

“智采” 系统

V8.0

目录

第 1 章	系统简介.....	4
1.1	系统环境要求和安装部署	4
1.2	“智采”系统特点	4
1.3	界面功能简介	6
第 2 章	任务区.....	8
2.1	模块列表.....	8
2.2	保存的任务	9
2.3	数据源.....	9
第 3 章	数据清洗任务中的子模块	10
3.1	转换类子模块	11
3.1.1	搜索位置	12
3.1.2	获取 IP 的坐标	13
3.1.3	获取路径信息	14
3.1.4	检索附近	15
3.1.5	自然语言处理	16
3.1.6	语言翻译转换	18
3.1.7	添加新列	20
3.1.8	自增键生成	21
3.1.9	列名修改器	23
3.1.10	删除该列	24
3.1.11	从爬虫转换	24
3.1.12	数据库匹配	26
3.1.13	重复当前值	28
3.1.14	获取请求响应	28
3.1.15	时间转字符串	29
3.1.16	URL 字符转义.....	30
3.1.17	HTML 字符转义.....	31
3.1.18	正则分割	32
3.1.19	字符串分割	33
3.1.20	转换为 Json	35
3.1.21	合并多列	36
3.1.22	Python 转换器.....	37
3.1.23	正则替换	38
3.1.24	正则转换器	39
3.1.25	提取数字	40
3.1.26	字符首尾抽取	41
3.1.27	启动并行	42
3.1.28	清除空白符	43
3.1.29	读取文件文本	44
3.1.30	读取文件数据	45
3.1.31	矩阵转置	46
3.1.32	子任务-转换	47

3.1.33	路径是否存在	48
3.1.34	重复项合并	49
3.1.35	延时	50
3.1.36	XPath 筛选器	51
3.2	执行类子模块	52
3.2.1	写入文件文本	53
3.2.2	子任务-执行	53
3.2.3	数据库操作	54
3.2.4	保存超链接文件	55
3.2.5	写入数据库	56
3.3	生成类子模块	57
3.3.1	获取文件夹文件	57
3.3.2	从数据库生成	58
3.3.3	生成区间数	59
3.3.4	从数据表生成	60
3.3.5	从文本生成	61
3.4	过滤类子模块	62
3.4.1	空对象过滤器	62
3.4.2	数字范围过滤器	63
3.4.3	正则筛选器	64
3.4.4	删除重复项	65
3.4.5	数量范围选择	66
第 4 章	属性区	68
4.1	网页采集器任务的属性配置器	68
4.2	数据清洗任务的属性配置器	69
第 5 章	活动资源区	70
5.1	算法视图	70
5.2	数据视图	70
第 6 章	日志区	70
6.1	任务管理视图	70
6.2	调试信息窗口	71
第 7 章	信息监测服务示例	72
7.1	界面和组件介绍	72
7.1.1	界面介绍	72
7.1.2	数据管理	73
7.1.3	模块管理	74
7.1.4	系统状态管理	75
7.2	网页采集器	76
7.2.1	原理（建议阅读）	76
7.2.2	基本列表	76
7.3	数据清洗	79
7.3.1	构造 url 列表	79
7.3.2	使用配置好的网页采集器	81
7.3.3	保存和导出数据	83

7.3.4	保存任务	84
7.4	总结.....	85

第1章 系统简介

“智采”系统，既可以用于科研支撑，帮助研究人员自主和高效的采集互联网中所需要的精确数据，构建自己所需要的研究数据库；也可以用于教学，培养相关专业的学生自主策划、采集和处理互联网上的大量数据，形成决策所需要的行业数据库，为科学的量化管理培养基于数据的管理和决策分析技能。

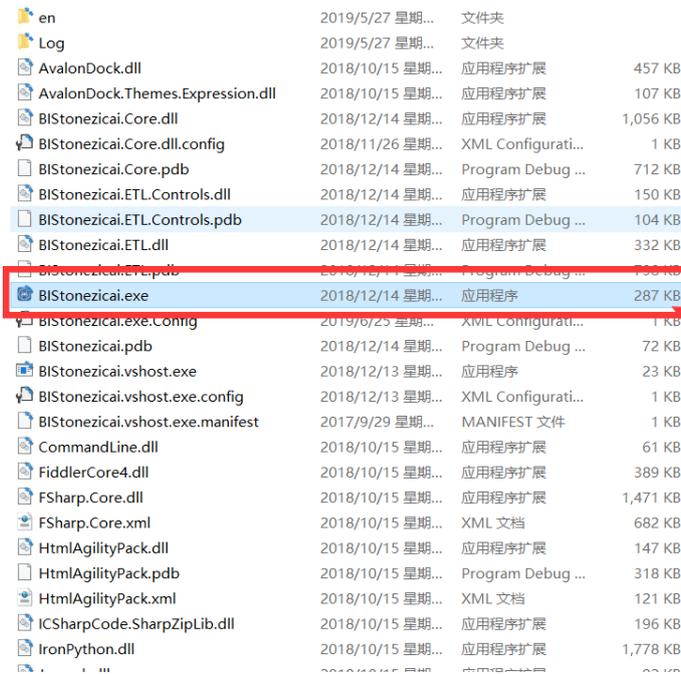
1.1 系统环境要求和安装部署

“智采”系统的设计初衷，是用于自动的采集、处理和提取网页类非结构化数据，以满足高等院校、科研机构对互联网信息进行周期性采集、监测和研究的使用要求。

既可以用于科研支撑，帮助研究人员自主和高效的采集和互联网中所需要的精确数据；也可以用于教学，培养相关专业的学生自主策划、采集和处理互联网上的大量数据，为科学的量化管理培养基于数据的管理和决策分析技能。

该系统支持 windows XP 到当前最新版本的 windows 操作系统，安装部署十分简单，需提前安装好.net framework4.5 版本，即可复制即运行。

下载压缩包，解压后，双击“BIStonezcai.exe”即可直接运行。



文件名	日期	类型	大小
en	2019/5/27 星期...	文件夹	
Log	2019/5/27 星期...	文件夹	
AvalonDock.dll	2018/10/15 星期...	应用程序扩展	457 KB
AvalonDock.Themes.Expression.dll	2018/10/15 星期...	应用程序扩展	107 KB
BIStonezcai.Core.dll	2018/12/14 星期...	应用程序扩展	1,056 KB
BIStonezcai.Core.dll.config	2018/11/26 星期...	XML Configurati...	1 KB
BIStonezcai.Core.pdb	2018/12/14 星期...	Program Debug ...	712 KB
BIStonezcai.ETL.Controls.dll	2018/12/14 星期...	应用程序扩展	150 KB
BIStonezcai.ETL.Controls.pdb	2018/12/14 星期...	Program Debug ...	104 KB
BIStonezcai.ETL.dll	2018/12/14 星期...	应用程序扩展	332 KB
BIStonezcai.ETL.pdb	2018/12/14 星期...	Program Debug ...	138 KB
BIStonezcai.exe	2018/12/14 星期...	应用程序	287 KB
BIStonezcai.exe.Config	2019/6/25 星期...	XML Configurati...	1 KB
BIStonezcai.pdb	2018/12/14 星期...	Program Debug ...	72 KB
BIStonezcai.vshost.exe	2018/12/13 星期...	应用程序	23 KB
BIStonezcai.vshost.exe.config	2018/12/13 星期...	XML Configurati...	1 KB
BIStonezcai.vshost.exe.manifest	2017/9/29 星期...	MANIFEST 文件	1 KB
CommandLine.dll	2018/10/15 星期...	应用程序扩展	61 KB
FiddlerCore4.dll	2018/10/15 星期...	应用程序扩展	389 KB
FSharp.Core.dll	2018/10/15 星期...	应用程序扩展	1,471 KB
FSharp.Core.xml	2018/10/15 星期...	XML 文档	682 KB
HtmlAgilityPack.dll	2018/10/15 星期...	应用程序扩展	147 KB
HtmlAgilityPack.pdb	2018/10/15 星期...	Program Debug ...	318 KB
HtmlAgilityPack.xml	2018/10/15 星期...	XML 文档	121 KB
ICSharpCode.SharpZipLib.dll	2018/10/15 星期...	应用程序扩展	196 KB
IronPython.dll	2018/10/15 星期...	应用程序扩展	1,778 KB

1.2 “智采”系统特点

“智采”系统作为一种数据采集和清洗的强大工具，有效地采集来自网页、数据库、文件的数据，并通过可视化地拖拽，快速地进行生成，过滤，转换等操作。

该系统的特点有如下几点：

1. 轻量级。

该系统是基于 windows 系统设计的轻量级信息监测服务系统，复制即用，无需安装，半天的培训即可上手，实现对于网页精确数据采集和提取的功用。

2. 功能强大。

该系统以工作流的方式，组织整个信息监测服务流程，内含 50 多种数据提取和清洗模块，覆盖了文本语义处理、数据存储、数据库投影等模块，变化无穷，功能强大。

3. 满足个性化采集要求。

大数据时代，对大数据的采集、分析和价值提取需求日益旺盛。人人都有个性化的数据采集需求。无需借助 IT 工程师的帮助，借助”智采”系统，即可快速实现对于个性化数据的采集。

注：附带案例。

一、 餐饮行业研究案例数据库

1. 北京餐饮门店评价数据库（来自大众点评网），包括：门店名称、评论、人均、类别、位置、地址、口味、环境、服务、优惠。
2. 北京餐饮门店评价数据的采集项目（XML 格式，可以基于该项目，变更为其他目标城市），包含四个子项目，可以自行运行采集北京所有餐饮门店数据。

二、 房地产行业研究案例数据库

1. 北京小区二手交易房价数据库（来自链家网），包括：小区名称、成交数、出租数、区域、特点、均价、正在出售房屋列表数据。
2. 北京在售二手房房价数据库（来自链家网），包括：房源标题、格局、面积、朝向、楼层、特点 1、特点 2、特点 3、总价、单价。
3. 北京小区二手交易房价数据库的采集项目（XML 格式，可以基于该项目，变更为其他目标城市），包含四个子项目，可以自行运行采集北京小区二手交易房价数据。
4. 北京在售二手房房价数据库的采集项目（XML 格式，可以基于该项目，变更为其他目标城市），包含四个子项目，可以自行运行采集北京在售二手房房价数据。

三、 旅游行业研究案例数据库

1. 西藏旅游线路数据库（来自携程网），包括：旅游线路 Id、旅游线路名称、旅游线路星级、旅行方式（跟团游、自由行）、详细信息链接、当前实时价格、出发城市、用户评分、出游人数、是否已经售罄、供应商、发团时间计划、所含节假日、是否首次发团、产品特色、线路服务内容、行程概要、行程详情、行程说明、产品经理推荐、产品概要、行程精华。
2. 西藏攻略数据库，包含所有攻略（合计 16000 多篇）的标题、采集链接、正文、游玩天数、游玩时间、和谁一起、花费、游玩方式。
3. 西藏旅游线路基本数据的采集项目（XML 格式，可以基于该项目，变更为其他目标城市），包

含两个子项目，可以自行运行采集西藏最新的旅游线路基本数据。

4. 西藏攻略数据的采集项目 (XML 格式，可以基于该项目，变更为其他目标城市)，包含两个子项目，可以自行运行采集西藏最新的旅游线路基本数据。

四、教育行业研究案例数据库:

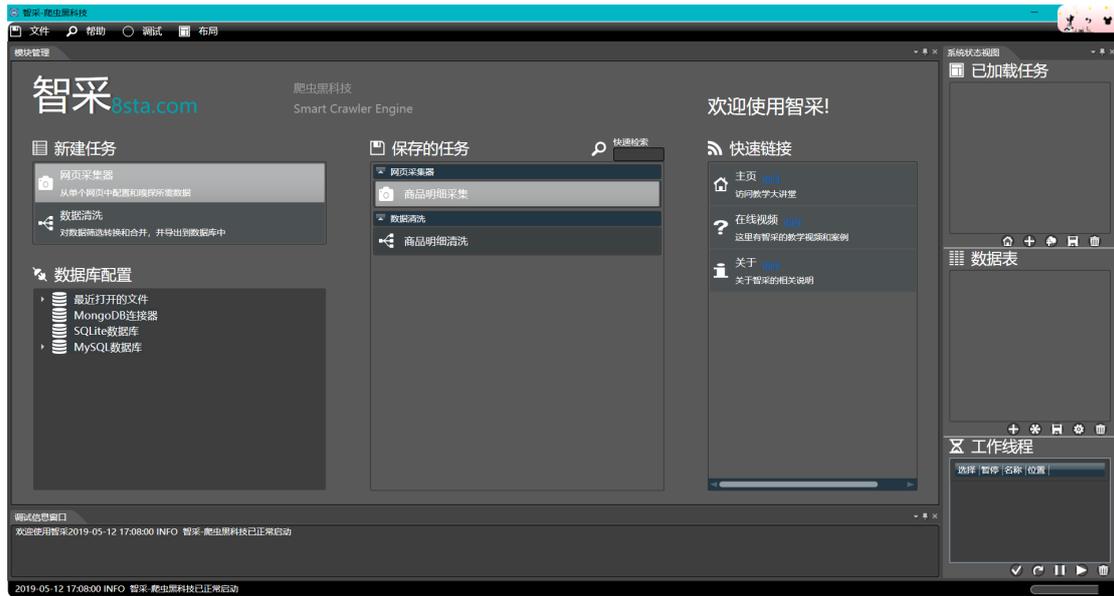
1. 北京、上海、广州的中小学、幼儿园的基本数据，字段包括：学校名称,所在地区（地市、区县）,重点级别（重点、非重点），性质（公办、民办），类别（中、小学、幼儿园）、点评数量、点评内容、地址、联系电话、地图经度、纬度（POI 信息）；
2. 北京、上海、广州的中小学教育机构基本数据的采集项目 (XML 格式，可以基于该项目，变更为其他目标城市)，包含两个子项目，可以自行运行采集国内最新的教育机构基本数据。

五、互联网金融行业研究案例数据库:

1. 国内上千家互联网金融平台的档案数据，字段包括：平台名称、平台状态、平台拼音简称、平台首字母、平均收益、平台上线时间、Android APP 下载地址、所在城市、注册资金、平台图标链接、投资期限、平台 ID、平台站岗指数、平台服务态度指数、平台提现指数、平台体验指数、微信二维码图标链接、IOS 下载链接、平台综合指数；
2. 互联网金融平台档案数据的采集项目 (XML 格式)，包含六个子项目，可以自行运行采集国内最新的互联网金融平台档案数据。

1.3 界面功能简介





系统主界面分为几大区域，任务区，用于管理所有的运行中任务；属性区，用于调整各项任务的属性；活动资源区：用于管理活动任务和数据；日志区：用于管理运行日志。下面对功能一一说明如下：

1. 任务区

- 模块列表：管理主模块，这是任务的入口。
包含如下两大主模块：
网页采集器：用于采集网页。
数据清洗：用于对网页数据进行提取、清洗和存储。
- 保存的任务：用于管理当前项目的所有任务。
项目下的任务列表，分为：数据采集任务和清洗任务两类。
- 数据源：用于管理所有的数据连接器。
当前项目数据存储的目标方式分为：
文件管理：连接本地文件系统中的文件。
MongoDB 方式：连接到 MongoDB 数据库。
MySQL 方式：连接到 MySQL 数据库。

2. 属性区

- 网页采集器任务的属性配置器
- 数据清洗任务的属性配置器

3. 活动资源区

- 算法视图：当前活动的网页采集、数据清洗任务列表。
- 数据视图：当前运行过程中的内存数据。

4. 日志区

- 任务管理视图：监测数据清洗任务的运行进度，可暂停、停止、删除任意任务和子任务。
- 调试信息窗口：记录各项操作日志。

第2章 任务区

任务区，以项目开始。每一个信息监测服务任务，在本系统中，统称为项目。每一个项目可以包含多个任务。用户可以新建一个项目，或者加载历史项目。



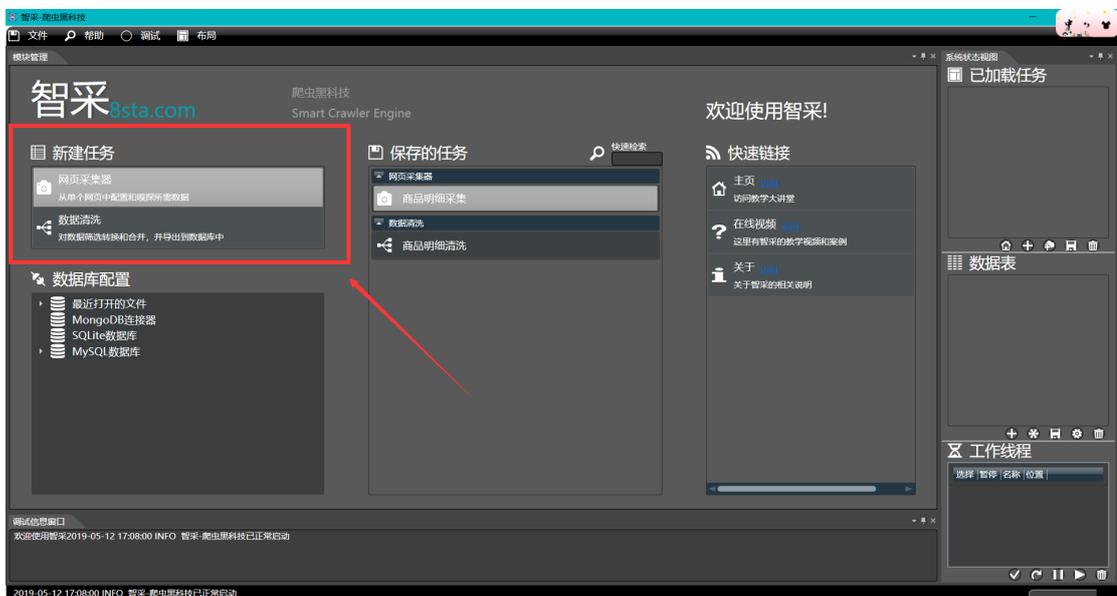
每次打开主界面，显示的界面就是任务区，任务区包含了三大部分：

- 模块列表：模块列表中，有两大主模块：网页采集器模块、数据清洗模块。
- 保存的任务：列表显示当前项目所包含的所有任务（网页采集器任务、数据清洗任务。）
- 数据源：列表显示当前项目所有可用的数据源。

2.1 模块列表

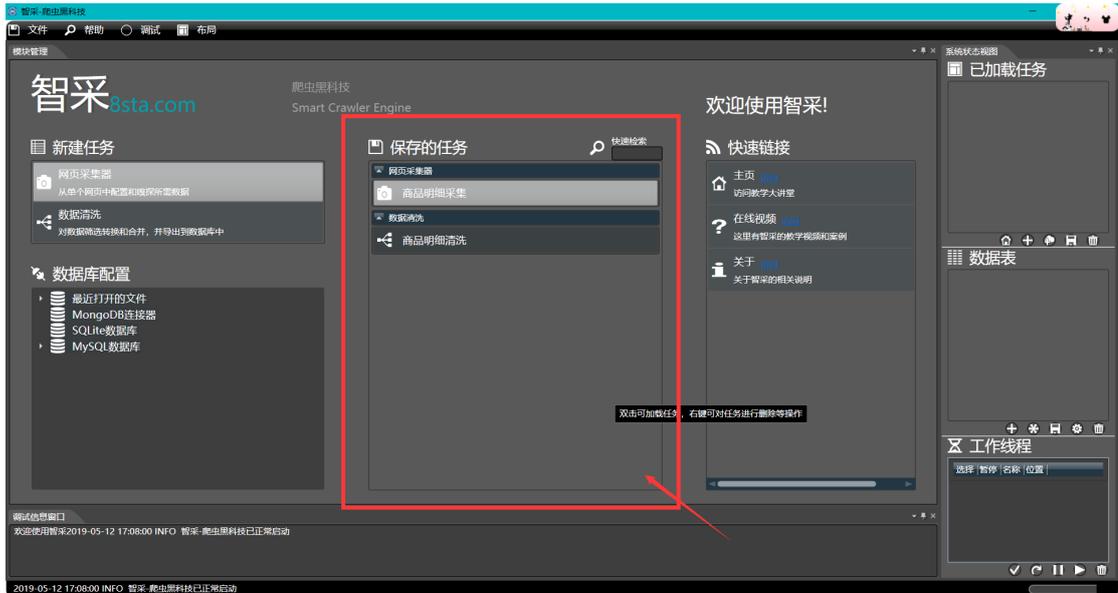
模块列表下的模块，是开展信息采集和数据清洗任务的主入口。当前主要包括如下两大主模块：

- 网页采集器：用于对于指定的网页链接，进行采集。同一个项目中，可以建立多个网页采集任务。
- 数据清洗：用于对网页采集器任务所采集的数据，进行数据清洗。同一个项目中，可以建立多个数据清洗任务。每个数据清洗任务，可以包含多个数据清洗子模块。数据清洗任务以任务流的方式，来串联每一个子模块。



2.2 保存的任务

项目下的任务列表，分为：数据采集任务和数据库清洗任务两类。

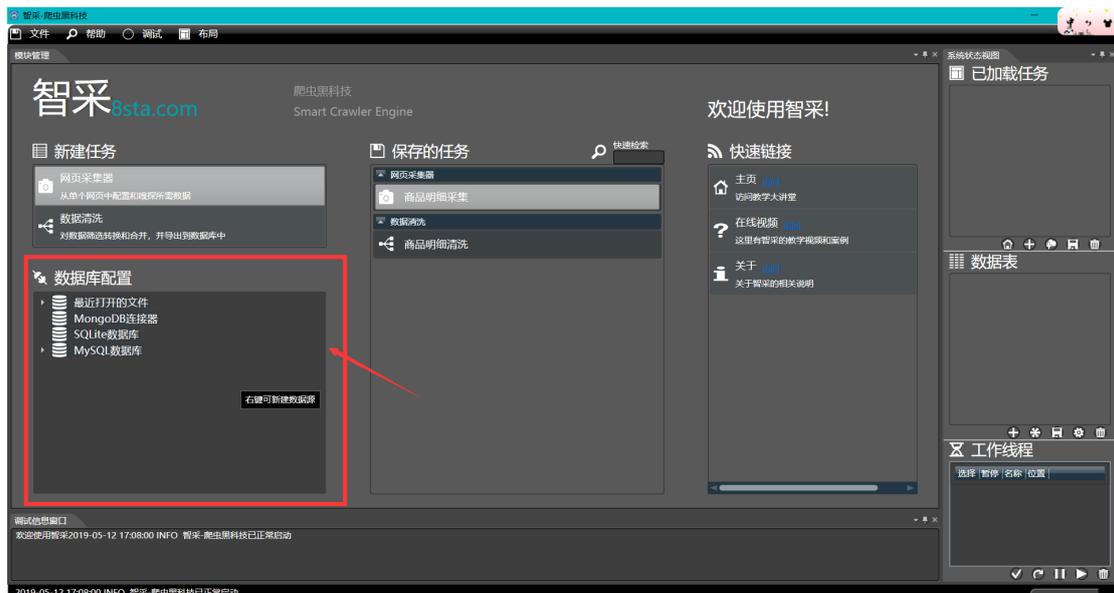


2.3 数据源

当前项目数据存储的目标方式。

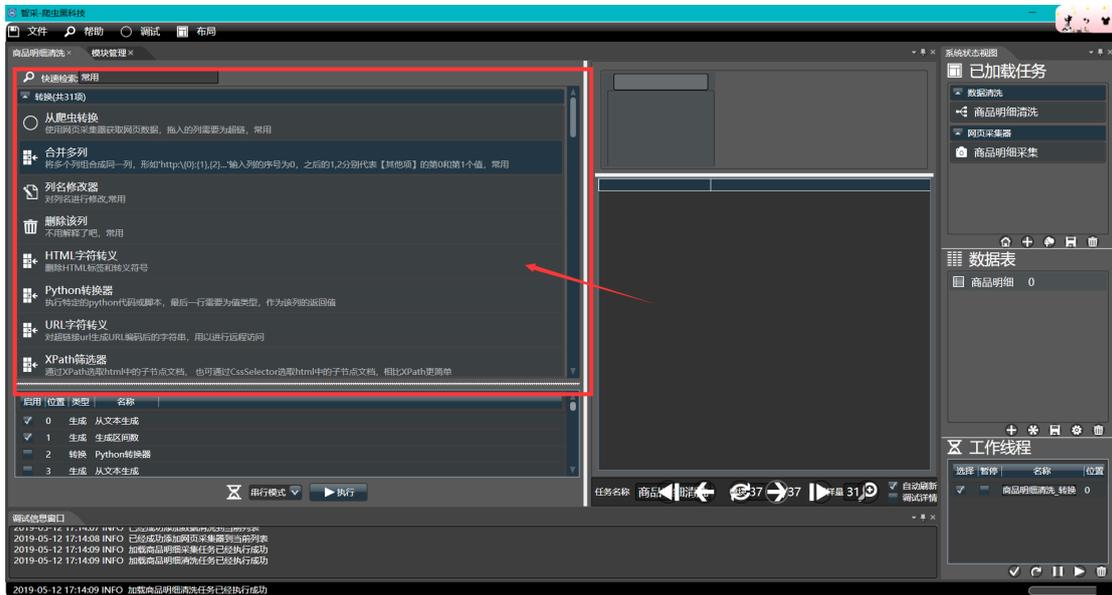
分为：

- 文件管理
- MongoDB 方式
- MySQL 方式



第3章 数据清洗任务中的子模块

数据清洗任务中，包含了 53 个非结构化数据清洗子模块，按照转换、执行、存储、生成和过滤进行分类，专门用于对采集下来的非结构化进行信息过滤、数据提取、格式转换、数据存储等操作，所有子模块都可以通过工作流的方式，进行串联执行，从而实现信息采集、监测任务的完全自动化。



子模块分为三个大类：

转换类子模块：一共包含 36 个数据转换类子模块，用于对非结构化数据的数据提取、处理和转换。子模块包括：搜索位置、获取 IP 的坐标、获取路径信息、检索附近、自然语言处理、语言翻译转换、添加新列、自增键生成、列名修改器、删除该列、从爬虫转换、数据库投影、重复当前值、获取请求详情、时间转字符串、URL 字符转义、HTML 字符转义、正则分割、字符串分割、转换为 Json、合并多列、Python 转换器、正则替换、正则转换器、提取数字、字符首尾抽取、启动并行、清除空白符、读取文件文本、读取文件数据、字典转换、子任务-转换、路径是否存在、重复项合并、延时、XPath 筛选器。

执行类子模块：一共包含 5 个任务执行类子模块，用于执行非结构化数据清洗子任务、数据存储任务。特别是通过“子任务-执行”类似的模块，实现对于非结构化数据清洗的多层嵌套，使得其功能组合变化无穷，可以满足几乎大多数的非结构化数据采集任务。子模块包括：写入文件文本、子任务-执行、数据库操作、保存超链接文件、写入数据库。

生成类子模块：一共包含 7 项生成类子模块，用于主动生成数据处理过程的过度数据。子模块有：获取文件夹文件、从连接器生成、生成区间数、从数据表生成、从文本生成、请求队列、子任务-生成。

过滤类子模块：一共包含 5 个过滤类子模块，用于对网页采集下来的结构化数据进行各种条件的数据过滤。子模块有：空对象过滤器、数字范围过滤器、正则筛选器、删除重复项、数

量范围选择。

3.1 转换类子模块

- 搜索位置：指定城市范围内，可以对城市内的地址，自动搜索出其准确的经纬度。系统可以自动去调度百度地图 API，获取当前地标的经纬度坐标。对于需要自动和批量精确采集 POI 的场景，非常强大。
- 获取 IP 的坐标：可以依据 IP 地址自动搜索该 IP 地址的经纬度。用于批量获取 IP 地址的经纬度坐标。
- 获取路径信息：指定目标位置，可以自动批量计算出某地址到目位置的时间，交通方式可以选择：公交、驾车和步行三种方案。
- 检索附近：获取当前经纬度某一半径范围内的所有地物，需要拖入的为代表经度的列
- 自然语言处理：通过语言云获取的自然语言处理功能，包括分词，词性标注，命名实体识别、依存句法分析、语义依存分析、语义角色标注等，输出文字格式包括：text、Json、XML 和 byte。
- 语言翻译转换：从当前语言翻译为目标语言（支持十三种语言）。可以对包括英语、日语、文言文在内的语种之间进行自动转换。
- 添加新列：为数据集添加新列，值为某固定值。
- 自增键生成：添加一个自增列。
- 列名修改器：修改列名。
- 删除该列：删除指定列。
- 从爬虫转换：使用网页采集器获取网页数据，拖入的列需要为超链接。
- 数据库投影：利用该模块，可以快速的查询数据的数据，投影到内存中。
- 重复当前值：对当前行进行重复性生成。
- 获取请求详情：使用网页采集器获取网页数据，拖入的列需要为超链接。
- 时间转字符串：将时间类型转换为特定格式的字符串。
- URL 字符转义：对超链接 url 生成 URL 编码后的字符串，用以进行远程访问。
- HTML 字符转义：删除 HTML 标签和转义符号。
- 正则分割：使用正则表达式分割字符串。
- 字符串分割：对字符串进行分割，可以分割为一列或者多列。
- 转换为 Json：从字符串转换为 json（数组或字典类型）
- 合并多列：将多个列组合成同一列，形如：`http://.....{0}{1}`，本列的序号为 0，其他项为 1,2,3
- Python 转换器：执行特定的 python 代码。文档列表：`[{}]`，转换为多个数据行构成的列表；单文档：`{}`，将结果的键值对附加到本行；不进行转换：直接将值放入本列。
- 正则替换：可以通过正则表达式，对列的内容进行替换。
- 正则转换器：通过正则表达式，对列的内容进行转换。
- 提取数字：提取当前列中的数字。
- 字符首尾抽取：提取字符串中，从首串到尾串中间的文本内容
- 启动并行：对多个种子合并为一个任务执行，这对于小型种子任务可以有效提升效率。该模块在执行时，会将本模块之前的流实例化，转换为实际的 list，用于提高并行性能。
- 清除空白符：清除字符串前后和中间的空白符。
- 读取文件文本：获取文件中的文本。
- 读取文件数据：从文件中读取内容。

- 字典转换：将两列数据，转换为一行数据，拖入的列为 key。
- 子任务-转换：从其他数据清洗模块中生成序列，用以组合大模块。
- 路径是否存在：判断某一个文件是否已经在指定路径上。
- 重复项合并：对重复的数据行，进行合并操作。
- 延时：在工作流中插入延时，单位为 ms，值为拖入列的值。
- XPath 筛选器：通过 XPath 选取 html 中的子节点文档。

3.1.1 搜索位置

指定城市范围内，可以对该城市内的地址，自动搜索出其准确的经纬度。系统可以自动去调用百度地图 API，获取当前地标的经纬度坐标。对于需要自动和批量精确采集 POI 的场景，非常强大。



基本选项：

- 标签：自定义模块标签。
- 类型：搜索位置
- 原列名：待搜索的地址列名。

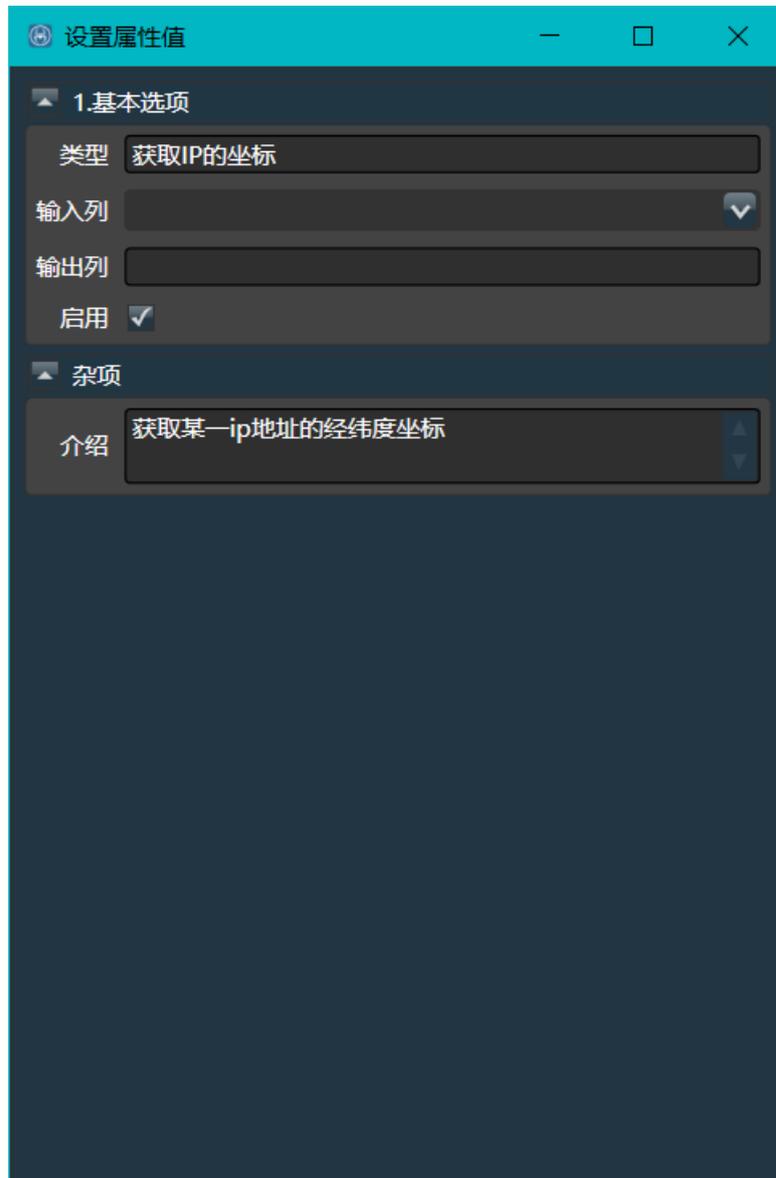
- 新列名：自定义经纬度坐标的列名。
- 启用：是否启用该模块。

杂项：

- 所属地市：指定地址所属的地市，以便缩小查找范围。
- 介绍：该子模块的介绍。

3.1.2 获取 IP 的坐标

可以依据 IP 地址自动搜索该 IP 地址的经纬度。用于批量获取 IP 地址的经纬度坐标。



基本选项：

- 标签：自定义模块标签。
- 类型：获取 IP 的坐标。
- 原列名：待搜索的 IP 地址列名。
- 新列名：自定义经纬度坐标的列名。
- 启用：是否启用该模块。

杂项:

- 介绍: 该子模块的介绍。

3.1.3 获取路径信息

指定目标位置,可以自动批量计算出某地址到目位置的时间,交通方式可以选择:公交、驾车和步行三种方案。

The screenshot shows a configuration window titled '设置属性值' (Set Attribute Value) with a teal header. It is divided into two sections: '1. 基本选项' (Basic Options) and '杂项' (Miscellaneous). In the '基本选项' section, the '类型' (Type) is set to '获取路径信息' (Get Path Information), '输入列' (Input Column) and '输出列' (Output Column) are empty, and the '启用' (Enable) checkbox is checked. In the '杂项' section, there is a '启用' (Enable) button, and fields for '目标位置' (Target Location), '目标城市' (Target City) set to '北京' (Beijing), and '源城市' (Source City) set to '北京' (Beijing). The '运动方案' (Transportation Scheme) dropdown is set to '公交' (Public Transport). The '介绍' (Introduction) field contains the text '从当前地名, 运动到对应坐标所需的时间' (Time required to move from the current location to the corresponding coordinates).

基本选项:

- 标签: 自定义模块标签。
- 类型: 获取路径信息。
- 原列名: 出发地点。
- 新列名: 从出发地点运动到目标位置所需的时间。
- 启用: 是否启用该模块。

杂项:

- 目标位置: 计算的目标位置。
- 目标城市: 目标位置所属的城市。

- 源城市：出发地点所属的城市。
- 运动方案：运动的方式，包括：公交、驾车和步行三种方案。

3.1.4 检索附近

获取当前经纬度某一半径范围内的所有地物，需要拖入的为代表经度的列。

The screenshot shows a configuration window titled '设置属性值' (Set Attribute Value) with a teal header. It contains two main sections: '1. 基本选项' (Basic Options) and '杂项' (Miscellaneous). In the '基本选项' section, '类型' (Type) is set to '检索附近' (Search Nearby), '输入列' (Input Column) is empty, '输出列' (Output Column) is empty, and '启用' (Enabled) is checked. In the '杂项' section, '所有结果' (All Results) is unchecked, '纬度列' (Latitude Column) is 'pos_lng', '查询地物' (Query POI) is empty, and '搜索半径' (Search Radius) is '2000'. An '介绍' (Introduction) field contains the text: '获取当前经纬度某一半径范围内的所有地物，需要拖入的为代表经度的列' (Get all POI within a certain radius of the current latitude and longitude, the one to be dragged in is the column representing longitude).

基本选项：

- 标签：自定义模块标签。
- 类型：检索附近。
- 原列名：待搜索的地址列名。
- 新列名：存储附近地物。
- 启用：是否启用该模块。

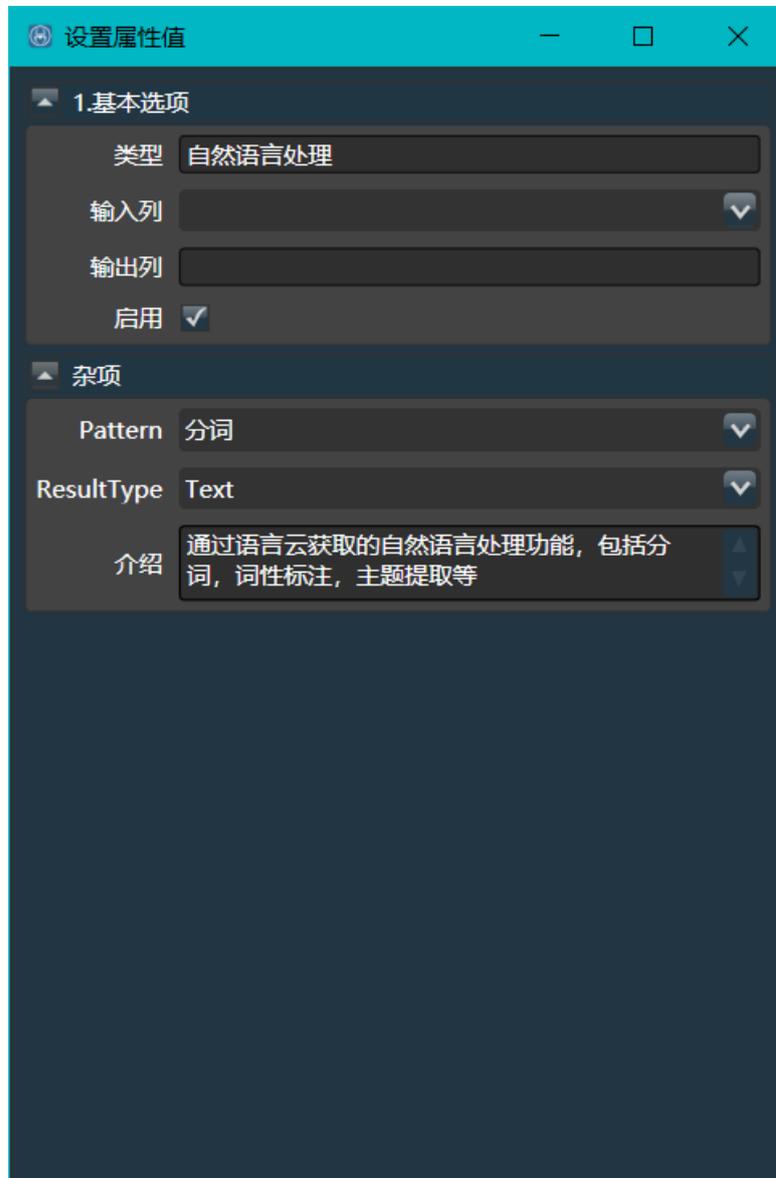
杂项：

- 所有结果：勾选记录所有结果。
- 纬度列：纬度所在列。
- 查询地物：比如：公园、加油站等。

- 搜索半径：半径单位为米。

3.1.5 自然语言处理

通过语言云获取的自然语言处理功能，包括分词，词性标注，命名实体识别、依存句法分析、语义依存分析、语义角色标注等，输出文字格式包括：text、Json、XML 和 byte。



基本选项：

- 标签：自定义模块标签。
- 类型：自然语言处理。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- Pattern（自然语言处理方法）：分词，词性标注，命名实体识别、依存句法分析、语义

依存分析、语义角色标注。

- ResultType (输出结果格式): text、Json、XML 和 byte。

分词示例:

content	new
005000020141231734948	005000020141231734948
客户姓名张三	客户姓名:张三
民生卡号: 1111111111111111	民生卡号: 1111111111111111
联系方式: 11111111111	联系方式: 11111111111
乐收银号码: 11111111111	乐收银号码: 11111111111
机具经办行: 广州天河区支行	机具经办行: 广州天河区支行
来电号码: 11111111111	来电号码: 11111111111
商户编号: 111111111111111	商户编号: 111111111111111
交易时间及金额: 11月11号的1111元+11号的1111元+11号的1111元	交易时间及金额: 11月 11号的 1111 元 + 11 号的 1111 元 + 11 号的 1111 元
商户名称: 广州市荔湾区青藤百草药行*	商户名称: 广州市 荔湾区 青藤百草药行 *
2015-01-06 10:46:59 分行处理 黄茵茵 您好, 联系商户, 商户称已到账, 建议结束工	2015-01-06 10:46:59 分行处理 黄茵茵 您好, 联系商户, 商户称已到账, 建议结束工单。
2015-01-06 10:56:09 分行分发 郑毓婷 结束。*	投诉认定结果: 无效投诉 客户满意度: 满意 2015-01-06 10:56:09 分行分发 郑毓婷 结束。*
003000020150104741271	003000020150104741271
2015-01-08 14:16:08 分行处理 陈赛1 清机无长款, 流水核实客户金额已冲正, 已联	2015-01-08 14:16:08 分行处理 陈赛1 清机无长款, 流水核实客户金额已冲正, 已联系客户核实已经
2015-01-08 14:21:22 分行处理 苏鼎新 结束	2015-01-08 14:21:22 分行处理 苏鼎新 结束
2015-01-08 14:25:54 分行分发 苏鼎新 结束*	2015-01-08 14:25:54 分行分发 苏鼎新 结束 *
003000020150105741290	003000020150105741290
2015-01-07 16:38:16 分行处理 鹿飞 分行已确认此笔错帐, 今日安排调帐, 工单办	2015-01-07 16:38:16 分行处理 鹿飞 分行已确认此笔错帐, 今日安排调帐, 工单办结。
2015-01-07 16:43:29 分行分发 彭开宇 办结。*	2015-01-07 16:43:29 分行分发 彭开宇 办结。*
001000020150105741292	001000020150105741292

词性标注示例:

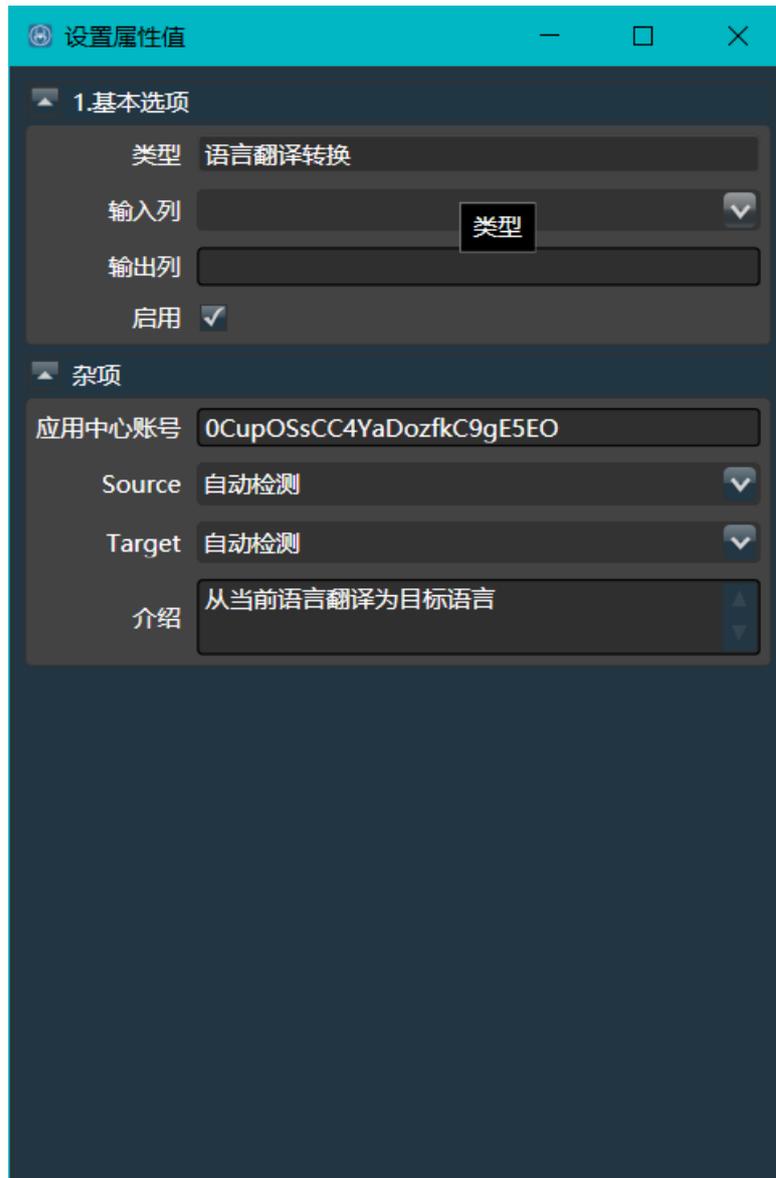
content	new
005000020141231734948	005000020141231734948_m
客户姓名张三	客户_n 姓名_n : wp 张三_nh
民生卡号: 1111111111111111	民生卡号_n : wp 1111111111111111_m
联系方式: 11111111111	联系_n 方式_n : wp 11111111111_m
乐收银号码: 11111111111	乐收银_n 号码_n : wp 11111111111_m
机具经办行: 广州天河区支行	机具_n 经办行_n : wp 广州_ns 天河河北_ns 支行_n
来电号码: 11111111111	来电_n 号码_n : wp 11111111111_m
商户编号: 111111111111111	商户_n 编号_n : wp 1111111111111111_m
交易时间及金额: 11月11号的1111元+11号的1111元+11号的1111元	交易_n 时间_n 及_c 金额_n : wp 11月_nt 11号_nt 的_u 1111_m元_q +_wp 11_m号_q 的_u 1111_m元_q
商户名称: 广州市荔湾区青藤百草药行*	商户_n 名称_n : wp 广州市_ns 荔湾区_ns 青藤百草药行_n_n *_wp
2015-01-06 10:46:59 分行处理 黄茵茵 您好, 联系商户, 商户称已	2015-01-06 m 10_m : wp 46_m : wp 59_m 分行_q 处理_v 黄_nh 茵茵_nh 您好_j , _wp 联系_v 商户_n
2015-01-06 10:56:09 分行分发 郑毓婷 结束。*	wp 投诉_v 认定_v 结果_n : _wp 无效_v 投诉_v wp 客户_n 满意度_n : _wp 满意_v 2015-01-06 m 10_m : wp 56:09_m 分行_n 分发_v 郑毓婷_nh 结束_v . _wp
003000020150104741271	003000020150104741271_m
2015-01-08 14:16:08 分行处理 陈赛1 清机无长款, 流水核实客户金	2015-01-08 m 14_m : wp 16_m : wp 08_m 分行_n 处理_v 陈赛_nh 1_m 清机_n 无_v 长款_n , _wp 流办
2015-01-08 14:21:22 分行处理 苏鼎新 结束	2015-01-08_m 14_m : wp 21_m : wp 22_m 分行_q 处理_v 苏鼎新_nh 结束_v
2015-01-08 14:25:54 分行分发 苏鼎新 结束*	2015-01-08 m 14_m : wp 25_m : wp 54_m 分行_n 分发_v 苏_j 鼎新_d 结束_v *_wp
003000020150105741290	003000020150105741290_m
2015-01-07 16:38:16 分行处理 鹿飞 分行已确认此笔错帐, 今日安	2015-01-07 m 16_m : wp 38_m : wp 16_m 分行_q 处理_v 鹿_n 飞_v 分行_n 已_d 确认_v 此_r 笔_q 错帐
2015-01-07 16:43:29 分行分发 彭开宇 办结。*	2015-01-07 m 16_m : wp 43_m : wp 29_m 分行_n 分发_v 彭_nh 开宇_nh 办_v 结_v . _wp
001000020150105741292	001000020150105741292_m

语义角色标注示例:

content	new
2015-01-06 10:46:59 分行	处理lv [黄茵茵您好, 联系商户, 商户称已到账, 建议结束工单]A1。 2015-01-06 10:46:59 分行处理 [黄茵茵]A0 [您好], 联系商户, 商户称已到账, 建议结束工单。 2015-01-06 10:46:59 分行处理 黄茵茵您好, [联系lv [商户]A1, 商户称已到账, 建议结束工单。 2015-01-06 10:46:59 分行处理 黄茵茵您好, 联系商户, [商户]A0 [称lv已到]A1, 建议结束工单。 2015-01-06 10:46:59 分行处理 黄茵茵您好, 联系商户, 商户称 [已]ADV [到lv [商户]A1, 建议结束工单。 2015-01-06 10:46:59 分行处理 黄茵茵您好, 联系商户, 商户称已到账, [建议lv [结束工单]A1。 2015-01-06 10:46:59 分行处理 黄茵茵您好, 联系商户, 商户称已到账, 建议 [结束lv [工单]A1。
2015-01-06 10:56:09 分行	2015-01-06 10: [56:09 分行分发 郑毓婷]A0 [结束lv。
00300002015010474127	
2015-01-08 14:16:08 分行	2015-01-08 14: 16: [08 分行]A0 [处理lv 陈赛 1 清机无长款, 流水核实客户金额已冲正, 已联系客户核实已经到账, 请 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, [无lv [长款]A1, 流水核实客户金额已冲正, 已联系客户核实已经到账 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, [流水]A0 [核实lv 客户金额已冲正, 已联系客户核实已经到账。请 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, 流水核实 [客户金额]A0 [已]ADV [冲正]lv, 已联系客户核实已经到账 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, 流水核实客户金额已冲正, [已]ADV [联系lv [客户]A1 [核实已经到 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, 流水核实客户金额已冲正, 已联系客户 [核实lv 已经到]A1, 请 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, 流水核实客户金额已冲正, 已联系客户核实 [已经]ADV [到lv [账]A 2015-01-08 14: 16: 08 分行处理 陈赛 1 清机无长款, 流水核实客户金额已冲正, 已联系客户核实已经到账, [请lv [结
2015-01-08 14:21:22 分行	2015-01-08 14: 21: [22 分行 处理 苏鼎新]A0 [结束lv
2015-01-08 14:25:54 分行	2015-01-08 14: 25: [54 分行]A0 [分发lv 苏鼎新 结束 * 2015-01-08 14: 25: 54 分行分发 苏 [鼎新]ADV [结束lv *
00300002015010574129f	
2015-01-07 16:38:16 分行	2015-01-07 16: 38: 16 分行 [处理lv [鹿]A1 飞分行已确认此笔错帐, 今日安排调账, 工单办结。 2015-01-07 16: 38: [16 分行 处理 鹿飞分行]A0 [已]ADV [确认lv [此笔错帐]A1, 今日安排调账, 工单办结。 2015-01-07 16: 38: 16 分行处理 鹿飞分行已确认此笔错帐, [今日]TMP [安排lv 调账, 工单办结。 2015-01-07 16: 38: 16 分行处理 鹿飞分行已确认此笔错帐, 今日安排调账, [工单]A0 [办]lv 结。
2015-01-07 16:43:29 分行	2015-01-07 16: 43: [29 分行]A0 [分发lv [彭开宇]A1 办结。 2015-01-07 16: 43: 29 分行分发 彭开宇 [办]lv [结]A1。
00100002015010574129f	

3.1.6 语言翻译转换

从当前语言翻译为目标语言。可以对包括英语、日语、文言文在内的语种之间进行自动转换。

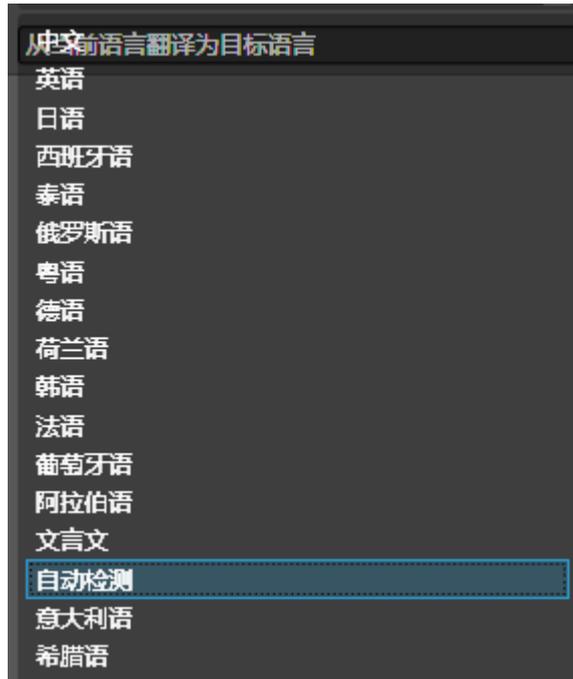


基本选项：

- 标签：自定义模块标签。
- 类型：语言翻译转换。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 应用中心账号：云翻译中心的登录账户。
- Source（当前语言）：支持多种语言（十六种语言）。
- Target（目标语言）：支持多种语言（十六种语言）。



3.1.7 添加新列

为数据集添加新列，值为某固定值。



基本选项:

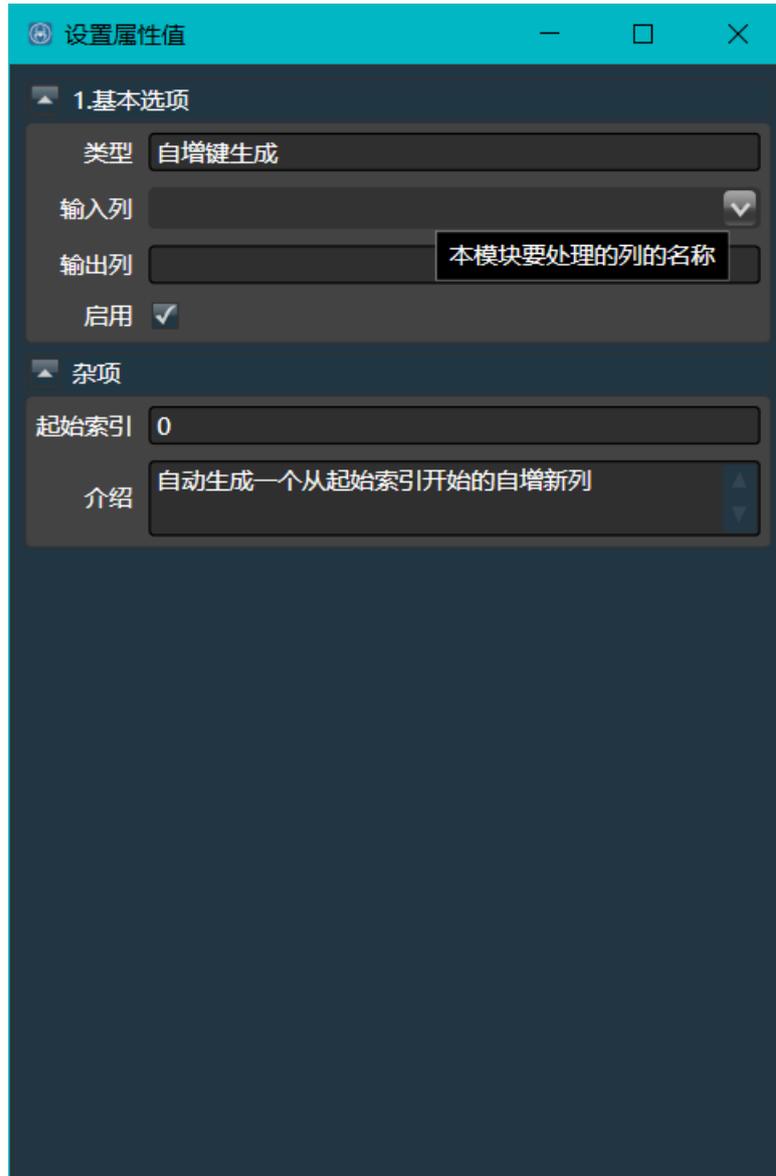
- 标签: 自定义模块标签。
- 类型: 添加新列。
- 原列名: 待处理列。
- 新列名: 结果列。
- 启用: 是否启用该模块。

杂项:

- 生成值: 为数据集添加新列, 此为新列的固定值。

3.1.8 自增键生成

添加一个自增列。



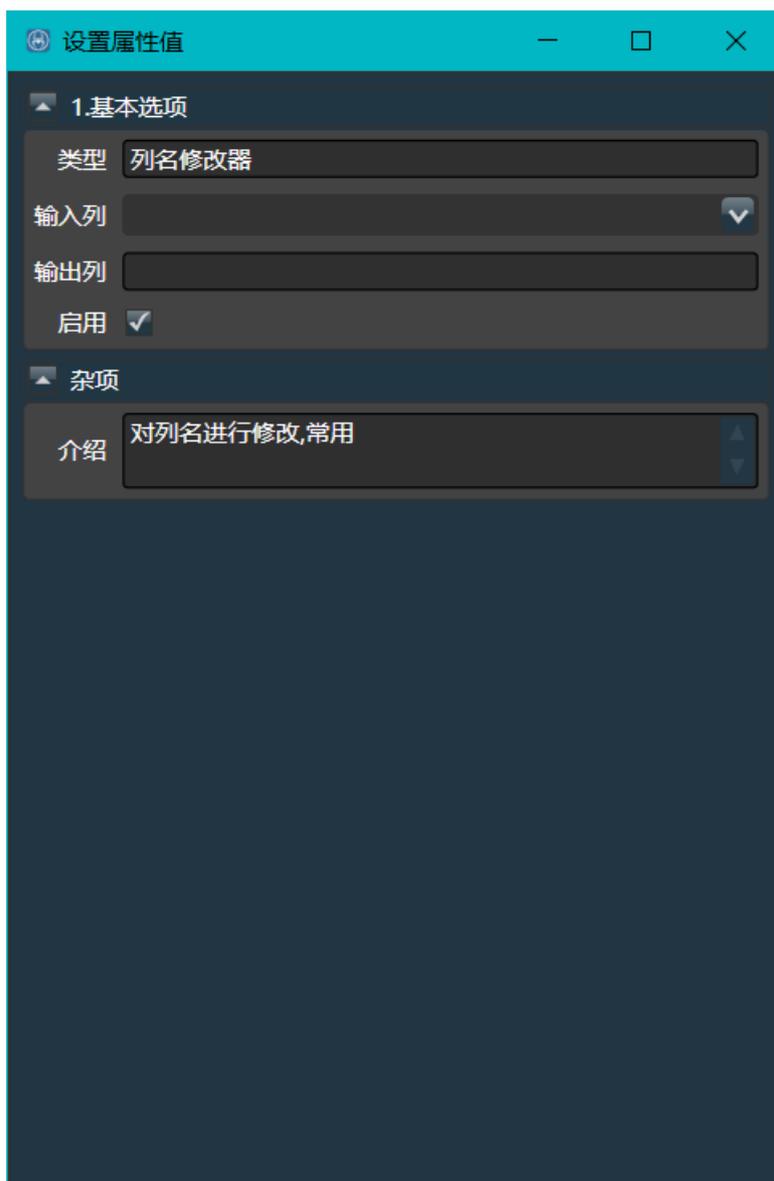
基本选项：

- 标签：自定义模块标签。
- 类型：自增键生成。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 起始索引：一般从 0 开始，每次自增 1。

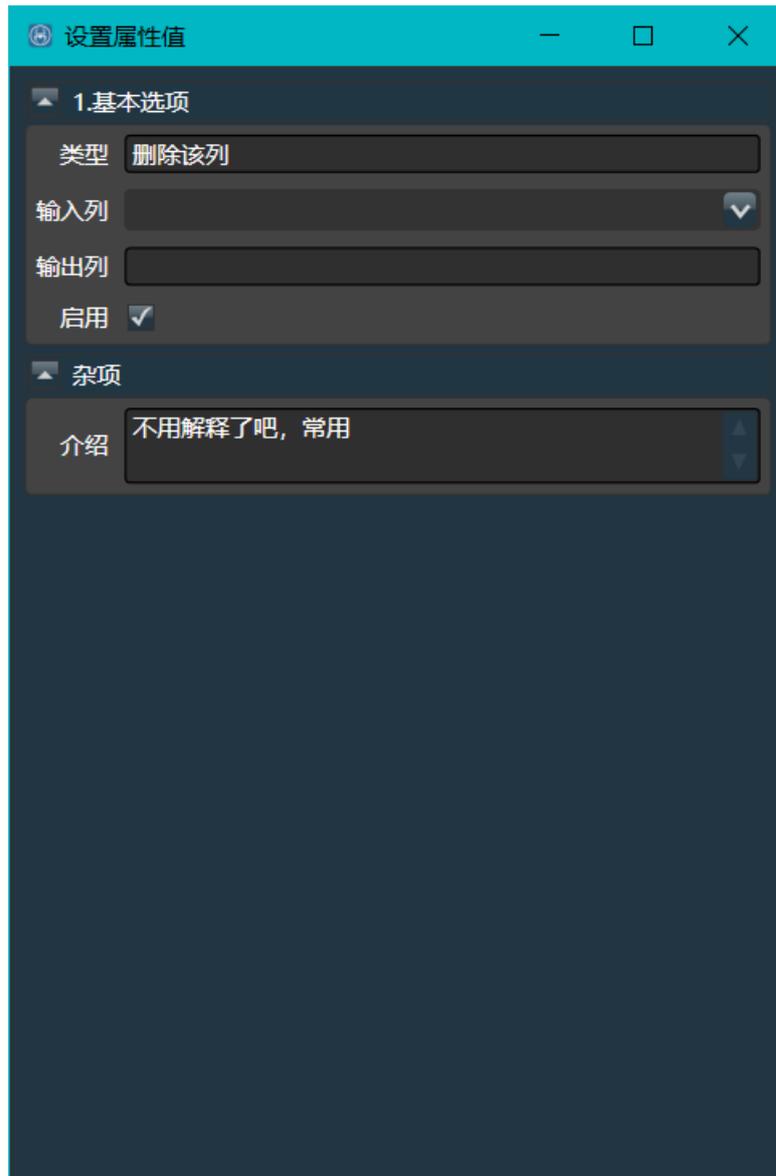
3.1.9 列名修改器



基本选项:

- 标签: 自定义模块标签。
- 类型: 列名修改器。
- 原列名: 待处理列。
- 新列名: 结果列。
- 启用: 是否启用该模块。

3.1.10 删除该列



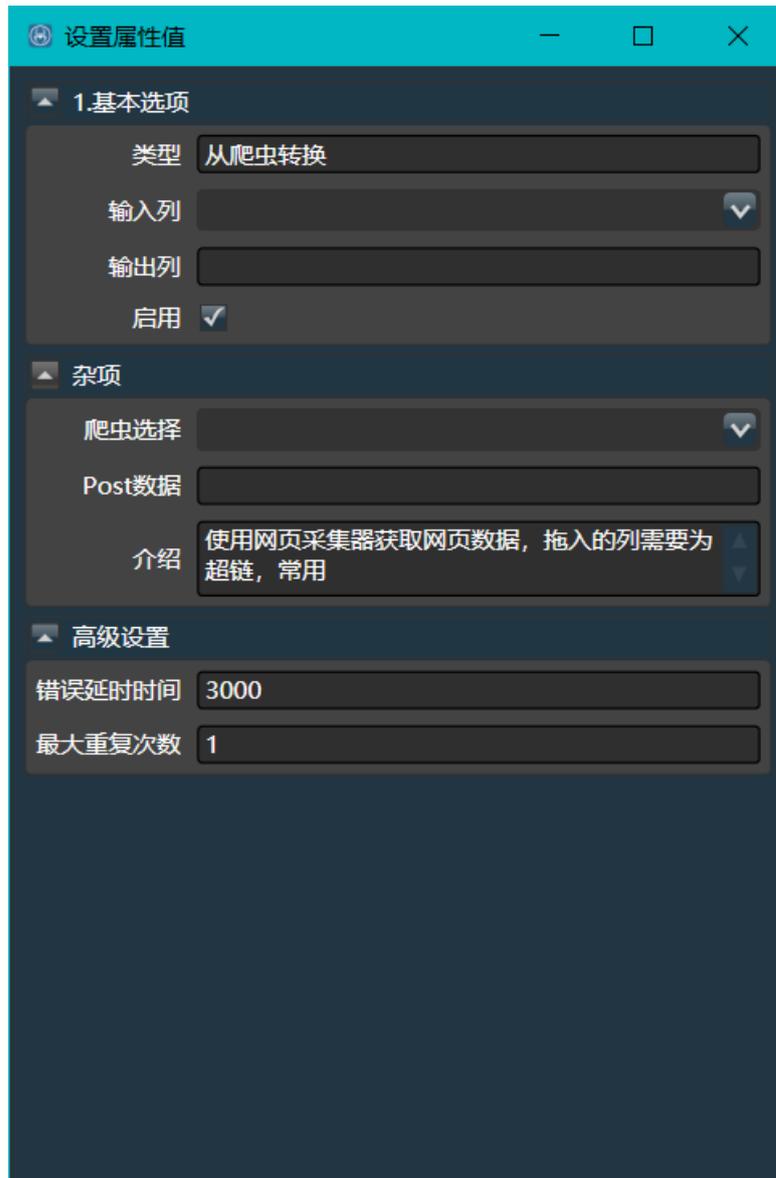
基本选项:

- 标签: 自定义模块标签。
- 类型: 删除该列。
- 原列名: 待删除列。
- 新列名: 结果列。(没用)
- 启用: 是否启用该模块。

3.1.11 从爬虫转换

此为一个重要的模块, 唯一的依靠该模块, 可以与网页采集器联合使用。该模块使用网页采集器获取网页数据。因此, 拖入的列需要为超链接。

该模块可以自动依据超链接列, 自动采集数据 (指定的网页采集器名), 生成多列 (通过指定的网页采集器定义)。



基本选项：

- 标签：自定义模块标签。
- 类型：从爬虫转换。
- 原列名：待处理列（超链接列）。
- 新列名：结果列（当网页采集器是单列模式【one】还是【list】模式，都会制定列的内容）。
- 启用：是否启用该模块。

杂项：

- 爬虫选择：填写指定的网页采集器名称。
- 延时时间：延时多长时间开始采集（ms）。
- 错误延时时间：延时多长时间重试（ms）。
- 最大重复次数：出错重复抓取的次数。
- Post 数据：通过 Post 提交的数据。

请求队列（暂可不用，用在高度并发的环境下）。

示例：

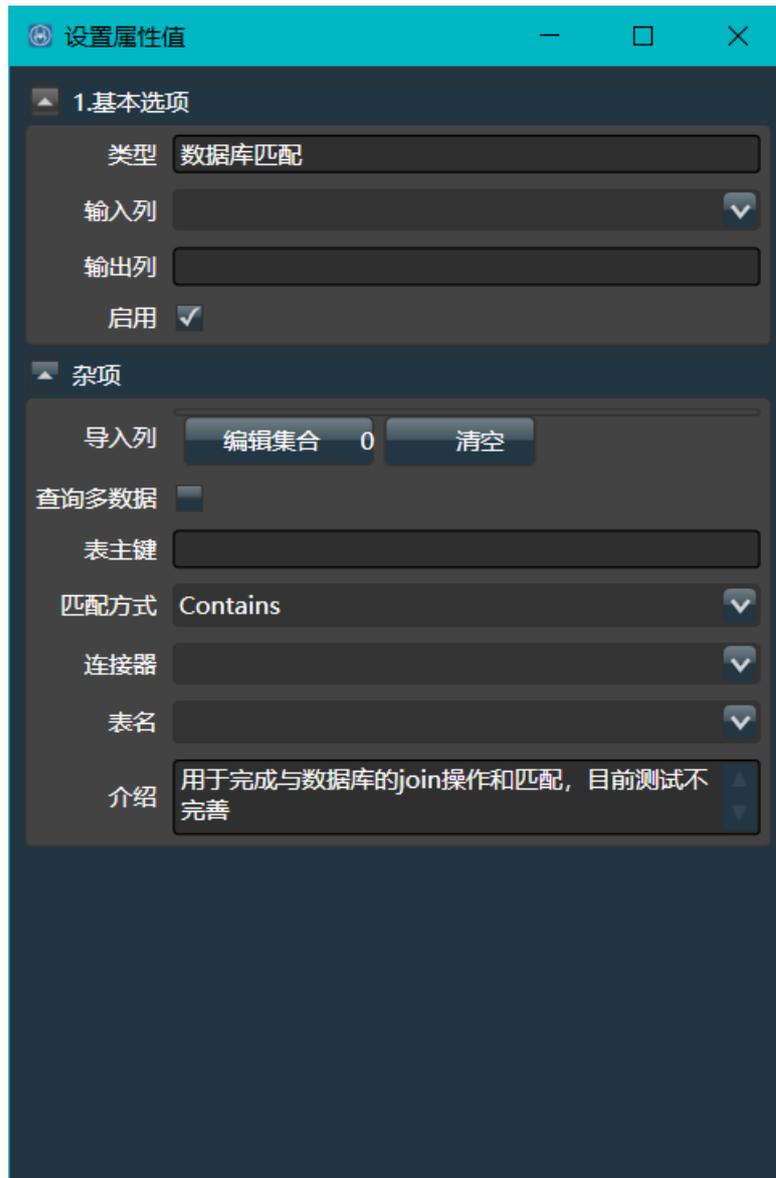
URL 为超链接列，拖拽本模块进入该列，自动生成相关数据。



URL	city	属性0	p
http://you.ctrip.com/sight/linzhi126.html	林芝	1-15 / 164条	11
http://you.ctrip.com/sight/ritu120147.html	日土		1
http://you.ctrip.com/sight/anduo120385.html	安多		1
http://you.ctrip.com/sight/dingri2450.html	定日		1
http://you.ctrip.com/sight/chayu120394.html	察隅		1
http://you.ctrip.com/sight/suoxian120391.html	索县		1
http://you.ctrip.com/sight/geer120143.html	噶尔		1
http://you.ctrip.com/sight/rikaze100.html	日喀则	1-15 / 94条	7
http://you.ctrip.com/sight/jiangzi2437.html	江孜		1
http://you.ctrip.com/sight/yadong120090.html	亚东		1
http://you.ctrip.com/sight/chaya120402.html	察雅		1
http://you.ctrip.com/sight/luozha120411.html	洛扎		1
http://you.ctrip.com/sight/ali99.html	阿里	1-15 / 44条	3
http://you.ctrip.com/sight/naqu120387.html	那曲		1
http://you.ctrip.com/sight/jiacha120409.html	加查		1

3.1.12 数据库匹配

利用该模块，可以快速的查询数据的数据，投影到内存中。



基本选项：

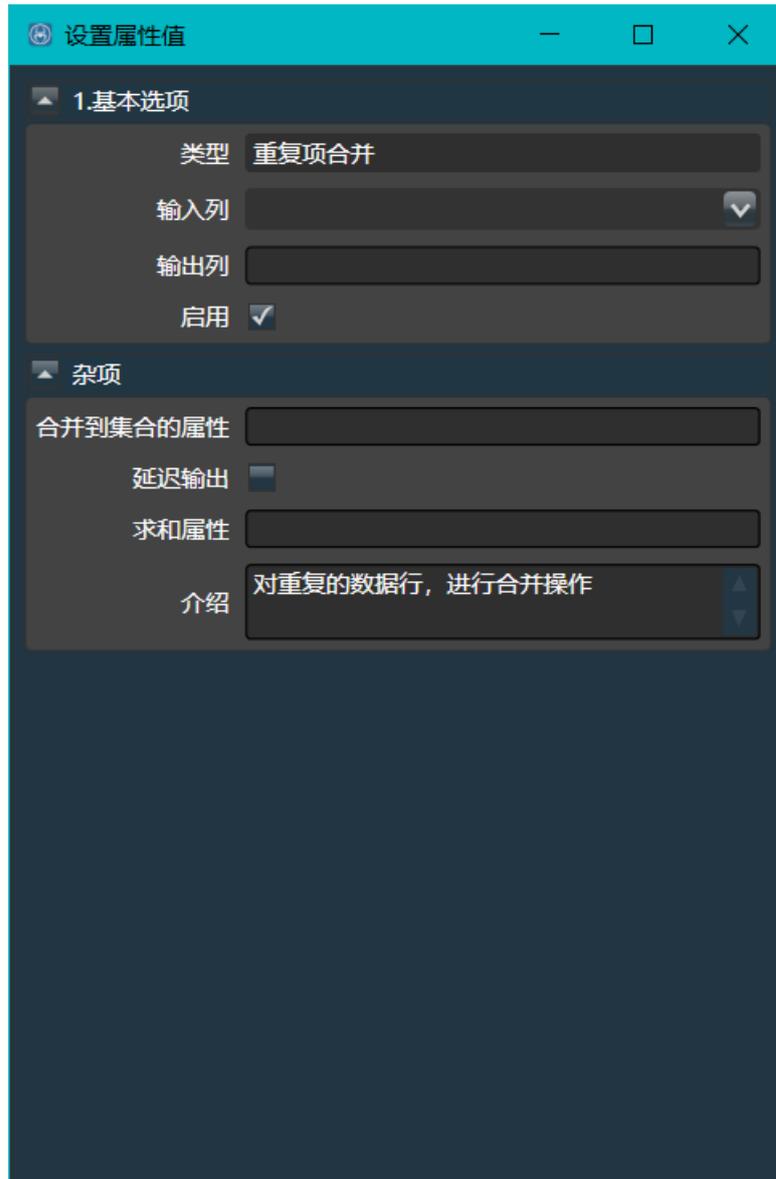
- 类型：数据库匹配。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 导入列：选择表后，这里会自动显示可用的表名，供选择投影进入内存的列。
- 查询多数据：选择该项时，会同时查询所有满足条件的项，将同一列保存为数组。
- 表主键：指定表的主键。
- 匹配方式：包含：Contains, Like, Match, Initials 四种方式（与待处理列通过这四种关系进行匹配）。
- 连接器：选择数据源列表下的所有连接器。
- 表名：连接器下的表。

3.1.13 重复当前值

对当前行进行重复性生成。



基本选项：

- 标签：自定义模块标签。
- 类型：重复当前值。
- 原列名：待处理列（超链接列）。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 重复次数：指定重复次数。
- 重复模式：指定重复的方式。

3.1.14 获取请求响应

使用网页采集器获取网页数据，拖入的列需要为超链接。



基本选项：

- 标签：自定义模块标签。
- 类型：重复当前值。
- 原列名：待处理列（超链接列）。
- 新列名：结果列。
- 启用：是否启用该模块。

头数据：

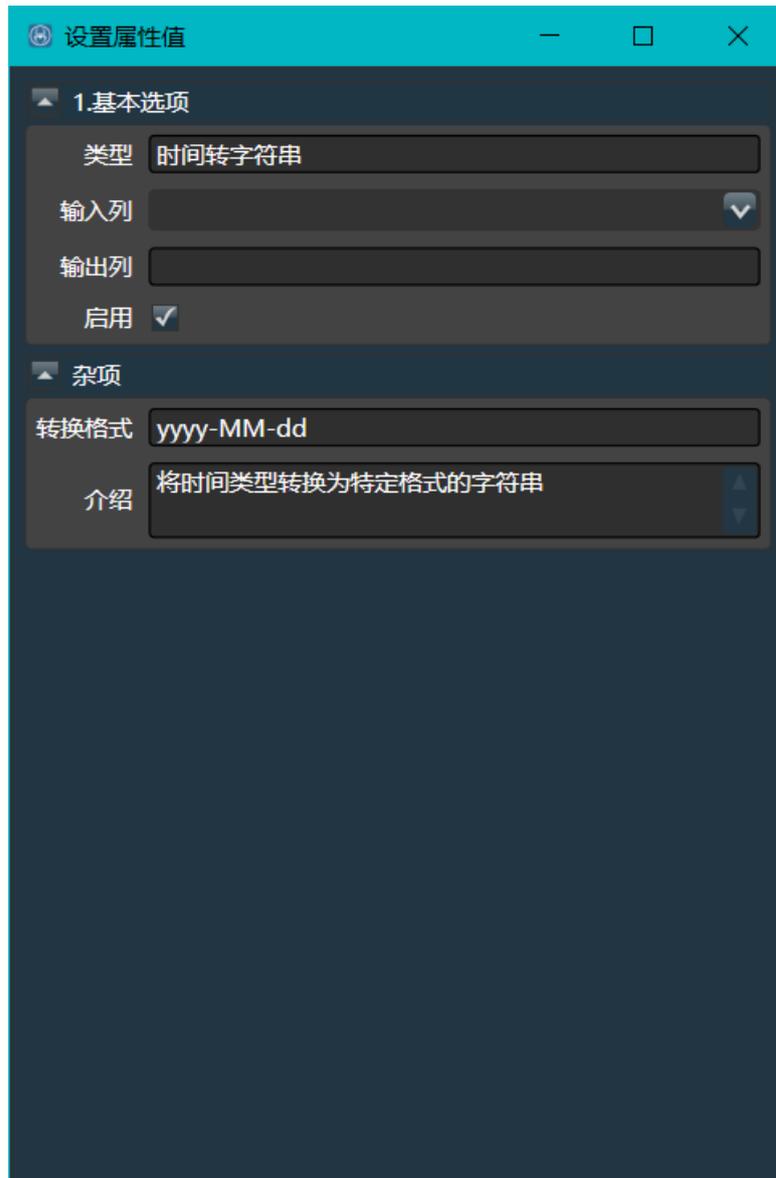
头数据过滤文件。

杂项：

- 爬虫选择：指定网页采集器。

3.1.15 时间转字符串

将时间类型转换为特定格式的字符串。



基本选项：

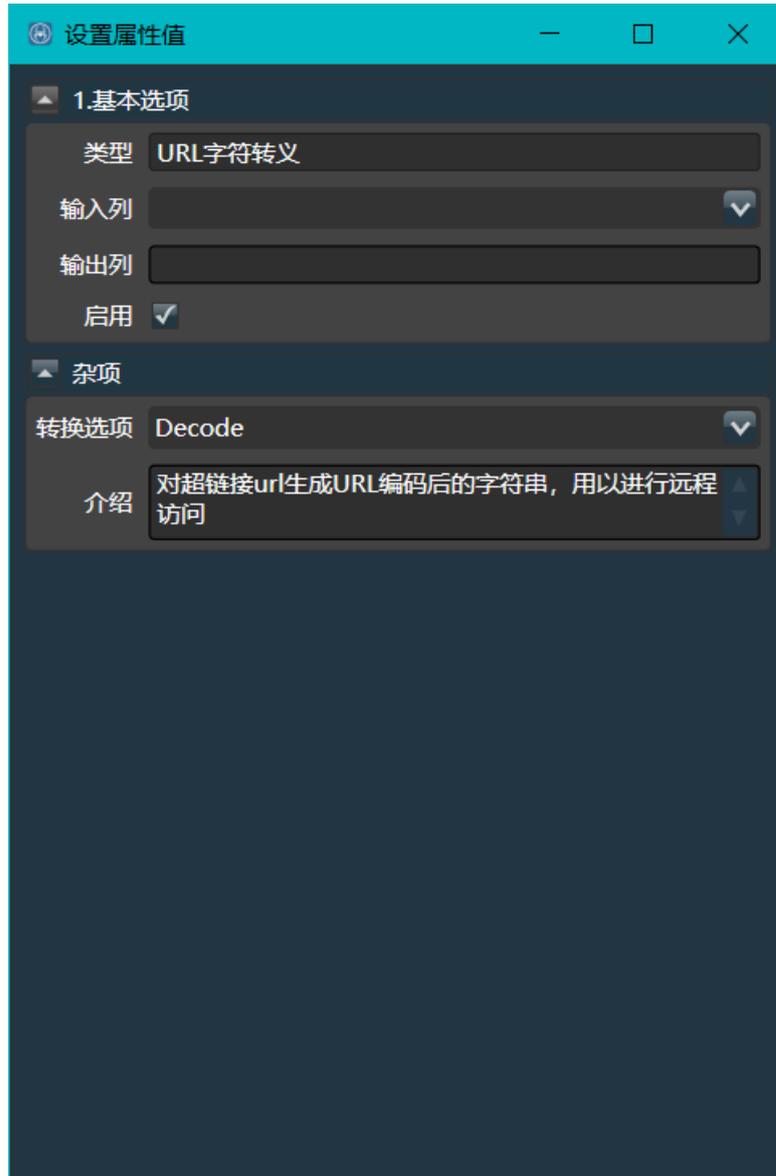
- 标签：自定义模块标签。
- 类型：时间转字符串。
- 原列名：待处理列（时间列）。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 转换格式：y 代表年，M 代表月，d 代表日，可自由组合格式。

3.1.16 URL 字符转义

对超链接 url 生成 URL 编码后的字符串，用以进行远程访问。



基本选项：

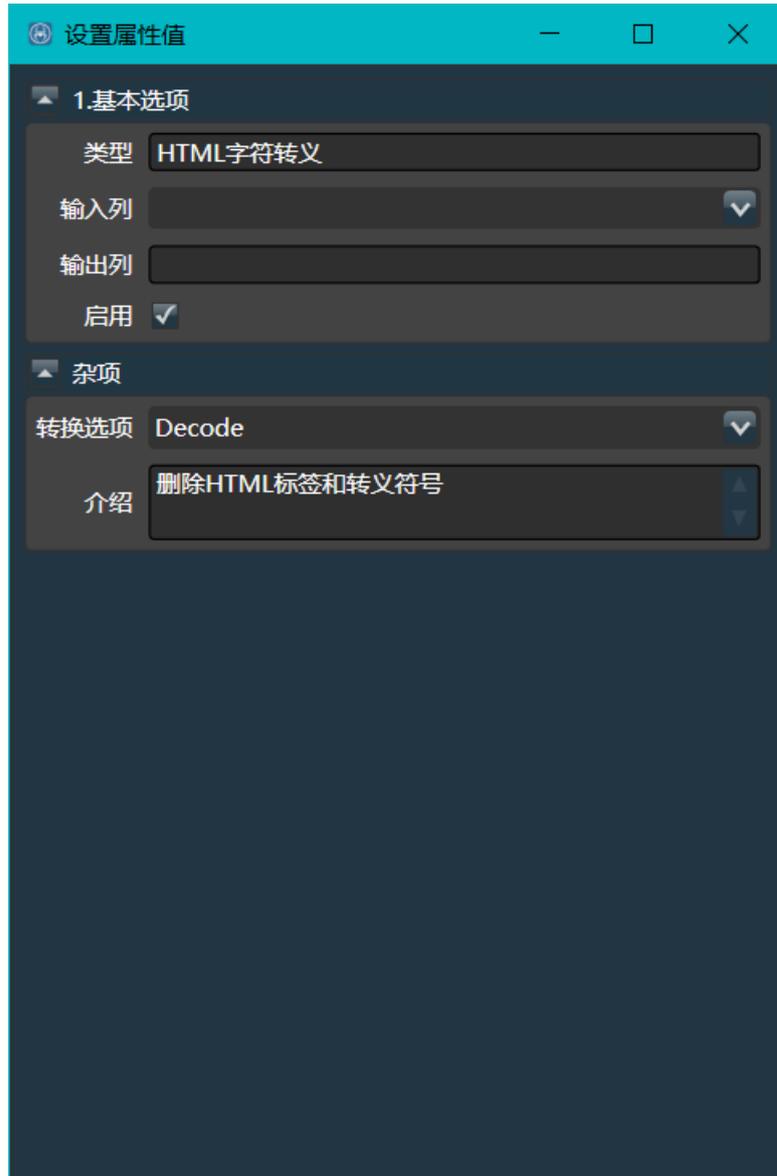
- 标签：自定义模块标签。
- 类型：URL 字符转义。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 转换选项：Decode，Encode。

3.1.17 HTML 字符转义

删除 HTML 标签和转义符号。



基本选项：

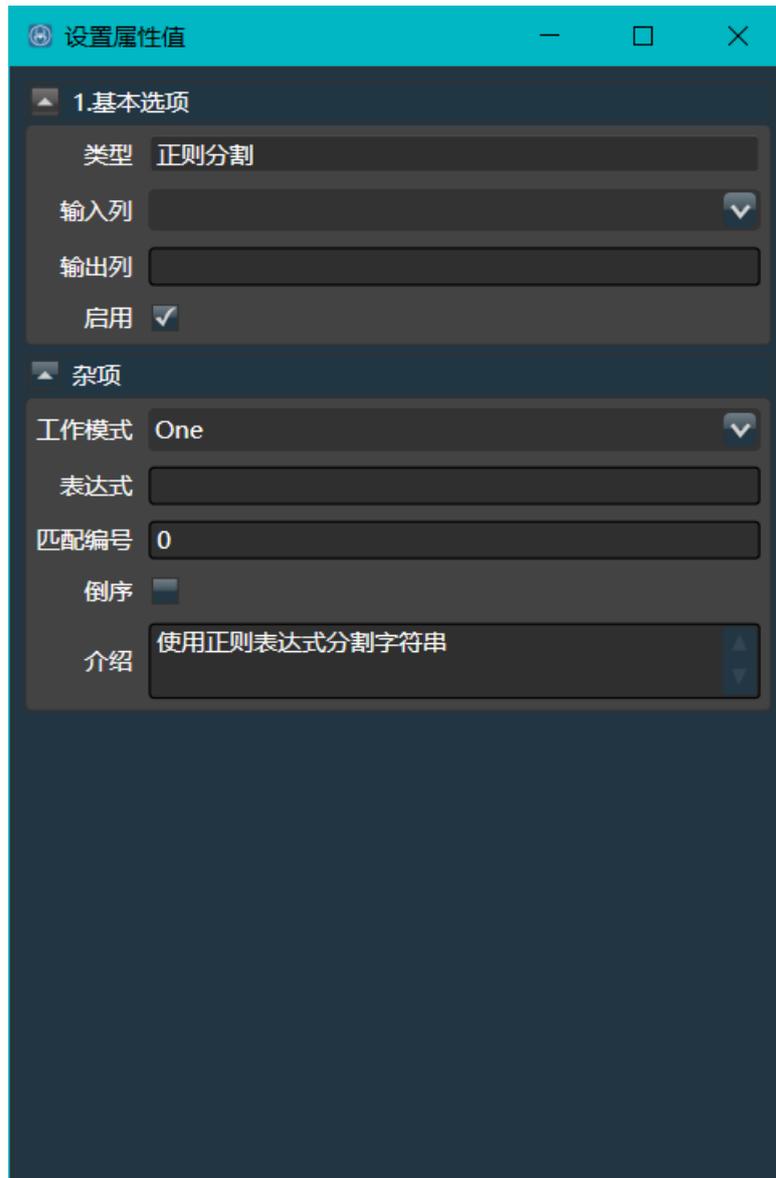
- 标签：自定义模块标签。
- 类型：HTML 字符转义。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 转换选项：Decode，Encode。

3.1.18 正则分割

使用正则表达式分割字符串。



基本选项：

- 标签：自定义模块标签。
- 类型：正则分割。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 倒序：选择此项，对字符串的处理顺序为倒序处理。
- 匹配编号：0 代表保留第一个匹配到的，1 代表保留第二个，以此类推。
- 表达式：正则表达式。

3.1.19 字符串分割

对字符串进行分割，可以指定风格字符，并通过匹配编号，保留指定匹配位置的信息。



基本选项：

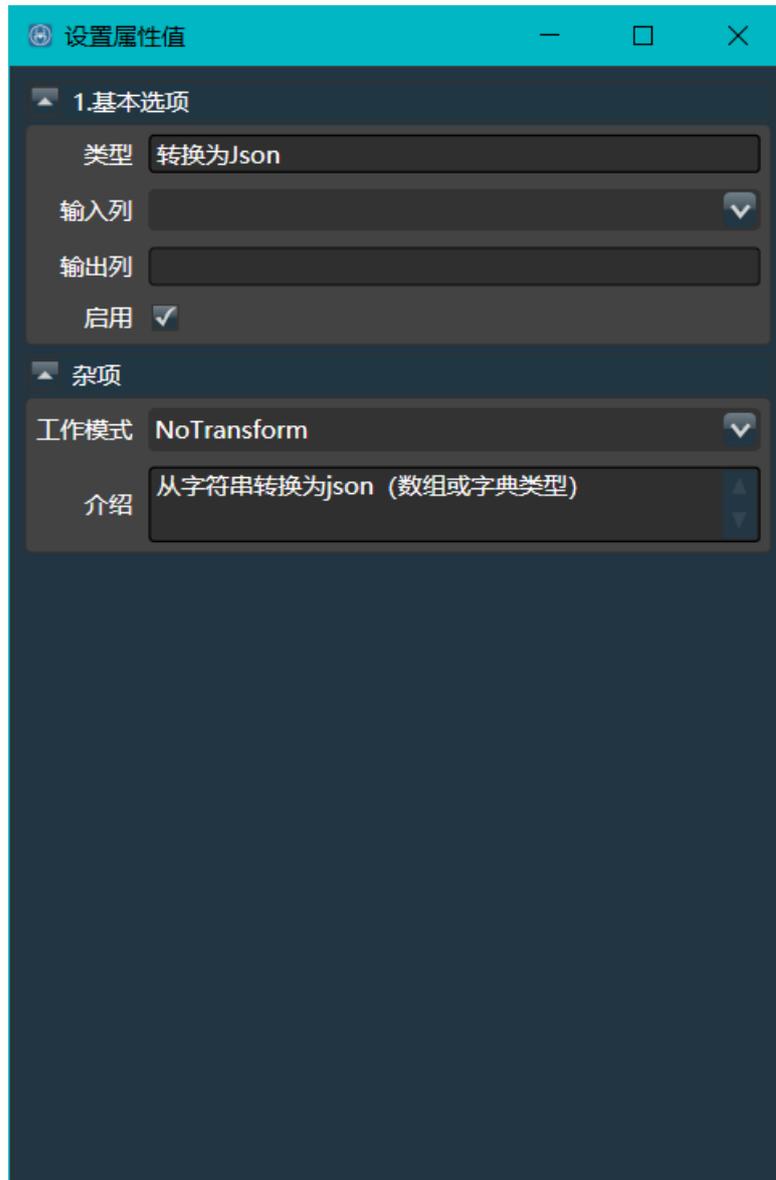
- 标签：自定义模块标签。
- 类型：字符串分割。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 倒序：选择此项，对字符串的处理顺序为倒序处理。
- 匹配编号：0 代表保留第一个匹配到的，1 代表保留第二个，以此类推。
- 分割字符：勾选表示选择指定字符进行分割。
- 换行分割：勾选表示通过换行符进行分割。
- 空格分割：勾选表示通过空格分割。
- 表达式：正则表达式。

3.1.20 转换为 Json

从字符串转换为 json（数组或字典类型）。



基本选项：

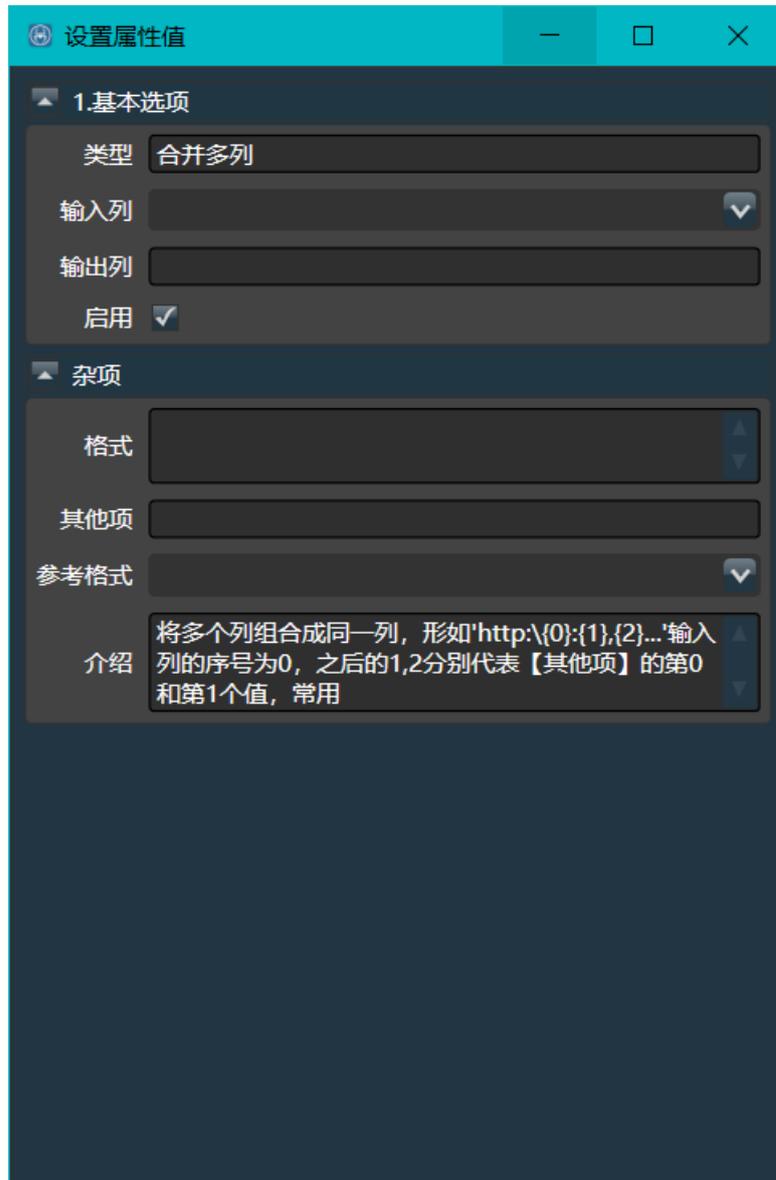
- 标签：自定义模块标签。
- 类型：转换为 Json。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 工作模式：可以转换为多种模式。

3.1.21 合并多列

将多个列组合成同一列，形如：http://.....{0}{1},本列的序号为 0，其他项为 1,2,3。



基本选项：

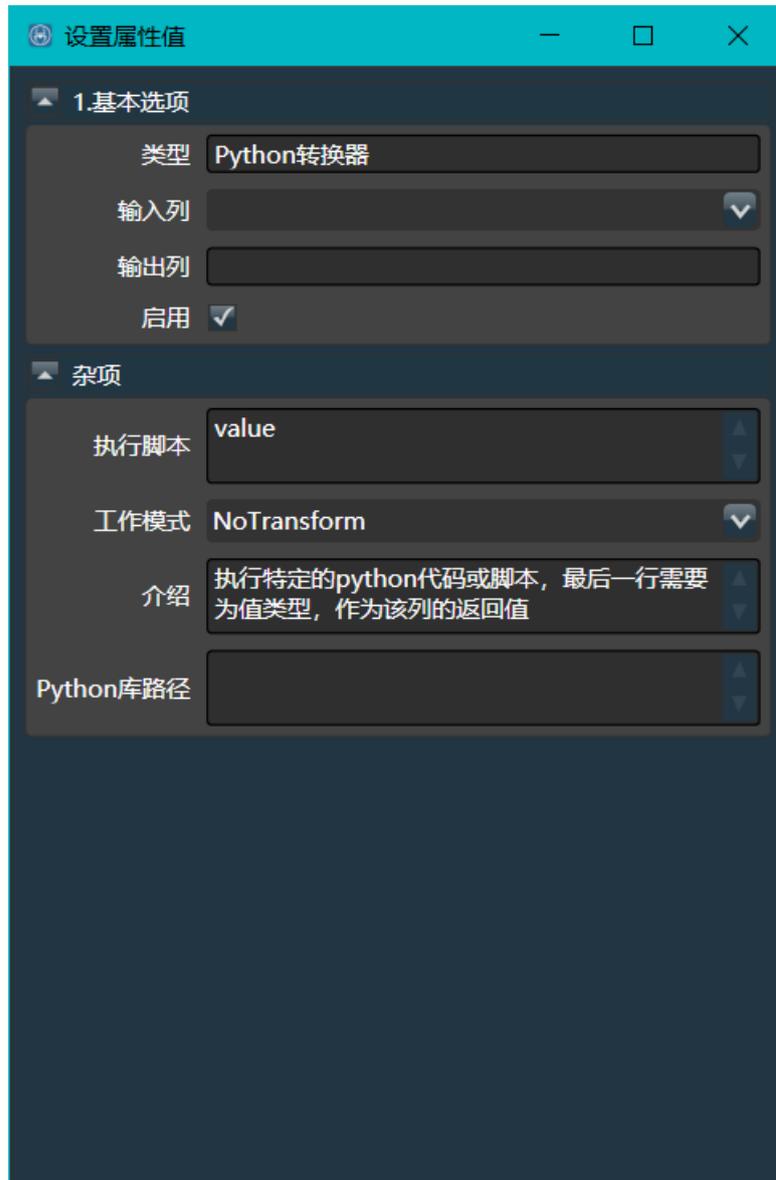
- 标签：自定义模块标签。
- 类型：合并多列。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- Format：指定新列格式，形如：http://.....{0}{1},本列的序号为 0，其他项为 1,2,3。
- 其他项：当前列之外的其他列，空格分割。

3.1.22 Python 转换器

执行特定的 python 代码。文档列表: [{}], 转换为多个数据行构成的列表; 单文档: {}, 将结果的键值对附加到本行; 不进行转换: 直接将值放入本列。



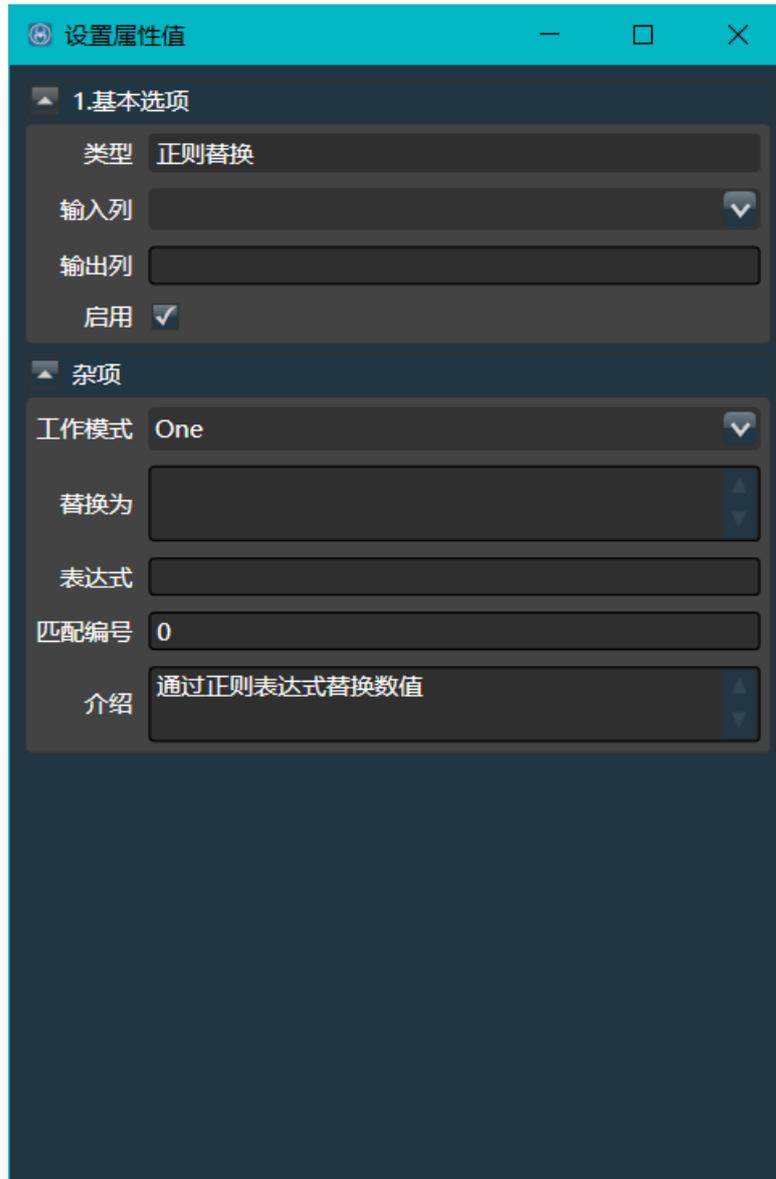
基本选项:

- 标签: 自定义模块标签。
- 类型: Python 转换器。
- 原列名: 待处理列。
- 新列名: 结果列。
- 启用: 是否启用该模块。

杂项:

- 执行脚本: 用于转换的自定义 Python 脚本。
- 工作模式: 可指定多种模式。

3.1.23 正则替换



基本选项：

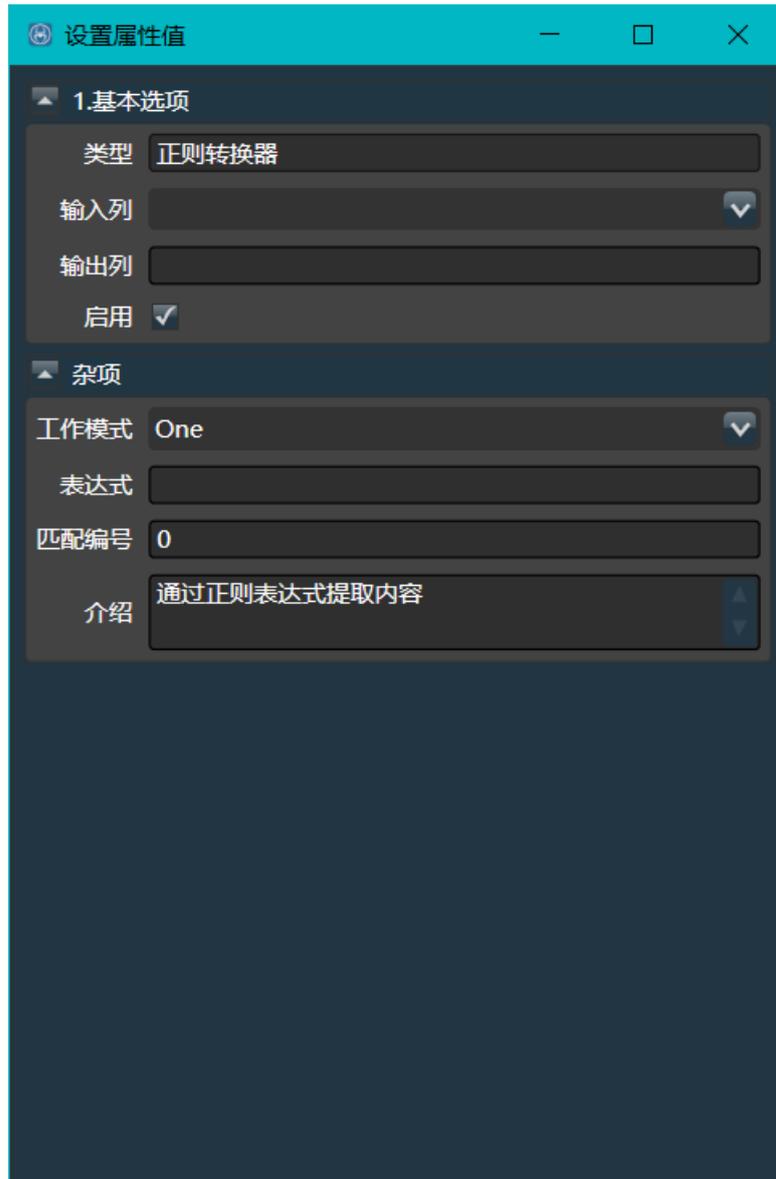
- 标签：自定义模块标签。
- 类型：正则替换。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 匹配编号：0 代表替换第一个匹配到的，1 代表替换第二个，以此类推。
- 替换为：需要替换的数值。
- 表达式：正则表达式。

3.1.24 正则转换器

通过正则表达式，对列的内容进行转换。



基本选项：

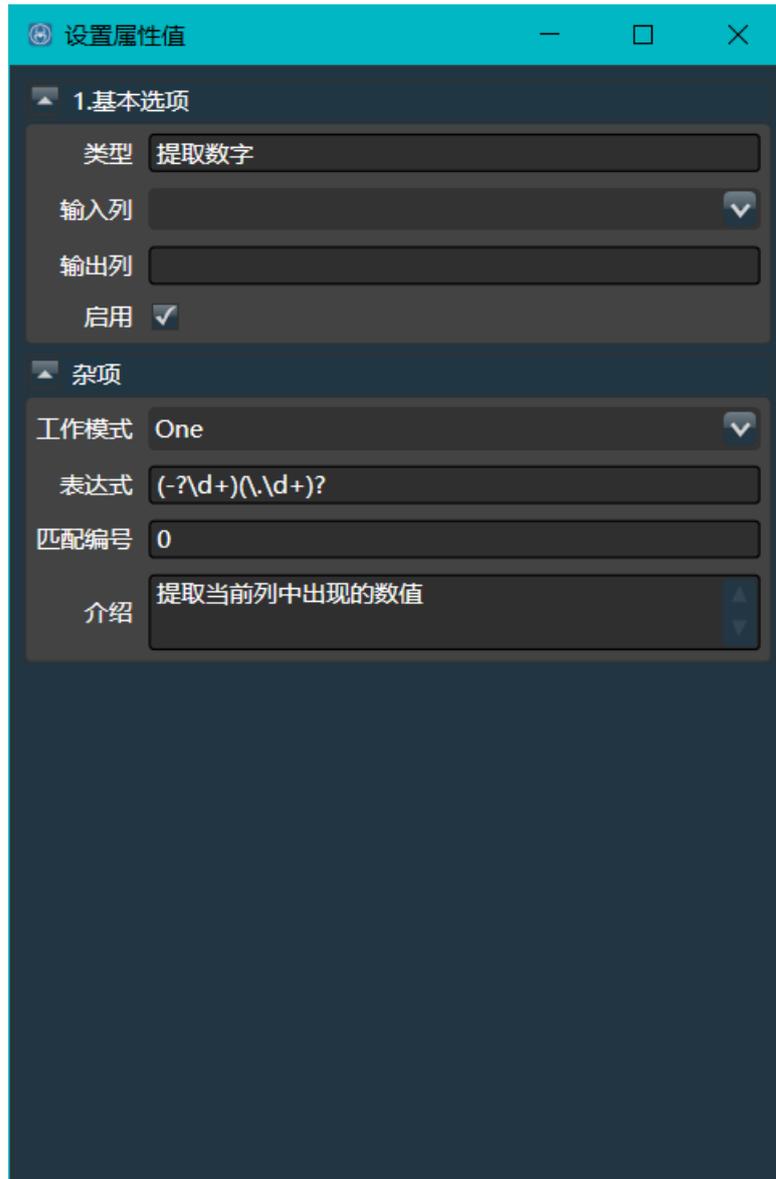
- 标签：自定义模块标签。
- 类型：正则转化器。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 匹配编号：若编号小于 0 且匹配出多个新列，列名可用空格分割，若该列不需要添加，可用_表示，如“_匹配 1_”。通过正则表达式提取内容。
- 表达式：正则表达式。

3.1.25 提取数字

提取当前列中的数字。



基本选项：

- 标签：自定义模块标签。
- 类型：提取数字。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 匹配编号：若编号小于 0 且匹配出多个新列，列名可用空格分割，若该列不需要添加，可用_表示，如“_匹配 1_”。通过正则表达式提取内容。
- 表达式：正则表达式。

3.1.26 字符首尾抽取

提取字符串中，从首串到尾串中间的文本内容。



基本选项：

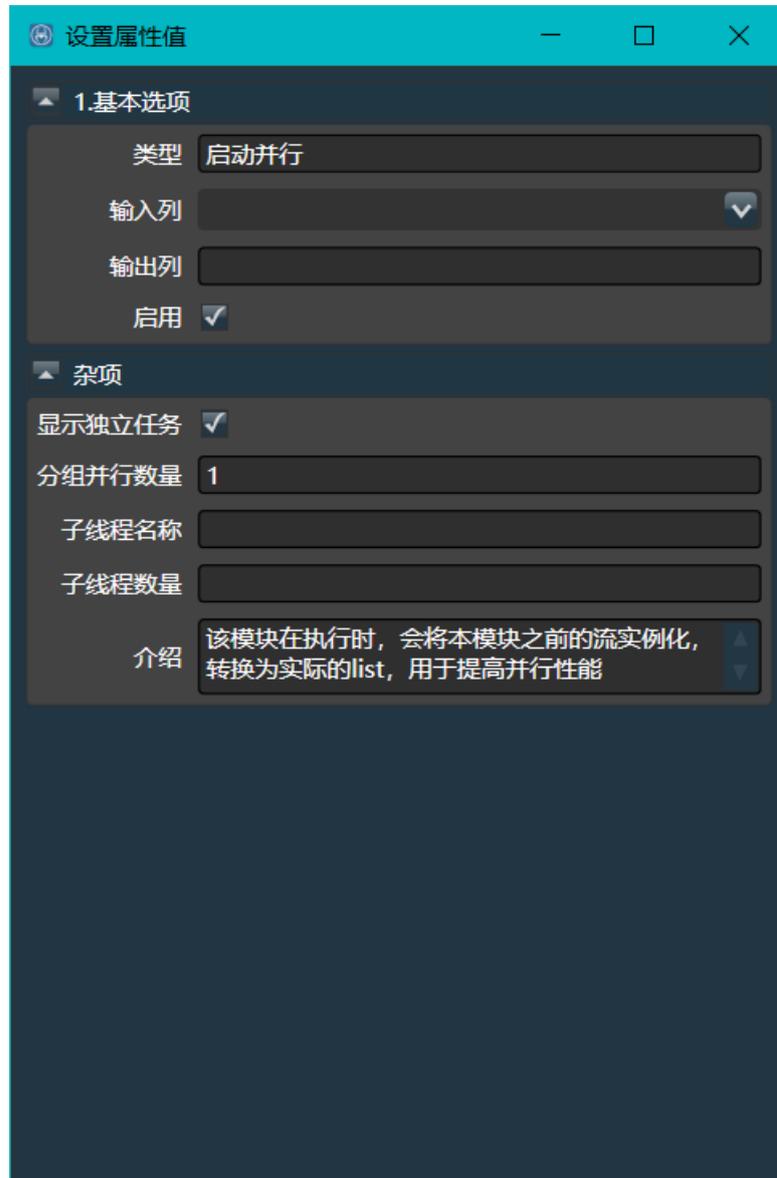
- 标签：自定义模块标签。
- 类型：字符首尾抽取。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 尾串：以该字符结尾。
- 首串：以该字符开始。
- 包含首尾串：勾选此项，提取串要包含首尾串。

3.1.27 启动并行

对多个种子合并为一个任务执行,这对于小型种子任务可以有效提升效率。该模块在执行时,会将本模块之前的流实例化,转换为实际的 list,用于提高并行性能。



基本选项:

- 标签: 自定义模块标签。
- 类型: 启动并行。
- 原列名: 待处理列。
- 新列名: 结果列。
- 启用: 是否启用该模块。

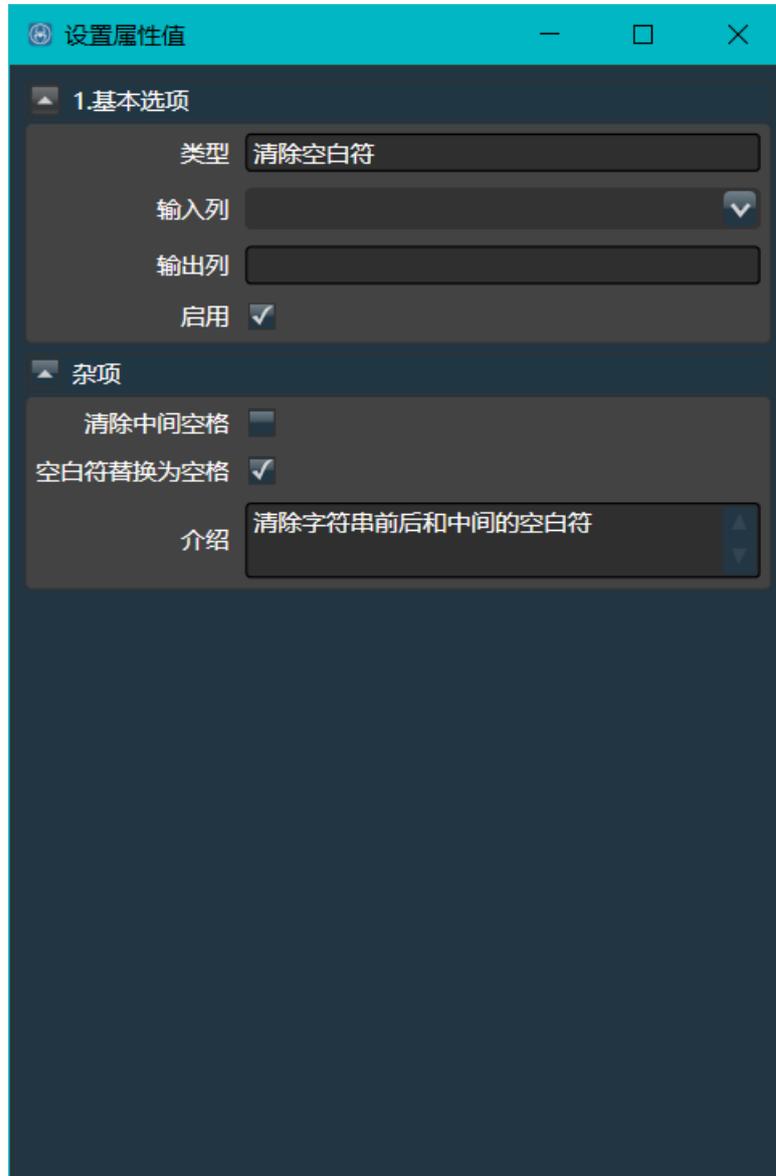
杂项:

- 显示独立任务: 是否将每个子线程插入到任务队列中, 从而显示进度。
- 分组并行数量: 并行线程数量。
- 子线程名称: 指示子线程名称。

- 子线程数量：并行的数量。

3.1.28 清除空白符

清除字符串前后和中间的空白符。



基本选项：

- 标签：自定义模块标签。
- 类型：清除空白符。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 清除中间空格：勾选此项，清除中间空格。
- 空白符替换为空格：将空白符替换为空格。

3.1.29 读取文件文本

获取文件中的文本。



基本选项：

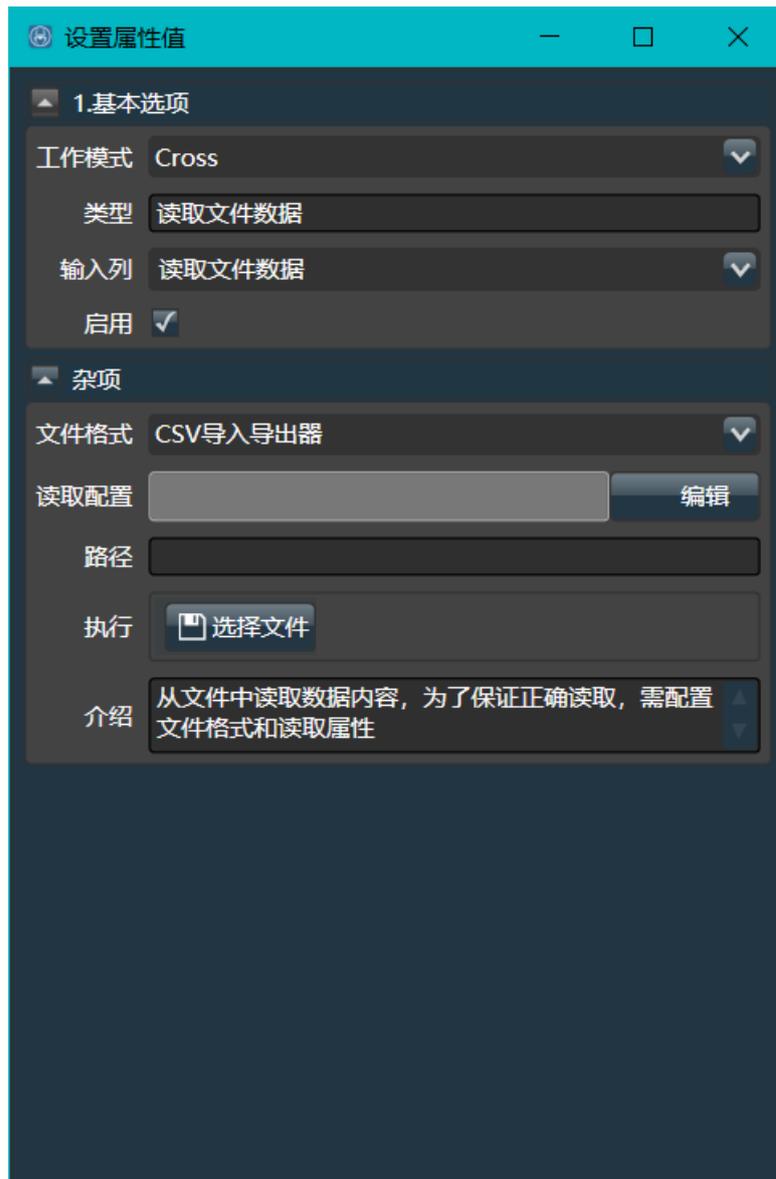
- 标签：自定义模块标签。
- 类型：读取文件文本。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

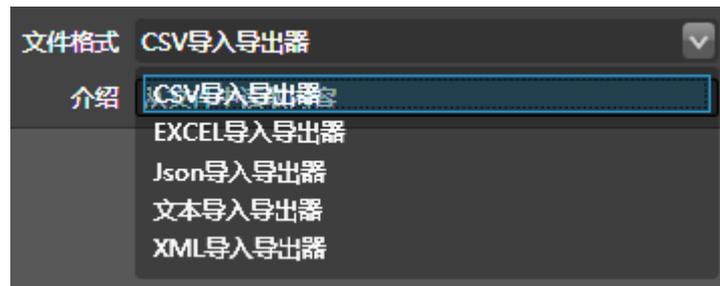
杂项：

- 编码：选择文本中的字符格式。

3.1.30 读取文件数据

从文件中读取内容。





基本选项：

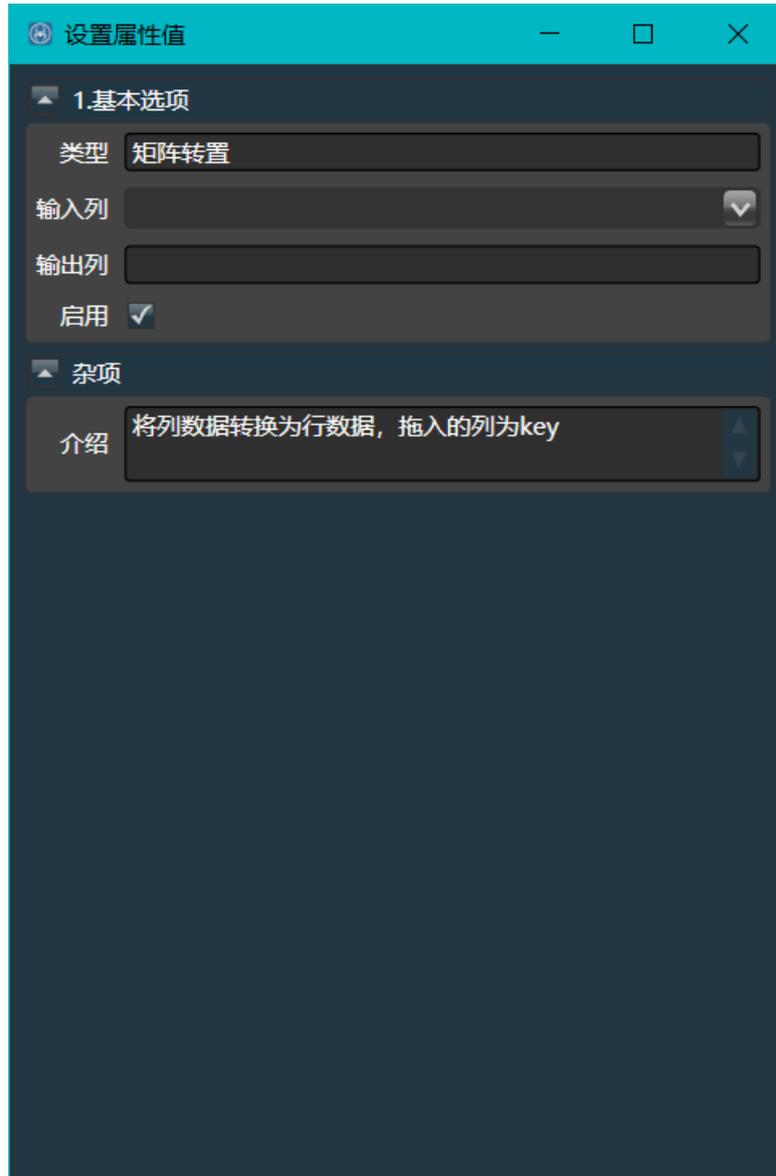
- 标签：自定义模块标签。
- 类型：读取文件数据。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 文件格式：提供包含 5 种文件格式的导入导出器（CSV,EXCEL,Json,文本,XML 五种格式）。

3.1.31 矩阵转置

将两列数据，转换为一行数据，拖入的列为 key。



基本选项：

- 标签：自定义模块标签。
- 类型：矩阵转置。
- 原列名：待处理列（key 列）。
- 新列名：结果列。
- 启用：是否启用该模块。

3.1.32 子任务-转换

从其他数据清洗模块中生成序列，用以组合大模块。



基本选项：

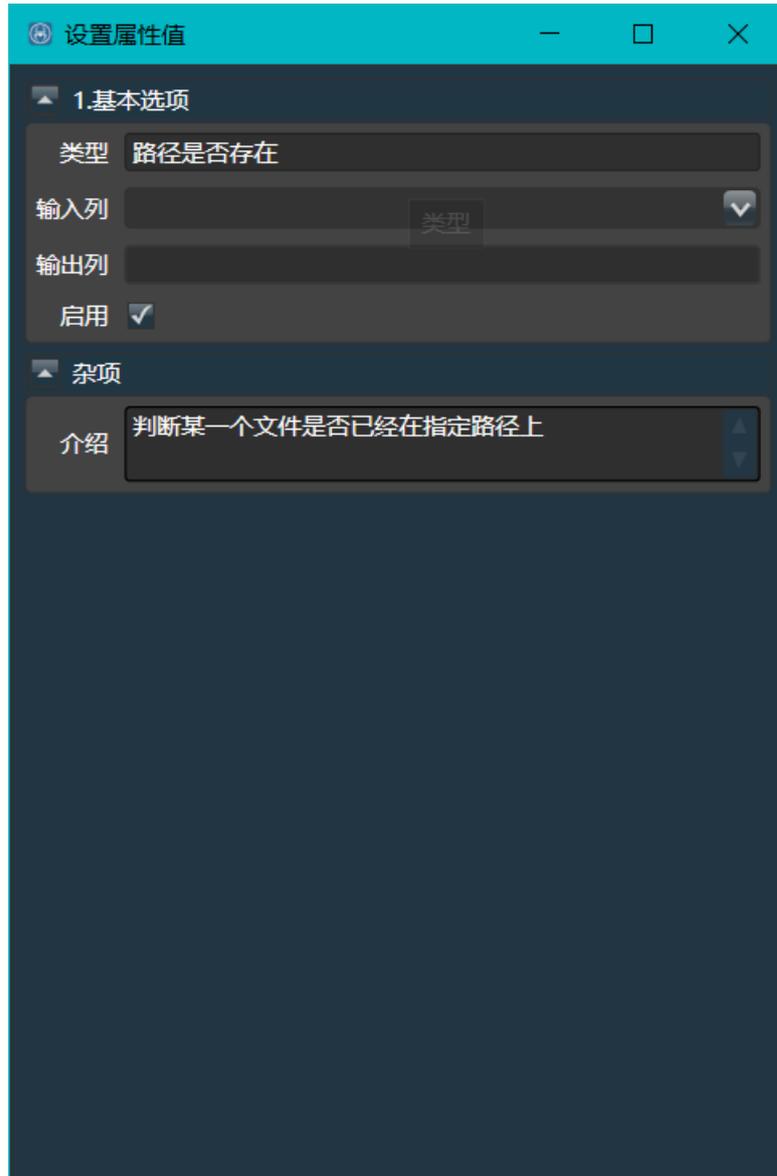
- 标签：自定义模块标签。
- 类型：子任务-转换。
- 原列名：待处理列。
- 启用：是否启用该模块。

杂项：

- 子任务-转换：输入 ETL 的任务名称。（子任务，指的是 ETL 数据清洗任务。）
- 递归到下列：勾选将递归到下列。
- 返回多个数据：勾选可以返回多个数据。
- 新列名：从原始数据中传递到子执行流中的列，多个列用空格分割。

3.1.33 路径是否存在

判断某一个文件是否已经在指定路径上。

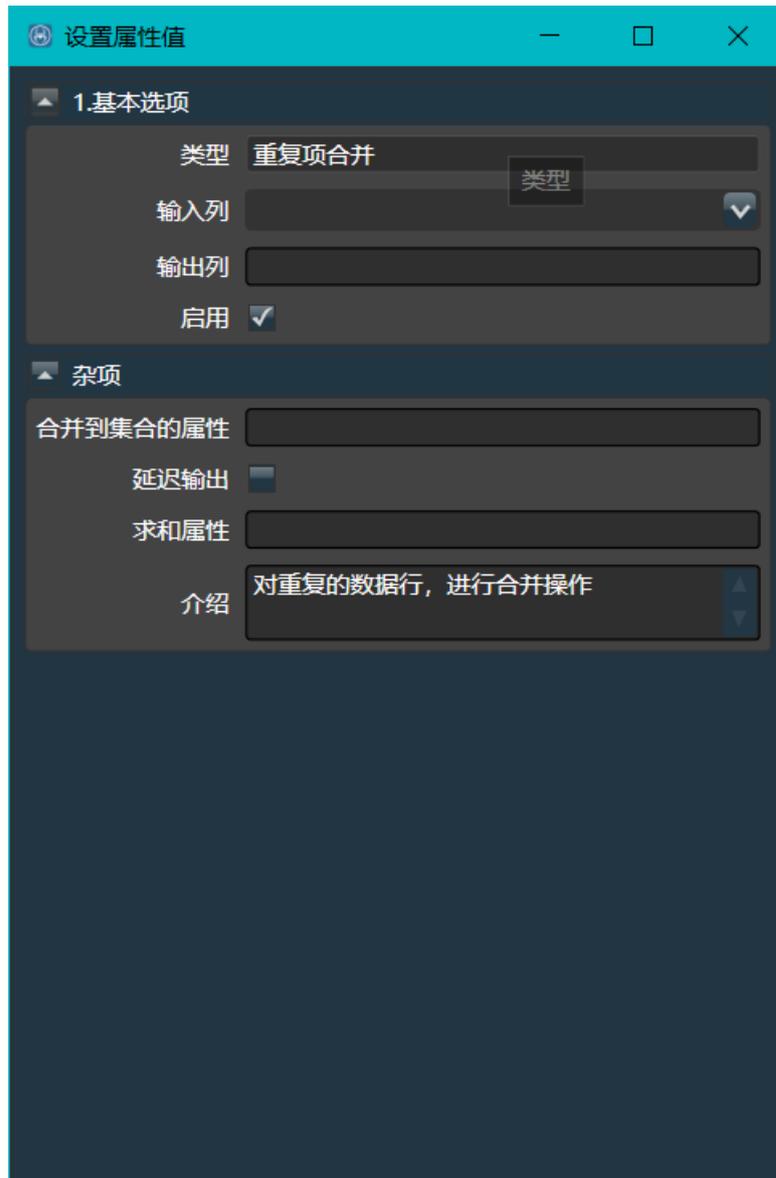


基本选项：

- 标签：自定义模块标签。
- 类型：路径是否存在。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

3.1.34 重复项合并

对重复的数据行，进行合并操作。



基本选项：

- 标签：自定义模块标签。
- 类型：重复项合并。
- 原列名：待处理列。
- 新列名：结果列。
- 启用：是否启用该模块。

杂项：

- 集合式合并键：空格分割的列名，键相同的写入同一个集合。
- 求和式合并键：空格分割的列名，键相同的所有项进行求和。

3.1.35 延时

在工作流中插入延时，单位为 ms，值为拖入列的值。



基本选项:

- 标签: 自定义模块标签。
- 类型: 延时。
- 原列名: 待处理列 (指定待延迟的时间)。
- 新列名: 结果列。
- 启用: 是否启用该模块。

3.1.36 XPath 筛选器

通过 XPath 选取 html 中的子节点文档。



- 获取节点数量：提取符合条件的节点数量。
- 获取正文：勾选此项，会提取新闻中的正文， XPath 路径可为空。
- 获取正文 HTML：勾选此项，会提取新闻中的 HTML， XPath 路径可为空。
- 插入空行：勾选此项，每个页面后会插入一个空行。
- 获取多个数据：当要获取符合 XPath 语法的多个节点时，勾选此项。

3.2 执行类子模块

- 写入文件文本：写入文件中的文本。
- 子任务-执行：从其他数据清洗模块中生成序列，用以组合大模块。
- 数据库操作：进行数据库操作，包括写入和更新，拖入的列为表的主键。
- 保存超链接文件：目标列需要为超链接类型，会保存链接的文件，如图片，视频等。
- 写入数据库：将数据保存至软件的数据管理器中，之后可方便进行其他处理，拖入到任意一列皆可。

3.2.1 写入文件文本

写入文件中的文本。



- 编码：写入时的文本编码。
- 要写入文件的完整路径：注意要提前建好文本文件，给出完整路径。

3.2.2 子任务-执行

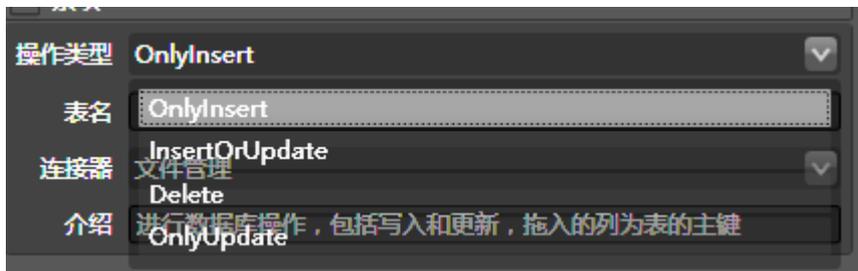
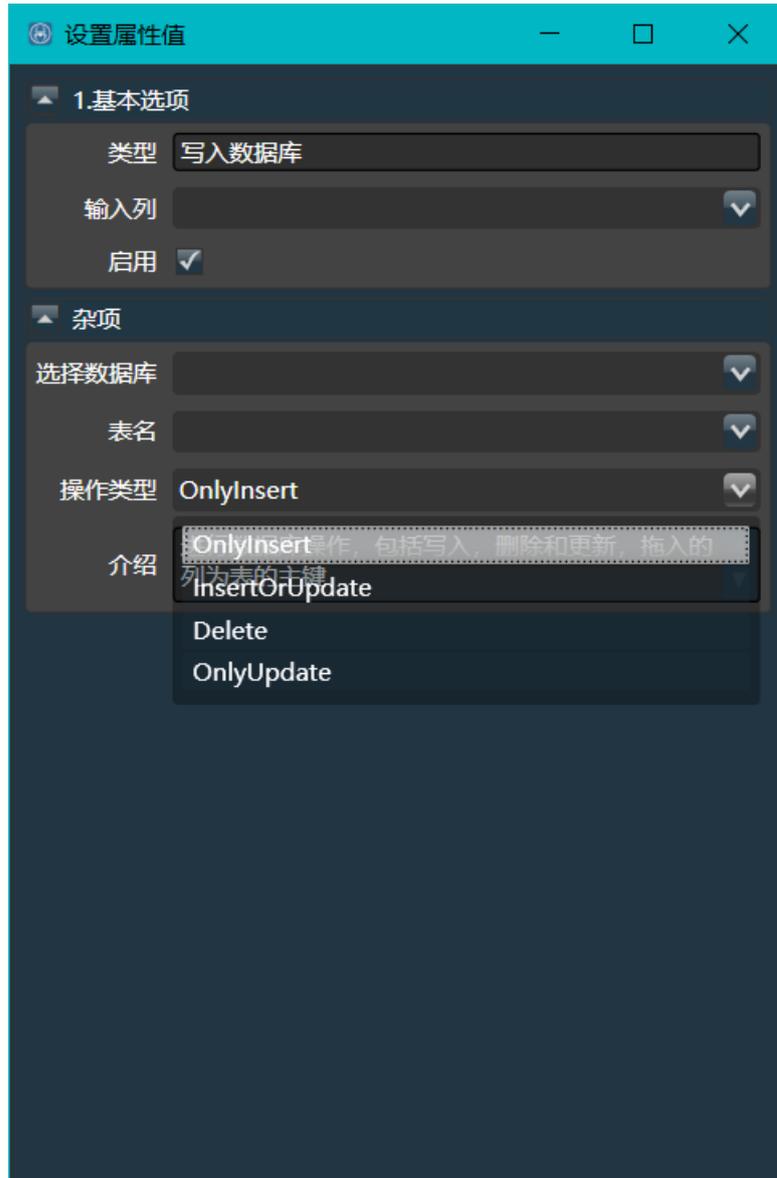
从其他数据清洗模块中生成序列，用以组合大模块。



- 子任务-选择：选择子任务任务。
- 新列名：从原始数据中传递到子执行流中的列，多个列用空格分割。

3.2.3 数据库操作

进行数据库操作，包括写入和更新，拖入的列为表的主键。



- 操作类型：包括对数据库的增删改查。
- 连接器：选择数据源的连接器。
- 表名：拟操作的表名。

3.2.4 保存超链接文件

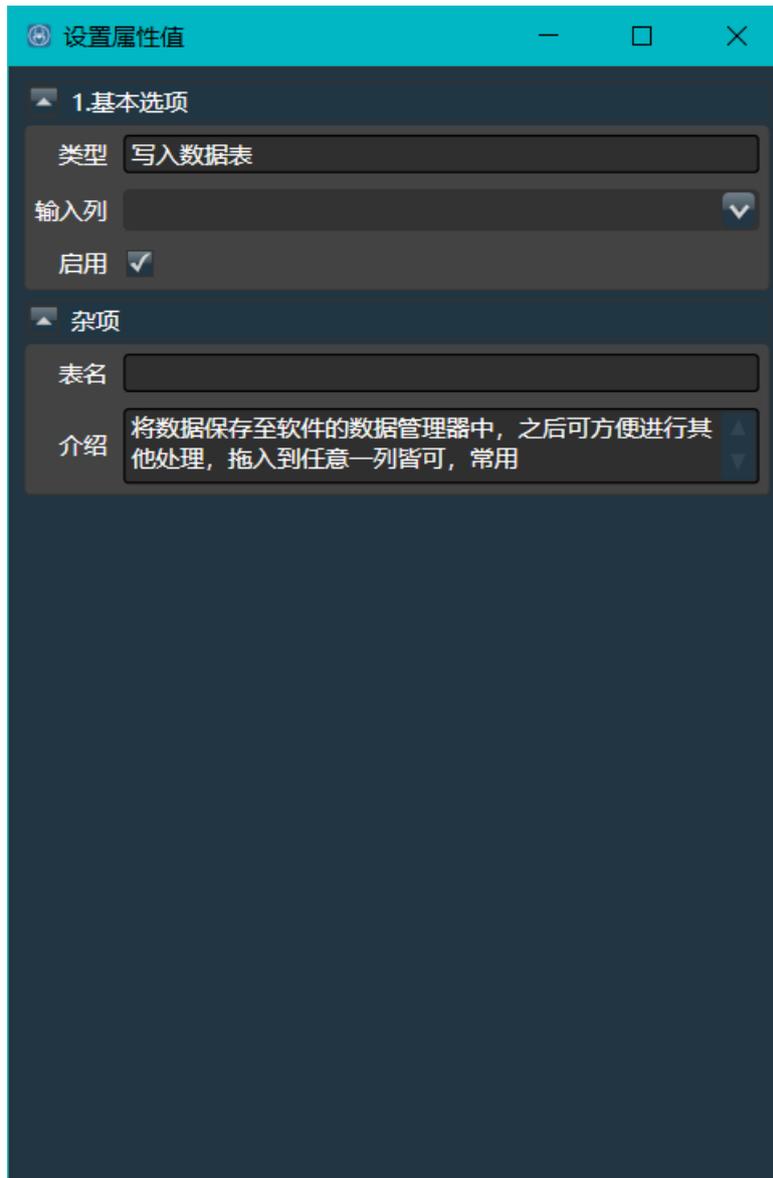
目标列需要为超链接类型，会保存链接的文件，如图片，视频等。



- 爬虫选择：要下载的文件链接。目标列需要为超链接类型，会保存链接的文件，如图片，视频等。
- 是否异步：通常选择异步进行。
- 保存位置：可以指定字段，存放保存路径。

3.2.5 写入数据库

将数据保存至软件的数据管理器中，之后可方便进行其他处理，拖入到任意一列皆可。



- 写入内存数据库中，可在数据视图浏览。

3.3 生成类子模块

- 获取文件夹文件：获取文件夹下的所有文件。
- 从连接器生成：从数据管理的连接器中生成序列。
- 生成区间数：生成某范围内的数值列。
- 从数据表生成：从数据管理中已有的数据表中生成。
- 从文本生成：每行一条数据，生成列。
- 请求队列
- 子任务-生成：从其他数据清洗模块中生成序列，用以组合大模块

3.3.1 获取文件夹文件

获取文件夹下的所有文件。



- 路径：指定路径，可以通过遍历，获取文件。
- 生成模式：提供多种生成模式。

3.3.2 从数据库生成

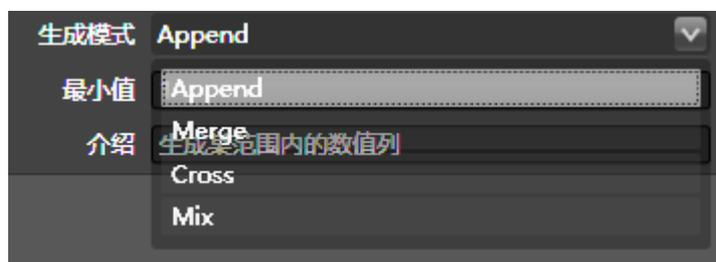
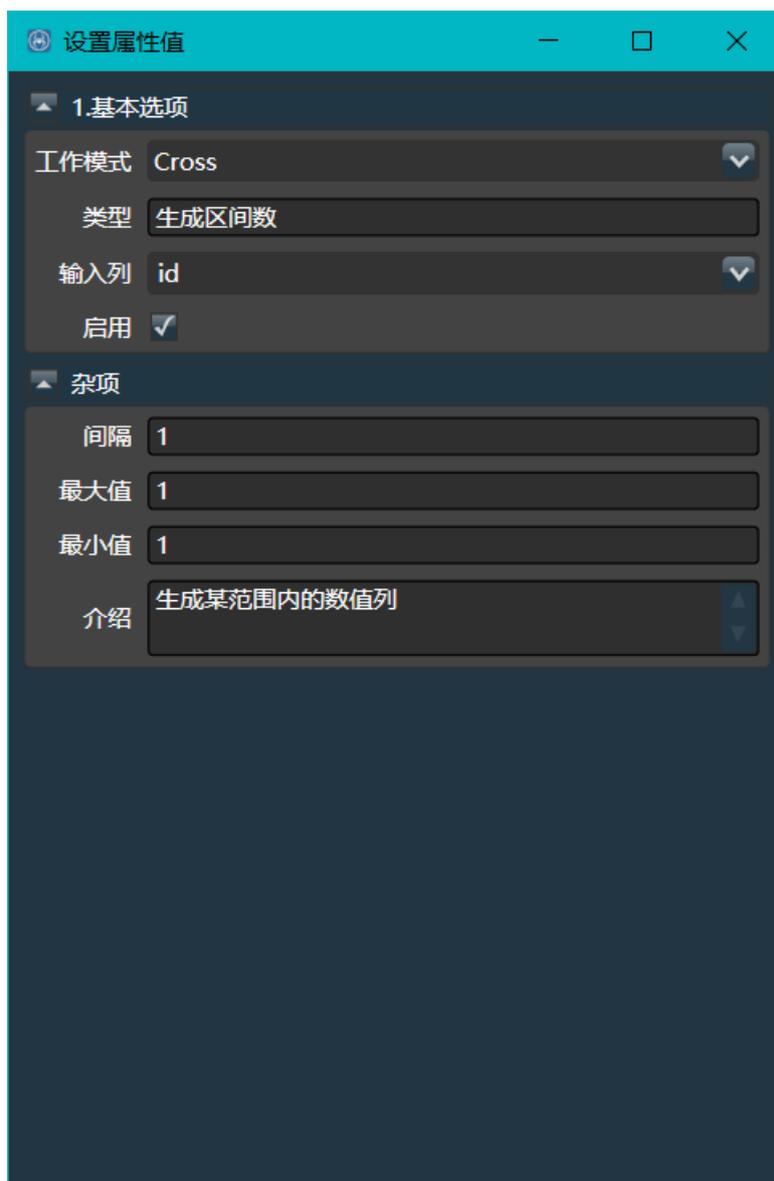
从数据管理的连接器中生成序列。



- 操作表名：指的是连接器选定后，所列出的表名。

3.3.3 生成区间数

生成某范围内的数值列。



- 最小值、最大值、间隔：生成最小值至最大值时间的数据，中间间隔可以自定义。

3.3.4 从数据表生成

从数据管理中已有的数据表中生成。



- 从数据管理中已有的数据表中生成。提供数据表。

3.3.5 从文本生成

每行一条数据，生成列。



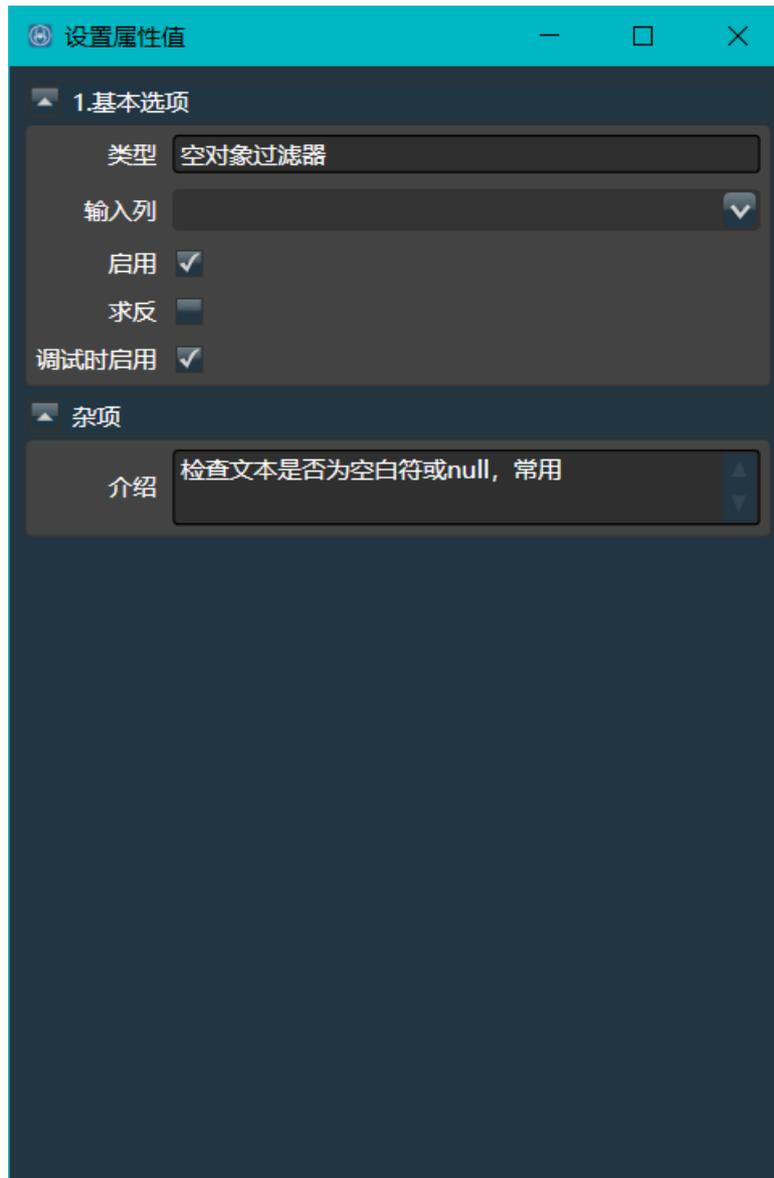
- 每行一条数据，生成列。

3.4 过滤类子模块

- 空对象过滤器：检查文本是否为空白符或 null。
- 数字范围过滤器：从数值列中筛选出从最小值到最大值范围的文档。
- 正则筛选器：编写正则表达式来过滤文本。
- 删除重复项：以拖入的列为键，自动去重，仅保留重复出现的第一项。
- 数量范围选择：选择一定数量的行，如跳过前 100 条，选取 50 条。

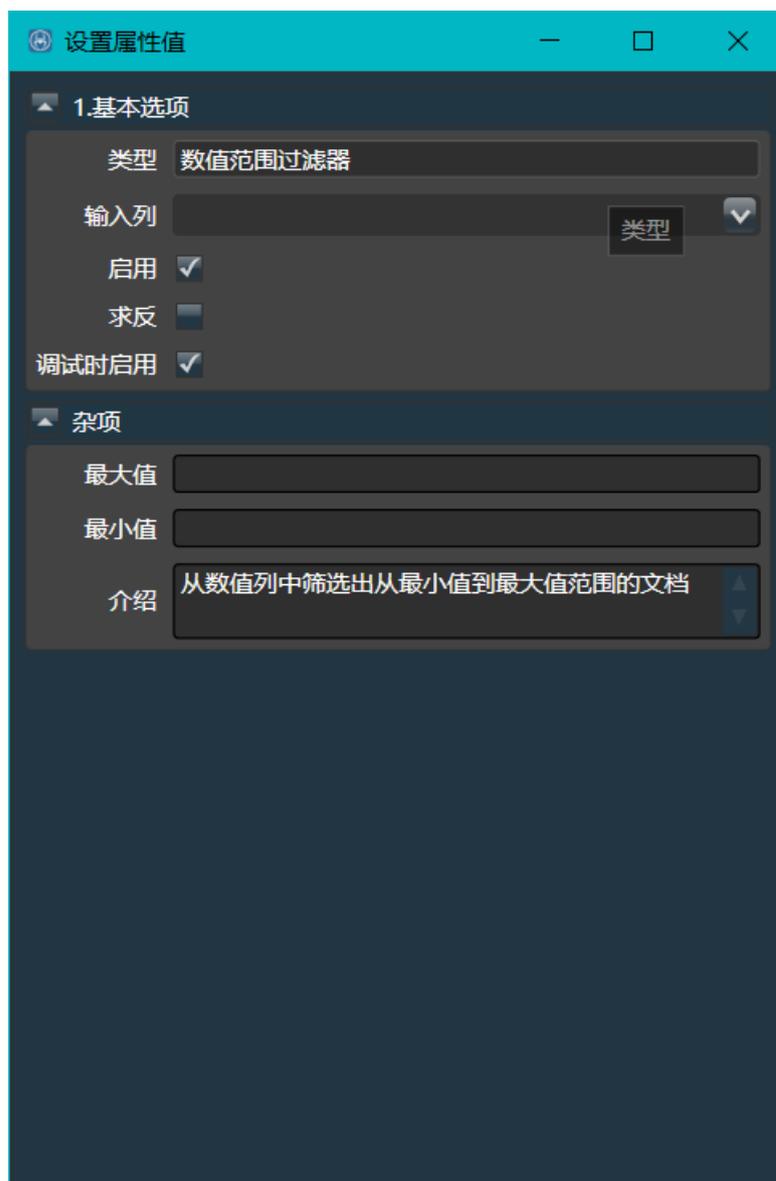
3.4.1 空对象过滤器

检查文本是否为空白符或 nul。



3.4.2 数字范围过滤器

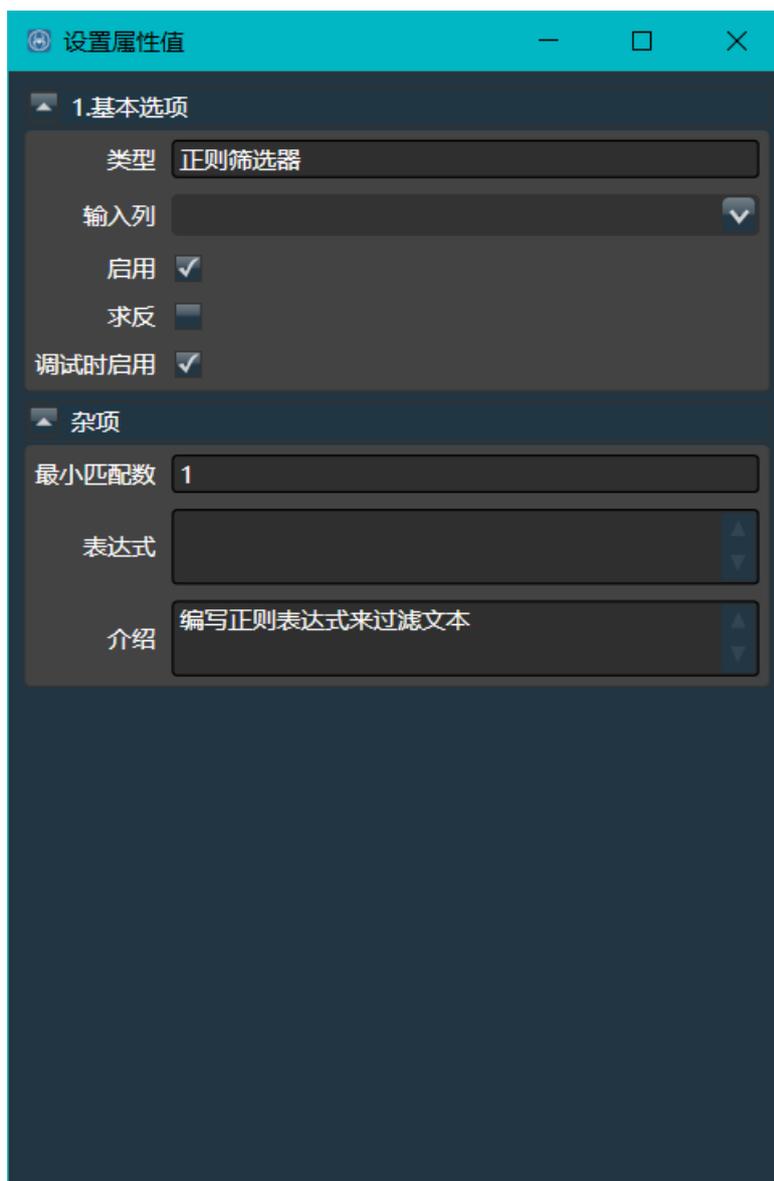
从数值列中筛选出从最小值到最大值范围的文档。



- 最大值、最小值: 分别制定范围。从数值列中筛选出从最小值到最大值范围的文档。

3.4.3 正则筛选器

编写正则表达式来过滤文本。



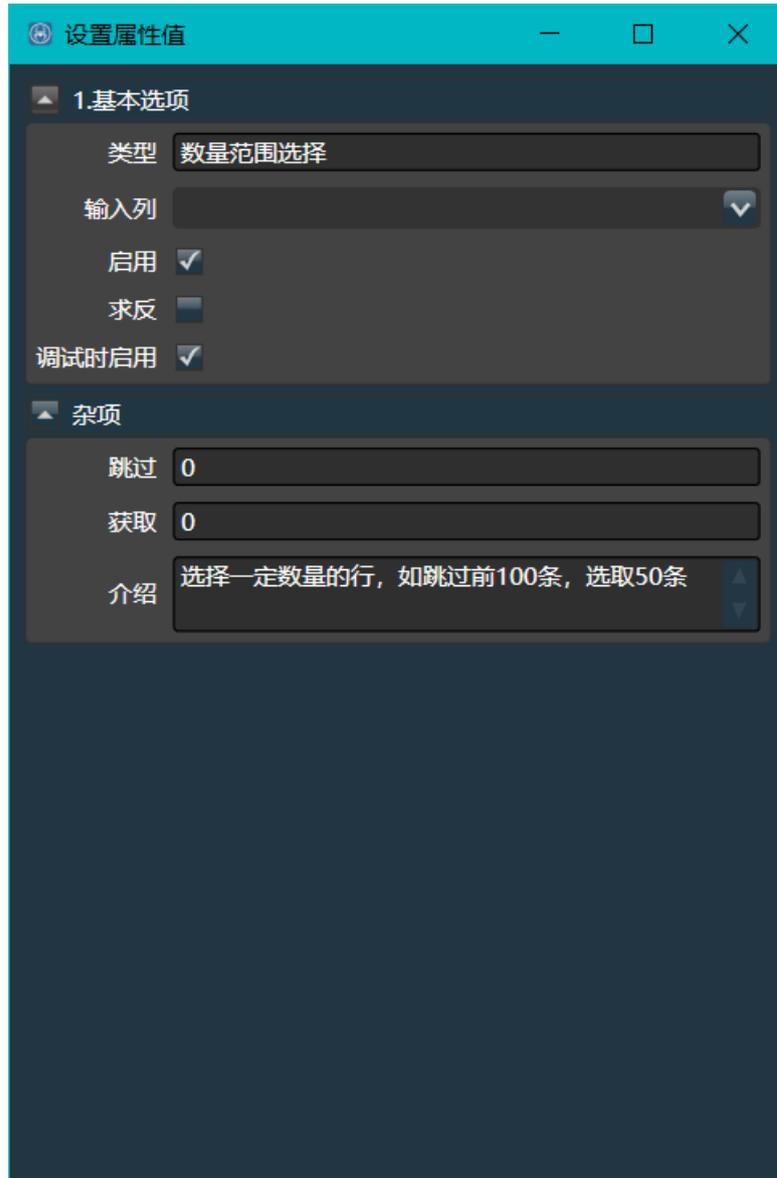
3.4.4 删除重复项

以拖入的列为键，自动去重，仅保留重复出现的第一项。



3.4.5 数量范围选择

选择一定数量的行，如跳过前 100 条，选取 50 条。

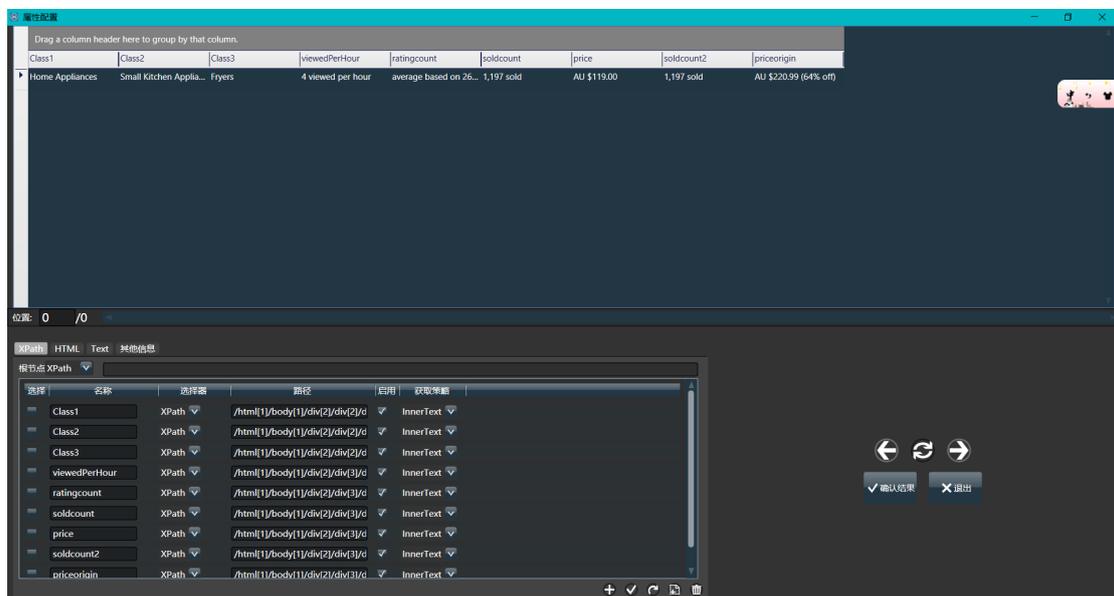
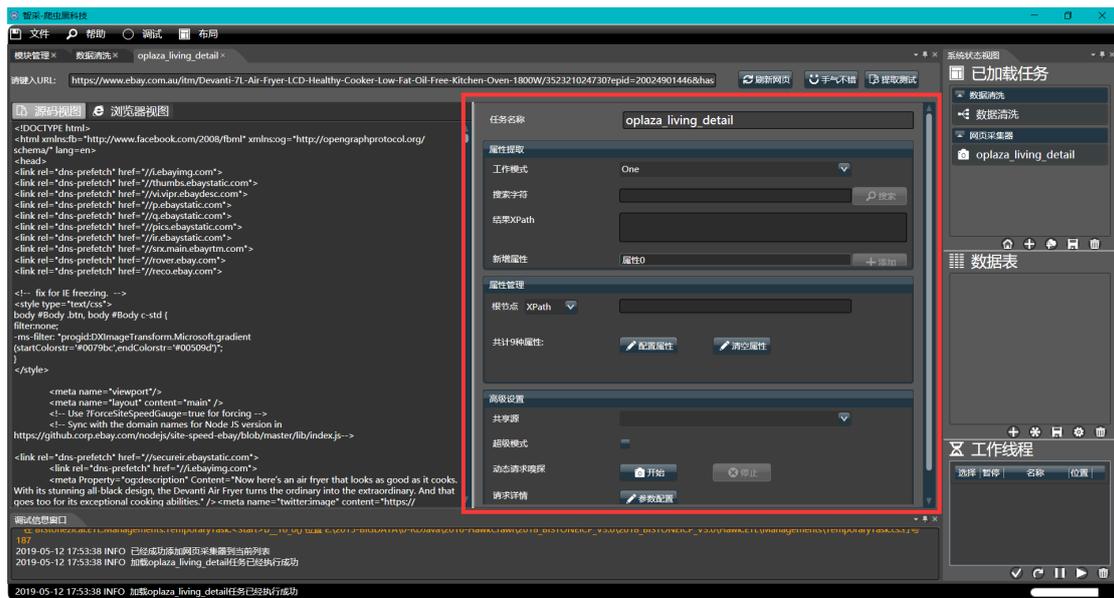


第4章 属性区

属性区，是配置两类主要任务属性的界面。网页采集任务的属性界面，用于指定链接的网页结构中，哪些内容是需要提取的。而数据清洗任务的属性界面，则提供了拖拽式工作流的画面，供组装工作流，预览结果，以及批量执行等功能。

4.1 网页采集器任务的属性配置器

网页采集器任务的属性配置界面如下。



基本信息

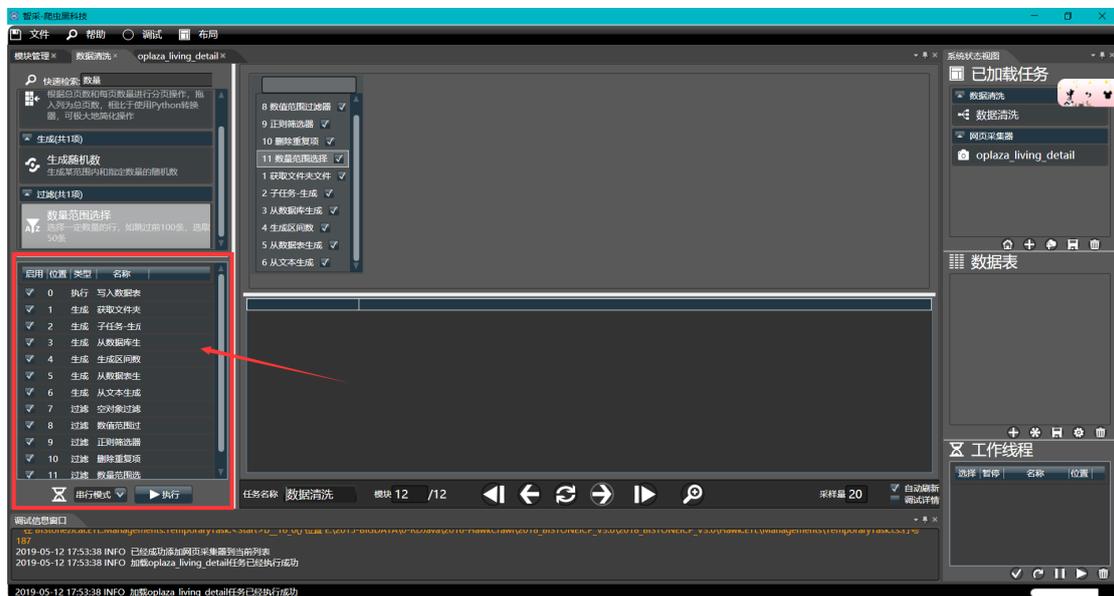
- 模块名称：可以自定义每个模块的名称。

属性提取

- 读取模式：分为 list 模式和 one 模式。前者，是指的一个网页可以生成多行数据；one 模式，指的一个网页对应一条数据。
- 搜索字符：输入想要提取的字符，系统自动搜索其 XPath 语法标记。
- 提取标签：勾选此项，系统可以进入到属性中进行字符搜索。
- 获取的 XPath：系统自动生成的 Xpath。
- 属性名称：对于提取的内容，一一命名，对应最终表格的字段，可以点击添加属性按钮进行添加，也可进行属性列表的编辑和清空操作。
- 手气不错：点击此按钮，系统可以自动搜索信息，节省 XPath 的配置时间。
- 提取测试：可以预览提取的结果。
- 父节点 XPath：所有节点公共的父节点 XPath。
- 请求详情：当前请求的头文件信息，可以更改，比如请求的字符格式等。

自动嗅探：系统提供的自动嗅探工具，帮助更好的了解结构。

4.2 数据清洗任务的属性配置器



基本信息

- 模块名称：可以自定义每个模块的名称。

清洗流程

- 已加载：模块列表，列出了所有模块所组成的工作流。可以编辑和修改。

调试

- 采样量：当前符合工作流的数据，进行采样。
- 命令：刷新当前工作流的运行态，弹出样例，查看目标数据。

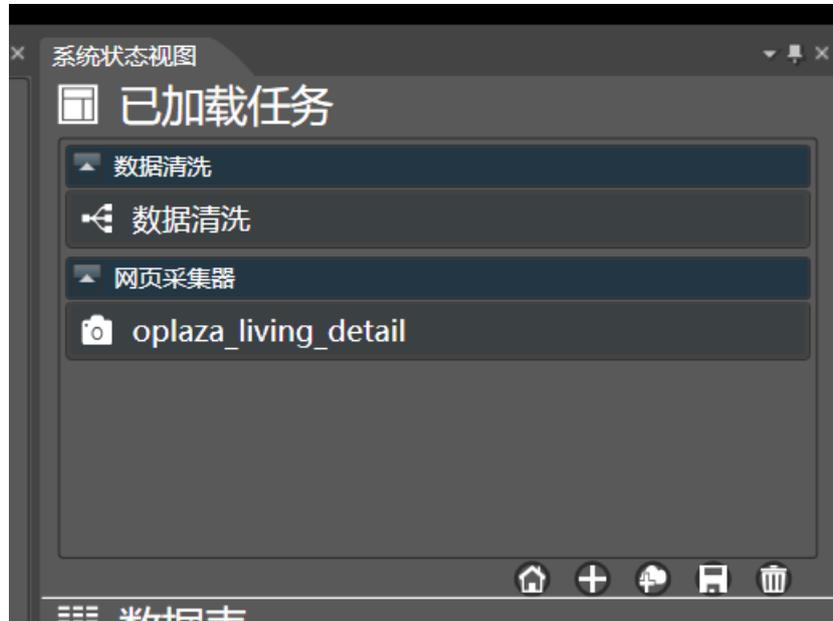
执行

- 工作模式：可以分为并行模式和串行模式。
- 最大线程数：可以自定义最大的线程数量。

第5章 活动资源区

5.1 算法视图

当前活动的网页采集、数据清洗任务列表，双击可以直接运行加载。右键鼠标，可以选择清空加载的任务，可以保存当前的任务。



5.2 数据视图

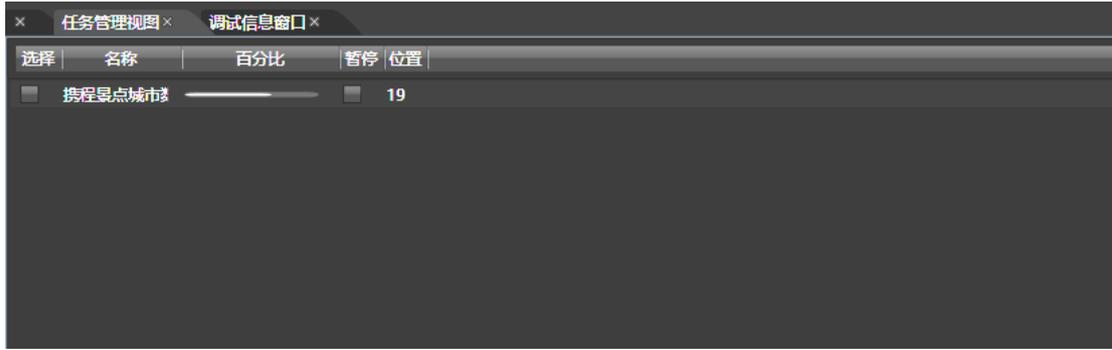
当前运行过程中的内存数据，可以鼠标右键点击任意一个数据，进行导出保存、预览等操作。也可以保存到数据源中。



第6章 日志区

6.1 任务管理视图

用于管理当前的任务，可以进行任务的暂停、删除等操作。



6.2 调试信息窗口

可以实时了解各项任务的运行情况。



第7章 信息监测服务示例

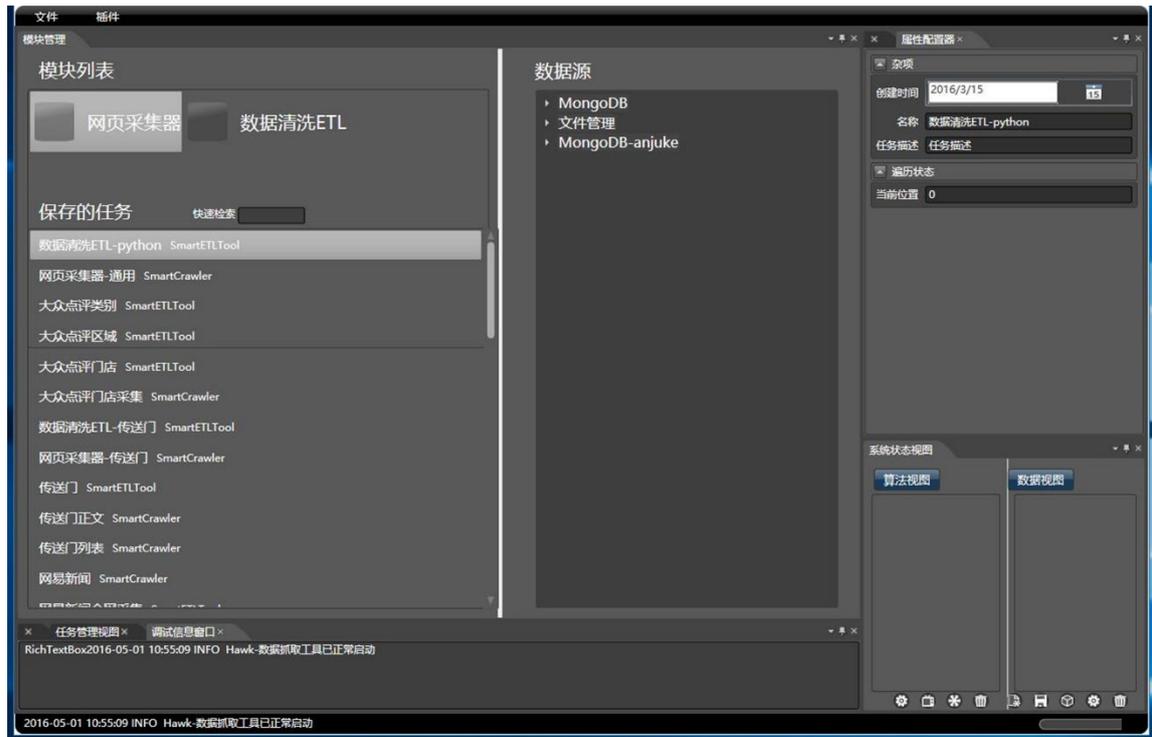
本文以抓取房地产网站链家为例，介绍了软件的整体使用流程，使用本软件可在 10 分钟内完成配置，在 1 小时之内自动并行抓取全部内容，并能监视子线程工作情况。而手工编写代码，即使是使用 python，一个熟练的程序员也可能需要一天以上：



7.1 界面和组件介绍

7.1.1 界面介绍

软件采用类似 Visual Studio 和 Eclipse 的 Dock 风格，所有的组件都可以悬停和切换。包括以下核心组件：



- 左上角区域：主要工作区，可模块管理。
- 下方： 输出调试信息，和任务管理，监控一项任务完成的百分比。
- 右上方区域： 属性管理器，能对不同的模块设置属性。
- 右下方区域： 显示当前已经加载的所有数据表和模块。

7.1.2 数据管理

能够添加来自不同数据源的连接器， 并对数据进行加载和管理：



在空白处，点击右键，可增加新的连接器。在连接器的数据表上，双击可查看样例，点击右键，可以将数据加载到内存中。

也可以选择加载虚拟数据集，此时系统会维护一个虚拟集合，当上层请求分页数据时，动态地访问数据库，从而有效提升性能。

7.1.3 模块管理

目前系统仅仅提供了两个模块：网页采集器和数据清洗 ETL，双击即可加载一个新的模块。



之前配置好的模块，可以保存为任务，双击可加载一个已有任务：



7.1.4 系统状态管理

当加载了数据集或模块时，在系统状态管理中，就可对其查看和编辑：

点击右键，可以对数据集进行删除，修改名称等。也可以将数据集拖拽到下方的图标上，如拖到回收站，即可删除该模块。

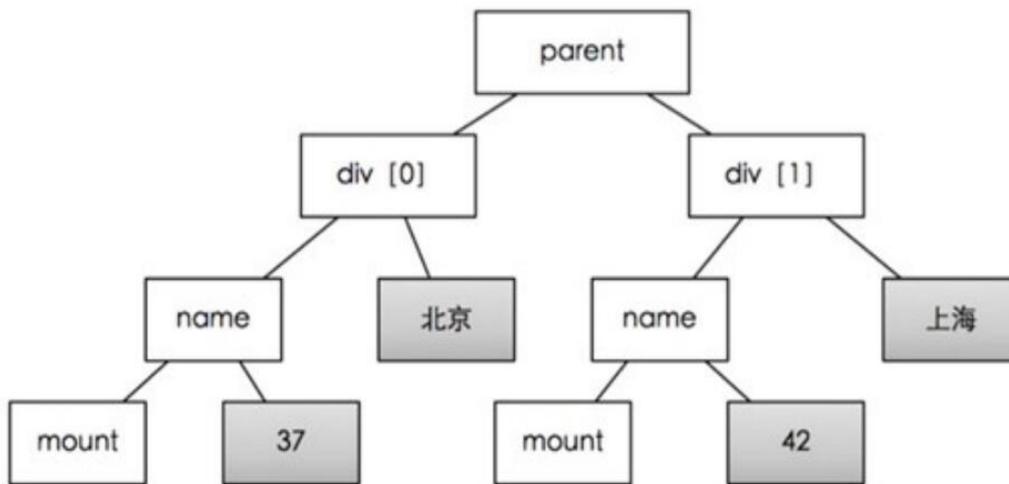
双击数据集或模块，可查看模块的内容。将数据集拖拽到数据清洗（数据视图的下方第一个图标），可直接对本数据集做数据清洗。



7.2 网页采集器

7.2.1 原理（建议阅读）

网页采集器的功能是获取网页中的数据。通常来说，目标可能是列表（如购物车列表），或是一个页面中的固定字段（如 JD 某商品的价格和介绍，在页面中只有一个）。因此需要设置其读取模式。传统的采集器需要编写正则表达式，但方法过分复杂。如果认识到 html 是一棵树，只要找到了承载数据的节点即可。XPath 就是一种在树中描述路径的语法。指定 XPath，就能搜索到树中的节点。



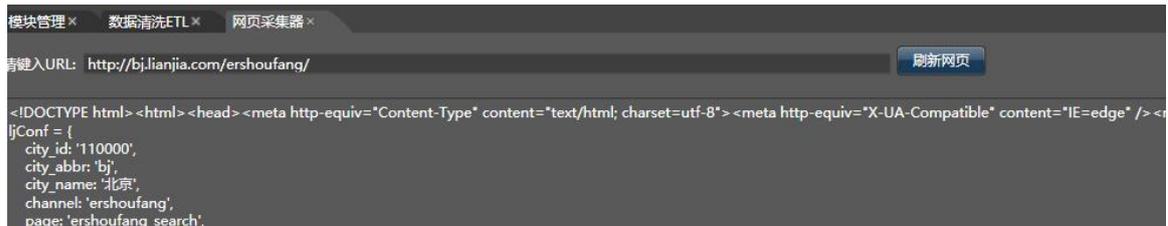
手工编写 XPath 也很复杂，因此软件可以通过关键字，自动检索 XPath，提供关键字，软件就会从树中递归搜索包含该数据的叶子节点。因此关键字最好是在页面中独一无二的。

如上图所示，只要提供“北京”和“42”这两个关键字，就能找到 parent 节点，进而获取 div[0]和 div1 这两个列表元素。通过 div[0]和 div1 两个节点的比较，我们就能自动发现相同的子节点（name, mount）和不同的节点（北京:上海, 37:42）。相同的节点会保存为属性名，不同的节点为属性值。但是，不能提供北京和 37，此时，公共节点是 div[0]，这不是列表。

软件在不提供关键字的情况下，也能通过 html 文档的特征，去计算最可能是列表父节点（如图中的 parent）的节点，但当网页特别复杂时，猜测可能会出错，所以需要至少提供两个关键字（属性）。

7.2.2 基本列表

我们以爬取链家二手房为例，介绍网页采集器的使用。首先双击图标，加载采集器：



在最上方的地址栏中，输入要采集的目标网址，本次是：

<http://bj.lianjia.com/ershoufang/>

并点击刷新网页。此时，下方展示的是获取的html文本。

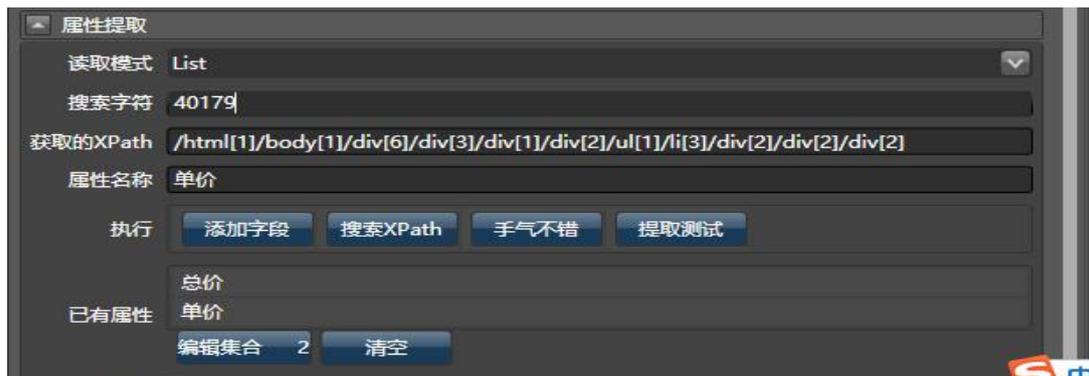
原始网站页面如下：

由于软件不知道到底要获取哪些内容，因此需要手工给定几个关键字，让系统搜索关键字，并获取位置。



以上述页面为例，通过检索 820 万和 51789（单价，每次采集时都会有所不同），我们就能通过 DOM 树的路径，找出整个房源列表的根节点。

下面是实际步骤：



由于要抓取列表，所以读取模式选择 List。填入搜索字符 700，发现能够成功获取 XPath，

7.3 数据清洗

数据清洗模块，包括几十个子模块，这些子模块包含四类：生成，转换，过滤和执行。



7.3.1 构造 url 列表

在前面介绍了如何实现一个页面的采集，但如何采集所有二手房数据呢？这涉及到翻页。



还是以链家为例，翻页时，我们会看到页面是这样变换的：

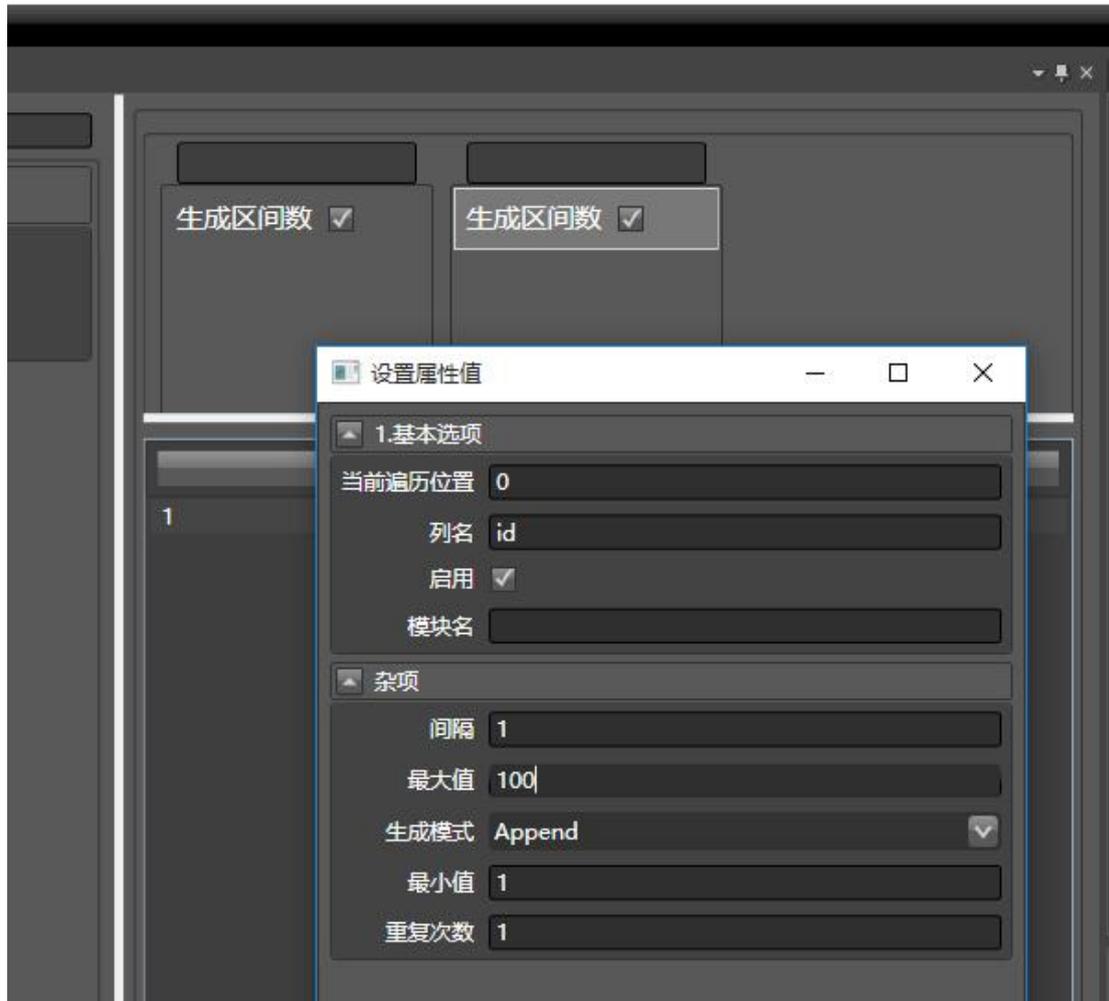
<http://bj.lianjia.com/ershoufang/pg2/>

<http://bj.lianjia.com/ershoufang/pg3/>

...

因此，需要构造一串上面的 url。聪明的你肯定会想到，应当先生成一组序列，从 1 到 100（假设我们只抓取前 100 页）。

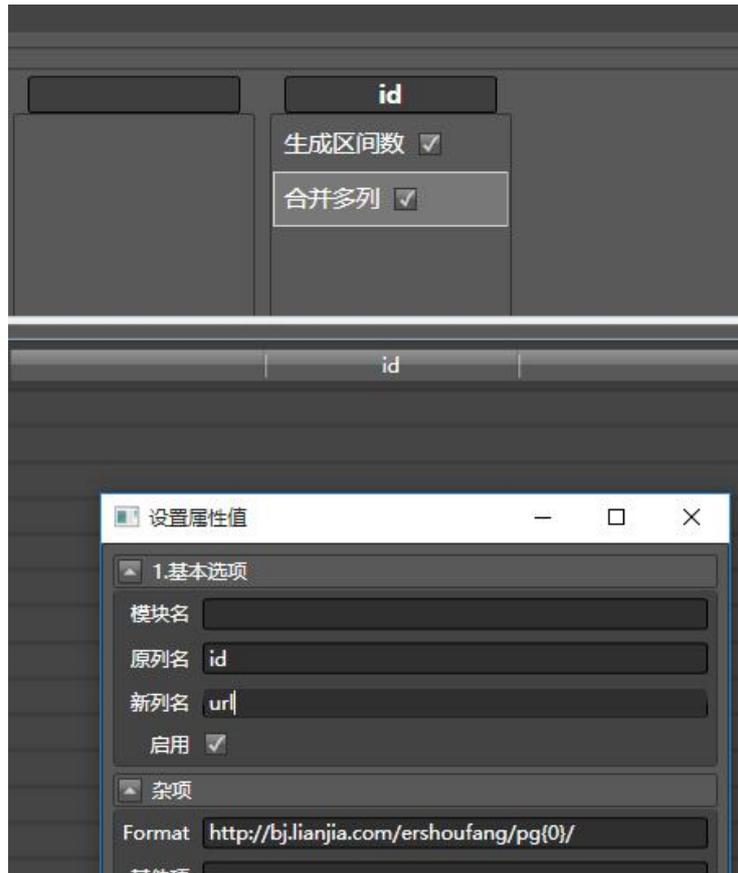
双击数据清洗 ETL 左侧的搜索栏中搜索生成区间数， 将该模块拖到右侧上方的栏目中：



在右侧栏目中双击生成区间数，可弹出设置窗口， 为该列起名字(id)， 最大值填写为 100, 生成模式默认为 Append：

为什么只显示了前 20 个？ 这是程序的虚拟化机制， 并没有加载全部的数据， 可在 ETL 属性的调试栏目中， 修改采样量（默认为 20）。

将数字转换为 url， 熟悉 C# 的读者， 可以想到 `string.format`， 或者 python 的 % 符号： 搜索合并多列， 并将其拖拽到刚才生成的 id 列， 编写 format 为下图的格式， 即可将原先的数值列变换为一组 url。



(如果需要多个列合并为一个列, 则在“其他项”栏目中填写其他列的列名, 用空格分割, 并在 *format* 中用 {1}, {2}.. 等表示)

(由于设计的问题, 数据查看器的宽度不超过 150 像素, 因此对长文本显示不全, 可以在右侧属性对话框点击[查看样例](#), 弹出的编辑器可支持拷贝数据和修改列宽。

7.3.2 使用配置好的网页采集器

生成这串 URL 之后, 我们即可将刚才已经完成的网页采集器与这串 url 进行合并。

拖拽从爬虫转换到当前的 url, 双击该模块: 将刚才的网页采集器的名称, 填入爬虫选择栏目中。

之后, 系统就会转换出爬取的前 20 条数据:

属性0	属性1	laisuzhou_	属性3	where_	属性5	属性6
观林园 有钥匙二居室 南北	观林园 有钥匙三居室 南北	观林园	3室2厅	140.43平米	南北	清河二手房
西直门 时代之光名苑 西南	西直门 时代之光名苑 西南	时代之光名苑	4室2厅	231.71平米	西南	西直门二手房
新华联南北通透 精装 免税	新华联南北通透 精装 免税	新华联家园南区	3室1厅	112平米	南北	果园二手房
满五唯一+南北通透+总价	满五唯一+南北通透+总价	天露园一区	3室2厅	128.11平米	南北	回龙观二手房
天通苑西三区【三朝南明卫	天通苑西三区【三朝南明卫	天通苑西三区	3室2厅	162.91平米	西南	天通苑二手房
南北通透 视野好 无遮挡大	南北通透 视野好 无遮挡大	万象新天一区	3室2厅	132.08平米	南北	常营二手房
季景沁园 全南2居 满五年唯	季景沁园 全南2居 满五年唯	季景沁园	2室2厅	110.33平米	南	望京二手房
果园 新华联家园南区 精装	果园 新华联家园南区 精装	新华联家园南区	3室2厅	126.71平米	南北	果园二手房
满五唯一，三居，地铁房，	满五唯一，三居，地铁房，	京通苑	3室2厅	146平米	南西	管庄二手房
电梯三层诚心出售，送全新	电梯三层诚心出售，送全新	天通苑北二区	3室2厅	147.03平米	南北	天通苑二手房
人济山庄 中心位置 东南	人济山庄 中心位置 东南	人济山庄	3室2厅	166.9平米	东南	紫竹桥二手房
樱花园全南向两居室，满五	樱花园全南向两居室，满五	樱花园	2室1厅	52.95平米	南	惠新西街二手房
回龙观大三居，南北通透	回龙观大三居，南北通透	龙槐苑东五区	3室2厅	124.77平米	南北	霍营二手房
彩虹新城商品房 双通透精装	彩虹新城商品房 双通透精装	彩虹新城	2室2厅	88.42平米	南北	枣园二手房
天通苑 南北通透大三居 高	天通苑 南北通透大三居 高	天通苑西二区	3室2厅	159.82平米	南北	天通苑二手房
满五年唯一 钥匙房源方便	满五年唯一 钥匙房源方便	北京新天地	1室1厅	66平米	东南	管庄二手房
龙多小区低楼层两居室 楼	龙多小区低楼层两居室 楼	龙多东区	2室1厅	67平米	南北	西二旗二手房

可以看到，数据中“属性3”列包含html转义符，拖拽html字符转义，到属性3列，即可自动转换所有转义符。

属性0	属性1	laisuzhou_	属性3	where_	属性5	属性6
观林园 有钥匙二居室 南北	观林园 有钥匙三居室 南北	观林园	HTML字符转义	HTML字符转义		
西直门 时代之光名苑 西南	西直门 时代之光名苑 西南	时代之光名苑	4室2厅	231.71平米	西南	西直门二手房
新华联南北通透 精装 免税	新华联南北通透 精装 免税	新华联家园南区	3室1厅	112平米	南北	果园二手房
满五唯一+南北通透+总价	满五唯一+南北通透+总价	天露园一区	3室2厅	128.11平米	南北	回龙观二手房
天通苑西三区【三朝南明卫	天通苑西三区【三朝南明卫	天通苑西三区	3室2厅	162.91平米	西南	天通苑二手房
南北通透 视野好 无遮挡大	南北通透 视野好 无遮挡大	万象新天一区	3室2厅	132.08平米	南北	常营二手房
季景沁园 全南2居 满五年唯	季景沁园 全南2居 满五年唯	季景沁园	2室2厅	110.33平米	南	望京二手房
果园 新华联家园南区 精装	果园 新华联家园南区 精装	新华联家园南区	3室2厅	126.71平米	南北	果园二手房
满五唯一，三居，地铁房，	满五唯一，三居，地铁房，	京通苑	3室2厅	146平米	南西	管庄二手房
电梯三层诚心出售，送全新	电梯三层诚心出售，送全新	天通苑北二区	3室2厅	147.03平米	南北	天通苑二手房
人济山庄 中心位置 东南	人济山庄 中心位置 东南	人济山庄	3室2厅	166.9平米	东南	紫竹桥二手房
樱花园全南向两居室，满五	樱花园全南向两居室，满五	樱花园	2室1厅	52.95平米	南	惠新西街二手房
回龙观大三居，南北通透	回龙观大三居，南北通透	龙槐苑东五区	3室2厅	124.77平米	南北	霍营二手房
彩虹新城商品房 双通透精装	彩虹新城商品房 双通透精装	彩虹新城	2室2厅	88.42平米	南北	枣园二手房
天通苑 南北通透大三居 高	天通苑 南北通透大三居 高	天通苑西二区	3室2厅	159.82平米	南北	天通苑二手房
满五年唯一 钥匙房源方便	满五年唯一 钥匙房源方便	北京新天地	1室1厅	66平米	东南	管庄二手房
龙多小区低楼层两居室 楼	龙多小区低楼层两居室 楼	龙多东区	2室1厅	67平米	南北	西二旗二手房

如果要修改列名，在最上方的列名上直接修改，点击回车即可修改名字。

where（面积）列中包含数字，想把数字提取出来，可以将提取数字模块拖拽到该列上，所有数字即可提取出来。

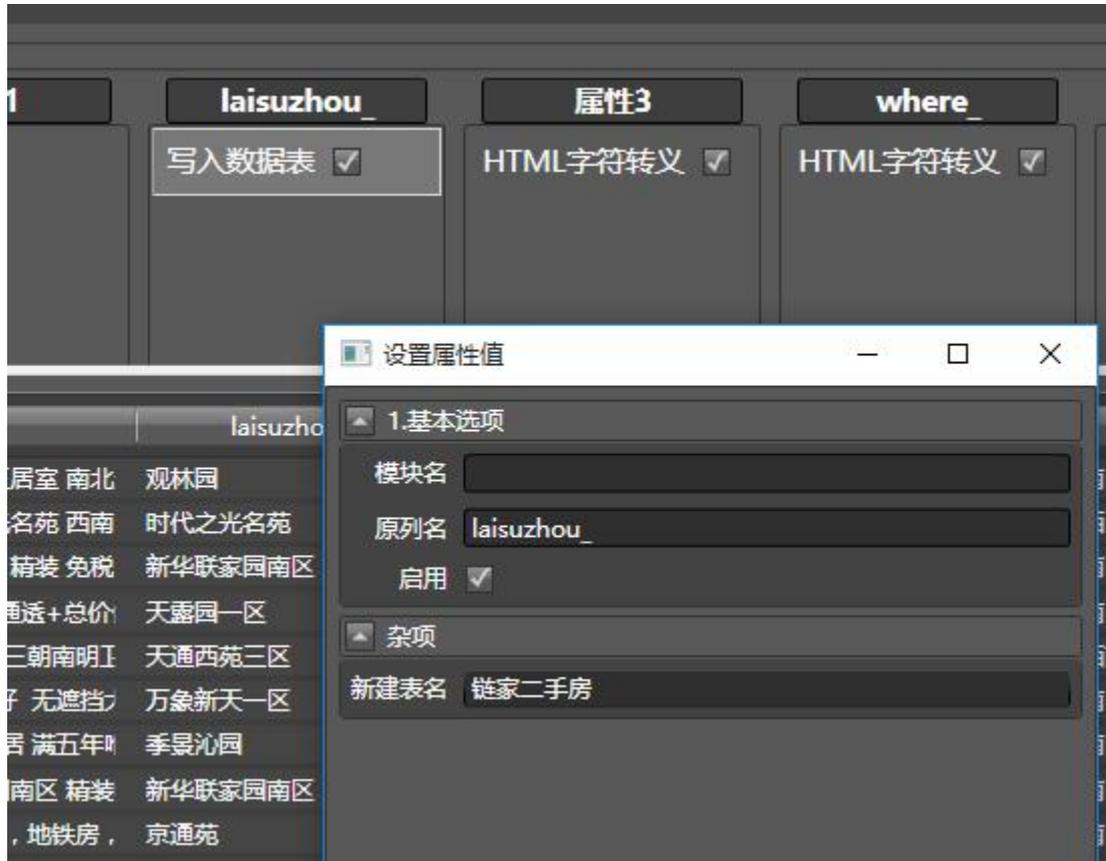
类似地，可以拖拽字符串分割或正则分割到某一列，从而分割文本和替换文本。此处不再赘述。

有一些列为空，可以拖拽空对象过滤器到该列，那么该列为空的话会自动过滤这一行数据。

7.3.3 保存和导出数据

需要保存数据时，可以选择写入文件，或者是临时存储（本软件的数据管理器），或是数据库。因此可以将“执行”模块，拖入清洗链的后端：

拖写入数据表到任意一列，并填入新建表名(如链家二手房)。

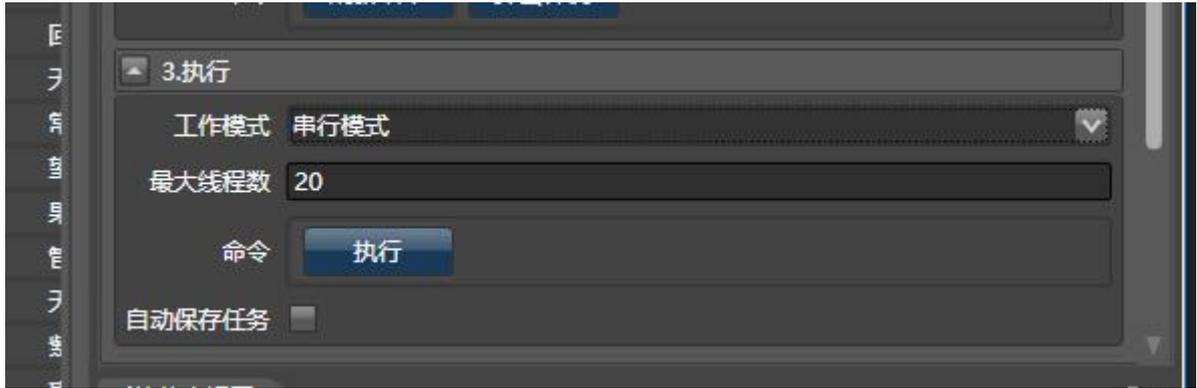


下图是这次操作的所有子模块列表：



之后，即可对整个过程进行操作：

选择**串行模式**或**并行模式**，并行模式使用线程池，可设定最多同时执行的线程数（最好不要超过100）。推荐使用并行模式，



点击**执行**按钮，即可在任务管理视图中采集数据。



之后，在**数据管理**的数据表**链家二手房**上点击右键，选择另存为，导出到 Excel, Json 等，即可将原始数据导出到外部文件中。

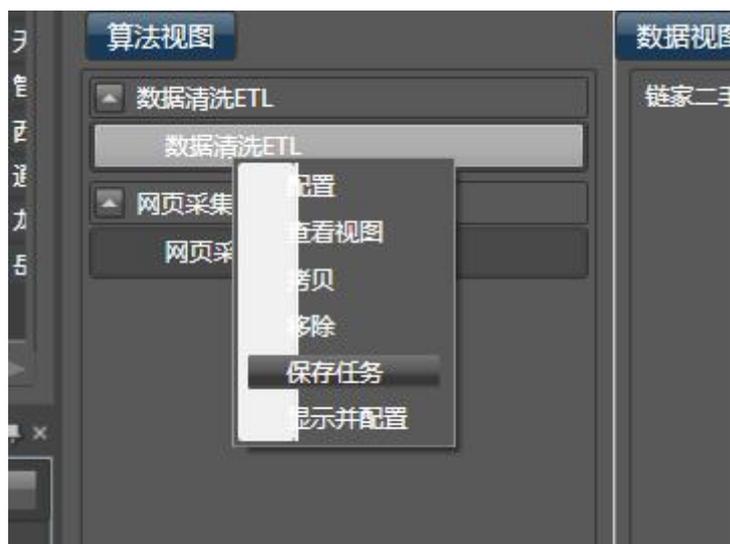


类似的，你可以在清洗流程中拖入执行器，则保存的是中间过程，也可以在结尾拖入多个执行器，这样就能同时写入数据库或文件，从而获得了极大的灵活性。

7.3.4 保存任务

在右下角的**算法视图**中的任意模块上点击右键，保存任务，即可在任务视图中保存新任务（任务名称与当前模块名字一致），下次可直接加载即可。如果存在同名任务，则会对原有任务进行覆盖。

在**算法视图**的空白处，点击**保存所有模块**，会批量保存所有的任务。



你可以将一批任务，保存为一个工程文件(xml)，并在之后将其加载和分发。

7.4 总结

上文以抓取房地产网站链家为例，介绍了软件的整体使用流程。当然，本系统功能远远不限于这些。

● 智采新版本特点:

序号	功能描述
1	增加 Mysql 数据库连接, 可以支持读写 Mysql 数据库。
2	优化“手气不错”。增加排序策略, 分为“按面积排序”、“按列数排序”、“按行数排序”、“按分数排序”。不同的排序策略, 可以主动搜索到的数据内容不同。
3	优化从数据表导出到 Excel 功能, 大大提升数据导出的效率。
4	布局大幅度优化和调整, 更为美观和易用。
5	增加全局登录, 为未来的线上模板大小基础
6、	为每一个节点增加文字解释