拟合的其他方法

慧航

2026年11月

加权平均

为了使得样本对总体的代表性更好，我们可能需要在做统计分析时对数据进行加权.

- 比如，在很多的抽样调查中，为了得到比较好的统计性质，通常抽样并非等概率的进行，而是针对某一群体，比如低收入家庭等，进行有重点地抽样.
- 此时，如果我们希望获得收入的总体均值，简单的计算样本平均会导致平均收入的低估.

Horvitz-Thompson估计量

为了解决这一问题，通常我们会使用**Horvitz-Thompson估计量**，也就是使用每个样本被抽中的概率π_i的倒数$1/\pi_i$作为权重，计算加权平均：

$$\bar{x}^w = \frac{1}{M}\sum_{i=1}^{N}\frac{1}{\pi_i}x_i$$

其中$M = \sum_{i=1}^{N}\frac{1}{\pi_i}$为总体中个体的数量. **Horvitz-Thompson估计量为总体均值的无偏估计量.**

逆概率加权

重新整理该估计量，有：

$$\bar{x}^w = \frac{1}{M}\sum_{i=1}^{N}\frac{1}{\pi_i}x_i = \frac{\sum_{i=1}^{N}\frac{1}{\pi_i}x_i}{\sum_{i=1}^{N}\frac{1}{\pi_i}} = \sum_{i=1}^{N}\left(\frac{\frac{1}{\pi_i}}{\sum_{i=1}^{N}\frac{1}{\pi_i}}\right)x_i \overset{\text{def}}{=} \sum_{i=1}^{N} w_i x_i$$

以上估计量也称为加权平均（weighted average），其中权重为概率的倒数，因而通常也被称为**逆概率加权**（**inverse probability weighting**）.

逆概率加权

概率的倒数可以简单理解为一个样本代表了总体中多少个个体，

- 如果一个样本被抽中的概率为万分之一，那么一个样本大概代表了一万个个体.
- 在实际的调查数据中，通常会使用“一个个体代表了多少个个体”这种形式来给出权重.

逆概率加权

Stata中的加权

在中国家庭金融调查（China Household Finance Survey）的数据（chfs_ind.dta）中，如果不使用权重，swgt变量指明了数据中1个人代表了总体中的多少人. 在Stata中，有四种加权方式可供使用：

- fweight：频数权重，即如果我们观察到m个一模一样的观测，那么我们可以将这m个一模一样的观测合并为一个观测，并设其权重为m.
- aweight：分析权重，适用于加总的数据，比如我们使用的数据为每个省份的平均值，那么可以用省份的人口作为权重. 权重在使用时会默认规范化所有的权重之和为N：$\sum_{i=1}^{N} w_i = N$.
- pweight：抽样权重，适用于抽样数据，权重为每个个体被抽中的概率的倒数，也就是我们刚刚提到的权重.
- iweight：重要性权重，Stata内部处理方法与aweight类似，区别在于使用iweight不会做规范化，适用于出于其他目的的加权.

逆概率加权

Stata中的加权

我们可以使用如下命令计算加权平均:

```
1 su labor_inc [aw=swgt]
```

加总数据的加权

加权平均的另一个应用是在加总的数据中. 比如如果我们有每个城市的平均收入，为了计算全国的平均收入，我们可以按照如下计算:

$$\bar{x} = \frac{\sum_{c=1}^{C}(\bar{x}_c \times p_c)}{\sum_{c=1}^{C} p_c} = \sum_{c=1}^{C}\left(\frac{p_c}{\sum_{c=1}^{C} p_c} \times \bar{x}_c\right) \stackrel{\text{def}}{=} \sum_{c=1}^{C}(w_c \times \bar{x}_c)$$

实际上，以上计算方法也是一种逆概率加权:

- 由于对于城市数据而言，每个城市只有1条数据，从而$1/p_c$代表了每个城市c中一个个体被抽中的概率
- 从而根据逆概率加权的思想，权重应该为$1/(1/p_c)=p_c$，即使用人口数量进行加权.

加总数据的加权

使用城市平均计算全国平均

如果我们需要计算2010年全国人均公共图书册数，使用citydata.dta中的城市数据，我们分别计算了使用人口加权和不加权两种不同的均值：

```
use datasets/citydata.dta, clear
keep if year==2010
su v210
su v210 [aw=v4]
```

根据计算结果，未使用加权平均计算的人均公共图书册数约为4.89册，而使用人口加权后，得到的结果为5.27册，如果人口多的城市人均公共册数也多，那么后者对于全国人均公共图书册数的计算更加精确，而未加权的结果会低估全国的平均册数.

加权最小二乘

在线性回归中同样面临着需要加权的问题，此时可以使用加权最小二乘法，即最小化经过权重调整的误差平方和：

$$\min_{\beta} \sum_{i=1}^{N} \left[w_i \left(y_i - x_i' \beta \right)^2 \right]$$

从而得到：

$$\hat{\beta}^w = \left(\sum_{i=1}^{N} w_i x_i x_i' \right)^{-1} \left(\sum_{i=1}^{N} w_i x_i y_i \right)$$

其中w_i为权重.

加权最小二乘

在一些抽样调查数据中，可以使用逆概率加权的方法对估计量进行调整，即令$w_i = 1/\pi_i$，这与我们上面计算加权平均的方法是一样的. 如果使用逆概率加权，我们可以将以上计算公式写为:

$$\hat{\beta}^w = \left(\frac{\sum_{i=1}^N \frac{1}{\pi_i} x_i x_i'}{\sum_{i=1}^N \frac{1}{\pi_i}} \right)^{-1} \left(\frac{\sum_{i=1}^N \frac{1}{\pi_i} x_i y_i}{\sum_{i=1}^N \frac{1}{\pi_i}} \right)$$

即将OLS公式中的两部分分别替换为了其无偏估计.

加权最小二乘

CHFS中的权重

在2002年中国家庭金融调查数据中，如果要比较不同教育程度的对数收入，可以使用如下回归：

```
gen log_income=log(labor_inc)
reg log_income i.a2012
```

而注意到由于抽样的问题，每个样本的重要性是不一样的，我们可以使用swgt变量作为权重进行加权：

```
gen log_income=log(labor_inc)
reg log_income i.a2012 [w=swgt]
```

得到的结果与不加权的相比有一些变化，两个结果相比较，不加权的回归系数可能低估了高教育程度与低教育程度的收入差距.

加总数据的权重

- 正如在加总数据中计算均值可能需要加权平均一样，在一些加总数据中，也需要使用加权最小二乘.
- 比如，如果对于每一个个体，有回归方程:

$$y_{ig} = x'_{ig}\beta + u_{ig}, g = 1, ..., G$$

其中g为一个分组变量，比如省份或者城市

- 但是我们观察不到个体数据，只能使用平均数据:

$$\bar{y}_g = \bar{x}'_g\beta + \bar{u}_g, g = 1, ..., G$$

此时我们可以认为g组的N_g个个体被一个抽象的“平均个体”$\left(\bar{y}_g, \bar{x}'_g\right)'$所代表了，因而类比于逆概率加权，可以使用$N_g$作为权重进行加权.

加总数据中的异方差

在上面的例子中使用加权最小二乘同时可能还处理了异方差问题.

- 如果假设$u_{ig} \sim (0, \sigma^2)$，那么$\bar{u}_g \sim (0, \sigma^2/N_g)$，从而出现了异方差问题：方差随着每个城市人口的变化而变化.
- 此时，我们可以考虑在方程两边同时乘以$\sqrt{N_g}$，得到：

$$\sqrt{N_g}\bar{y}_g = \sqrt{N_g}\bar{x}_g'\beta + \sqrt{N_g}\bar{u}_g$$

那么此时$\sqrt{N_g}\bar{u}_g \sim (0, 1)$，从而消去了异方差问题.

- 再进行最小二乘回归，就得到了：

$$\begin{aligned}\hat{\beta} &= \left(\sum_{i=1}^{N}\left[\left(\sqrt{N_g}\bar{x}_g\right)\left(\sqrt{N_g}\bar{x}_g\right)'\right]\right)^{-1}\left(\sum_{i=1}^{N}\left[\left(\sqrt{N_g}\bar{x}_g\right)\left(\sqrt{N_g}\bar{y}_g\right)\right]\right) \\ &= \left(\sum_{i=1}^{N}\left[N_g\bar{x}_g\bar{x}_g'\right]\right)^{-1}\left(\sum_{i=1}^{N}\left[N_g\bar{x}_g\bar{y}_g'\right]\right)\end{aligned}$$

上式无非就是使用N_g作为权重的加权最小二乘.

加权最小二乘

美国单边离婚法案

Friedberg（1998）在研究单边离婚法案（unilateral divorce law）对美国离婚率的影响时，使用了如下设定：

$$\text{divrate} = b_0 + b_1 \times \text{unilateral} + x'\beta + u$$

由于离婚率可以看成是一个州每个女性是否离婚的均值，所以他们在回归时使用州的人口作为权重，以下代码展示了他们的基础回归结果：

加权最小二乘

美国单边离婚法案

```
clear
set more off
use "datasets/Divorce-Wolfers-AER.dta"
egen state=group(st)
// reg
reg div_rate unilateral divx* i.state i.year if year>1967 & year
    <1989
reg div_rate unilateral divx* i.state i.year if year>1967 & year
    <1989 [w=stpop]
```

局部估计

考虑一个一维的x

- 如果如果我们希望获得

$$\mathbb{E}\left(y|x=x_0\right)$$

的估计，我们仅仅关心在$x=x_0$点处的估计

- 一个最简单的方法是在最小二乘法的目标函数中，给与$x=x_0$点附近的样本残差平方以更大的权重，而远离$x=x_0$点处的样本残差平方以更小的权重
- 那么只要最小化加权的最小二乘目标函数：

$$\min_{\beta}\sum_{i=1}^{N}\left[w_i\left(y_i-\alpha-\beta x_i\right)^2\right]$$

- 问题：权重如何选取?

核函数

权重一般可以如下选取:

- 令$K(x)$为一个以纵轴对称的函数，即$K(x)=K(-x)$，从而$\int_{-\infty}^{\infty} xK(x)\,\mathrm{d}x=0$，且在$x\in[0,\infty)$是单调递减的，$K(x)\geq 0$
- 令权重:

$$w_i = K\left(\frac{x_i - x_0}{h}\right)$$

其中$h>0$为**窗宽（bandwidth）**，而$K(x)$被称为**“核函数”（kernel function）**

- 一般核函数可以选取为对称分布的密度函数.

Rectangle核函数

如果令:

$$K_0(x) = \begin{cases} 1 & |x| \le 1 \\ 0 & |x| > 1 \end{cases}$$

那么权重为:

$$w_i = K_0\left(\frac{x_i - x_0}{h}\right) = \begin{cases} 1 & x_0 - h \le x_i \le x_0 + h \\ 0 & otherwise \end{cases}$$

带入到目标函数中去，就得到了:

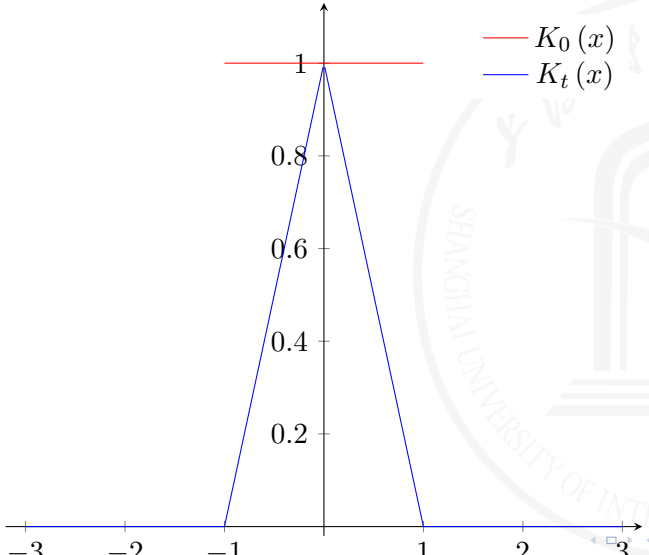
$$\min_{\beta} \sum_{i=1}^{N} \left[\mathbb{1}\left\{ |x_i - x_0| \le h \right\} (y_i - \alpha - \beta x_i)^2 \right]$$

以上目标函数等价于在区间$[x_0 - h, x_0 + h]$内做简单的最小二乘法.

Rectangle核函数

- 这也就是h取名“窗宽”的由来:
  - h决定了x_0附近区间的大小，h越小，则在x_0附近取的区间越小，使用的数据量也就越少.
- 注意到$K_0(x)$在临近的区间内权重都相等，所以我们也称其为矩形（rectangle）核函数

核函数



Triangle核函数

- 我们还可以令权重在临近区间内不相等：当x_i距离x_0越近时权重越高
- 此时可以在$K_0(x)$的基础上进行修改，使用：

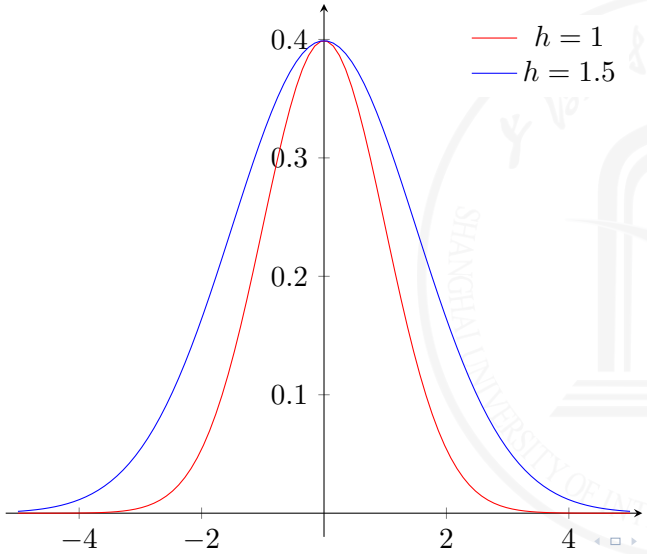
$$K_t(x) = \begin{cases} 1-|x| & |x| \leq 1 \\ 0 & |x| > 1 \end{cases}$$

- 该函数同样在$|x|>1$时取值为0，但是在$|x| \leq 1$这个区间内，随着x远离0，有个递减的过程.
- 我们称该核函数为三角（triangle）核函数.

高斯核函数

- 或者，也可以取$K(x)=\phi(x)$，其中$\phi(\cdot)$为标准正态分布的密度函数，该核函数被称为高斯核函数.
- 权重：$w_i=\phi\left(\frac{x_i-x_0}{h}\right)$
  - 同样的，当x_i越靠近x_0时，权重w_i越大
  - 不过不会像$K_0(x)$那样变为0，而是会收敛到0.
  - 而在这种情况下，h同样也被称为窗宽，因为h扮演的作用是一样的：
    - h越大，则随着x_i远离x_0，权重收敛到0的速度越慢，相当于用了一个更“大”的区间；
    - 反之h越小，则权重收敛到0的速度越快，相当于用了一个更“小”的区间.

核函数



局部常数估计

- 如果只在局部使用常数项对$\mathbb{E}(y|x=x_0)$进行估计：

$$\min_{\beta} \sum_{i=1}^{N} \left[w_i (y_i - \alpha)^2 \right]$$

- 此时可以计算得到：

$$\hat{y}_0 = \hat{\alpha} = \frac{\sum_{i=1}^{N} w_i y_i}{\sum_{i=1}^{N} w_i} = \sum_{i=1}^{N} \frac{w_i}{\sum_{i=1}^{N} w_i} y_i = \sum_{i=1}^{N} w_i^* y_i$$

其中w_i^*为规范化的权重，使得$\sum_i w_i^* = 1$.

局部常数估计

- 如果将核函数带入，就得到了：

$$\hat{y}_0 = \frac{\sum_{i=1}^{N} K\left(\frac{x_i - x_0}{h}\right) y_i}{\sum_{i=1}^{N} K\left(\frac{x_i - x_0}{h}\right)}$$

  - 如果我们取核函数$K(\cdot) = K_0(\cdot)$，以上估计量无非就是在$[x_0 - h, x_0 + h]$邻域内对y_i进行一个简单的加权平均
  - 如果取$K(\cdot) = \phi(\cdot)$，也是同样的道理
- 以上估计量也被称为“**局部常数项估计**”（**local constant estimator**）.

局部常数估计

一个模拟

假设数据生成过程:

$$y = \exp\left(\sin x^3\right) + u$$

其中$x \sim \mathcal{U}(0,2), u \sim \mathcal{N}(0,1)$，假设样本量$N = 300$. 如果我们关心的是当$x = 2$时$y$的预测值（真实值为2.6895），我们选取标准正态分布的密度函数作为核函数，此外选取$h = 0.1$，计算得到$\hat{y}_{x=2} = 2.07$（local_constant.do）.

局部线性估计

- 注意到，在上例中，局部常数项回归计算的实际上是在$x = 2$的一个小的邻域中的均值
- 然而在上例中，由于$x = 2$恰好是x的取值范围的上界，所以我们实际上只使用了$x = 2$左边的一个小的邻域$[2 - h, 2]$.
- 可以想象，由于在$x = 2$左边，真实的数据生成过程是单调递增的，所以在这个小邻域中计算均值会低估$\mathbb{E}(y|x = 2)$.
  - 上例的结果也可以看出，局部常数项的估计的确低估了$\mathbb{E}(y|x = 2)$.

局部线性估计

- 为此，我们可以在这个小的邻域中做一个线性回归.
- 一个常用的处理方法是首先计算$x^{\#} = x - x_0$，带入到目标函数中就是：

$$\min_{\alpha,\beta} \sum_{i=1}^{N} \left[K\left(\frac{x_i - x_0}{h} \right) \left(y_i - \alpha - \beta x_i^{\#} \right)^2 \right]$$

$$\Leftrightarrow \min_{\alpha,\beta} \sum_{i=1}^{N} \left[K\left(\frac{x_i - x_0}{h} \right) \left[y_i - \alpha - \beta \left(x_i - x_0 \right) \right]^2 \right]$$

- 当$x = x_0$时，$x^{\#} = 0$，从而对于$\mathbb{E}\left(y | x = x_0\right)$的预测$\hat{y}_{x=x_0} = \hat{\alpha}$.
- 由于该方法可以看作是在一个小的邻域中使用线性回归对$x = x_0$处的y进行预测，所以也叫做**局部线性**（**local linear**）回归.

局部线性回归

局部线性回归模拟

接上例，我们可以使用如下代码进行局部线性回归:

```
gen w=normalden((x-2)/0.1)
gen x_2=x-2
reg y x_2 [iw=w]
di _b[_cons]
```

结果为$\hat{y}_{x=2} = 2.776$，与真实值更为接近，并且没有低估真实值了.

局部多项式回归

更一般的，我们可以使用**局部多项式**（local polynomial）回归:

$$\min_{\beta} \sum_{i=1}^{N} \left[K\left(\frac{x_i - x_0}{h}\right) \left(y_i - \alpha - \sum_{k=1}^{K} \beta_k \left(x_i^{\#}\right)^k \right)^2 \right]$$

在局部进行更精细的逼近.

局部多项式回归

局部多项式回归模拟

接上例，我们可以使用如下代码进行局部三阶多项式回归:

```
gen w=normalden((x-2)/0.1)
gen x_2=x-2
gen x_22=x_2^2
gen x_23=x_2^3
reg y x_2* [iw=w]
di _b[_cons]
```

结果为$\hat{y}_{x=2} = 2.495$.

窗宽和多项式阶数选取

- 多项式阶数并不是越多越好，过高的多项式阶数会导致预测结果，特别是在端点的预测效果不稳定.
- 而关于窗宽h，考虑局部常数项回归以及$K(\cdot)=K_0(\cdot)$作为例子，此时的估计量无非是$[x_0-h,x_0+h]$区间的所有y_i的平均数
  - 可以想象一个过小的窗宽意味着能够使用的样本量更少，所以估计量的方差会很大；但是由于窗口比较小，我们上面所讨论的“低估”就会更不明显，也就是说估计量的偏差（bias）会更小.
  - 而反过来，一个大的窗宽会降低估计量的方差，但是偏差则会提高.
- 回忆均方误差可以写为偏差的平方和方差之和，所以理论上应该会有一个最优的h，使得均方误差达到最小.

选取方法

一般多项式阶数和窗宽的选取方法:

- 理论推导计算
  - 一些特殊情况有理论计算结果，如非参数回归、RD设计等
- 交叉验证
  - 我们仅仅关注$x = x_0$处的预测，所以在做交叉验证时，并不需要所有的样本点都作为测试集，而是仅仅把离x_0最近的一些点作为测试集就好了.

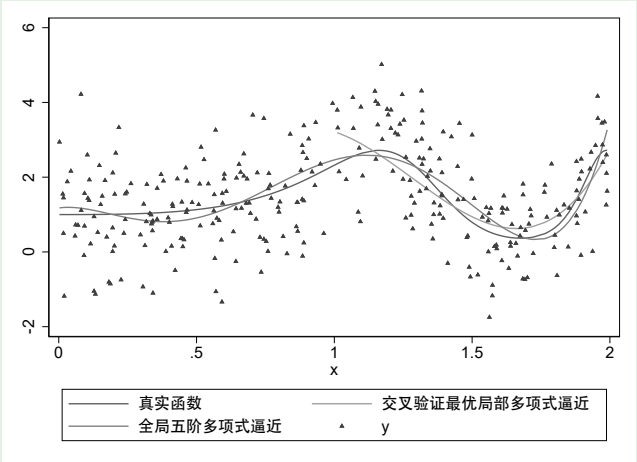
窗宽和多项式阶数选取

交叉验证选取多项式阶数和窗宽

接上例，我们使用local_poly_cv.do代码，在$p = 1, 2, ..., 5$阶多项式、$h = 0.01, 0.02, ..., 0.5$的范围内搜索最优的p和h的组合. 在以上代码中，我们针对每一个(p, h)的组合，都使用与$x = 2$最近的10个点作为测试集，用留一验证的方法在测试集上计算交叉验证的均方误差，最后选取交叉验证均方误差最小的(p, h)的组合，并进行了局部多项式的回归. 选取的结果是当$h = 0.48, p = 3$时，均方误差最小，此时预测为$\hat{y}_{x=2} = 2.743$，与真实值2.6895非常接近.

窗宽和多项式阶数选取

交叉验证选取多项式阶数和窗宽



多个解释变量

- 现在如果我们有两个解释变量，即$x=[x_1,x_2]'$，如果需要预测$\mathbb{E}\left(y|x_1=x_1^0,x_2=x_2^0\right)$，那么可以在$x$的两个维度上分别取一个核函数和一个窗宽，并使用两个变量核函数的乘积作为权重：

$$w_i=K_1\left(\frac{x_{1i}-x_1^0}{h_1}\right)K_2\left(\frac{x_{2i}-x_2^0}{h_2}\right)$$

  然后做加权最小二乘就可以了.

- 由于必须在多个维度都很接近x_0才会对$\mathbb{E}\left(y|x=x_0\right)$的估计有贡献，然而在有限样本的情况下，随着维度的增加，x_0附近的点会越来越少，为了保证相对较小的方差，就必须扩大范围，而扩大范围会造成比较大的偏差，所以在多维解释变量的情况下，以上的局部多项式估计可能并不理想，我们将这种现象称为“维数的诅咒”（the curse of dimensionality）.