Stata 基础训练营

第一讲　软件基础与数据处理

江俊澄

jc_jiang@stu.zuel.edu.cn

中南财经政法大学财政税务学院
学生学术科研中心 副主编

2024.11.17

课前问卷

STATA: STATistics Aided by Technology, Applications, and Software.

训练营的设计

经济学的学术研究在如今，理论模型离不开实证的检验，而随着大数据时代的来临，处理经济数据是经济学学生的必修技能。

在以往的课程学习中，更多地注重于计量方法的介绍和讲解，但运用计量方法处理数据的实操环节较为贫乏。

根据学院师生们的反馈和建议，似乎有必要组织一些研讨培训，对基本的数据处理和 stata 操作进行入门性的介绍。于此，Stata 基础训练营应运而生。

本训练营的定位是 Stata 的入门小白，因此不会涉及过为复杂的操作技术，从最基本的安装和认识 stata 开始，逐步讲解如何对数据进行清洗、整理、可视化、回归和结果输出；最后以 top 期刊上公开的 code 为例，向大家演示复现论文的实操过程。

学员构成

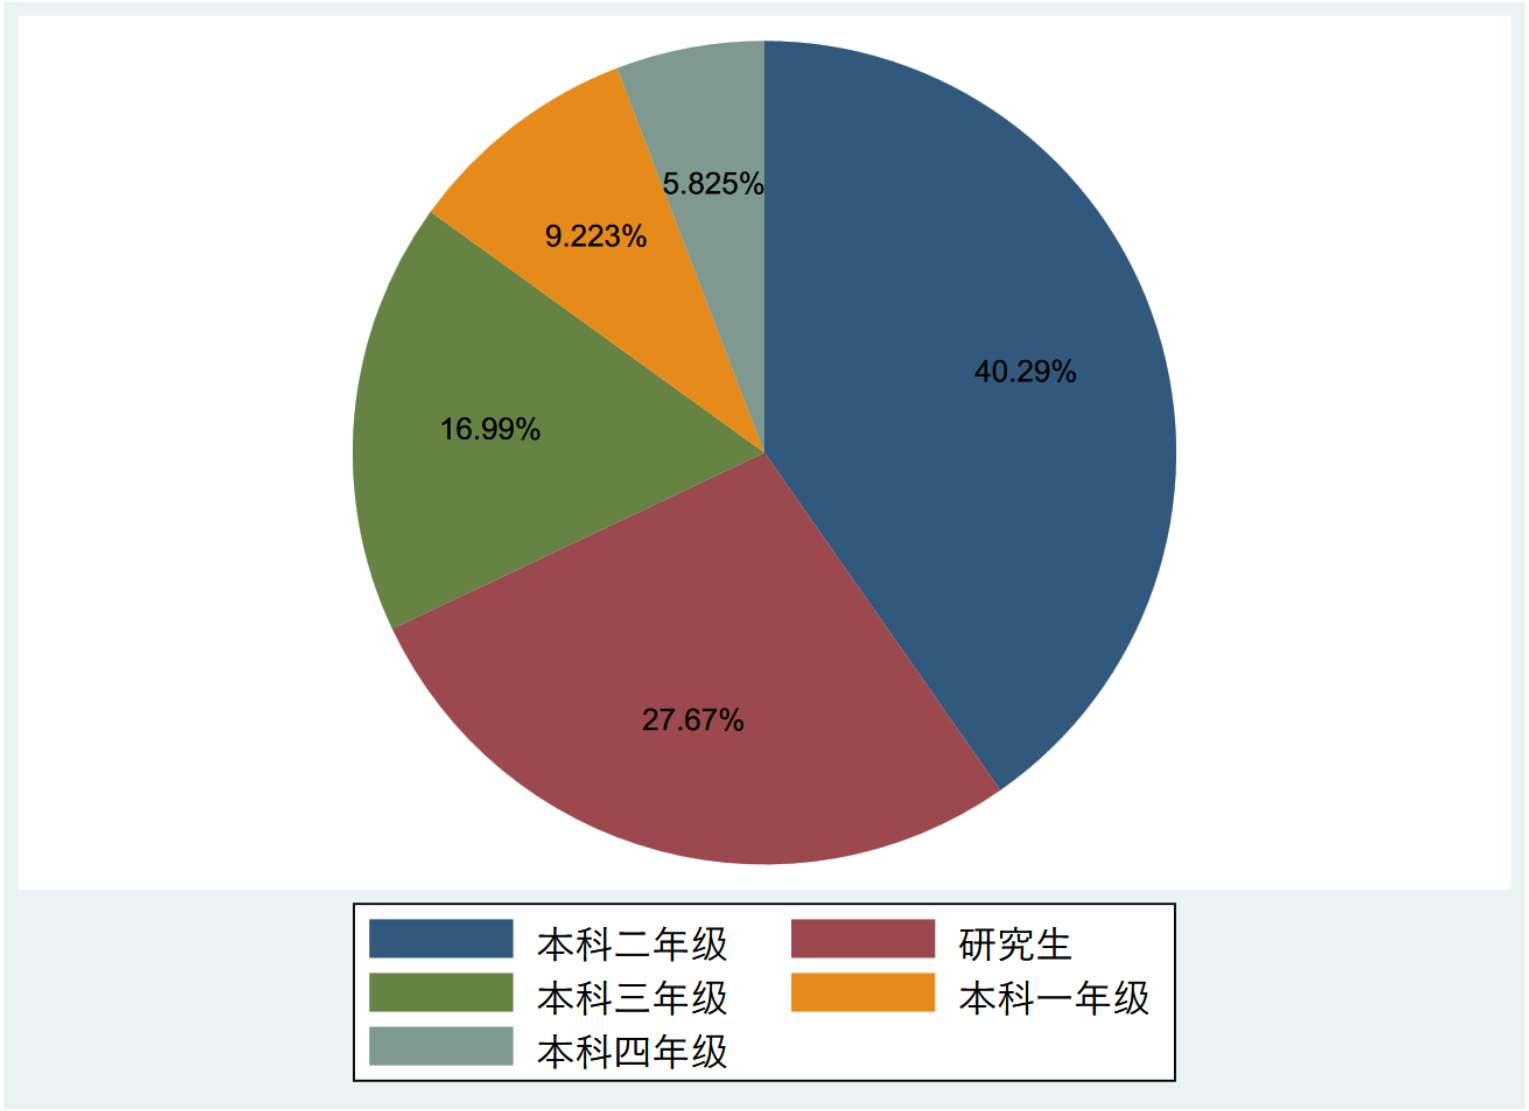

图: 学员构成

Stata 软件版本介绍

Stata 每一期常见的有三个版本：MP SE BE

- Stata/MP：最快的 Stata 版本（适用于四核、双核和多核/多处理器计算机），可以分析最大的数据集
- Stata/SE：标准版；对于更大的数据集
- Stata/BE：基础版；用于中型数据集

简单来说，三个版本功能比较 MP $>$ SE $>$ BE，而此次我们分享的版本为 MP 版本，为 Stata 最高配版。

目前，Stata 已经更新到第 18 版。安装步骤参见训练营预备篇安装教程。

Stata 第一版发行于 1985 年 1 月。

Stata 的窗口和菜单栏

- 命令窗口
- 结果窗口
- 历史窗口
- 变量窗口
- 属性窗口

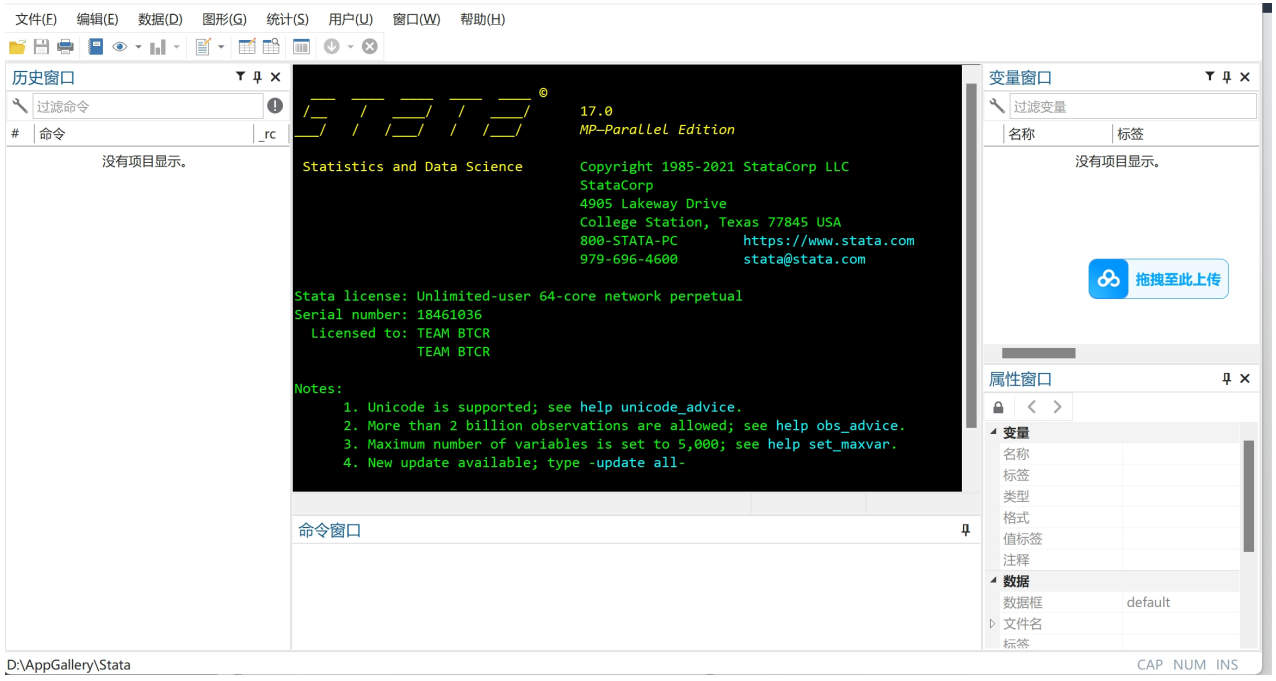

Stata 中的文件格式

- Stata 中可以识别的数据文件名以.dta 作为后缀；你可以在搜集整理数据是以.xsl 或.csv 先行储存，之后导入到 stata 中进行保存，导入的方式会即将介绍。

Stata 中的文件格式

- Stata 中可以识别的数据文件名以.dta 作为后缀；你可以在搜集整理数据是以.xsl 或.csv 先行储存，之后导入到 stata 中进行保存，导入的方式会即将介绍。
- 与其他编程语言类似，你可以在将所有的命令写进 do file 里，从而执行该文件而不上选择人机交互地逐次输入命令，do 文件的存储后缀为.do

Stata 中的文件格式

- Stata 中可以识别的数据文件名以.dta 作为后缀；你可以在搜集整理数据是以.xsl 或.csv 先行储存，之后导入到 stata 中进行保存，导入的方式会即将介绍。
- 与其他编程语言类似，你可以在将所有的命令写进 do file 里，从而执行该文件而不上选择人机交互地逐次输入命令，do 文件的存储后缀为.do
- 此外，当你运行 do file 时可以选择记录你的运行过程，stata 有专门的日志命令可以帮你记录，它的后缀是.smcl(只能用 stata 打开)，不过你可以通过 translate 将其转换为.log 或者.pdf 格式

数据整理形式——Tidy Data

一般我们将 “在列中包含变量，在行中包含观测值” 的数据成为整洁数据 (tidy data)；
有三个相互关联的规则使数据集整洁（Wickham, H. 2014）：

1. 每个变量都是一列；每一列都是一个变量
2. 每个观测值都是一行；每一行都是一个观测值
3. 每个值都是一个单元格；每个单元格都是一个值

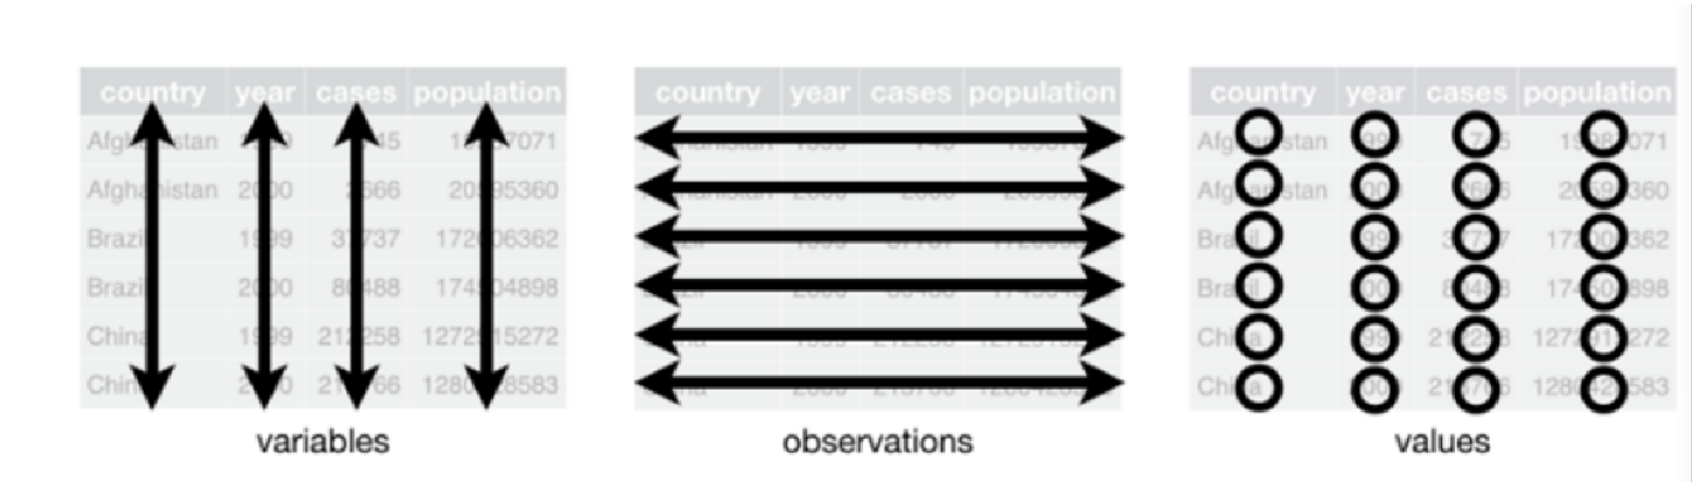

其他组织方式

```
table1
#> # A tibble: 6 × 4
#>   country      year  cases population
#>   <chr>       <dbl>  <dbl>      <dbl>
#> 1 Afghanistan  1999    745   19987071
#> 2 Afghanistan  2000   2666   20595360
#> 3 Brazil       1999  37737  172006362
#> 4 Brazil       2000  80488  174504898
#> 5 China        1999 212258 1272915272
#> 6 China        2000 213766 1280428583
```

```
table3
#> # A tibble: 6 × 3
#>   country      year rate
#>   <chr>       <dbl> <chr>
#> 1 Afghanistan  1999 745/19987071
#> 2 Afghanistan  2000 2666/20595360
#> 3 Brazil       1999 37737/172006362
#> 4 Brazil       2000 80488/174504898
#> 5 China        1999 212258/1272915272
#> 6 China        2000 213766/1280428583
```

```
table2
#> # A tibble: 12 × 4
#>   country      year type           count
#>   <chr>       <dbl> <chr>          <dbl>
#> 1 Afghanistan  1999 cases            745
#> 2 Afghanistan  1999 population   19987071
#> 3 Afghanistan  2000 cases           2666
#> 4 Afghanistan  2000 population   20595360
#> 5 Brazil       1999 cases           37737
#> 6 Brazil       1999 population  172006362
#> # ℹ 6 more rows
# Spread across two tibbles
table4a  # cases
#> # A tibble: 3 × 3
#>   country     `1999` `2000`
#>   <chr>        <dbl>  <dbl>
#> 1 Afghanistan    745   2666
#> 2 Brazil       37737  80488
#> 3 China       212258 213766
table4b  # population
#> # A tibble: 3 × 3
#>   country         `1999`      `2000`
#>   <chr>            <dbl>       <dbl>
#> 1 Afghanistan   19987071    20595360
#> 2 Brazil       172006362   174504898
#> 3 China       1272915272  1280428583
```

常见问题

五种常见的混乱的数据集问题（补救措施参见原文）：

- 列标题是值，而不是变量名。
- 多个变量存储在一列中。
- 变量存储在行和列中。
- 同一表中存储了多种类型的观测单位。
- 一个观测单位存储在多个表中

经济数据的结构

通常来说，可以将经济数据分为三/四类：

- 横截面数据 cross-section data
  - 由在给定时间点采集的个人、家庭、公司、城市、国家或各种其他单位的样本组成。
  - 忽略微小的时差，在一年内不同月份对不同的人进行了调查。
- 时间序列数据 time series data
  - 由对一个或多个变量随时间变化的观察组成。
  - 很少假设经济数据在时间上是独立的。
  - 需要关注数据搜集时的数据频率。(每天/周/月/季/年？)
- (混合横截面数据 pooled cross section)
  - 同时具有横截面和时间序列特征。
    如：2022 年调查了一组人，2024 年调查了新的一组人。
- 面板数据 panel data
  - 由数据集中每个横截面单位的一个时间序列组成。

判断结构类型

Data Editor (Browse)

Edit mode

海报[7] http://img5.mtime.cn/mt/2023/07/26/144520.68448668_1280X720X2.jpg

	电影名	电影id	年代	海报	时光评分	评论人数	导演	编剧	类型	国家地区
4	丛林大冒险	274737	2019	http://img5.mtime.c…	0.0	1人评分	咪咪·梅纳德	Martin BehnkeMarina…	动画/冒险/喜剧	比利时
5	艾尔米塔什博物馆：艺术的力…	274325	2019	http://img5.mtime.c…	0.0	0人评分			纪录片	意大利
6	京门烽火	268322	2020	http://movie.mtime.…	0.0	0人评分	刘子铭		2D	中国
7	野蛮人入侵	270412	2021	http://img5.mtime.c…	0.0	7人评分	陈翠梅	陈翠梅	剧情	中国香港
8	拉斐尔：年轻的画圣	274660	2021	http://img5.mtime.c…	0.0	0人评分			纪录片	意大利
9	湄公河巨兽	274736	2022	http://img5.mtime.c…	0.0	0人评分	李·通坎	李·通坎	惊悚/科幻/恐怖	澳大利亚
10	热烈	272254	2022	http://img5.mtime.c…	7.7	201人评分	大鹏	大鹏苏彪	剧情/喜剧	中国
11	女王的肖像	274659	2022	http://img5.mtime.c…	0.0	0人评分			纪录片	意大利
12	消失的她	273294	2022	http://img5.mtime.c…	6.8	327人评分	崔睿	陈思诚顾舒怡殷一雄	中国	中国
13	火山挚恋	272736	2022	http://img5.mtime.c…	8.4	73人评分	Sara Dosa	Shane BorisErin Cas…	中国	加拿大
14	爱犬奇缘	270236	2022	http://img5.mtime.c…	0.0	0人评分	陈国辉			中国
15	欢乐丛林之外星人大冒险	274180	2023	http://img5.mtime.c…	0.0	1人评分	邢海顺		中国	中国
16	最遗憾是错过你	274094	2023	http://img5.mtime.c…	0.0	0人评分			爱情/剧情	中国台湾
17	学爸	270250	2023	http://img5.mtime.c…	0.0	34人评分	苏亮	苏亮	剧情/喜剧	中国
18	忠爱无言2	262838	2023	http://img5.mtime.c…	0.0	0人评分	谈宜之	谈宜之	剧情	中国
19	潜艇总动员：环游地球80天	274622	2023	http://img5.mtime.c…	0.0	1人评分			中国	中国
20	北京2022	273815	2023	http://img5.mtime.c…	0.0	4人评分	陆川		纪录片/剧情/运动	中国
21	雪域少年	272275	2023	http://img5.mtime.c…	0.0	0人评分	路奇	王运生路武楠	中国	中国
22	巨齿鲨2：深渊	270273	2023	http://img5.mtime.c…	6.5	209人评分	本·维特利	乔·霍贝尔埃里希·霍…	动作/科幻/冒险	中国
23	长安三万里	272782	2023	http://img5.mtime.c…	8.3	423人评分	谢君伟	红泥小火炉	动画/历史	中国
24	力量密码	274483	2023	http://img5.mtime.c…	0.0	2人评分			剧情/历史/传记	中国
25	看不见的他们	274797	2023	http://img5.mtime.c…	0.0	0人评分	李飞		家庭/惊悚/恐怖	中国
26	川流不“熄”	270506	2023	http://img5.mtime.c…	0.0	7人评分	冯锜予		剧情	中国
27	暗杀风暴	255768	2023	http://img5.mtime.c…	0.0	37人评分	邱礼涛	沈锡然	悬疑/犯罪	中国
28	GT赛车：极速狂飙	273470	2023	http://img5.mtime.c…	0.0	6人评分	尼尔·布洛姆坎普	杰森·霍尔扎克·贝林…	动作/剧情/冒险	美国
29	我经过风暴	270490	2023	http://img5.mtime.c…	0.0	34人评分	秦海燕	秦海燕	家庭/剧情	中国
30	百变马丁：怪兽大作战	274470	2023	http://img5.mtime.c…	0.0	3人评分	张天晓		动画/冒险	中国

Vars: 17 Order: Dataset | Obs: 53 | Length: 65

图：混合截面数据

最常用的类型--面板数据

平衡面板数据是指在一个特定的时间段内，每个观测对象都有完整的观测值。即对于每一个体，每一时间点上的数据都是齐全的。

Data Editor (Browse) — wc14.dta

var620[11]

	pid	year	age	male	drink_lastyr
1	010104102001	2011	57	0	0.None
2	010104102001	2013	59	0	0.None
3	010104102001	2015	61	0	0.None
4	010104102001	2018	64	0	0.None
5	010104102002	2011	60	1	1.Yes
6	010104102002	2013	62	1	1.Yes
7	010104102002	2015	64	1	1.Yes
8	010104102002	2018	67	1	1.Yes
9	010104104001	2011	61	1	0.None
10	010104104001	2013	63	1	0.None
11	010104104001	2015	64	1	0.None
12	010104104001	2018	67	1	0.None
13	010104104002	2011	53	0	.m:missing
14	010104104002	2013	55	0	0.None
15	010104104002	2015	57	0	0.None
16	010104104002	2018	60	0	1.Yes
17	010104105001	2011	66	0	0.None
18	010104105001	2013	69	0	0.None
19	010104105001	2015	70	0	0.None
20	010104105001	2018	73	0	0.None
21	010104105002	2011	68	1	1.Yes
22	010104105002	2013	70	1	1.Yes
23	010104105002	2015	72	1	1.Yes
24	010104105002	2018	75	1	0.None
25	010104107001	2011	79	1	0.None
26	010104107001	2013	81	1	0.None
27	010104107001	2015	83	1	0.None

Vars: 5 of 617 Order: Dataset Obs: 36,080

图：平衡面板数据

Data Editor (Browse) — wc14.dta

var626[9]

	pid	year	age	male	drink_lastyr
1	010104101001	2015	50	0	0.None
2	010104101001	2018	53	0	0.None
3	010104101002	2013	50	1	1.Yes
4	010104101002	2015	52	1	1.Yes
5	010104101002	2018	55	1	0.None
6	010104102001	2011	57	0	0.None
7	010104102001	2013	59	0	0.None
8	010104102001	2015	61	0	0.None
9	010104102001	2018	64	0	0.None
10	010104102002	2011	60	1	1.Yes
11	010104102002	2013	62	1	1.Yes
12	010104102002	2015	64	1	1.Yes
13	010104102002	2018	67	1	1.Yes
14	010104103001	2013	50	1	1.Yes
15	010104103001	2015	52	1	1.Yes
16	010104103001	2018	55	1	1.Yes
17	010104103002	2015	50	0	0.None
18	010104103002	2018	53	0	0.None
19	010104104001	2011	61	1	0.None
20	010104104001	2013	63	1	0.None
21	010104104001	2015	64	1	0.None
22	010104104001	2018	67	1	0.None
23	010104104002	2011	53	0	.m:missing
24	010104104002	2013	55	0	0.None
25	010104104002	2015	57	0	0.None
26	010104104002	2018	60	0	1.Yes
27	010104105001	2011	66	0	0.None

Vars: 5 of 617 Order: Dataset Obs: 63,135

图：非平衡面板数据

非平衡的转换

在计量分析中，平衡面板数据相比非平衡面板更易于处理。但并不是说一定要用平衡面板才能跑回归。

如果你想仅保留非平衡面板数据在给定年限中均存在的个体，从而将其转为平衡面板，具体用到的命令为：xtbalance

外部命令下载安装为：ssc install xtbalance
语法格式为：xtbalance, range(numlist) [miss(varlist)]
注意事项为：使用前需要先进行面板数据设定声明。

转化的具体操作可以参见连享会，这里不作展开讲解：
Stata 数据处理：xtbalance-非平衡面板之转换
https://blog.csdn.net/arlionn/article/details/118815391

数据类型

数据的三种类型（在 stata 中以颜色区分）

- 红色：文本（可以按照字母顺序进行排序）type:string(str) 字符串
  - 一种：纯数字 (stkcd 股票代码)
  - 另一种：纯文字 (省份名称、行业名称)
- 黑色：数字（可以做回归分析）
- 蓝色：数字-文字对应表（虚拟变量）实质上也是数字

数据整理常见步骤 Stata command

- 查看工作路径 (pwd); 改变工作路径 (cd)
- 导入 Excel 文件 (import excel),CSV 文件 (import delimited),dta 文件 (use)
- 添加变量或变量数值标签 (label)
- 生成新变量 (gen) 或统计量变量 (egen)
- 将观测值按照变量数值大小排序 (sort;gsort
- 改变变量前后顺序 (order)
- 将数据集进行长宽转换 (reshape)
- 合并数据集 (merge
- 删除 (drop) 或保留 (keep) 观测值或变量
- 导出 Excel, CSV 文件 (export) 或 dta 文件 (save)

STATA 环境命令举例

```
use xxx.dta, clear
keep a b c
gen d
gen dummy=1 if year>=2022 //生成虚拟变量

.......

outreg2 using statistic,word replace sum(log)  /*
*/ sortvar(income price interest) /*
*/ keep(price income interest)
*基本回归
```

基本命令 list

```
use "file.dta", clear //读取.dta数据
sort air_time dest //对列进行排序
order month day //  对行进行排序
rename (old) (new) //重命名
keep in 1/200
keep if day>5 & day<10
keep if in range(day,5,10)
keep month day carrier//保留子集行或列
gen  dist_sq=distance^2 //创建新变量
replace a=dep_delay+arr_delay //修改现有变量
drop varlist [if] [in]  //删除变量
.......
```

本讲你将学到：

```
1  use xxx.dta, clear
2  log
3  global local
4  rename
5  label
6  encode
7  destring
8  keep
9  gen
10 replace
11 sort
12 .......
```

启动 Stata

DO!