

# 工作任务二：数据采集

# (一) 认识数据

## 1、 确定数据类型是数据采集前的关键步骤。常见数据类型包括：

(数据的存在方式可以是文字、模型、多媒体、软件语言或特定学科规范的特定格式。

在数据新闻的生产过程中，常见的数据格式包括**文本格式 (.txt)**、**电子表格式 (.xls或.xlsx)**、**逗号分隔符文件格式 (.csv)**、**可扩展标记语言格式 (XML)**、**轻量数据交换格式 (.json)**、**地图数据格式 (.shp)** 等。

## 常见文本数据格式一览表

格式名称	扩展名	说明	打开方式
HTML	.htm、.html、.shtml、.xhtml	带超文本格式的文本，网页	可以使用网页制作工具如Microsoft SharePoint Designer、SeaMonkey、Dreamweaver等打开，同时以源代码形式展示出来，并可编辑其内容。
TeX	.tex、.ltx	TeX文件，可以是Plain TeX、LaTeX等	WinEdt、TeXworks等专用编辑器，Vim、Emacs、Gedit、Kate等通用文本编辑器
DOC	.doc、.docx	Word文档	Word、Docx需要Word2017、金山WPS Office、OpenOffice等可以部分兼容
PPT	.ppt、.pptx	PowerPoint演示文稿	PowerPoint、pptx需PowerPoint2010、金山WPS Office、OpenOffice等可以部分兼容
WPS	.wps	WPS文档	金山WPS Office的文字处理程序的文件格式，通MS Word的DOC结构一致，与Microsoft Office的Word的组件兼容，但是需要将扩展名修改为.doc
PDF	.pdf	可携式文件	Adobe Reader

## (一) 认识数据

**数据**就是数值，是通过观察、实验或计算得出的结果。数据只有在被使用的过程中才能转化为信息，并通过与故事结合呈现其意义。**大数据**是指那些规模巨大、复杂多变、难以用常规数据库和软件工具进行管理和处理的数据集合。

选用数据主要从以下角度出发：

**1.用户需求：**从用户角度出发，考虑他们可能关注的数据点，以及这些数据如何帮助他们思考和做出决策。

**2.数据质量：**考虑数据的准确性、完整性、一致性等因素，确保收集到的数据具有高质量。

**3.合规性：**确保数据收集和使用符合相关法律法规的要求，如隐私政策、数据保护法等。

## (二) 数据采集

1、在数据化社会中，数据确实无处不在，《数据新闻手册》列出的7种数据查找方法为我们提供了全方位的数据获取途径。



## (二) 数据采集

### 2、数据查找中最常用的工具是搜索引擎和各类开放数据：

(1) **搜索引擎**：在网络搜索框中输入想要查找的内容直接搜索，能帮助我们提供搜索效率，下面介绍几种常用的技巧。

**使用准确的关键词**：选择与你要查找的内容直接相关的关键词。使用具体的词汇代替模糊的词汇，例如“大学生饮食消费”而非“饮食”。注意避免使用常见的停用词，如“的”、“是”、“在”等，它们对搜索结果的影响很小。

**在特定网站内搜索**：如果你想在特定网站内搜索信息，可以在搜索框中输入“site:网站域名 关键词”。例如，在知乎上搜索关于Python的问题，可以输入“site:zhihu.com Python”。

## (二) 数据采集

### 3、数据查找中最常用的工具是搜索引擎和各类开放数据：

(2)**开放数据**：开放数据是一类可以被任何人免费使用、再利用、再分发的数据。数据开放平台的建设不仅促进了政府数据资源的共享，也推动了市场和社会主体开发应用数据。截至2023年8月，我国已有226个地方政府上线了数据开放平台，数量增长迅速。

例如：**百度指数、微信指数、艾瑞咨询、艾媒咨询、36氪、CNNIC**等，提供关键词搜索热度趋势，适合做需求洞察、用户画像等。**国家统计局、工业和信息化部、中国人民银行、银监会**等官网数据平台，可提供垂直类数据信息。

## **(二) 数据采集**

问卷中的问题序列会影响到被调查者对问题的回答，甚至影响到调查的顺利进行。安排好问题的顺序一般有以下常用的规则：

- 1.个人背景资料可放前面，也可放后面。**
- 2.按照一定的逻辑顺序排列问题。**
- 3.把简单易答的问题放在前面，把复杂难答的问题放在后面。**
- 4.把能引起被调查者兴趣的问题放前面，把容易引起他们紧张、顾虑的问题放在后面。**
- 5.把行为方面的问题放在前面，把态度、意见方面的问题放在后面。**
- 6.把开放式问题放在后面。**

## (二) 数据采集

第一步，注册。登录“问卷星”官网，完成注册。

第二步，创建问卷。在登录后，网页左边为“创建问卷”操作区。可单击创建问卷，根据自己需求设计好问卷内容



## (二) 数据采集

例如创建一个关于“大学生消费情况”的调查问卷。在创建问卷时，我们需要明确调查的目的，比如了解大学生的**消费结构、消费观念、消费习惯等**。这将有助于设计问卷的具体问题和内容。

设计问题时，要确保问题的表述清晰、简洁、易于理解。避免使用过于专业或复杂的术语，确

但问题过于复杂，同时，避免问话过于冗长，避免影响受访者的回答。如下图所示：

**大学生消费情况调查问卷**

\* 1. 您的性别

男

女

\* 2. 年级

大一

大二

大三

大四

\* 3. 在校期间的平均月消费

600-1000

1500-2000

2000以上

\* 4. 生活费来源

全部来自家庭

部分来自家庭，部分靠自己赚取

全部靠自己赚取

\* 5. 每月用于校内食堂就餐的费用约为

300以下

300-600

600-1000

1000以上

\* 6. 您购物的频率通常为

每周一次

每周两次

每周三次

每周四次

\* 7. 购物的方式通常为

实体店

网购

\* 8. 每月购置生活用品及衣物的费用

100以下

100-500

500-1000

1000以上

\* 9. 每学期在化妆品或护肤品方面的花费

无

200以下

200-500


## (二) 数据采集

第三步，完成问卷的创建之后，发出问卷链接。单击“发送问卷”，菜单栏中有发送“问卷链接与二维码”，将问卷链接或二维码推送给被调查对象即可。



## (二) 数据采集

第四步，回收答卷。点击左边菜单栏的“分析下载”，单击它即可看到分析结果。



## (二) 数据采集

第五步，点击“查看下载问卷”。如图所示，我们可以下载Excel文件获得调查结果。

序号	提交答卷时间	所用时间	来源	来源详情	来自IP	1、您的性	2、年	3、在校期间的平均月	4、生活费来	5、每月用于校内食堂就餐的费	6、每月用于零食及校外饮食	7、购物的方式
1	2024/5/7 11:04:13	81秒	微信	N/A	223.160.235.73(广西-南宁)	2	2	2	1	2	3	
2	2024/5/7 11:04:31	69秒	微信	N/A	39.144.133.223(广西-河池)	2	2	4	3	4	4	
3	2024/5/7 11:04:39	68秒	微信	N/A	180.138.215.235(广西-南宁)	2	2	1	1	1	2	
4	2024/5/7 11:04:50	44秒	微信	N/A	171.108.100.193(广西-南宁)	1	2	1	1	1	2	
5	2024/5/7 11:04:54	72秒	微信	N/A	220.200.127.43(广西-南宁)	2	2	3	2	1	3	
6	2024/5/7 11:05:09	96秒	微信	N/A	39.144.135.254(广西-南宁)	2	2	1	1	1	2	
7	2024/5/7 11:05:19	62秒	微信	N/A	116.10.88.248(广西-南宁)	1	2	2	1	1	2	
8	2024/5/7 11:05:22	94秒	微信	N/A	180.139.180.16(广西-南宁)	2	2	2	1	2	4	
9	2024/5/7 11:05:29	75秒	微信	N/A	171.111.161.31(广西-南宁)	1	2	1	2	2	3	
10	2024/5/7 11:05:32	128秒	微信	N/A	106.127.211.229(广西-南宁)	2	2	1	3	1	2	
11	2024/5/7 11:05:36	163秒	微信	N/A	113.15.9.206(广西-柳州)	2	2	3	1	1	4	
12	2024/5/7 11:05:39	126秒	微信	N/A	220.200.127.190(广西-南宁)	2	2	1	3	1	1	
13	2024/5/7 11:05:41	84秒	微信	N/A	103.251.99.179(广西-南宁)	2	4	4	2	1	4	
14	2024/5/7 11:05:46	88秒	微信	N/A	220.200.126.155(广西-南宁)	2	2	2	2	2	4	
15	2024/5/7 11:05:48	62秒	微信	N/A	117.141.132.186(广西-南宁)	2	2	2	2	1	4	
16	2024/5/7 11:05:55	141秒	微信	N/A	171.105.91.239(广西-南宁)	2	3	2	2	1	2	
17	2024/5/7 11:05:59	68秒	微信	N/A	223.104.93.251(广西-南宁)	1	3	2	1	1	2	

### (三) 数据转换

#### 1、数据转化具有以下作用：

(1) **兼容性和可访问性**：不同的软件、应用程序或系统可能支持不同的文件格式。为了在不同平台或软件之间共享数据，通常需要将数据转换格式，以确保数据能够被正确地读取和解析。

(2) **数据分析和处理**：某些数据分析工具或软件可能仅支持特定的文件格式。为了使用这些工具进行分析，需要将数据转换为相应的格式。此外，不同的文件格式可能具有不同的数据结构和组织方式，将数据转换为更适合的格式可能使数据分析和处理更加高效。

不同类型的数据格式，需要用不同的数据工具完成转换。常见的如网页形式的文本型数据，需要用**open refine**或者**tabletools2**转换为表格；PDF形式的数据需要用tabula提取数据转换为逗号分隔符csv格式；纸质文本型数据，需使用文本提取工具OCR等等。

### (三) 数据转换



2、Tabula 是一款用于提取 PDF 文档中的表格的开源软件。

首先，先进入 Tabula 官网。



### (三) 数据转换


目前，本软件最新版本是 1.2.1，发布于 2018 年 6 月。Tabula 可运行在 Windows、macOS、Linux 等操作系统上。例如，如果当前你的系统是 Windows 操作系统，可点击官网的“Download for Windows”按钮，直接下载。



ackend. (You can

## (三) 数据转换

Tabula 依赖于 Java 运行。如果你的电脑上未安装 Java 运行时，则首次运行该软件时，Tabula 会自动打开 Java 官网的下载页面：<https://www.java.com/zh-CN/download/>



### (三) 数据转换


下载 Java 后，点击安装即可。

下载完毕后，解压压缩包tabula-win-1.2.1.zip，解压后直接点击应用程序tabula。电脑的默认浏览器会自动打开 <http://127.0.0.1:8080/>。如下图。



### (三) 数据转换

首先，点击 Browse...按钮选择要处理的PDF文件。点击Import 按钮即可完成文件导入。通过tabula进度条可以看到导入进度。




### (三) 数据转换

导入完成后，即可看到类似如下的界面：



### (三) 数据转换

框选出包含表格的区域。将鼠标指针挪至待提取表格的左上角，按下鼠标左键不放，然后拖拽鼠标，直至将表格都框选起来。



### (三) 数据转换


当所需表格都被框选完后，点击当前页右上方选项 Preview & Export Extracted Data，来预览和导出从被框选的表格中提取出来的数据。如下图，提取出来的数据以表格形式呈现了出来。

The screenshot shows the Tabula web interface. At the top, there is a navigation bar with the Tabula logo and links for 'My Files', 'My Templates', 'About', 'Help', and 'Source Code'. On the right, there is a link to 'Support Tabula on OpenCollective!'. Below the navigation bar, there is a header area with the source file name '(源) 【数字100】 2023中国消费趋势洞察...', the 'Export Format' dropdown set to 'CSV', and buttons for 'Export' and 'Copy to Clipboard'. The main content area is titled 'Preview of Extracted Tabular Data' and displays a table of survey results. The table has three columns: the first column shows percentages from 50% down to 0%, the second column shows percentages from 33% down to 15%, and the third column shows percentages from 19% down to 17% and 14%. The text in the table is in Chinese, indicating a survey about the importance of certain concepts after the COVID-19 pandemic.

经历疫情后,您对以下说法/观念的看重程度有何变化?【多选】		
共给出33个关键词,回答人数 N=1990		
50%		
40%		
30%	33%	
	19%	更加看重
20%	16%	不变-仍旧看重
10%		
	15%	17% 14%
0%		
	环保	道德 公益

### (三) 数据转换

点击表格上方的Export选项。通过左侧的下拉框来选择导出格式。 .csv文件可以用Microsoft Office 直接打开。为了便于后续操作可以用 Excel软件打开.csv文件，并导出为.xls或.xlsx文件。



### (三) 数据转换

3、当数据为纸质版材料时，可使用OCR文本提取工具将纸质数据转换电子文本格式。以下用易飞文字识别小程序举例，主要步骤如下：

第一步，打开微信，搜索“易飞文字识别”小程序，点击进入主页面，选择“图片转文字”

选项。



### (三) 数据转换

第二步，页面跳转出现“拍照”“相册选图”“微信聊天图片”三个选项，相应选择。

禁止提交涉及国家秘密/违法违规内容，共建绿色安全网络环境



拍照



相册选图



微信聊天图片



首页



文档





我的

### (三) 数据转换

第三步，识别完成后，点击“图文校对”，进一步核对文本内容。

第四步，核对完成后，点击“完成校对”，导出文件。



## 思政融入：

数据的真实性需兼顾局部与整体，要求局部与全局都准确无误。首先，权威的数据支撑与科学的运用策略，是数据新闻效果的关键。首先，需善于借助开放的数据平台，注重自身长期积累的高质量数据库的构建。其次，面对纷繁复杂的数据，需要具备梳理其逻辑脉络，洞察其间联系的能力。另外，还需在使用数据时遵循法律法规，兼顾数据开放需求、数据安全保障与知识产权维护等因素之间的平衡点。你认为在数据采集的过程中，我们应具备哪些能力素养？

**思政元素：理性思维、实证探索**

谢谢观看

