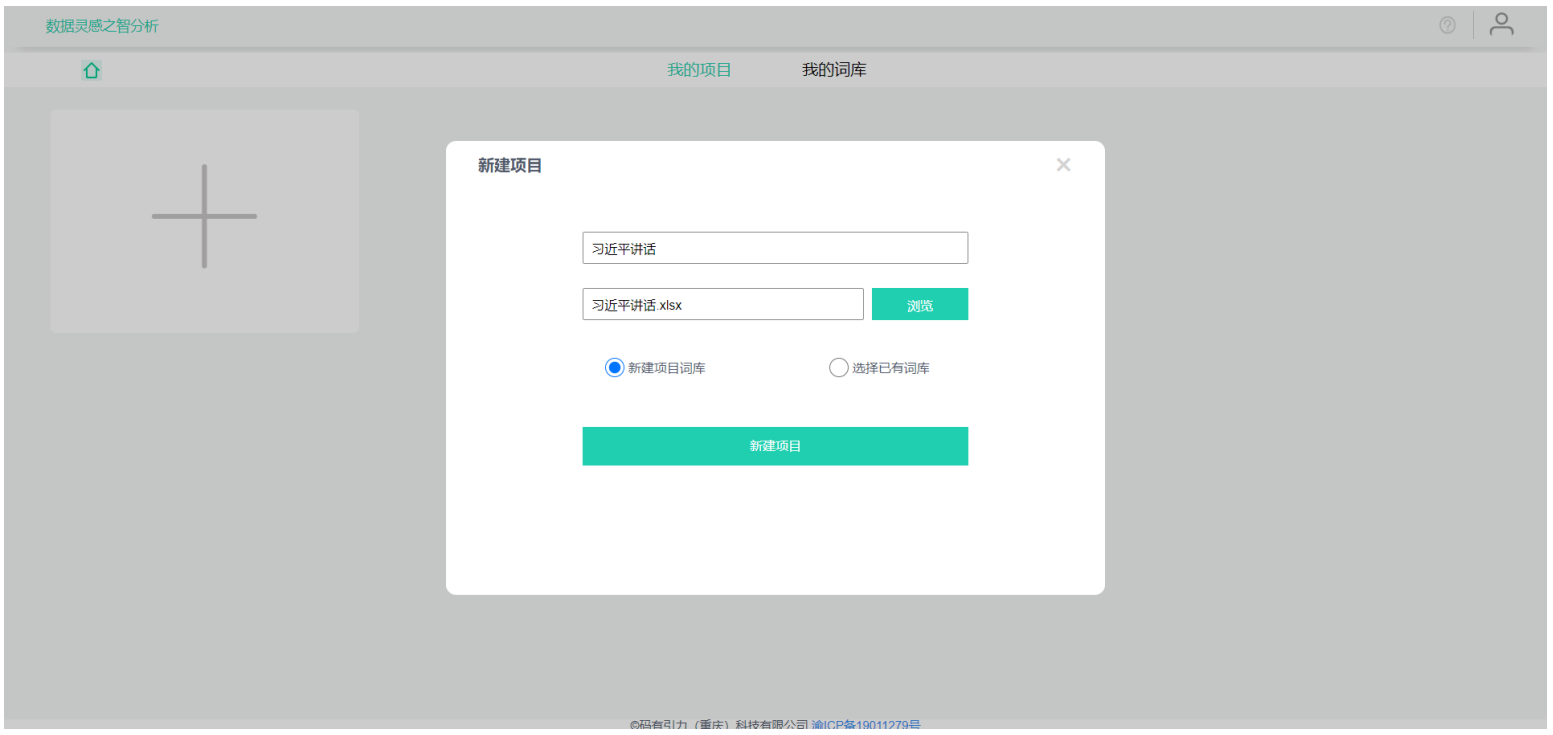

3. 创建项目成功后点击您所创建的项目，进入数据浏览页面

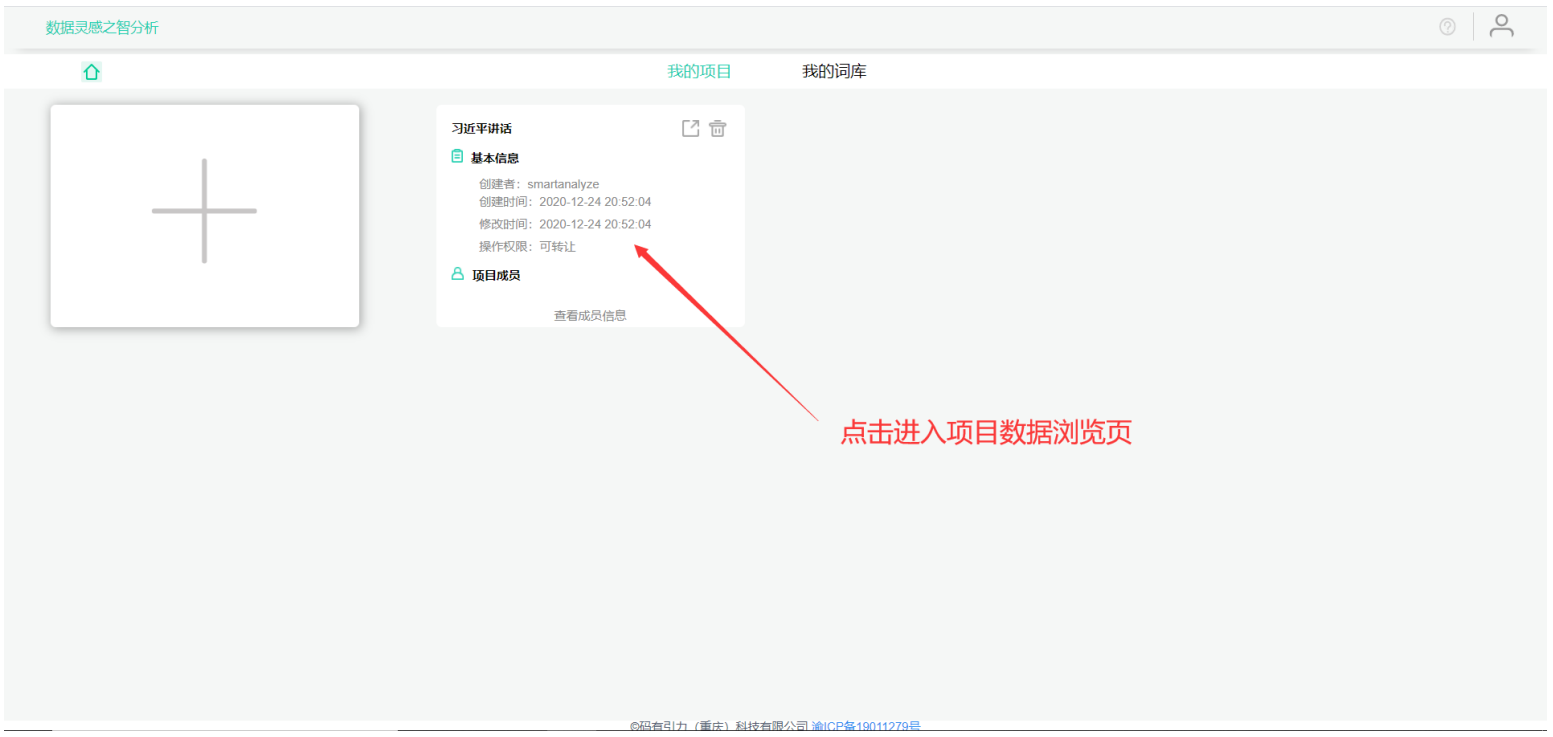

4. 点击“开始分析”按钮，稍等片刻，即可开始您的智分析之旅~

结果调试

可从数据灵感结果中看到，有的词语并不是我们想要的，比如：”我们“、”年月日“等；有的词语比较简单，并未表达出准确意思，比如：”问题“、”坚持“等。怎么让结果更准确呢？

1. 进入新词发现，筛选出新词短语，并右键添加到词库中

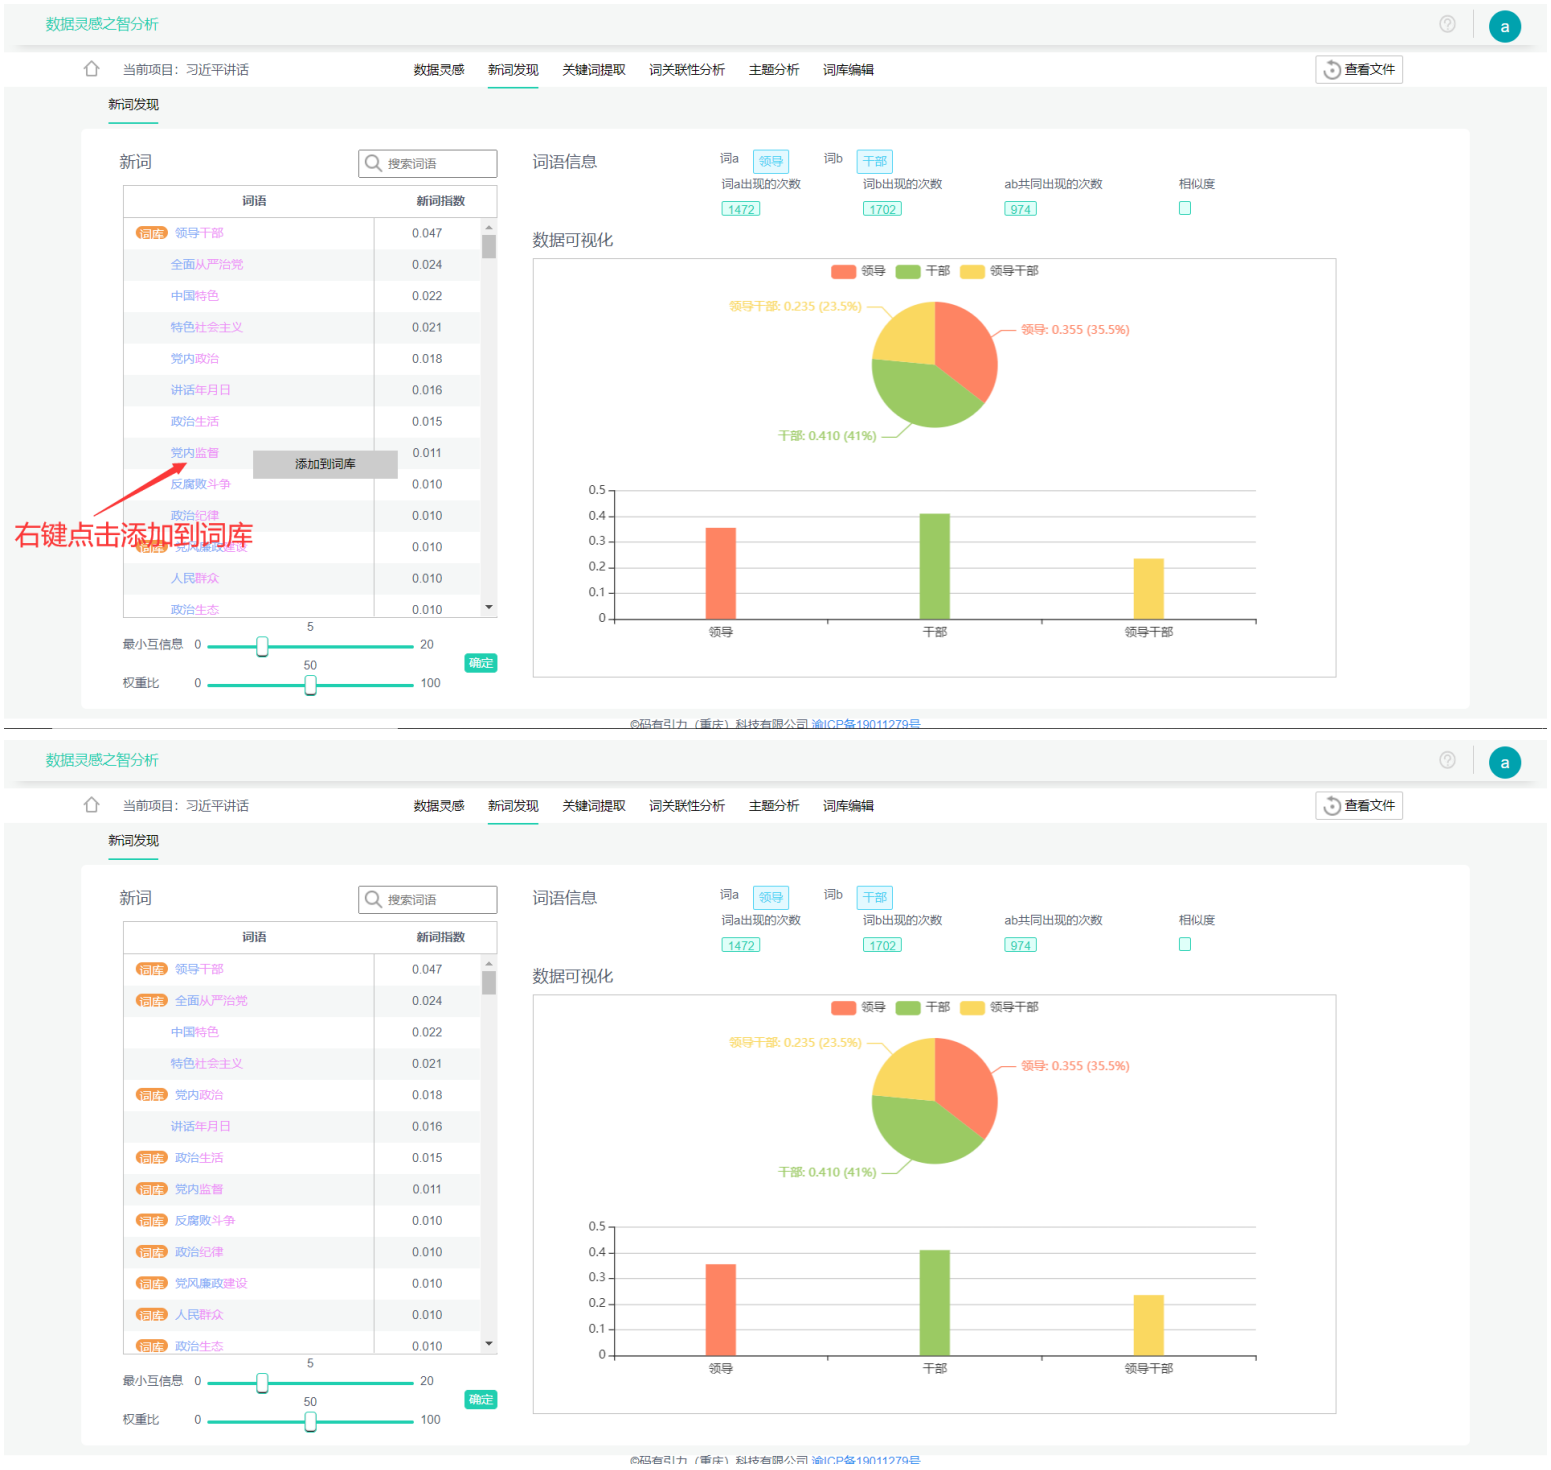

2. 筛选添加到词库完毕后，进入关键词分析，查看排名靠前的词语中有没有我们不想要的，如果有，则右键添加到停用词库中

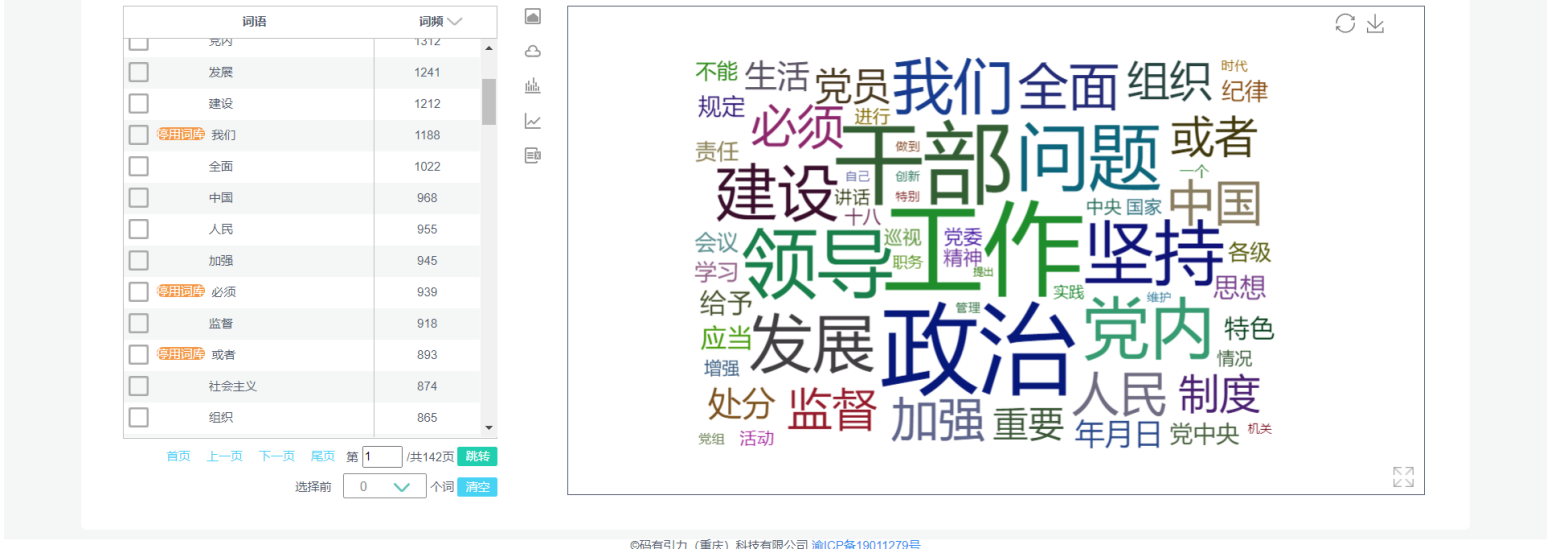

3. 添加完毕后，点击<查看文件>，再点击重新计算，即可进行重新分词

可通过数据灵感直观看到，此结果要比最开始的好很多

4. 反复进行以上结果调试步骤，直到结果满意为止

功能介绍

项目/词库管理

在<我的项目/词库>页面可进行项目查看、创建或删除操作，同时，<项目/词库>支持分享，分享后，别人即可获得您的分析结果，还能与您进行协同分析。

> <我的词库>页面不能进行词库创建，词库的创建是在创建项目时勾选新建项目词库创建的

项目/词库 分享（协同分析）

只有<项目/词库>**创建者**才能进行<项目/词库>分享操作

1. 点击<项目/词库>分享按钮

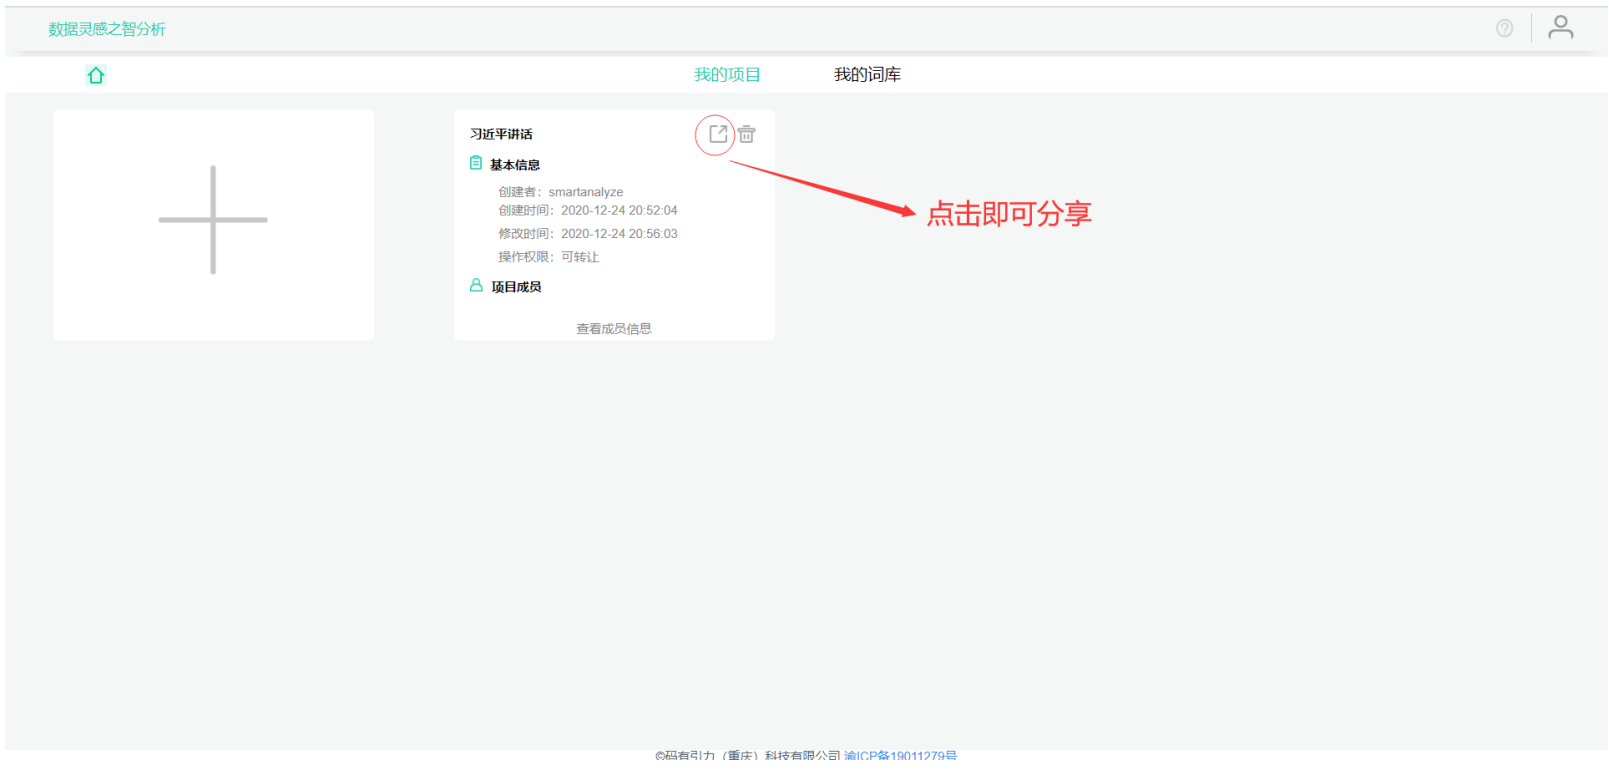

2. 输入对方的用户名，编辑分享权限，权限分为“可读”和“可编辑”

> 项目权限解释：

- 可读：对方只能浏览您的项目结果，不能进行新词发现调参计算、词关联性分析初始化、主题分析重置、重新分词计算等改变您计算结果的操作。**一般用于项目结果分享**
- 可编辑：对方拥有可读权限的同时，可以进行新词发现调参计算、词关联性分析初始化、主题分析重置、重新分词计算等操作。**一般用于项目协同分析**

词库权限解释：

- 可读：对方有读取您的词库权限，并可用您的词库进行项目分词计算，但不能进行词库编辑。**一般用于词库结果分享，借用**
- 可编辑：对方拥有可读权限的同时，可以进行词库编辑。 **一般用于词库协同共建**

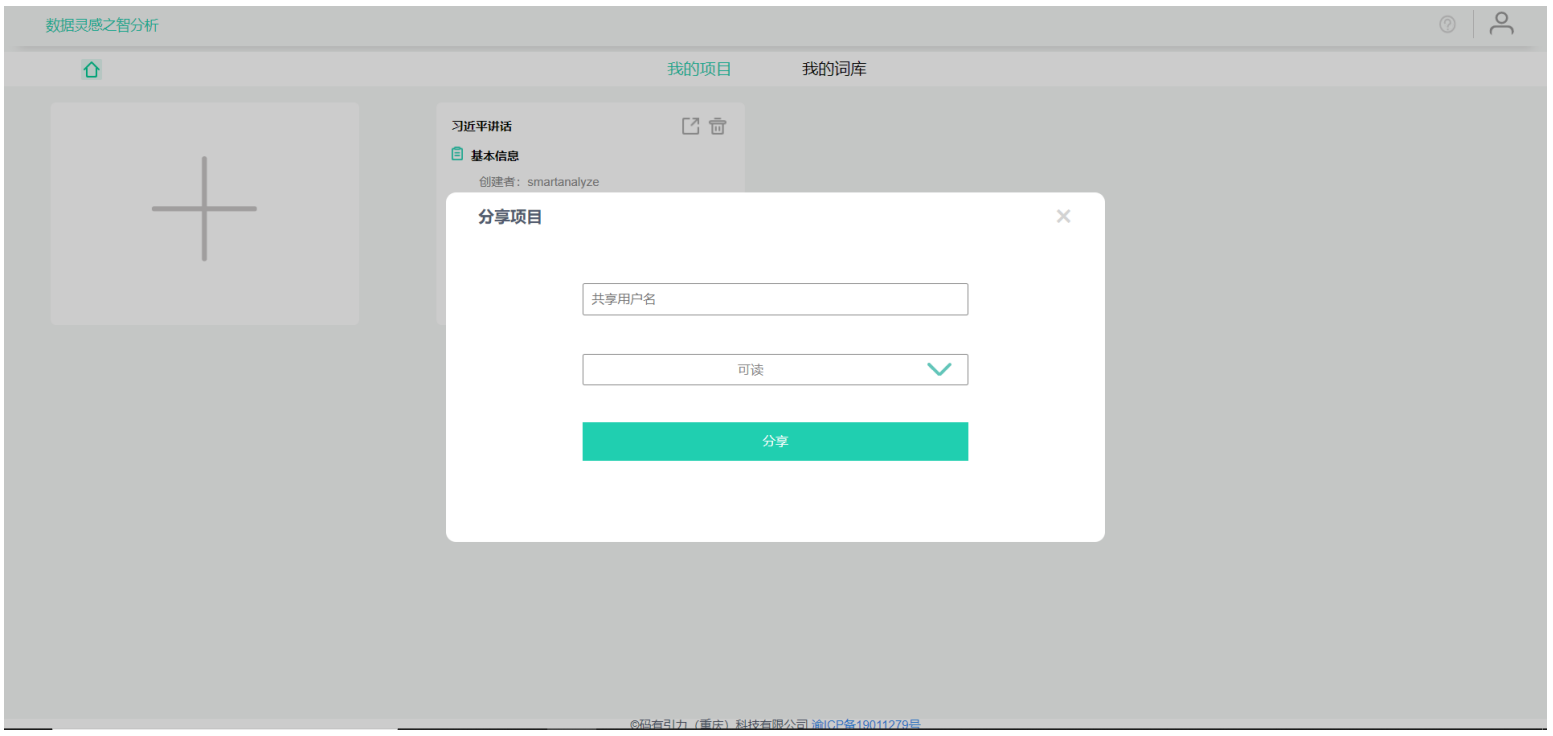

3. 点击查看成员信息可查看<项目/词库>成员

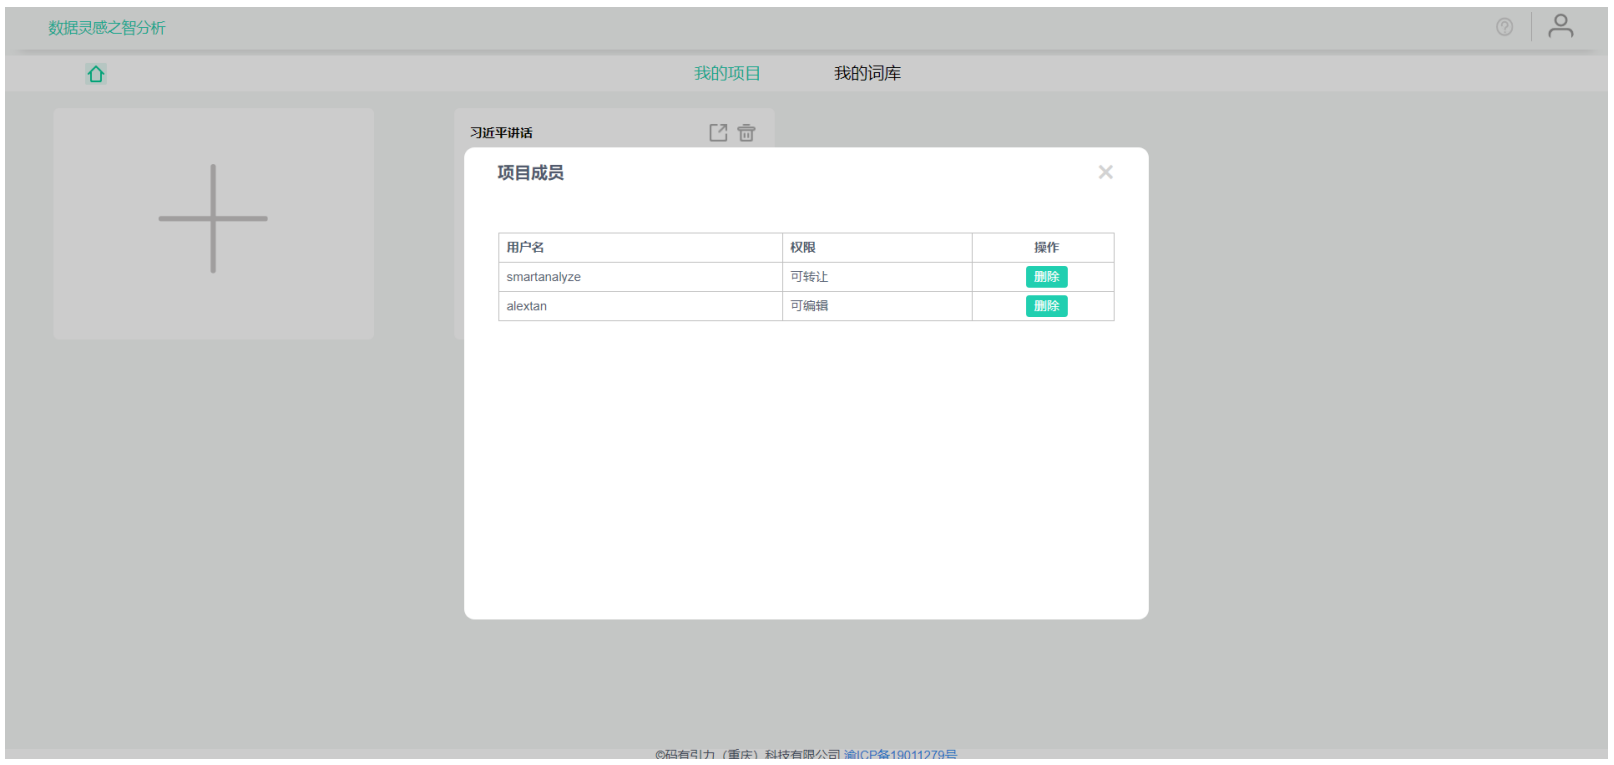

同时在<项目/词库>成员页面可进行项目成员删除操作（取消分享）

开始分析

进入项目后，点击开始分析，智分析便能帮您进行全自动分析，在这里，智分析会自动识别您所上传文件的内容，其中最重要的是内容列、时间列、计数项列（分类列），然后自动提取内容列里所有单元格的内容进行分词计算，同时智分析会通过算法匹配可能能结合分析的列（项）进行多维度分析计算

数据灵感

> 数据灵感旨在为用户提供一键智能化分析的功能，顾名思义，一键为用户带来数据的灵感，根据所上传的数据，呈现出相应的图，所有图形支持直接保存到本地。

计数项分析

> 计数项指的是excel表格中可以计数的一项，或者可以理解为能分类的一项，比如下列表格中的“态度”可分为：积极、消极、中性。
>
> 智分析会根据表格内容自动分析出可能作为“计数项”的一列，自动呈现出计数项图，如果没有找到计数项，则不会呈现。
>
> 如果系统判断有误，或者想对其他项进行计数，也可以在图形中手动选择计数项。
>
> > 部分图形计数项和计数类支持用户手动选择

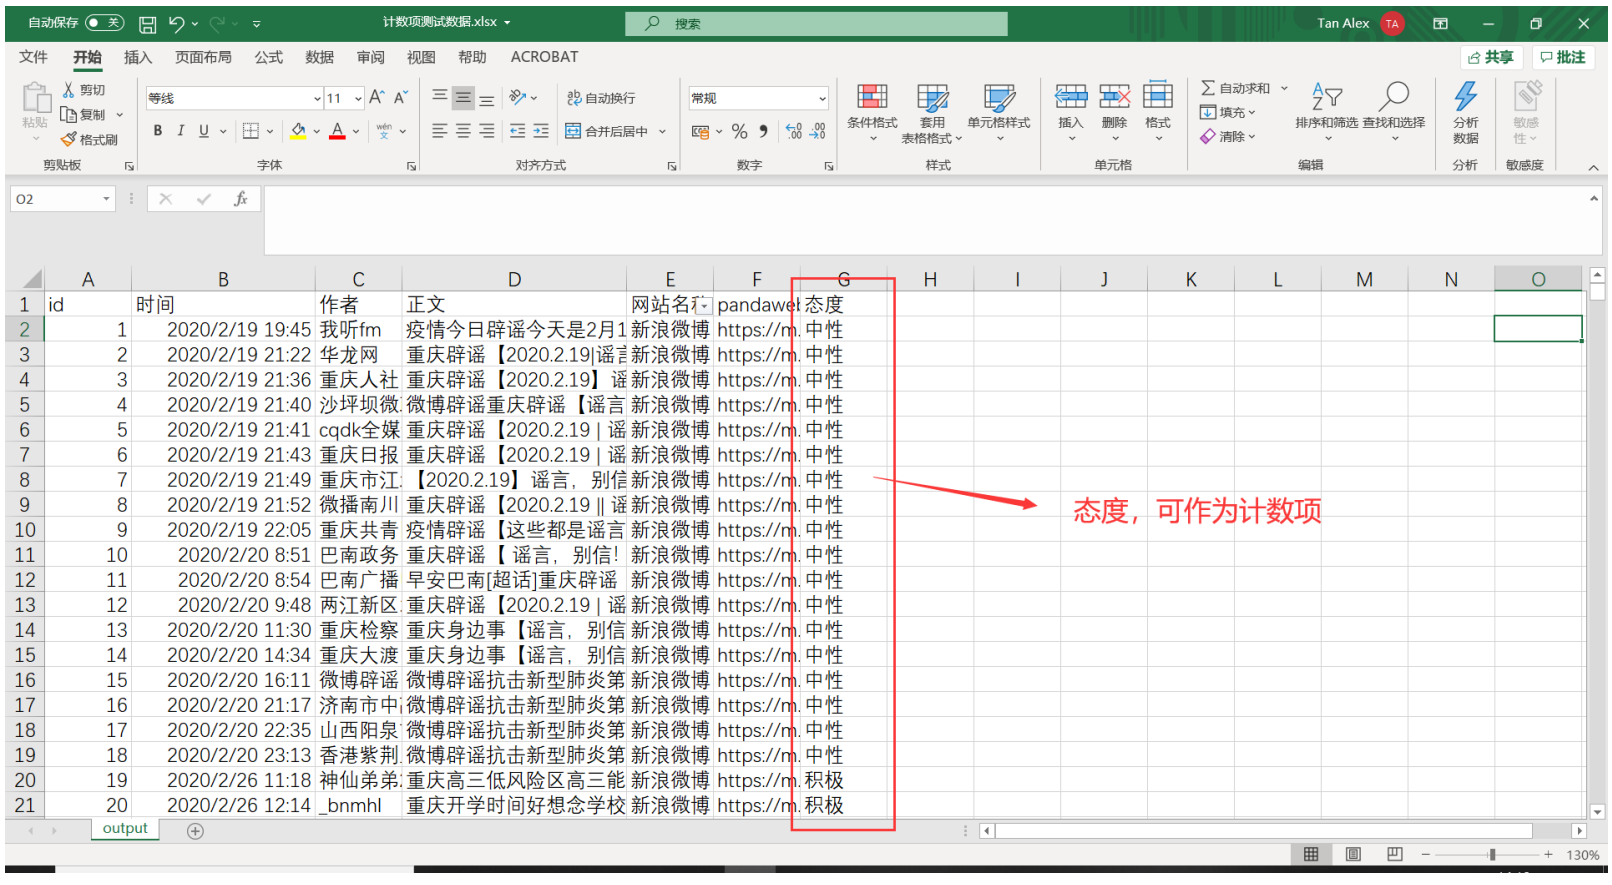

计数项条形图

当数据中含有计数项时会呈现此图，该图会对计数项进行数量统计，横坐标代表不同的类别，能直观展示出不同类别的数量。

计数项扇形图

当数据中含有计数项时会呈现此图，该图对计数项进行了数量统计，图中不同颜色代表计数项中不同的类别，可整体展现不同类别所占的数量比例。

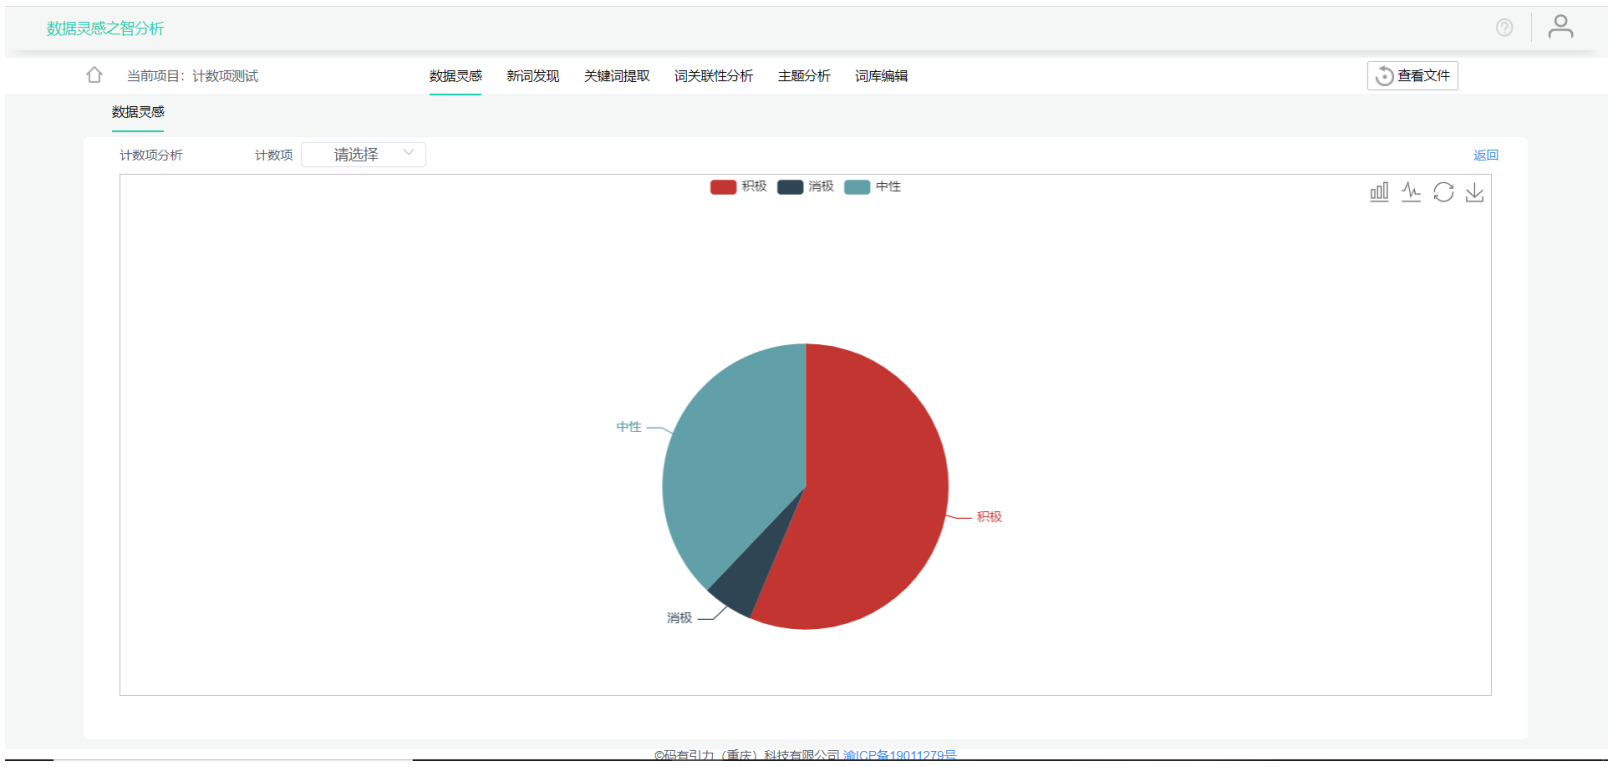

计数项词云图

当数据中含有计数项时会呈现此图，可对计数项中某一类别中的内容进行词频统计，绘制成词云图。该图中词频越大，词的大小就越大，能够提炼出某一类别中的关键词语。

> 词频：即词语在全文中所出现的次数

计数项趋势分析折线图

> 当数据中同时拥有时间项、计数项时会呈现此图，将计数项与时间项结合分析，按时间统计某一类别的数量，绘制成折线图，不同颜色代表不同类别，能表示出不同类别的趋势信息。
>
> > 智分析会自动识别判断时间项，并选择合适的时间间隔，时间间隔也可以手动选择。

计数项词频堆积图

> 当数据中包含计数项时会展现此图，该图将计数项和词频结合分析，统计某一类别中某个词语的词频，绘制成堆积图，不同颜色代表不同类别，能表现出词语在各类别中所占的数量与比例，默认取词频排名前10的词语。

计数项TF-IDF条形图

> 当数据中包含计数项时会展现此图，该图将计数项和TF-IDF信息结合分析，统计某一类别中某个词语的TF-IDF值，绘制成条形图，能表现出各类别中的关键词语以及词语在类别中的关键程度，默认取TF-IDF排名前10的词语。

词频统计图

> 统计全文词频信息，取排名前十的词语，横坐标为词语，纵坐标为词频，能表现出全文中排名前十的关键词词频信息

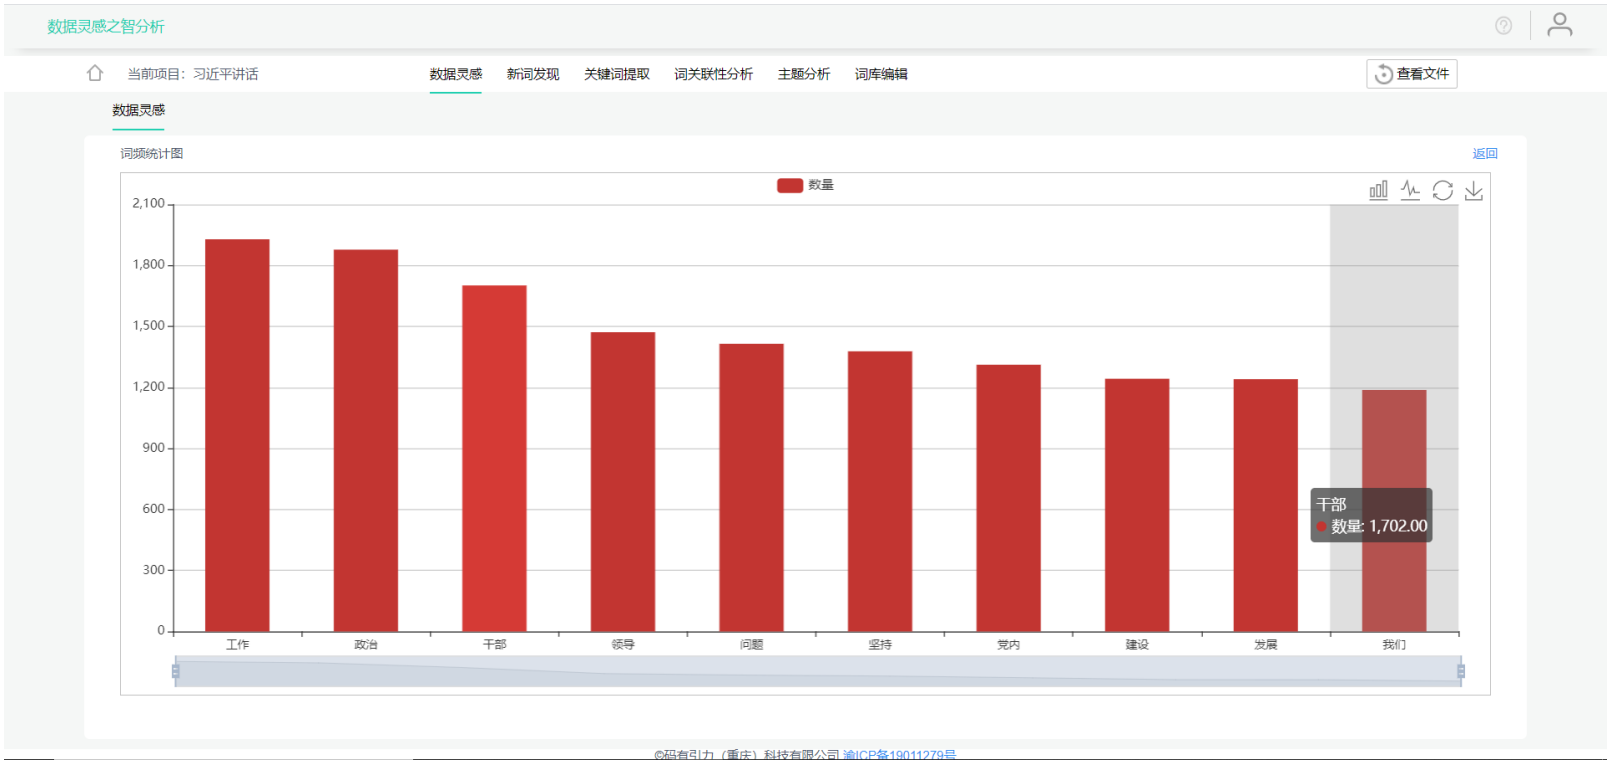

TF-IDF统计图

> 统计全文TF-IDF信息，取排名前十的词语，横坐标为TFIDF值，纵坐标为词语，能表现出全文中排名前十的关键词TF-IDF信息

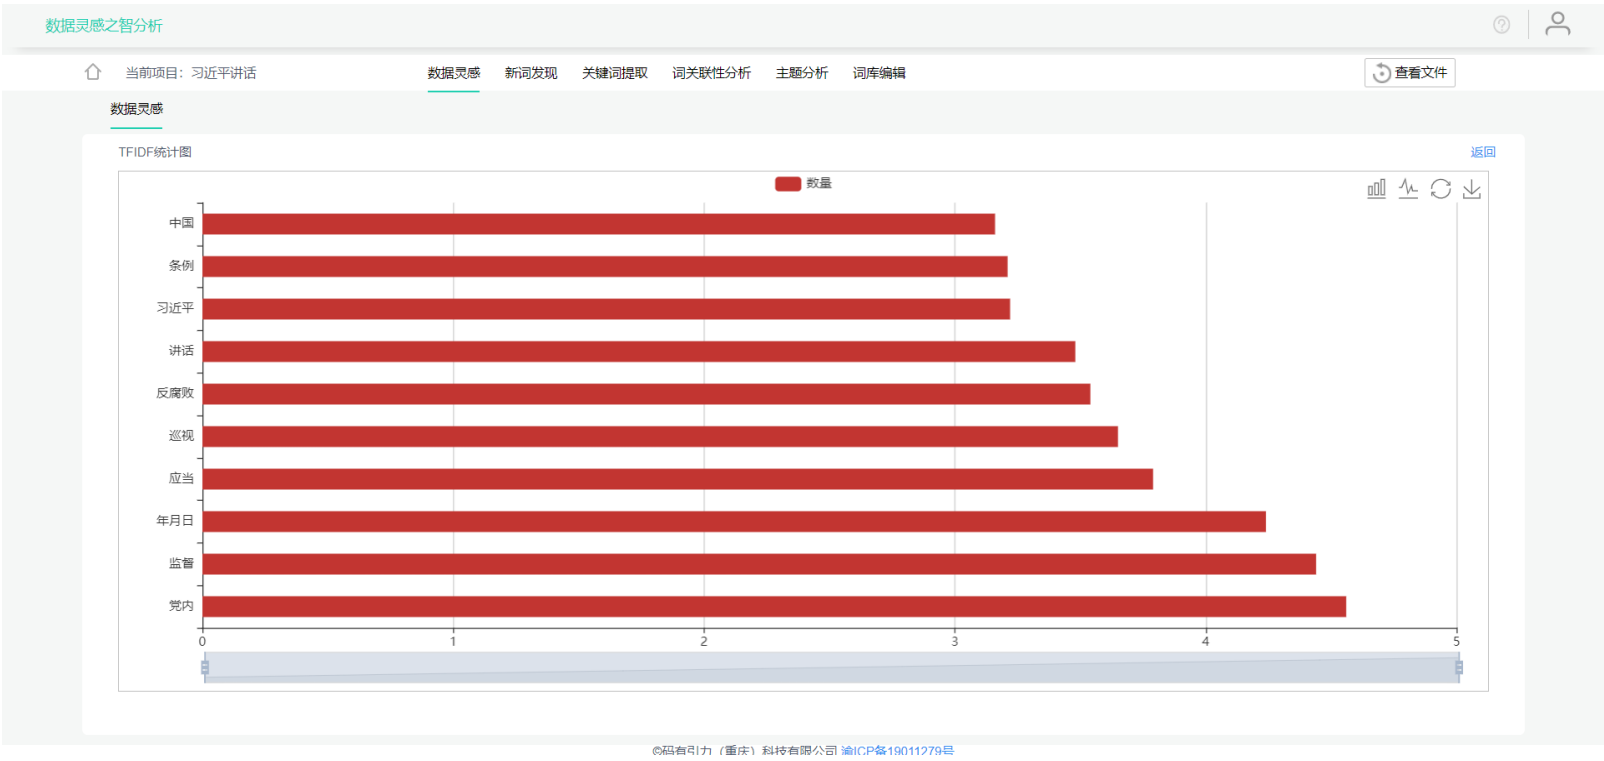

词云图

> 统计全文的词频信息，取排名前200的词语，绘制成词云图，能展现出全文中的关键词信息

发文趋势图

> 当数据中含有时间项时呈现此图，按时间统计文章数量，能表现出发文数量趋势

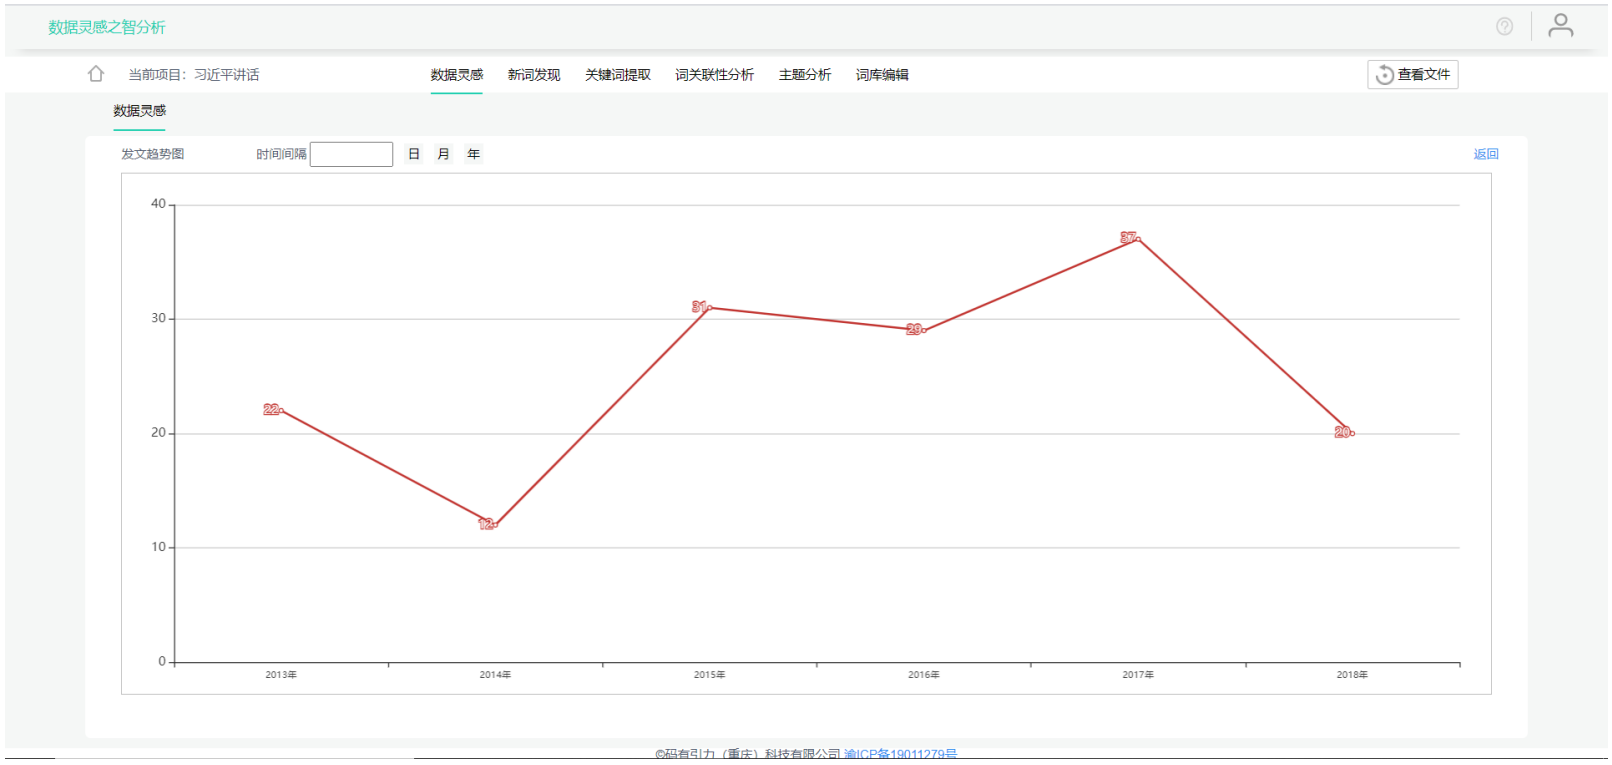

词频堆积图

> 当数据中含有时间项时呈现此图，按时间统计词频信息，绘制成堆积图，不同颜色代表不同的关键词，能表选出各个时间段里的词频信息。

TF-IDF趋势变化图

> 当数据中含有时间项时呈现此图，按时间统计TF-IDF信息，绘制成折线图，不同颜色代表不同的关键词，能表现出关键词TFIDF随时间变化的趋势。

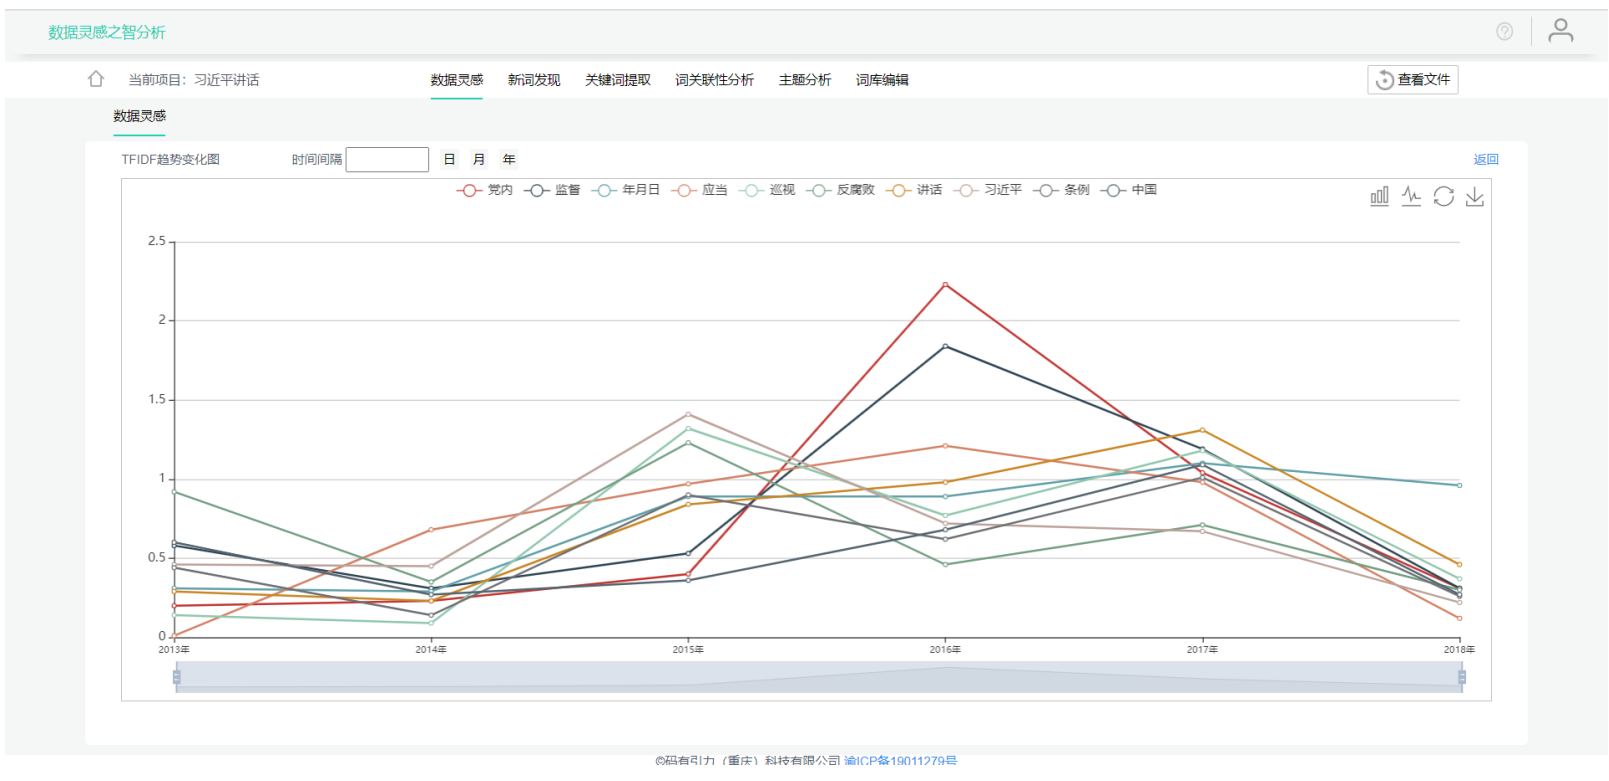

新词发现

> 新词发现又叫做短语抽取，是通过左右熵、互信息算法自动计算出有可能组成短语的新词，计算出的新词一般是通过两两词语组成，其设计目的在于帮助用户减小词库建设的人工成本，用户可直接根据智分析自动计算得到的结果进行人工筛选后添加到词库，以此来提高智分析的分词准确性。

> 最小互信息：即互信息小于此设定值的词语将为被排除，建议取值范围5-12，可根据数据量自行调节
>
> 权重比：指互信息与左右熵的权重比例，关于互信息和左右熵的解释详见<进阶使用-分词与词库-新词发现>

> 新词指数：一般来说新词值数越高，越可能是一个短语（新词）
>
> 共现次数：组成短语的两个词语共同出现在一句话中的次数
>
> 相似度：组成短语的两个词语的关联性，关于其理论知识详见<进阶使用-词语分析-词关联性分析-相似度>
>
> 扇形图中的比例：
>
> > 本功能中的扇形图里比例的计算公式为：
> >
> > X/(Count A+Count B+Count AB)
> >
> > 因此，本图中各个颜色的比例越相近，越可能是一个新词短语

关键词提取

> 在关键词提取功能里，用户可根据词频或TF-IDF值排序，查看所有关键词，并勾选自己想要的关键词进行绘图或导出为表格文件，同时关键词支持搜索功能。

关键词提取

> 关键词提取默认根据词频绘制词云图，用户也可把词频切换为TF-IDF，同时还可根据用户所勾选的词语绘制条形图、堆积图、折线图，所有图形均可下载到本地，同时支持把勾选的关键词信息导出为表格文件。
>
> > 由于图形最大显示数量原因，支持勾选的词语数量为2-20个
> >
> > 导出表格时不限制词语勾选数量

绘制条形图

> 任意勾选2-20个词语，点击绘制条形图图标，即可绘制出图形。

绘制词云图

> 词云图无需勾选词语，默认选取当前页前50个词语进行词云图绘制，点击绘制词云图图标即可绘制图形。

绘制堆积图

> 任意勾选2-20个词语，点击绘制堆积图图标，即可绘制出图形。
>
> 注意：绘制该图的数据中必须包含时间字段。

绘制折线图

> 任意勾选2-20个词语，点击绘折线图图标，即可绘制出图形。
>
> 注意：绘制该图的数据中必须包含时间字段。

计数项分析

> 该功能支持计数项和关键词的结合分析，用户可手动选择计数项和计数类，对某个类别中的关键词进行更深入的分析，同时也支持用户手动勾选词语进行图形绘制与表格导出功能。

单词图形

> 单词指单个词语，该图形由条形图和饼图组成，主要用于展现所选择的词语在不同类别中的数量/TFIDF和占比。

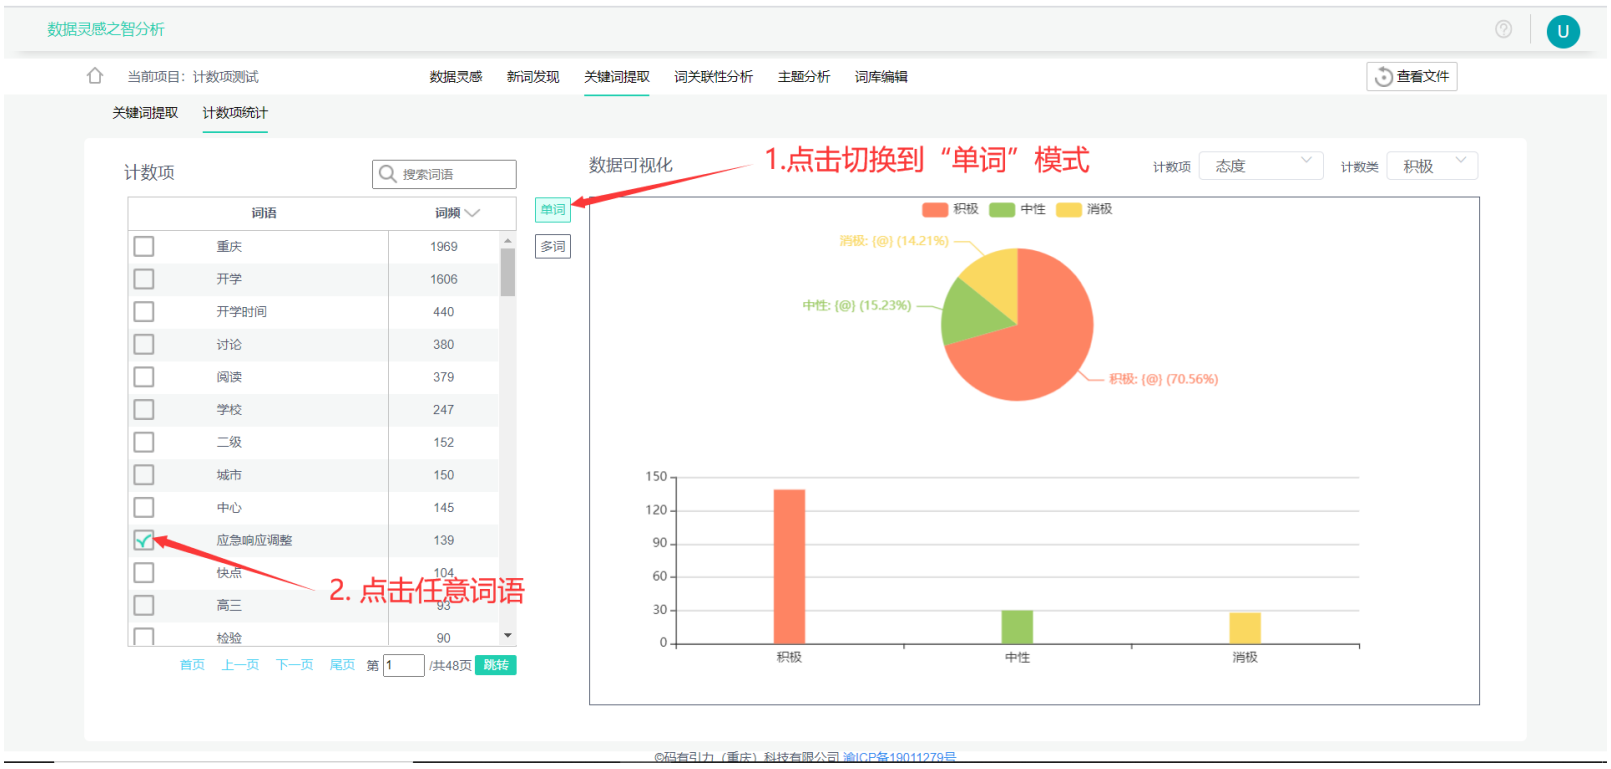

> 切换词语后右边图形也会随之切换为该词结果。

多词-堆积图

> 任意勾选2-20个词语，点击绘制堆积图图标，即可绘制出图形。和关键词提取中的堆积图不同的是，该图中横坐标代表不同词语，不同颜色代表不同的类别（计数类）。

多词-多指标柱形图

> 任意勾选2-20个词语，点击绘制多指标柱形图图标，即可绘制出图形。该图横坐标表示不同类别，不同颜色的柱子代表不同词语，纵坐标表示词频或TFIDF。

多词-条形图

> 任意勾选2-20个词语，点击绘制条形图图标，即可绘制出图形。该图横坐标表示词频或TFIDF，纵坐标表示不同词语，切换不同类别可展现不同类别中的关键词。

词关联性分析

> 词关联性分析的设计目的主要是挖掘词与词之间的关联性，同时根据选择不同的词语，亦或者是主题词，可深入挖掘主题与主题之间的关联性。
>
> 初始化：选择需要进行词关联性分析的词语，及距离对象和共现标准
>
> > 距离对象：计算词向量(word2vec)时的不同算法
> >
> > > 词语：对应CBOW模型，可以通俗理解为计算相似度是比对词语本身的相似度

> 上下文：对应Skip-gram模型，可以通俗理解为计算相似度是比对词语上下文的相似度
>
> 关于其理论知识详见<进阶使用-词语分析-词关联性分析-词向量>

共现标准：统计共现次数的衡量标准

> 以文章：两个或两个以上词语共同出现在同一篇文章中，则计为共同出现，并统计其次数
>
> 以句子：两个或两个以上词语共同出现在一句话中，则计为共现，并统计其次数

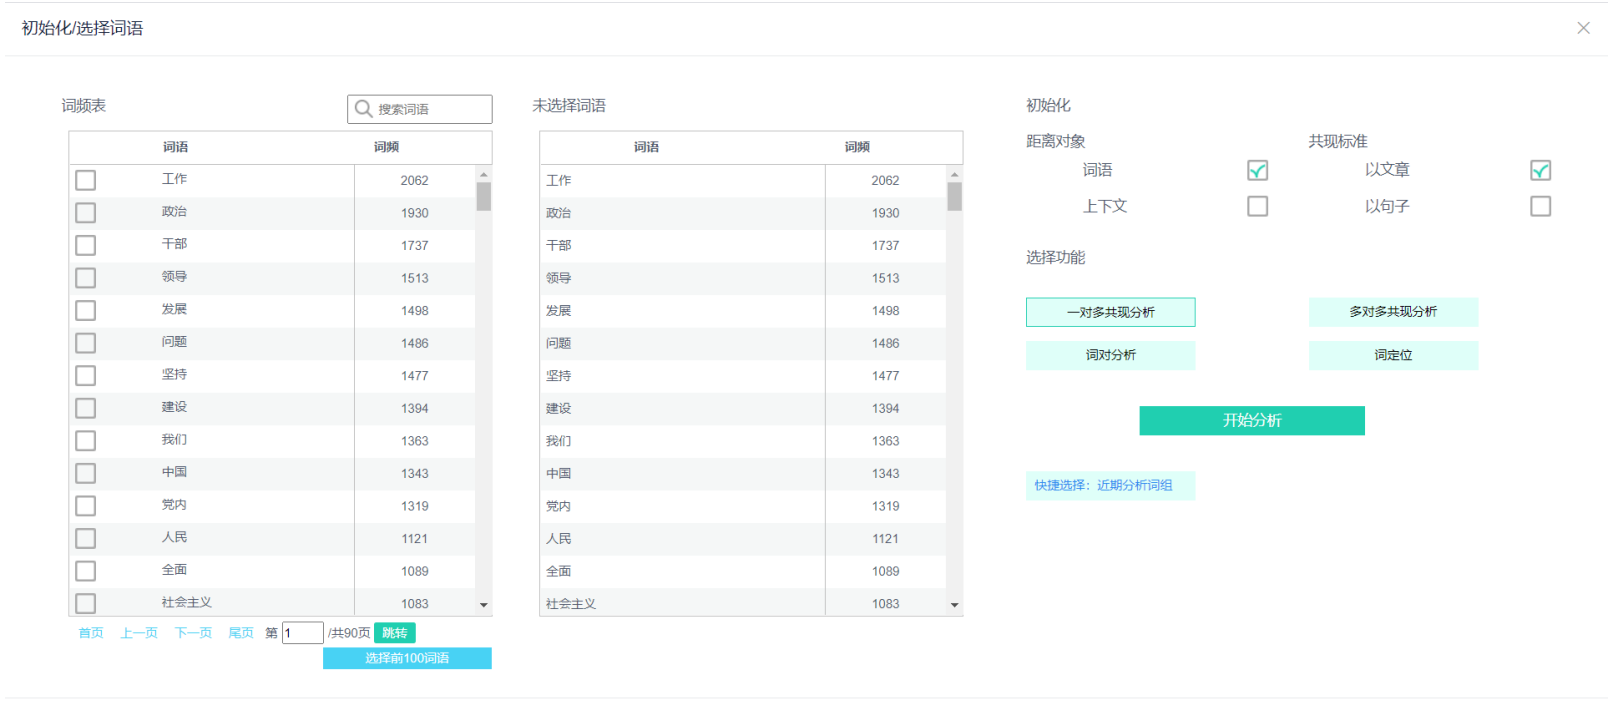

一对多分析

> 一对多分析用于以一个词为中心，分析它与其他词之间的关系

数值分析

> 点击<查看数值>图标按钮可具体查看与中心词关联性最强的前十个词语的关系数值，其中包括单独出现的次数、共现次数、共现比例。

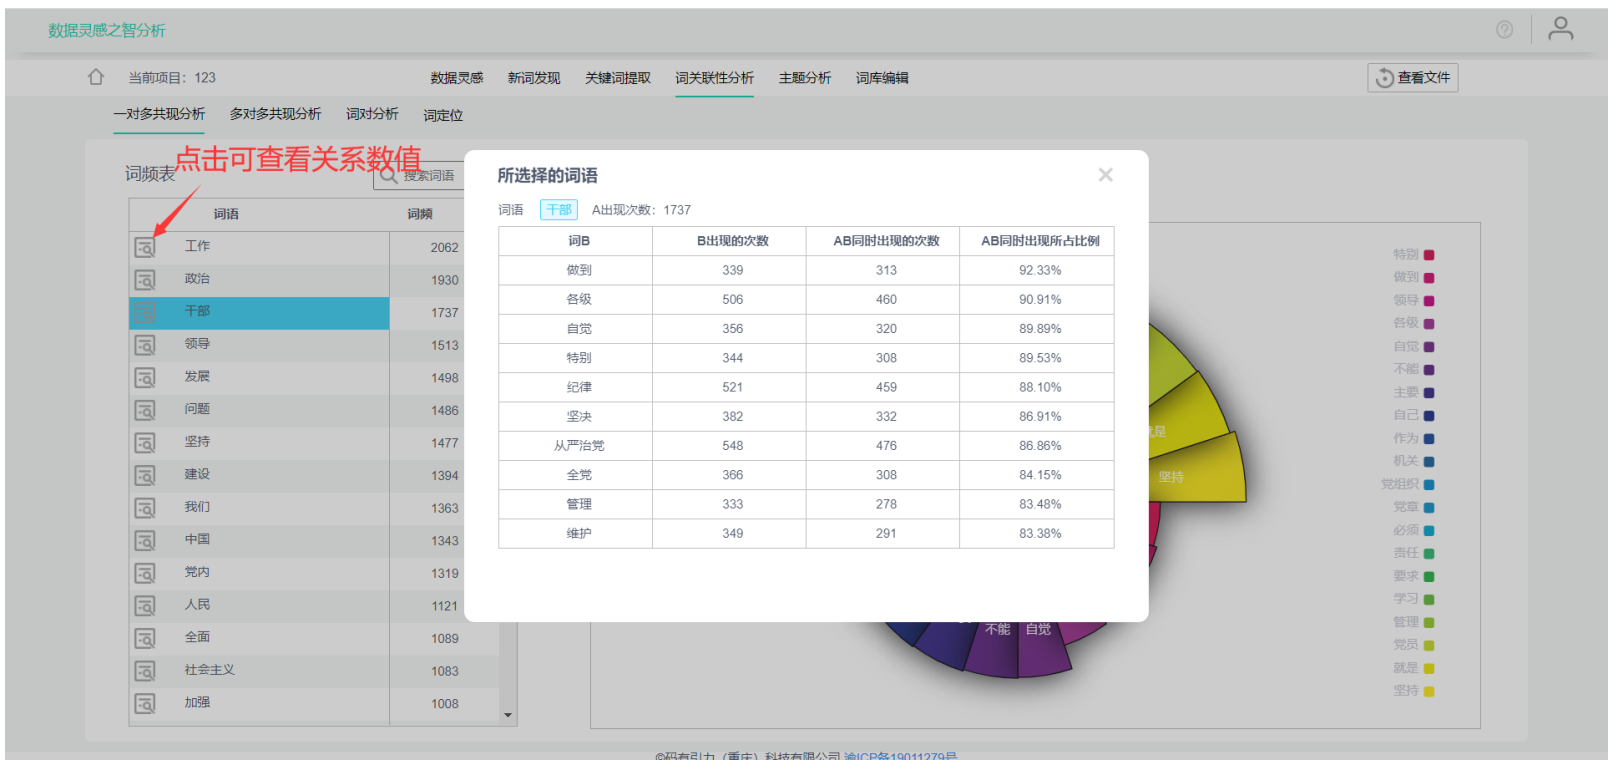

关系图

> 关系图中，展示的是词与词之间的距离，即距离越近，词之间的关联性越强，该图默认显示与所选词距离最近的前20个词语，不同颜色代表不同的词语，长短代表距离的长短，能直观展现出所选词与其他词之间的距离关系。
>
> > 点击左边表格中不同的词语可切换中心词
> >
> > 关于距离的理论知识详见<进阶使用-词语分析-词关联性分析-词距离>

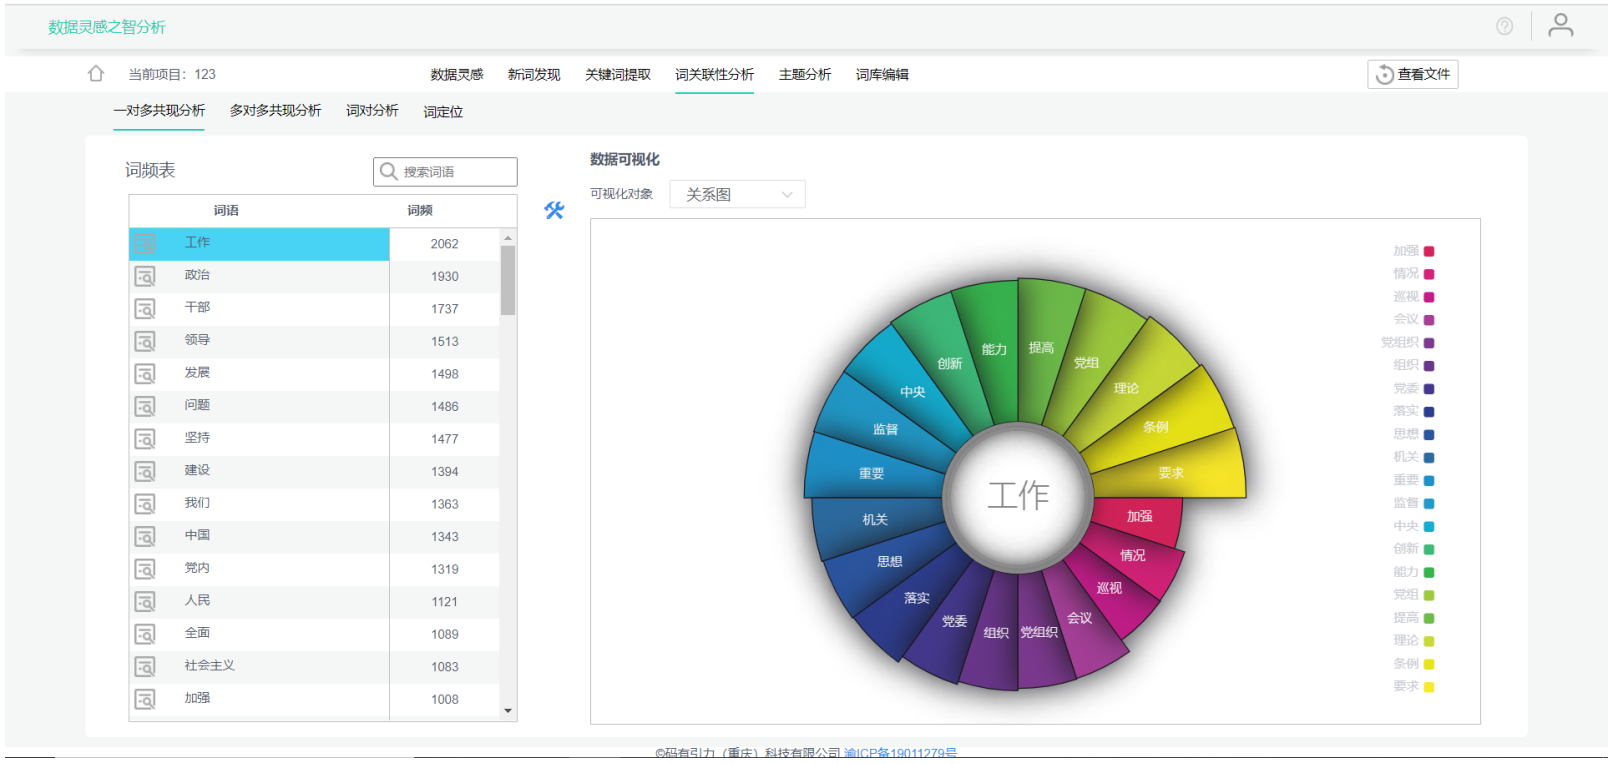

距离条形图

> 距离条形图能直观显示出词之间的距离数值
>
> > 点击左边表格中不同的词语可切换中心词

关于距离的理论知识详见<进阶使用-词语分析-词关联性分析-词距离>

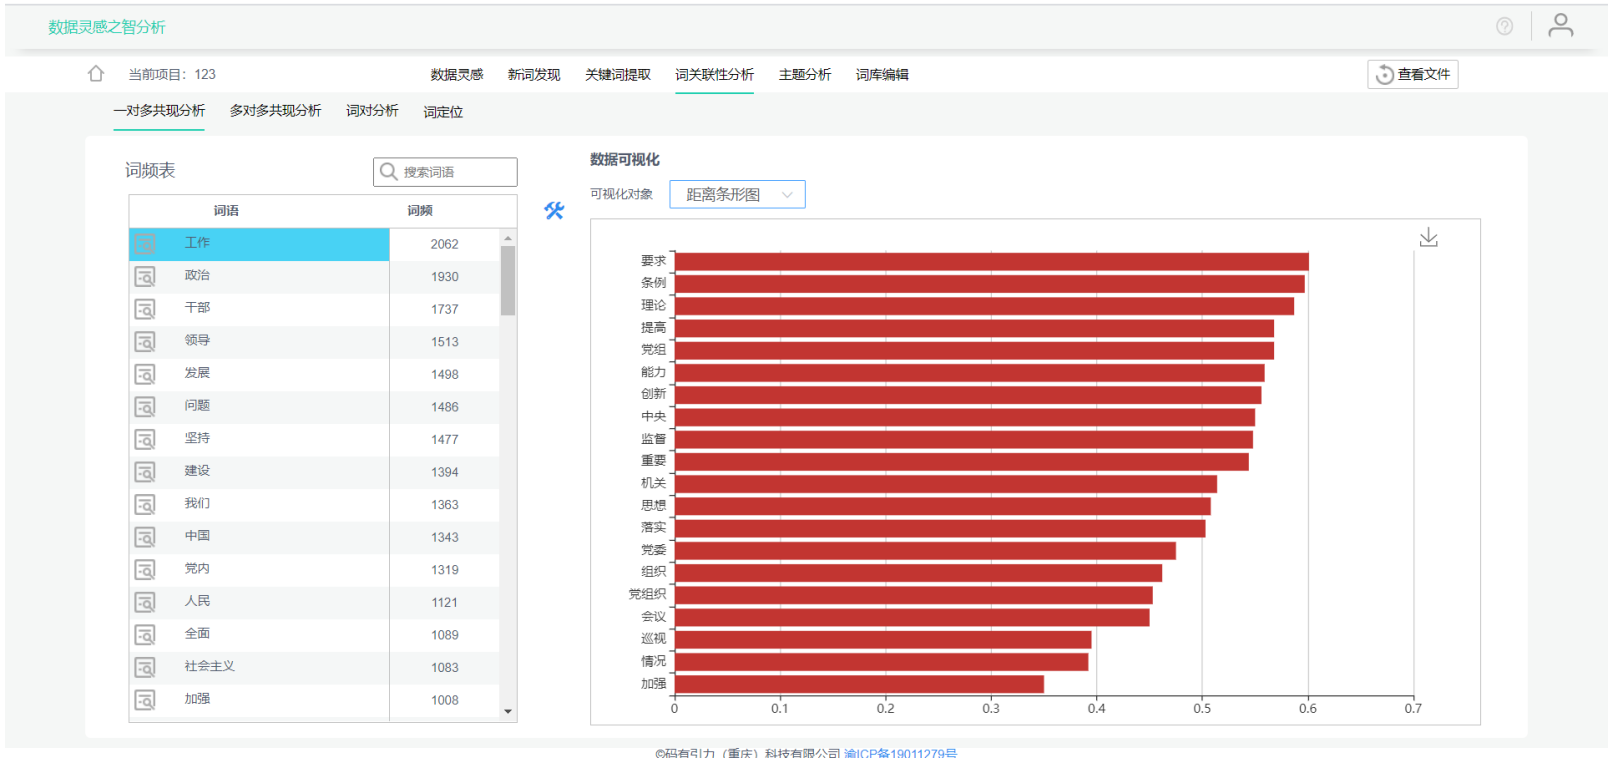

共现概率图

> 共现概率图能直观显示出词之间的共现概率，注意：和词之间的距离不一样，共现概率越高，词之间的关联性越强，即代表两个词经常出现在同一句话或同一篇文章里，至于是同一句话还是同一篇文章，根据词关联性分析初始化（选词）时勾选的共现标准决定。
>
> > 点击左边表格中不同的词语可切换中心词

关于共现概率的理论知识详见<进阶使用-词语分析-词关联性分析-共现>

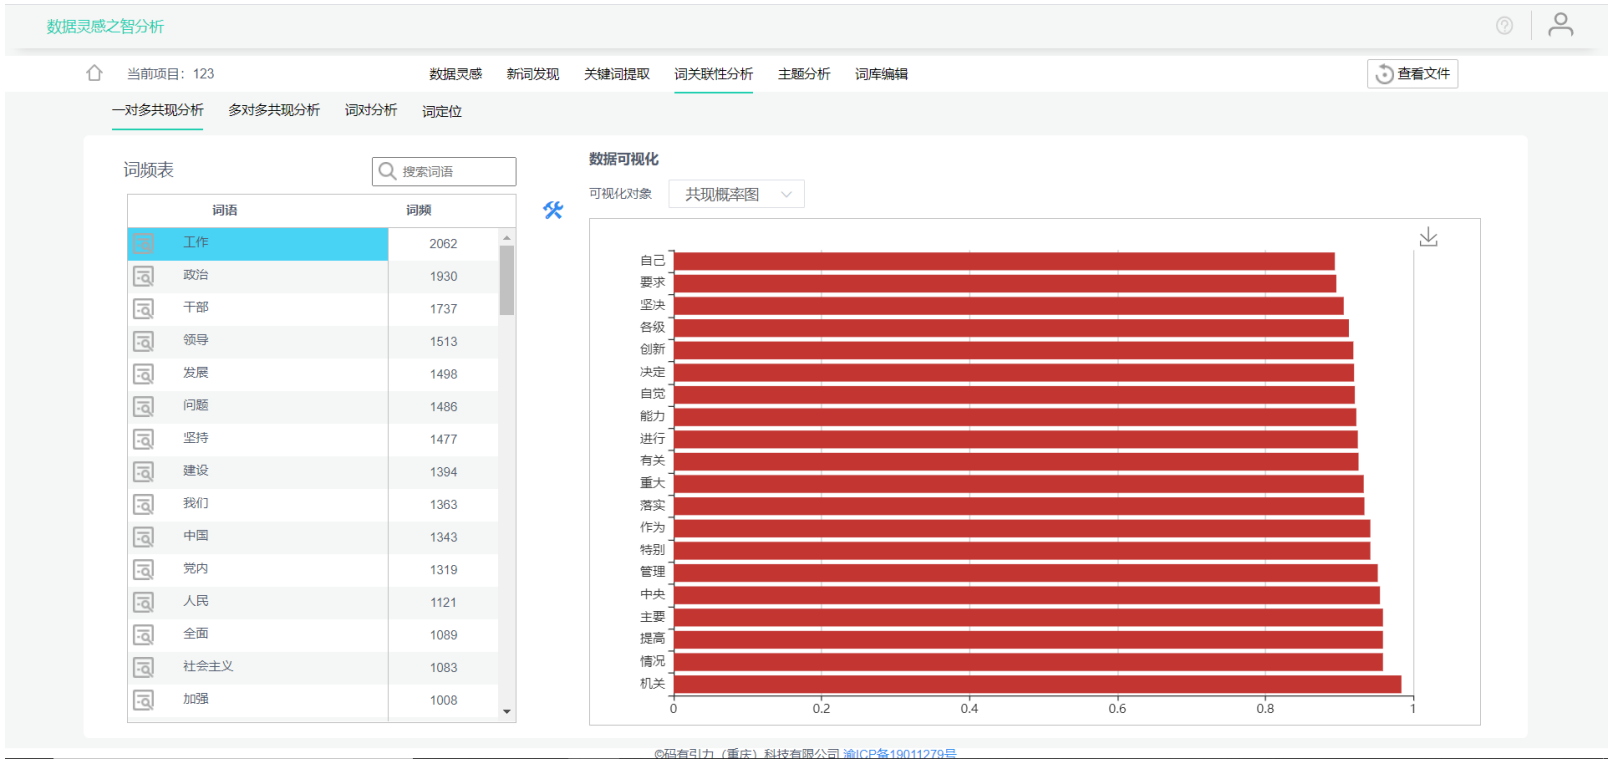

多对多分析

> 多对多分析用于整体上分析词与词之间的关联性

共现矩阵

> 进入多对多分析，点击<显示表格>按钮可查看共现矩阵，共现矩阵横纵第一项都为所选择的词语，中间数值为两两的共同出现的次数，数值越大，代表关联性越强。
>
> > 关于共现的理论知识详见<进阶使用-词语分析-词关联性分析-共现>

相似矩阵

> 进入多对多分析，点击<显示表格>按钮，再点击表格切换为相似矩阵，可查看相似矩阵，相似矩阵横纵第一项都为所选择的词语，中间数值为两两的相似度，相似度越大，代表关联性越强。
>
> > 关于相似度的理论知识详见<进阶使用-词语分析-词关联性分析-相似度>

共现多维度图

> 共现多维度图是由共现矩阵通过MDS降维，并通过K-means聚类得到，图中还加入了词频信息。
>
> 即其表示意义为：圆越大的词，词频越高，图上距离越近表示两个词关系越近，不同颜色表示不同类别。
>
> > 关于MDS的理论知识详见<进阶使用-词语分析-词关联性分析-MDS降维>
> >
> > 关于K-means聚类的理论知识详见<进阶使用-词语分析-词关联性分析K-means聚类>

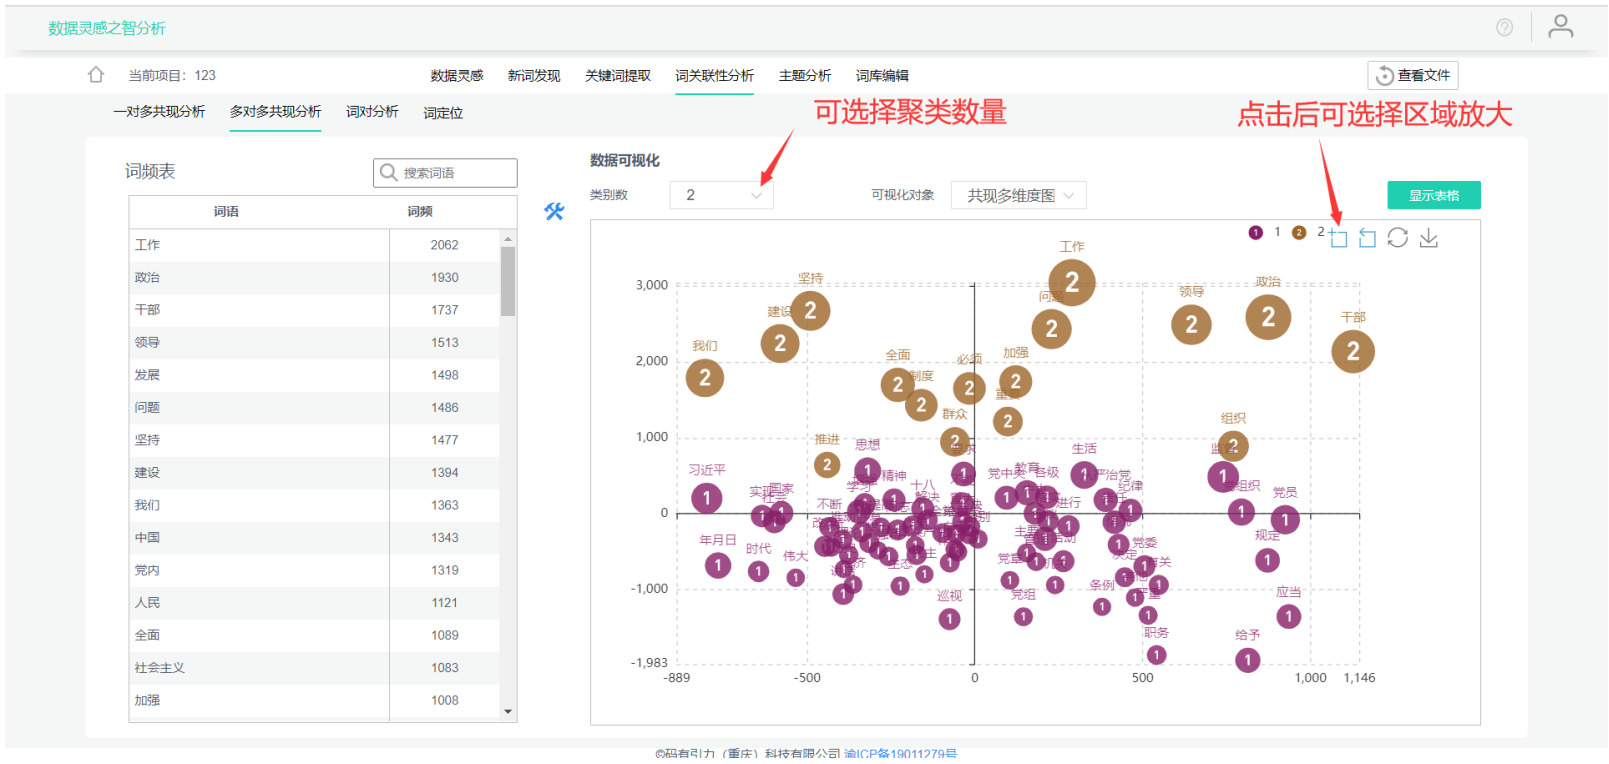

相似多维度图

> 和共现多维度图类似，只不过相似多维度图是用相似矩阵通过MDS降维，并通过K-means聚类得到，图中还加入了词频信息。
>
> 即其表示意义为：圆越大的词，词频越高，图上距离越近表示两个词关系越近，不同颜色表示不同类别。
>
> 关于MDS的理论知识详见<进阶使用-词语分析-词关联性分析-MDS降维>
>
> 关于K-means聚类的理论知识详见<进阶使用-词语分析-词关联性分析K-means聚类>

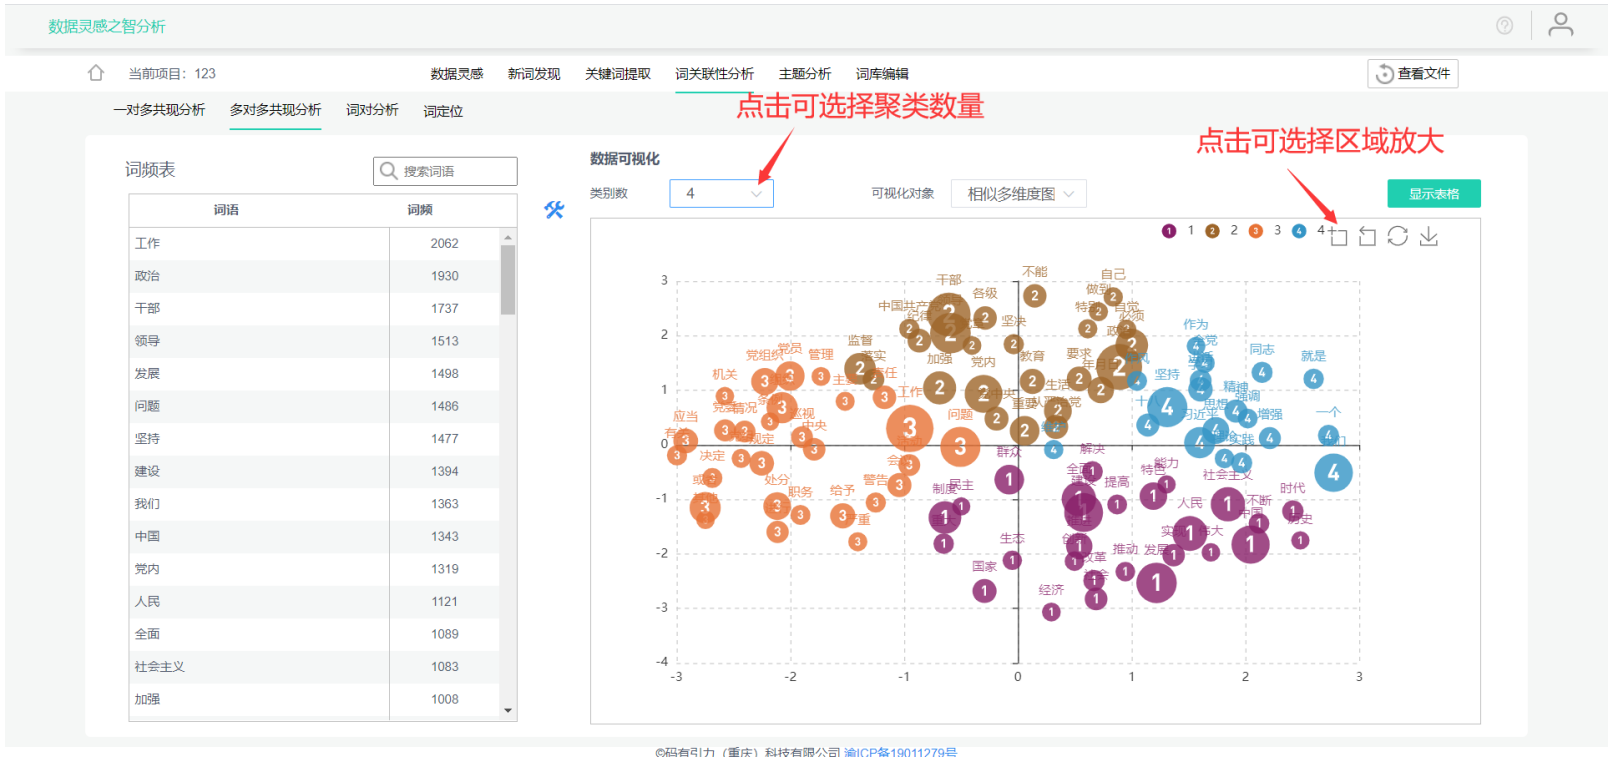

词对分析

> 词对分析用于分析一个词对（即两个词）与其他词之间的关系，可进一步说明两个词之间的关联性。
>
> 1. 该功能需要用户选择两个词语，即词a和词b

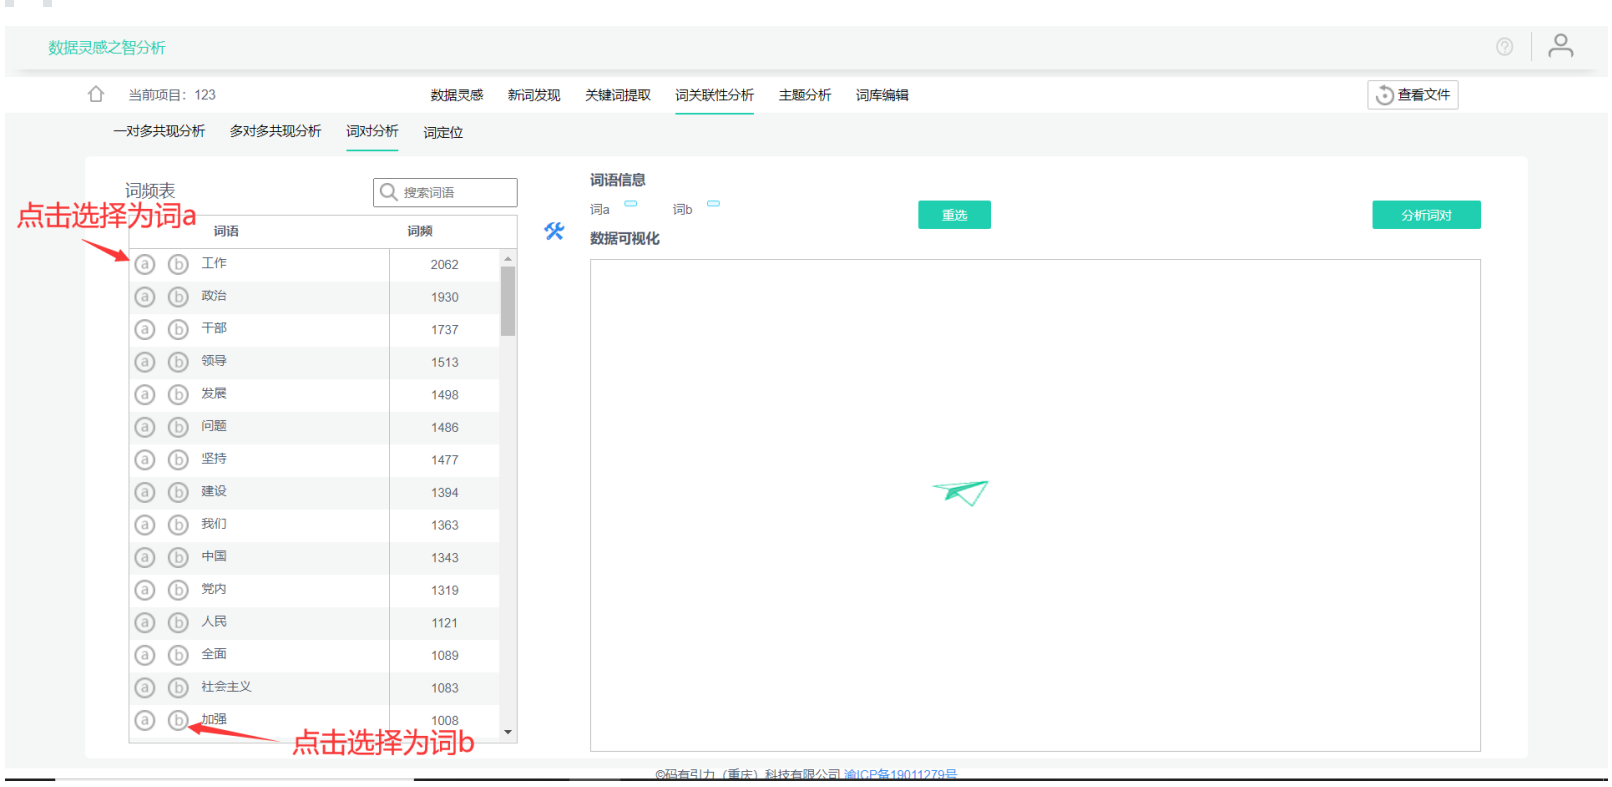

> 2. 下图分别显示出“工作”单独出现的次数、"加强"单独出现的次数以及两个词共同出现的次数。然后点击分析词对

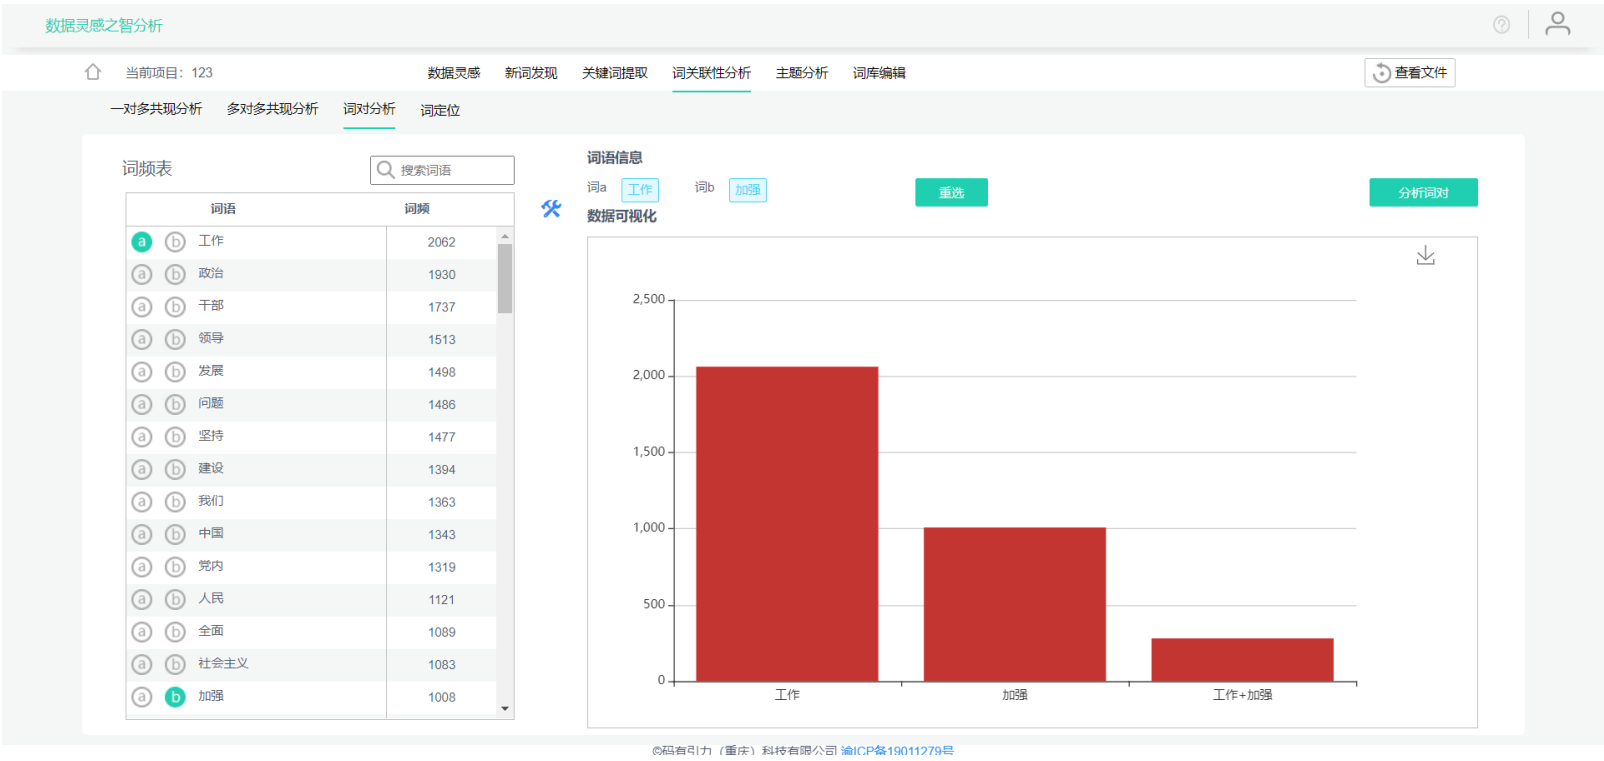

3. 下图展示了该词对与其他词之间的共现关系，即下图中

> 红色柱子代表左边的词与“工作”单独出现的次数
>
> 深绿色代表左边的词与“加强”单独出现的次数
>
> 浅绿色代表三个词共同出现的次数

4. 点击表格分析可显示所选词对和其他词之间的共现数值

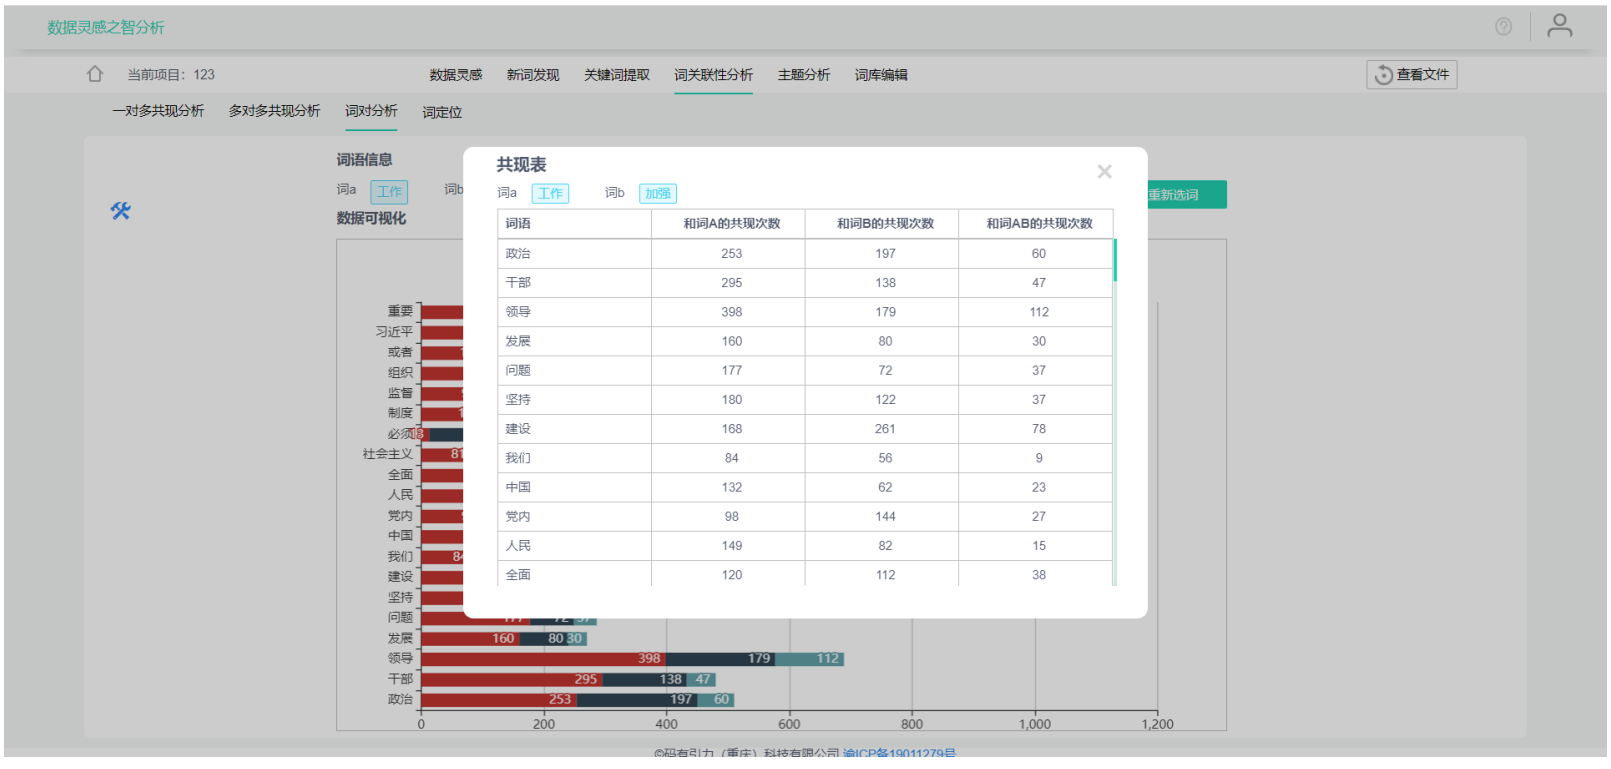

5. 点击<词A与词B的共现数值>可查看该词对的共现数值

词定位

> 词定位用于查看词语在原文中的具体位置与上下文关系

主题分析

> 用于分析数据中的主题

主题聚类

> 采用K-means+TFIDF进行主题聚类，用主题词的形式来表现主题，并结合时间进行主题趋势分析

设置主题数

> 由于图形限制，主题数可支持2-10个主题
>
> 当数据中含有时间项时，可编辑时间间隔

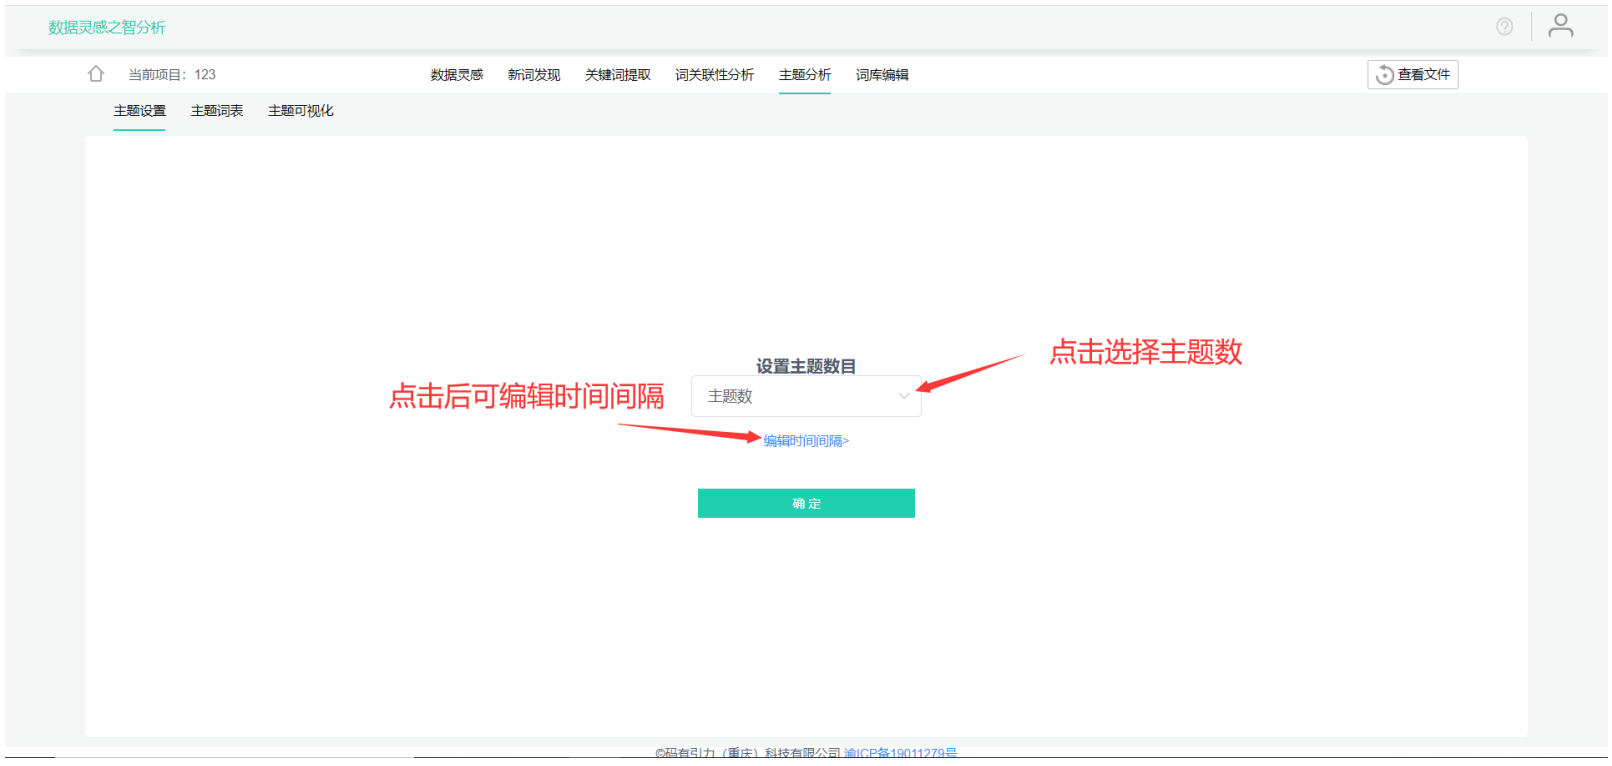

编辑主题词

> 主题词默认选择每个主题里TF-IDF排名前10的词语，当其中有你不想要的词语时，可点击"X"按钮删除，删除后，右键选中左边词表中任一词语，可替换成您选择的词语。

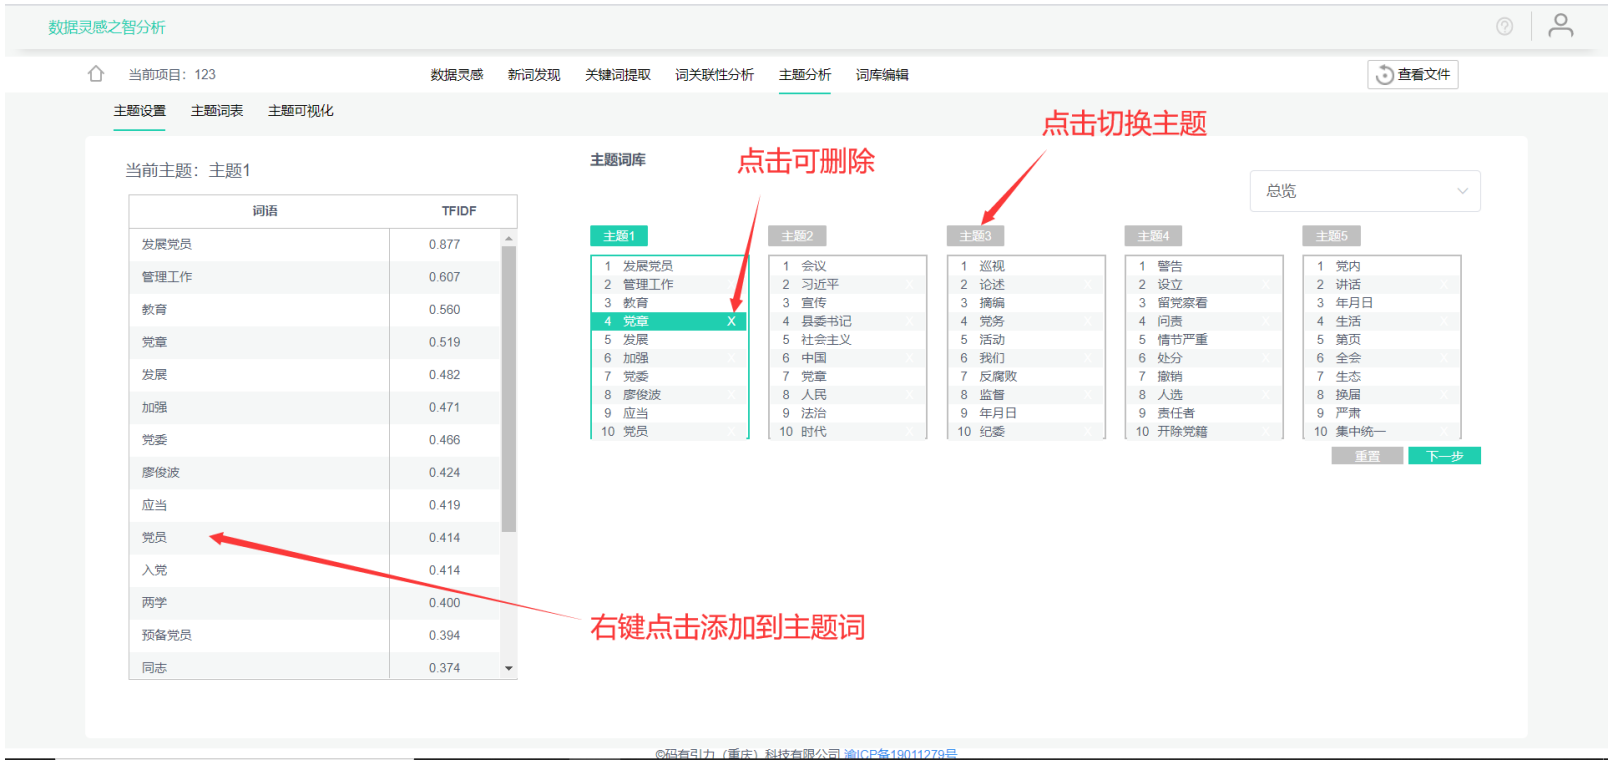

主题归纳

> 编辑完成后点击下一步，显示您所选择的主题词，用户可根据主题词归纳，编辑主题名，然后再点击可视化可进行图形绘制

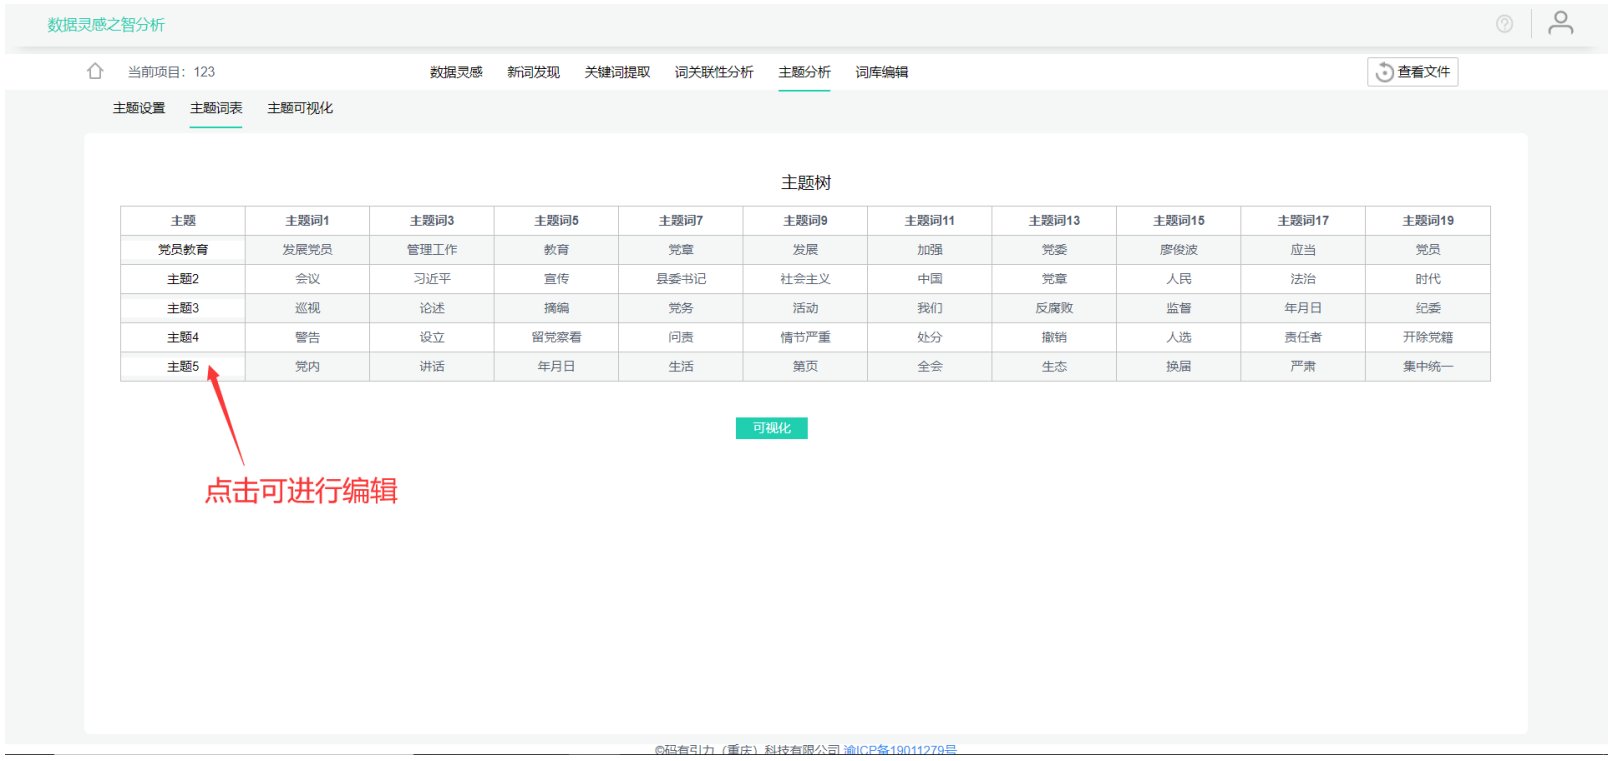

主题树图

> 以树图的形式展现主题分布

主题河流图

> 不同颜色代表不同主题，结合时间分析主题，看各时间段的主题分布、占比与发展趋势

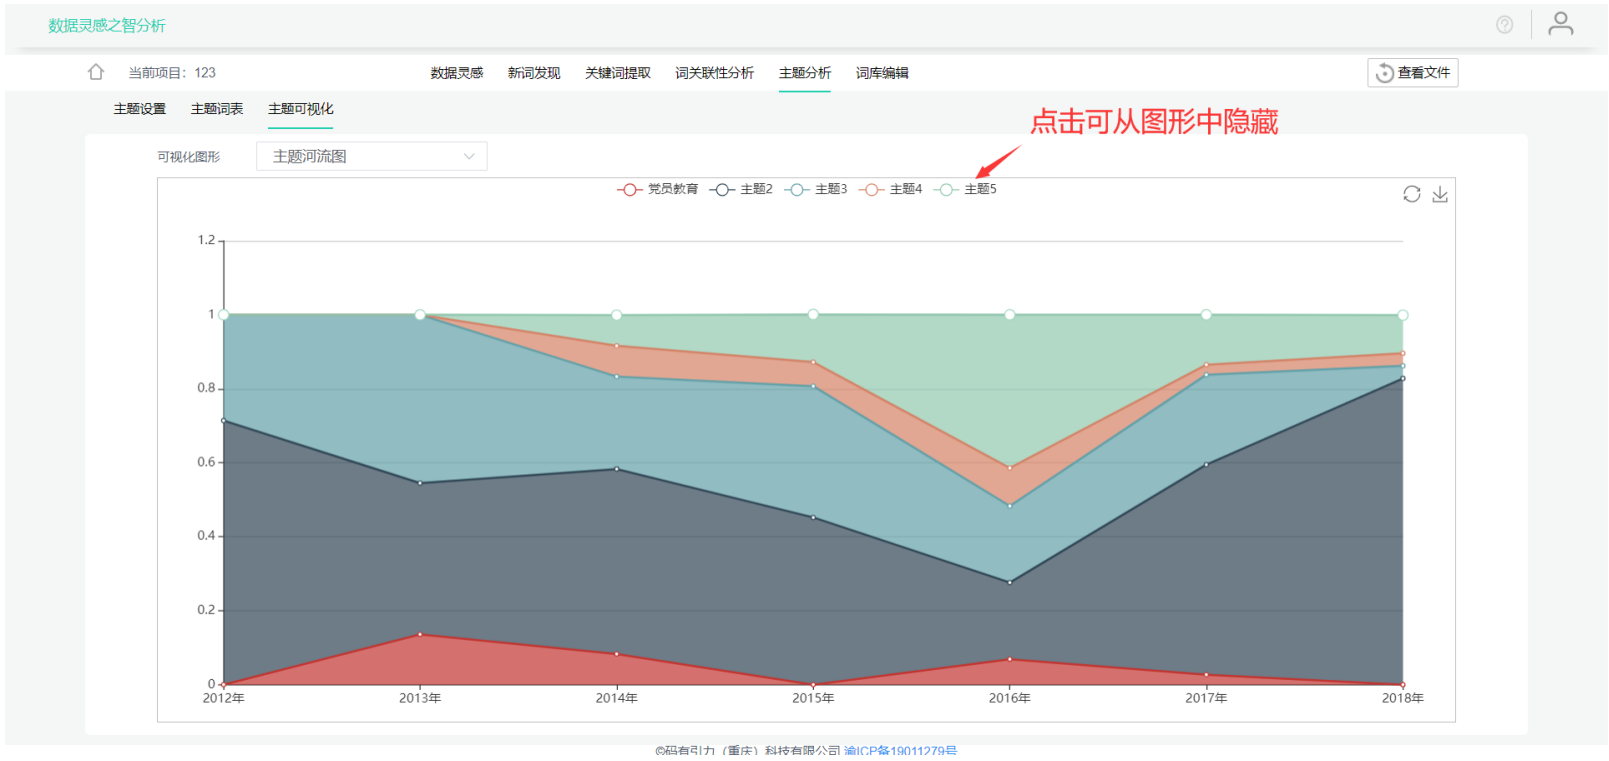

主题趋势图

> 该图中不同颜色代表不同主题；一个小方块代表一个主题词，方块的高度代表该词的TF-IDF数值，方块越高TF-IDF越大；图中同种色块前后时间段有曲线连接（贝塞尔曲线），代表在两个时间段都出现了该主题，即说明该主题有发展趋势，色块越高，主题占比越大。

主题模型

即将推出，敬请期待

社区划分

即将推出，敬请期待

词库编辑

> 词库编辑页面可查看词库中的词语以及词库编辑日志，同时可以编辑词库中的词语，分析词库和停用词库支持导入功能。

分析词库

> 分析词库中的词语是智分析自动识别不出而又要用到的词语或短语，添加到词库的词语，点击查看文件后再点击重新计算（重新分词）生效。
>
> 分析词库支持导入功能，暂只支持TXT文件，且文件内不同词语需用**回车**隔开。

示例TXT文件：

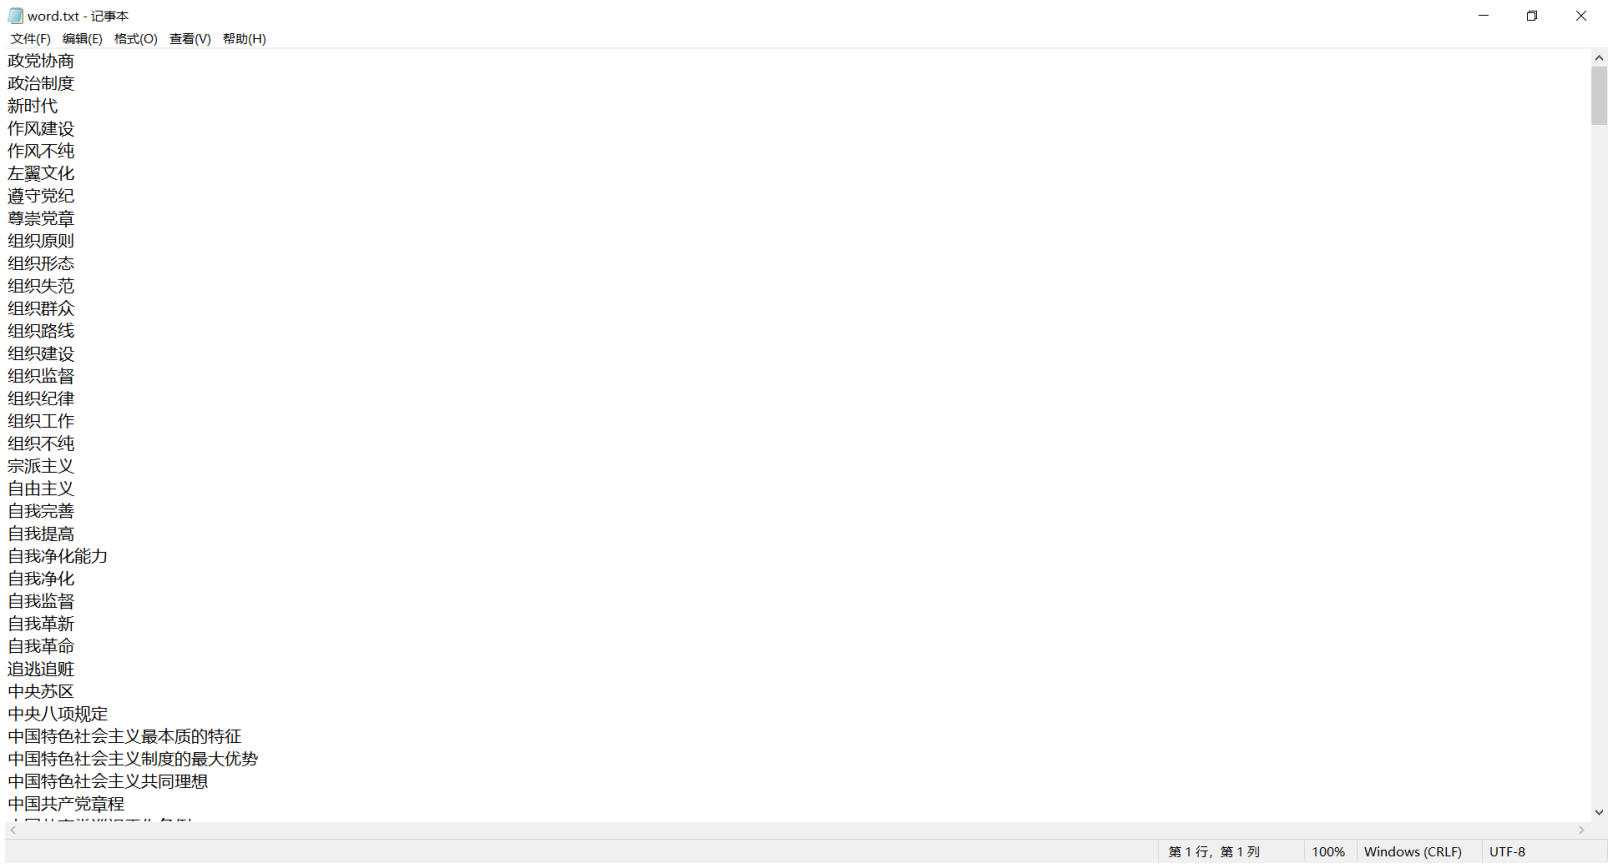

停用词库

> 停用词库中的词语是需要移除的词语，以免这些词语影响分析结果。停用词库也和分词词库一样支持导入功能，且暂也只支持TXT文件。

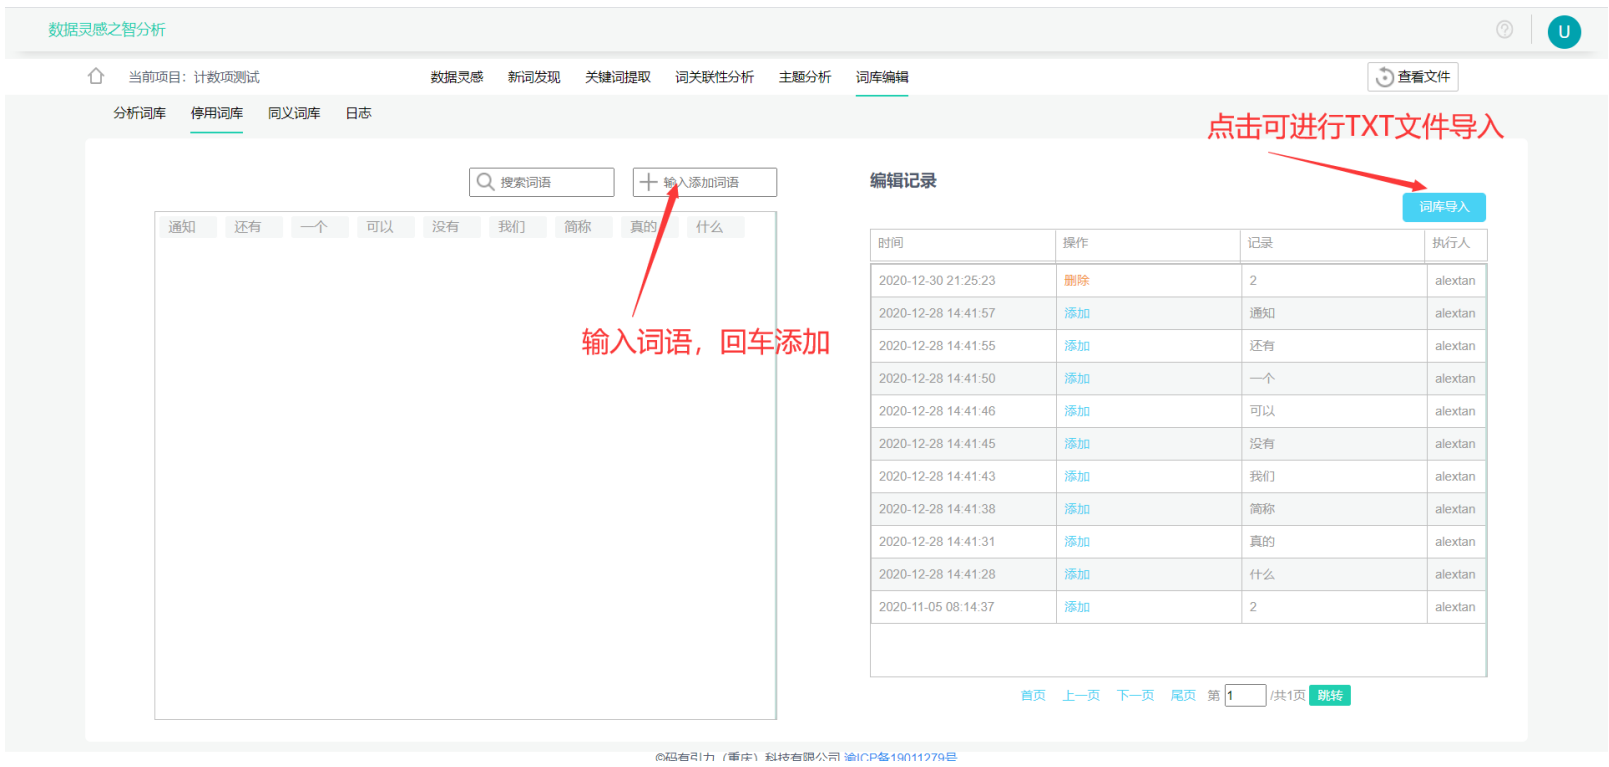

同义词库

> 同义词库中的词语是需要进行合并分析的词语，分为中心词和同义词，在智分析自动分析过程中，会把一个中心词下的所有同义词都替换成中心词，以此完成合并分析。其操作过程如下图：

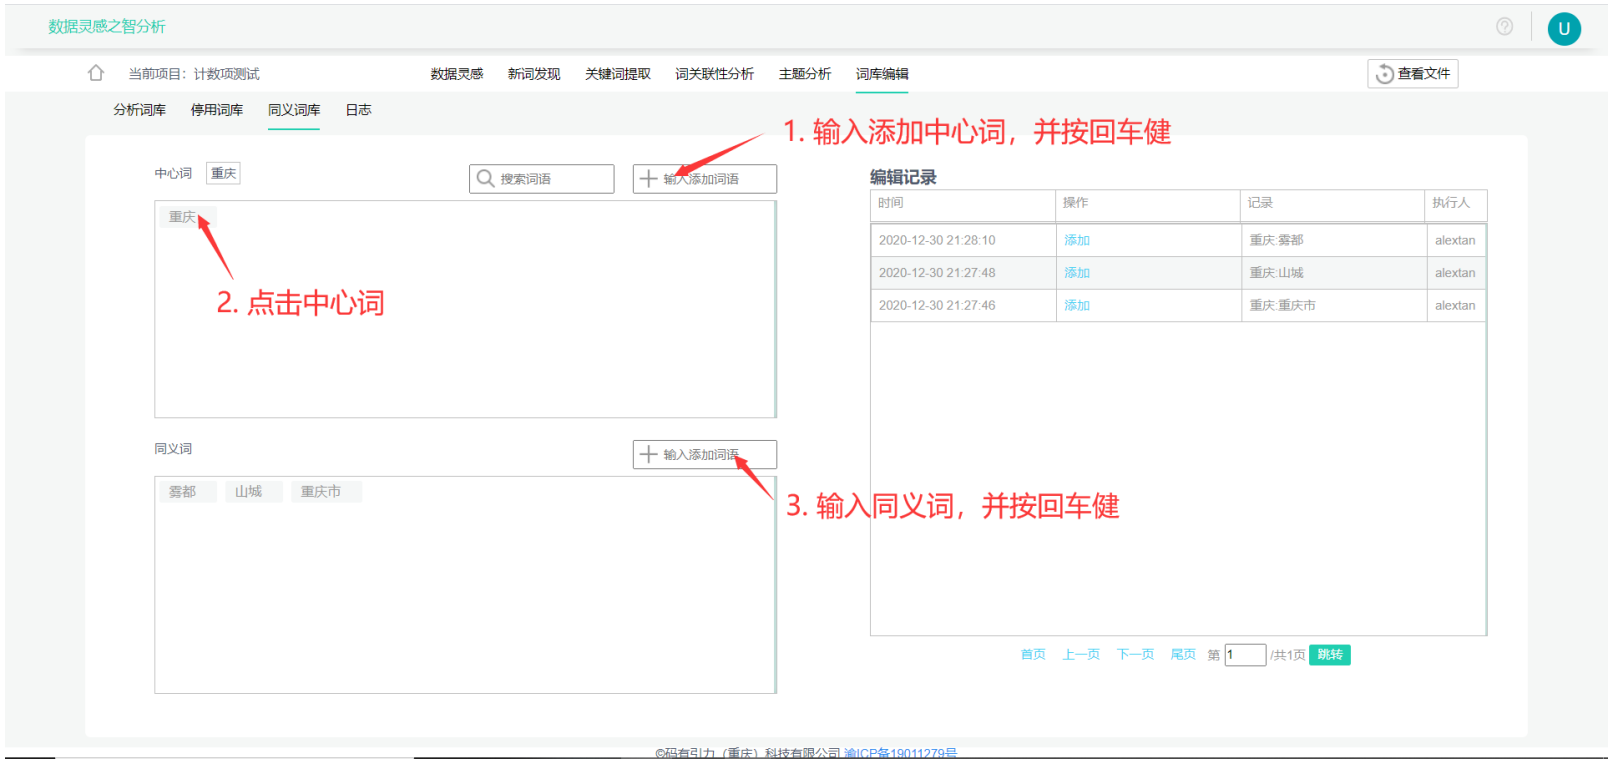

> 如果需要查看某个中心词的同义词，点击该中心词即可。

查看文件，重新分析

> 在使用任何分析功能时，都可以点击右上角的<查看文件>按钮查看数据。

> 在查看文件页面，可点击<重新计算>按钮进行重新分词计算，使词库中的词语生效。

进阶使用

> 本章节内容建议用户根据自己的数学基础酌情阅读

基础统计

> 基础统计指不包括文本分析的统计，只是对数据进行一些基础分析，其中主要包括利用时间项、计数项等结合分析。

计数项

计数项是指可以计数的一项，其命名来源于excel，换句话说，是可以标注该条（行）数据的类别的一项，比如说：作者、来源、期刊等，即计数项为作者时，可以把数据按作者归类进行统计，例如统计《红楼梦》前120回的作者数据：

如图所示，《红楼梦》前120回中，其中有40回的作者是高鹗，80回的作者是曹雪芹。

智分析能自动判断出数据中是否包含计数项，如果有，则会自动出现计数项相关功能；如果数据中含有多个计数项，智分析会默认使用第一个计数项，用户可手动选择计数项，选择不同的计数项，可以实现对数据按不同的标准进行归类统计。

计数项最多支持**30**个类别。

时间项

时间项指数据中全为时间的一列，智分析能通过时间，对数据进行统计分析，如图所示：

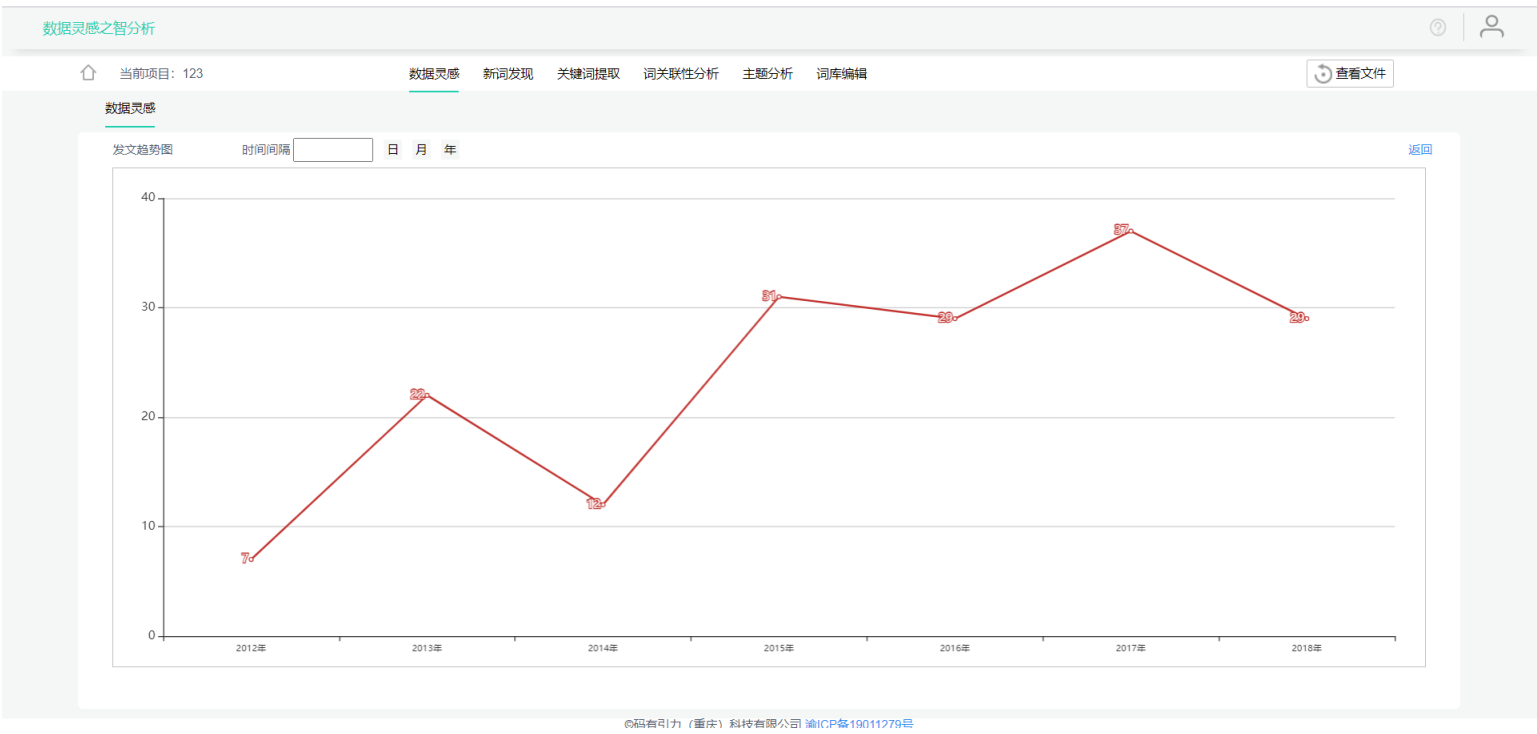

智分析按年统计了数据里的文章数量，智分析能自动判断出数据中是否包含时间项，如果包含，会自动选择一个合适的时间间隔进行数据统计，同时也支持用户手动选择时间间隔。

注意：时间项中必须保证每个

多维分析

多维分析是指多个项结合分析，例如计数项和时间项可结合得到下图：

该图设置计数项为态度，时间间隔为1日，分别统计了态度中积极、消极、中性在每日中各有多少数量，并以折线图的形式展示，展现出了不同态度每日的趋势情况。

当然，计数项、时间项也可以结合文本进行分析，比如，可结合计数项和关键词统计得到如下词云图：

图中展示了消极态度的词云，用户也可手动切换为其他计数类。

分词与词库

分词与词库是智分析中最核心的一个功能，分词是文本分析的基础，进行了分词后，才能进行一系列的数学处理；而词库是“人工+智能=越用越智能”的基础，即词库是人工的结晶，有了专业的词库，分出来的词语才能更加地准确，而后的数学分析才能分析出更精确的结果。

设计来源：由于汉语文化博大精深，目前中文分词技术在全世界范围内也没有得到良好的解决，属于中文自然语言处理技术的一大难题，也是最重要的难题。中文不像英文，英文每个单词是用空格隔开的，一个单词就能有具体的意思，即便是单词与单词组合形成的短语，大部分也与原单词含义关联性较强，甚至是含义相近。而中文不同，中文是字和字形成词，不同字组成的词含义可能天差地别，因此，中文自然语言处理技术一般以词为单位进行分析；而在中文文本中，词之间并没有任何符号隔开，因此就需要分词。

而在中文词语的发展中，随着时间的推移，随时可能出现新的词语，例如：一带一路、耗子尾汁这类词语，且不同专业有着不同专业的词语，随着时间也会出现大量新词，像这类词，算法是很难自动把这些词分出来的。因此就需要借助（人工）词库，来帮助计算机进行自动分词，让计算机也能理解博大精深的汉语。

分词

目前在自然语言处理领域，常用的分词方法主要有：基于词典分词、词典和统计结合的分词和基于统计模型的分词。基于词典的分词虽然过度依赖词典和规则库，对歧义词和未登录词的识别能力低，但由于其速度快、效率高，仍在一些特定语境环境仍被“智分析”采用。在统计模型中，CRF（条件随机场模型），HMM(隐马尔可夫模型)，MEMM(最大熵隐马尔可夫模型)都常用来做序列标注的建模，像分词、词性标注，以及命名实体标注，这三种模型应用在中文分词中都已经取得了不错的效果。由于HMM模型的输出独立性假设，导致该模型不能考虑上下文的特征，限制了特征的选择；MEMM模型则解决了HMM模型的问题，可以任意选择特征，但由于其在每一节点都要进行归一化，所以只能找到局部的最优解，同时也带来了标记偏见问题，即凡是训练语料中未出现的情况全都忽略掉；CRF模型则很好的解决了局部最优解的问题。CRF模型并不在每一个节点进行归一化，而是对所有特征进行全局归一化，因此可以求得全局的最优解。

“智分析”在运用CRF分词时，结合了人文社会科学领域的多位专家经验，通过人工配置的特征函数模板，有针对性的对人文社科全领域大量语料库，提取局部上下文特征，从而学习到特征权重。“智分析”在“特征工程”构建上，有大量人文社科领域专家参与，使得在分词（特别是规范性文本）的准确性上，表现出优秀的能力。对于互联网短文本等非规范性文本，“智分析”结合了神经网络最新成果，在“特征学习”上运用了RNN、LSTM、BiLSTM等多种神经网络模型。但由于RNN类模型的效果，一是依赖于语料库的规模，二是算法本身的效率问题，“智分析”在处理跨领域全文本的分词问题时，以平台化的方式提供该功能。

分词是文本分析的起始点，即几乎所有文本分析都离不开分词，它是最基础也是最重要的功能。智分析中，对分词算法进行了大量优化，不管从速度上还是从精确度上，都在行业处于领先水平。

> 智分析分词是基于概率算法及词库的，此部分内容读者只需重点关注词库即可。在词库内容为空时，智分析会根据分词算法自动分出词语，此时基本上能包含汉语中经常出现的词语，当分词结果不准确时，可通过添加词语到词库，再重新计算（分词），来调试结果。

分析词库

> 分析词库中的词语是分词时要切分出的词语（分析时要用到的词语或短语），分析词库里一般添加的是通过智分析分词无法分出来的词语，例如像：一带一路、耗子为汁这类词语。

停用词库

> 一般在中文文本分析中，出现次数很高的词语一般是分析里不需要的词，而这类词会大大影响分析结果，比如“我们”、“这个"、“怎样”、“怎么”等，一般是一些代词、介词等。而想去掉这些词语怎么办？可以把这些词语添加到停用词库中，然后再进行重新分词计算，即可去掉停用词库里的词语。

同义词库

> 在中文文本分析中，有的词含义相同，即同义词。在智分析中，可以把同义词添加到同义词库中进行合并分析，在智分析的自动分析过程中会把所有同义词合并成同一个词。

新词发现/短语抽取

> “智分析”综合了互信息和左右熵，来对中文文本进行新词发现。互信息(Mutual Information)是信息论里一种有用的信息度量，它可以看成是一个随机变量中包含的关于另一个随机变量的信息量，或者说是一个随机变量由于已知另一个随机变量而减少的不肯定性。对于词而言，互信息越大，越能说明两个或多个词经常一起出现，这意味着两个或多个词的凝固程度越大，这两个或多个词组成一个新词的可能性也就越大。
>
> “智分析” 用信息熵来衡量一个文本片段的左邻字集合和右邻字集合有多随机。计算一对词之间的左熵和右熵，熵越大，越说明是一个新词。因为熵表示不确定性，所以熵越大，不确定越大，也就是这对词左右搭配越丰富，越多选择。
>
> 我们已经对大量人文社会科学语料库进行了分类的互信息搭配和信息熵统计。“智分析”包含了大量领域词库。通过“智分析”建议的最低互信息（PMI_LIMIT），互信息权值、左右熵权值，能够得到待研究文本精确的短信抽取（新词发现）结果。通过使用此方法，可对专业领域文章进行分析，自动发现、提取专业领域新词。
>
> - **互信息**
>
>   摘自百度百科，互信息(Mutual Information)是信息论里一种有用的信息度量，它可以看成是一个随机变量中包含的关于另一个随机变量的信息量，或者说是一个随机变量由于已知另一个随机变量而减少的不肯定性。其计算公式为：
>
> $$I(X;Y)=\sum_{x\epsilon X}\sum_{y\epsilon Y}p(x,y)\,log\frac{p(x,y)}{p(x)\,p(y)}$$
>
>   在文本分析中，互信息能说明词语的凝固程度。例如：在公式中，P(x)可看作词X出现的概率，P(y)可看作词Y出现的概率，P(x,y)可理解为词X和词Y一起出现的实际概率，而P(x)P(y)则能表示词X和词Y一起出现的理论概率，因此上述公式可简单理解为两个词一起出现的实际概率/理论概率。
>
> - **左右熵**
>
>   熵是一种表示信息量的指标，熵越高就意味着信息含量越大，不确定性越高，越难以预测。通常对于一个随机变量 X, 它的熵可以被表示成：
>
> $$H(X) = -\sum_{x\in X} p(x)\log_2 p(x)$$
>
>   p(x) 表示的是事件 x 出现的概率，在文本分析中就是一个词出现的概率。我们用信息熵来衡量一个文本片段的左邻字集合和右邻字集合有多随机，一个文本片段的左右邻接字越随机，即这个文本片段越可能是一个新词。
>
> - 关于左右熵和互信息的更多知识请参阅互联网时代的社会语言学：基于SNS的文本数据挖掘

词语分析

> 在汉语中，大多数词语就能表达一个独立的含义。因此，一般在中文文本分析中，是以词语为基础进行分析的，而智分析也是如此。智分析里的词语分析目前主要分为关键词分析和词关联性分析。

关键词分析

> 关键词能一定程度上表示文本里的重点，智分析支持按词频和TF-IDF两种指标来统计关键词。

词频统计

> 词频统计是统计一个词语在文本中所出现的次数。**注意：对于某个四字词语包含了某个两次词语或三字词语时，智分析是分别进行词频统计的。例如：“领导小组”和“领导”这两个词语，智分析会分别统计词频，即“领导”所出现的次数里不包括“领导小组”中“领导”所出现的次数。**

TF-IDF

> TF-IDF算法已经被证明是一个高效的关键词提取算法。TF-IDF是建立在这样一个假设之上的：对区别文档最有意义的词语应该是那些在文档中出现频率高，而在该文档所属领域语料库文档中出现频率低的词语。另外，考虑到单词区分不同类别的能力，TF-IDF算法认为一个单词出现的文本频数越小，它区别不同类别文本的能力就越大。TF-IDF实际上是：TF * IDF，TF词频(Term Frequency)，IDF逆向文件频率(Inverse Document Frequency)。实际情况是如果一个词在一个类别的文档中频繁出现，说明该词能够比较好代表该类别的文本特征，这样的词应该赋予较高的权重，并用来作为该类别文本的特征词。但按照IDF的定义，如果在语料库中出现的频次高，则反应

> 不出来该词的重要性，这就是IDF的不足之处。另外，对于IDF来说，它本身是一种抑制噪声的权重，倾向于文本中频率小的词，使得TF-IDF算法的精度存在问题。另外，像词的位置信息如标题、首尾等含有较重要的信息，也未在算法中得到体现。
>
> 实事上，“智分析”在分词阶段所构建的“特征工程”，在很大程度上被用于关键词提取阶段。“智分析”结合了TF-IDF效率高的优点，同时又结合了浅层语义分析。在TF-IDF候选关键词语义不明确时，又结合运用了主题模型的方法，在“特征工程”基础上，取得了不错的关键词提取效果。

词关联性分析

> 在“智分析”中，词关联分析是领域专家甚至用户自己构建“特征工程”非常重要的功能。词关联分析是在分词、关键词提取和短语抽取的基础上，由用户根据单个词频、共现词频、TFIDF权值等进行综合分析，得出关键词或者短语之间的逻辑关系，从而构建起具有待研究领域的“特征工程”。在此基础上，进一步增加后续文本语义分析的精确性。
>
> 由于词是支撑主题的最小语义元素，因此挖掘出词与词之间的关系，是进行语义挖掘的基本手段之一。“智分析”中，我们用词的关系，粗略代表了主题与主题之间的关系。其中，我们对词与词的关系的界定，包含了（不限于）对如下关系的分析：
>
> ■ 主从关系
>
> ■ 并列关系
>
> ■ 层次关系
>
> ■ 递进关系
>
> ■ 先后关系
>
> ■ 因果关系
>
> ■ 对比关系

共现

> 共现指两个或多个词语共同出现，其界定单位可以是一句话或一篇文章。共现次数能一定程度表现词语之间的关联程度，即如果两个词经常一起出现，则表示这两个词语的关联程度较强，至于其是否有着特殊含义，则需要通过人工解读。

词向量

> 词向量是词的一种数学表示，词向量分很多种，智分析中的词向量是通过word2vec算法计算得到。得到词向量后可通过数学运算计算词与词之间的相似度，同时也能计算词与词之间的距离，关于word2vec的理解大家可以参考秒懂词向量Word2vec的本质。

词距离/相似度

> 词距离/相似度是表示词与词之间的关联程度的另一种形式。相似度越大，词距离越小，即代表词语之间关联程度越大。
>
> 在智分析中，是通过余弦相似度来计算词与词之间的相似度的，其公式如下所示：
>
> $$\mathbf{similarity} = \cos(\theta) = \frac{A \cdot B}{\|A\|\|B\|} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n} (A_i)^2} \times \sqrt{\sum_{i=1}^{n} (B_i)^2}}.$$
>
> 向量间的距离公式有很多，比如说欧式距离、余弦距离、曼哈顿距离、切比雪夫距离等等，而在智分析中，使用的距离公式是余弦距离，即余弦距离=1-余弦相似度。

矩阵分析

> 矩阵（Matrix）是一个按照长方阵列排列的复数或实数集合，是高等代数中的常见工具。而在智分析中，主要用到的是共现矩阵和相似矩阵，其中横纵里的第一项都为用户所选择的词，内容为词与词的共现次数或者相似度，可以整体上分析词与词之间的关联性。

MDS降维

> **MDS(多维尺度变换)**算法解决的问题是:当n个对象之间的相似性给定，确定这些对象在低维空间中的表示，并使其尽可能与原先的相似性大致匹配。高维空间中每一个点代表一个对象，因此点与点之间的距离和对象之间的相似度高度相关。可以这么理解，两个相似的对象在高维空间中由两个距离相近的点所表示，两个不相似的对象在高维空间中由两个距离比较远的点表示。**经典MDS算法流程如下:**
>
> (1)计算原始空间中数据点的距离矩阵。
>
> (2)计算内积矩阵 B 。
>
> (3)对矩阵B进行特征值分解，获得特征值矩阵 Λ 和特征向量矩阵 V 。
>
> (4)取特征值矩阵最大的前 Z 项及其对应的特征向量 $Z = V_z A_z^{1/2}$ 。
>
> 因此，MDS能较好地对共现矩阵和相似矩阵进行降维处理，使词语分布在同一平面中，距离越近的词语则关联性越强。

K-means聚类

> k均值聚类算法（k-means）是一种迭代求解的聚类分析算法，其步骤是随机选取K个对象作为初始的聚类中心，然后计算每个对象与各个种子聚类中心之间的距离，把每个对象分配给距离它最近的聚类中心。聚类中心以及分配给它们的对象就代表一个类别。每分配一个样本，聚类的中心会根据聚类中现有的对象被重新计算。这个过程将不断重复直到满足某个终止条件。终止条件可以是没有（或最小数目）对象被重新分配给不同的类别，没有（或最小数目）聚类中心再发生变化，误差平方和局部最小即达到算法收敛。

主题挖掘

> 主题挖掘功能用于挖掘文本中的主题，对文本内容进行一个主题性的概况，目前智分析支持无监督的主题聚类算法，半监督和全监督的主题算法正在研发中，敬请期待。

主题聚类

> 针对时间序列文本，“智分析”通过Kmeans等算法实现主题聚类，其具体流程如下：
>
> 1.首先，把所有文本通过TF-IDF算法进行文本特征向量化，得到文本向量；
>
> 2.其次，运用Kmeans等算法对各个向量进行聚类，得到各个主题类别关键词；
>
> 3.再次，对各个主题类别关键词，分别进行TF-IDF计算提炼出各个类别的主题关键词；
>
> 4.最后，再对原文本按照不同时间段进行划分，划分后再次进行1、2和3步骤，可得到各个时间段内每个主题的代表词。
>
> 其中，k均值聚类算法（k-means）是一种迭代求解的聚类分析算法，其步骤是随机选取K个对象作为初始的聚类中心，然后计算每个对象与各个种子聚类中心之间的距离，把每个对象分配给距离它最近的聚类中心。聚类中心以及分配给它们的对象就代表一个类别。每分配一个样本，聚类的中心会根据聚类中现有的对象被重新计算。这个过程将不断重复直到满足某个终止条件。终止条件可以是没有（或最小数目）对象被重新分配给不同的类别，没有（或最小数目）聚类中心再发生变化，误差平方和局部最小即达到算法收敛。
>
> 作为“智分析”文本主题挖掘的第一步，在TF-IDF基础上使用聚类算法对文本进行分类，能够快速有效确定待分析文本的类别数量及主题特征。在文档类别数量不是特别大、且单主题（无多重语义的文档）文档集合，能达到比较好的文本主题聚类效果。而对于多主题文档构成的文档集合，则适合用LDA主题模型或者带监督学习的LDA模型进行主题挖掘。

主题模型

即将推出，敬请期待

社区划分

即将推出，敬请期待

常见问题

1. 我该如何准备要分析的数据？

   > - 对于文章数据而言，如果想结合计数项和时间项进行分类和趋势分析，可把时间、内容、计数项字段复制到excel表格中（表格中要有时间、内容等标题字段），然后直接导入智分析进行分析
   > - 针对线上数据而言，如微博、豆瓣、知乎、今日头条等，可通过爬虫等技术手段采集数据，如果不会技术，可联系我们提供技术服务
   > - 针对线下数据，如书、报纸等数据，可通过OCR等电子化手段变成电子数据，整理成excel后便可导入智分析进行分析，同时也可以联系我们提供电子化服务

2. 智分析支持什么数据？支持什么文件格式？

   > 智分析支持任何中文文本数据，不管是知网论文，还是微博头条，都能导入智分析开启文本分析世界的大门
   >
   > 智分析目前支持Excel、TXT文件格式的数据，**注意：TXT文件只支持文本分析，不支持计数项和趋势分析**

3. 为什么我导入数据后没找到计数项功能？

   > 这是因为系统未识别出计数项，智分析会自动识别数据中的计数项，计数项里的类别必须大于等于2歌，且不能超过30个，否则无法识别出计数项。

4. 为什么我导入数据后没有趋势分析功能？

   > 这是因为系统未识别出时间项，时间项最好为：年/月/日 的格式，且要求每条数据里都得有时间，即不能某一条数据里的时间为空或者其他内容（可以使用excel的筛选功能查看），检查每条数据都有时间后，智分析便能自动识别出时间。

5. 为什么我导入数据后，数据灵感只有三个图，而别人的有十多个？

   > 当您导入的数据中既没有时间字段，又没有可以计数的字段（计数项）时（例如导入TXT文件），就只能进行文本分析，无法进行其他分析，因此数据灵感中就只有三个图。

6. 我把词语已经添加到词库中了，如何让它们生效？

可点击右上角的<查看文件>按钮，然后再点击重新计算，即可让词库中的词语生效。