

课程主页: <http://staff.ustc.edu.cn/~ynyang/2022>

第十四讲 广义最小二乘

2022.12.2

$$\text{var}(x_i) = \sigma_i^2, \text{var}\left(\frac{\sum x_i / \sigma_i^2}{1 / \sigma_i^2}\right) \leq \text{var}(\bar{x})$$

一个简单例子

例1. 若 y_1, \dots, y_n 独立, $y_i \sim (\mu, \sigma_i^2)$, $\mu = E(y_i)$ 未知, $\sigma_i^2 = \text{var}(\sigma_i^2)$ 已知, 则 μ 可由 OLS 或 GLS/WLS 估计:

普通的最小二乘法 (Ordinary LS, OLS): $\min_{\mu} \sum (y_i - \mu)^2 \Rightarrow \hat{\mu}_{OLS} = \bar{y}$

直观上, 因为诸 y_i 方差不等, μ 的估计中方差大的数据应该给予较小权重.

加权最小二乘 (Weighted LS, WLS), 以 $1/\sigma_i^2, i=1,2,\dots$ 作为权重:

$$\min_{\mu} \sum_{i=1}^n \left(\frac{y_i - \mu}{\sigma_i} \right)^2 = \min_{\mu} \sum_{i=1}^n \frac{(y_i - \mu)^2}{\sigma_i^2} \Rightarrow \hat{\mu}_{WLS} = \frac{\sum y_i / \sigma_i^2}{\sum 1 / \sigma_i^2}$$

$$WLS \text{ 估计方差更小: } \text{var}(\hat{\mu}_{WLS}) = \frac{1}{\sum 1/\sigma_i^2} \leq \frac{\sum \sigma_i^2}{n^2} = \text{var}(\hat{\mu}_{OLS}).$$

广义最小二乘 (GLS)

异方差模型
(方差几乎
完全已知)

假设如下异方差模型 (误差方差除了一个常数倍之外完全已知):

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad E(\boldsymbol{\varepsilon}) = \mathbf{0}, \quad \text{var}(\boldsymbol{\varepsilon}) = G = \sigma^2 G_0 > 0, \quad \boldsymbol{\varepsilon} \text{ 与 } X \text{ 独立}$$

假设 G_0 已知, σ^2 未知.

重要情形:

(1) $G = \sigma^2 I_n$, 即通常的GM假设。

(2) 抽样调查数据, $G = \sigma^2 \text{diag}(1/w_1, \dots, 1/w_n)$, w_1, \dots, w_n 已知权重

因为方差齐性模型中LS估计是最优的, 因此我们将其转换为齐性模型:

方程 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ 两边左乘 $G_0^{-1/2}$, 记 $\tilde{\mathbf{y}} \triangleq G_0^{-1/2} \mathbf{y}$, $\tilde{X} = G_0^{-1/2} X$, $\tilde{\boldsymbol{\varepsilon}} = G_0^{-1/2} \boldsymbol{\varepsilon}$, 得

$$\tilde{\mathbf{y}} = \tilde{X}\boldsymbol{\beta} + \tilde{\boldsymbol{\varepsilon}}, \quad \tilde{\boldsymbol{\varepsilon}} \sim (\mathbf{0}, \sigma^2 I_n) \quad (*)$$

对(*)应用普通LS (OLS, Ordinary LS), 其误差平方和为

$$(\tilde{\mathbf{y}} - \tilde{X}\boldsymbol{\beta})^\top (\tilde{\mathbf{y}} - \tilde{X}\boldsymbol{\beta}) = (\mathbf{y} - X\boldsymbol{\beta})^\top G_0^{-1} (\mathbf{y} - X\boldsymbol{\beta})$$

所以对模型(*)应用OLS方法 (左端) \Leftrightarrow 对原模型极小化右端函数。

方差齐性模型(*)的OLS解为原模型的GLS解, 对

$$\tilde{\mathbf{y}} = \tilde{X}\boldsymbol{\beta} + \tilde{\boldsymbol{\varepsilon}}, \quad \tilde{\boldsymbol{\varepsilon}} \sim (\mathbf{0}, \sigma^2 I_n) \quad (*)$$

应用OLS得:

$$\begin{aligned} \hat{\boldsymbol{\beta}}_{GLS} &= (\tilde{X}^T \tilde{X})^{-1} \tilde{X}^T \tilde{\mathbf{y}} = (X^T G_0^{-1} X)^{-1} X^T G_0^{-1} \mathbf{y} \\ \hat{\sigma}_{GLS}^2 &= \|\tilde{\mathbf{y}} - \tilde{X} \hat{\boldsymbol{\beta}}_{GLS}\|^2 / (n - p) = (\mathbf{y} - X \hat{\boldsymbol{\beta}}_{GLS})^T G_0^{-1} (\mathbf{y} - X \hat{\boldsymbol{\beta}}_{GLS}) / (n - p). \end{aligned}$$

广义最小二乘

广义最小二乘法 (GLS): GLS极小化加权误差平方和

$$\min_{\boldsymbol{\beta}} (\mathbf{y} - X\boldsymbol{\beta})^T G^{-1} (\mathbf{y} - X\boldsymbol{\beta}) \Leftrightarrow \min_{\boldsymbol{\beta}} (\mathbf{y} - X\boldsymbol{\beta})^T G_0^{-1} (\mathbf{y} - X\boldsymbol{\beta})$$

最优解称为GLS估计: $\hat{\boldsymbol{\beta}}_{GLS} = (X^T G_0^{-1} X)^{-1} X^T G_0^{-1} \mathbf{y}$,

σ^2 的GLS估计: $\hat{\sigma}_{GLS}^2 = (\mathbf{y} - X \hat{\boldsymbol{\beta}}_{GLS})^T G_0^{-1} (\mathbf{y} - X \hat{\boldsymbol{\beta}}_{GLS}) / (n - p)$.

GLS是BLUE

命题1. $E(\hat{\boldsymbol{\beta}}_{\text{GLS}} | X) = \boldsymbol{\beta}$, $\text{var}(\hat{\boldsymbol{\beta}}_{\text{GLS}} | X) = \sigma^2 (X^\top G_0^{-1} X)^{-1}$,
 $\hat{\boldsymbol{\beta}}_{\text{GLS}}$ 是 $\boldsymbol{\beta}$ 的最优线性无偏估计(BLUE)。

证明: 对模型(*),由GM定理, $\hat{\boldsymbol{\beta}}_{\text{GLS}}$ 是BLUE, 则对原模型它也是BLUE。

GLS与OLS

异方差模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim (\mathbf{0}, G = \sigma^2 G_0)$ 也可应用普通的最小二乘法(OLS: Ordinary LS),应用OLS得

$$\hat{\boldsymbol{\beta}}_{\text{LS}} = (X^\top X)^{-1} X^\top \mathbf{y} = \text{argmin} \|\mathbf{y} - X\boldsymbol{\beta}\|^2$$

容易验证: $E(\hat{\boldsymbol{\beta}}_{\text{LS}} | X) = \boldsymbol{\beta}$, $\text{var}(\hat{\boldsymbol{\beta}}_{\text{LS}} | X) = (X^\top X)^{-1} X^\top G X (X^\top X)^{-1}$

由命题1, $\text{var}(\hat{\boldsymbol{\beta}}_{\text{LS}} | X) \geq \text{var}(\hat{\boldsymbol{\beta}}_{\text{GLS}} | X)$, 即

$$(X^\top X)^{-1} X^\top G X (X^\top X)^{-1} \geq (X^\top G^{-1} X)^{-1}$$

即, 对异方差模型应用OLS是一种低效率(方差较大)的做法。

多元正态

定义：若 p 维随机向量 \mathbf{x} 的密度为

$$f(\mathbf{x}) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^\top \Sigma^{-1}(\mathbf{x} - \boldsymbol{\mu})\right), \quad \mathbf{x} \in \mathbb{R}^p$$

其中参数 $\boldsymbol{\mu} \in \mathbb{R}^p$, Σ 为 $p \times p$ 正定矩阵, 则 $\mathbf{x} \sim N_p(\boldsymbol{\mu}, \Sigma)$ 服从多元正态分布。

正态模型下的MLE和GLS

假设 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim N(0, G)$, $G = \sigma^2 G_0$ (G_0 已知, σ^2 未知), 似然函数:

$$L(\boldsymbol{\beta}) = \frac{1}{(2\pi)^{n/2} |G|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{y} - X\boldsymbol{\beta})^\top G^{-1}(\mathbf{y} - X\boldsymbol{\beta})\right)$$

极大似然函数等价于极小化:

$$-2 \log L = \log |\sigma^2 G_0| + (\mathbf{y} - X\boldsymbol{\beta})^\top G_0^{-1}(\mathbf{y} - X\boldsymbol{\beta}) / \sigma^2.$$

对 $\boldsymbol{\beta}$ 求导 (不依赖于 σ^2): $\max_{\boldsymbol{\beta}} L \Leftrightarrow \min_{\boldsymbol{\beta}} (\mathbf{y} - X\boldsymbol{\beta})^\top G_0^{-1}(\mathbf{y} - X\boldsymbol{\beta}) \Rightarrow \hat{\boldsymbol{\beta}}_{mle} = \hat{\boldsymbol{\beta}}_{GLS}$,

对 σ^2 求导: $n / \sigma^2 - RSS / \sigma^4 \Rightarrow \hat{\sigma}_{mle}^2 = (\mathbf{y} - X\hat{\boldsymbol{\beta}}_{GLS})^\top G_0^{-1}(\mathbf{y} - X\hat{\boldsymbol{\beta}}_{GLS}) / n = \frac{n-p}{n} \hat{\sigma}_{GLS}^2$

MLE与OLS

特别地, 若 $G = \sigma^2 I_n$, 极大似然估计:

$$\tilde{\boldsymbol{\beta}}_{mle} = (X^\top X)^{-1} X^\top \mathbf{y} = \hat{\boldsymbol{\beta}}_{LS}, \quad \tilde{\sigma}_{mle}^2 = \|\mathbf{y} - X\tilde{\boldsymbol{\beta}}_{mle}\|^2 / n = \hat{\sigma}_{LS}^2 \times \frac{n-p}{n}.$$

WLS与抽样调查

加权最小二乘

假设模型 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}$, $E(\boldsymbol{\varepsilon}) = 0$, $G = \text{var}(\boldsymbol{\varepsilon}) = \sigma^2 W^{-1}$, 其中 $W = \text{diag}(w_1, \dots, w_n)$, w_1, \dots, w_n 为已知权重, 则加权最小二乘目标函数形式如下:

$$(\mathbf{y} - X\boldsymbol{\beta})^T W (\mathbf{y} - X\boldsymbol{\beta}) = \sum_{i=1}^n w_i (y_i - \tilde{\mathbf{x}}_i^T \boldsymbol{\beta})^2$$

$$\Rightarrow \hat{\boldsymbol{\beta}}_{WLS} = (X^T W X)^{-1} X^T W \mathbf{y} = \left(\sum_{i=1}^n w_i \tilde{\mathbf{x}}_i \tilde{\mathbf{x}}_i^T \right)^{-1} \left(\sum_{i=1}^n w_i \tilde{\mathbf{x}}_i y_i \right),$$

$$\hat{\sigma}_{WLS}^2 = (\mathbf{y} - X\hat{\boldsymbol{\beta}}_{WLS})^T W (\mathbf{y} - X\hat{\boldsymbol{\beta}}_{WLS}) / (n - p) = \sum_{i=1}^n w_i (y_i - \tilde{\mathbf{x}}_i^T \hat{\boldsymbol{\beta}}_{WLS})^2 / (n - p),$$

其中加权残差 $e_i = \sqrt{w_i} (y_i - \tilde{\mathbf{x}}_i^T \hat{\boldsymbol{\beta}}_{WLS})$,

例如, 在抽样调查 cluster survey 中, 第 i 个 cluster 的响应通常是类内所有 m_i 个个体的数据汇总, 比如平均或中位数, 自变量 \mathbf{x}_i 为第 i 个 cluster 的特征, 则需假设异方差模型

$$y_i = \tilde{\mathbf{x}}_i^T \boldsymbol{\beta} + \varepsilon_i, E(\varepsilon_i) = 0, \text{var}(\varepsilon_i) = \sigma^2 / m_i, w_i = 1 / m_i$$

注: 大多数 cluster 汇总统计量的方差与 $1/m_i$ 成正比, 但也有例外, 如果汇总是最大值或最小值, 则其方差可能与 $1/\sqrt{\log(m_i)}$ 成正比。

例2 (简单线性回归的 WLS). 假设 $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \varepsilon_i \sim (0, \sigma^2 / w_i)$, w_i 已知. WLS 极小化

$$\sum_{i=1}^n w_i (y_i - \beta_0 - \beta_1 x_i)^2$$

$$\hat{\beta}_1 = \frac{\sum w_i (x_i - \bar{x}_w) y_i}{\sum w_i (x_i - \bar{x}_w)^2}, \quad \bar{x}_w = \frac{\sum w_i x_i}{\sum w_i}; \quad \hat{\beta}_0 = \bar{y}_w - \hat{\beta}_1 \bar{x}_w, \quad \bar{y}_w = \frac{\sum w_i y_i}{\sum w_i},$$

$$\text{var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum w_i (x_i - \bar{x}_w)^2}, \quad \text{var}(\hat{\beta}_0) = \frac{\sigma^2}{\sum w_i} + \frac{\bar{x}_w^2 \sigma^2}{\sum w_i (x_i - \bar{x}_w)^2}$$

注意: 如果将加权最小二乘目标函数写成普通最小二乘的形式(变换 y, x):

$$\sum_{i=1}^n w_i (y_i - \beta_0 - \beta_1 x_i)^2 = \sum_{i=1}^n (\sqrt{w_i} y_i - \sqrt{w_i} \beta_0 - \beta_1 \sqrt{w_i} x_i)^2$$


记 $\tilde{y}_i = \sqrt{w_i} y_i, \tilde{x}_i = \sqrt{w_i} x_i, \tilde{z}_i = \sqrt{w_i}$, 上述右端平方和为 $\sum_{i=1}^n (\tilde{y}_i - \tilde{z}_i \beta_0 - \tilde{x}_i \beta_1)^2$

对应的方差齐性模型 $\tilde{y}_i = \tilde{z}_i \beta_0 + \tilde{x}_i \beta_1 + \tilde{\varepsilon}_i$ 不含截距项。

例3. 数据集 salarygov (alr4) 汇总了美国政府某部门495种职位的信息，把包括每种职位的最高工资、每种职位的人数、女性人数和难度系数(Score)。目的是研究工资与职位难度的关系。变量具体描述如下：

变量	描述
MaxSalary	职位最高工资
Score	职位难度系数 (82-1017)
NE	该职位的雇员总数
NW	该职位的女性人数

JobClass	NW	NE	Score	MaxSalary
Account_clerk	52	68	258	1549
Account_clerk_Interm	26	29	269	1712
Account_clerk_Principal	10	13	321	2182
Account_clerk_Senior	16	24	273	1982
Accountant	1	12	352	2555
...				



WLS: lm函数指定 weights: $w_i = \sqrt{\log(NE)}$
 $\text{lm}(y \sim x, \text{weights} = (w_1, w_2, \dots, w_n))$

$x_1, \dots, x_n \text{ iid} \sim N(0,1), x_{(n)} = \max(x_i)$

$\text{var}(x_{(n)}) \approx \frac{c}{\sqrt{\log(n)}}, E(x_{(n)}) \approx \sqrt{2\log(n)}$

迭代加权最小二乘方法(IRLS)

复杂的误差方差结构 $G = G(\theta)$ 下, 其中 θ 是未知参数, 通用的方法是极小化

$$Q(\theta, \beta) = (\mathbf{y} - X\beta)^\top G^{-1}(\theta)(\mathbf{y} - X\beta) + \log |G(\theta)|,$$

可以认为是极小化加权误差平和的时候施加惩罚 $\log |G(\theta)|$, 实际上该目标函数是正态模型下的对数似然函数。


虽然极小化Q函数可以同时求解最优的 β 和 θ , 但更简单的方法还是分开求解 β 和 θ , 即

- 给定当前的 θ 解, 利用GLS求解 β ;
- 给定 β , 利用残差求解 θ

上述两步反复迭代直至收敛。

例4. 右图所示的误差在第 m 个样本点处转变,

$\mathbf{y} = X\beta + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim (0, G), G = \text{diag}(\sigma^2, \dots, \sigma^2, \tau^2, \dots, \tau^2),$
假设 m 已知, $\theta = (\sigma^2, \tau^2)$ 。



$$\begin{aligned}
Q(\boldsymbol{\theta}, \boldsymbol{\beta}) &= \log |G(\boldsymbol{\theta})| + (\mathbf{y} - X\boldsymbol{\beta})^\top G^{-1}(\boldsymbol{\theta})(\mathbf{y} - X\boldsymbol{\beta}) \\
&= m \log(\sigma^2) + (n - m) \log(\tau^2) + \sum_{i=1}^m \frac{(y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2}{\sigma^2} + \sum_{i=m+1}^n \frac{(y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2}{\tau^2}
\end{aligned}$$

虽然直接同时极小化 $\boldsymbol{\theta}, \boldsymbol{\beta}$ 很容易，但我们下面分步对它们求解：

IRLS解法：

Step0. $k = 0$, 初始化 $\hat{\boldsymbol{\beta}}^{(k)} = \hat{\boldsymbol{\beta}}_{\text{OLS}}$,

Step1. $k = k + 1$, 计算残差 $\mathbf{e} = \mathbf{y} - X\hat{\boldsymbol{\beta}}^{(k-1)}$, 并估计 σ^2, τ^2 :

$$\hat{\sigma}_{(k)}^2 = \sum_{i=1}^m e_i^2 / m, \quad \hat{\tau}_{(k)}^2 = \sum_{i=m+1}^n e_i^2 / (n - m), \quad G_k = \text{diag}(\hat{\sigma}_{(k)}^2, \dots, \hat{\sigma}_{(k)}^2, \hat{\tau}_{(k)}^2, \dots, \hat{\tau}_{(k)}^2)$$

Step2. 计算GLS估计 $\hat{\boldsymbol{\beta}}^{(k)} = (X^\top G_k^{-1} X)^{-1} X^\top G_k^{-1} \mathbf{y}$,

goto Step1, 重复至收敛。

例5. 配对数据中每一对中的两个个体接受不同的处理，其响应 y_{1j} , y_{2j} 不独立，通常假设他们共享一个共同的随机变量 β_j ，假设混合效应模型

(mixed-effects model):

$$\begin{cases} y_{1j} = \mu + \beta_j + \delta_{1j} \\ y_{2j} = \mu + \beta_j + \alpha + \delta_{2j} \end{cases}, \quad \delta_{ij} \text{ iid} \sim N(0, \sigma^2), j = 1, \dots, J,$$

其中 $\beta_1, \dots, \beta_J \text{ iid} \sim N(0, \tau^2)$ 称为随机效应(randomeffects), 与 δ 's独立, δ_{1j} 和 δ_{2j} 分别是第 j 对两个个体的个体效应(随机误差), α, μ 是参数(称为固定效应 fixed effects), 固定效应 α 代表了两个个体的差异。记每一对的方差协方差矩阵

$$\Psi = \text{var} \begin{pmatrix} y_{1j} \\ y_{2j} \end{pmatrix} = \begin{pmatrix} \tau^2 + \sigma^2 & \tau^2 \\ \tau^2 & \tau^2 + \sigma^2 \end{pmatrix}.$$

记所有响应 $\mathbf{y} = (y_{11}, y_{21}, y_{12}, y_{22}, \dots)^\top$, $\boldsymbol{\beta} = (\mu, \alpha) \Rightarrow$ 异方差模型

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N(0, G), \quad G = \begin{pmatrix} \Psi & 0 & & \\ 0 & \Psi & & \\ & & \ddots & \\ & & & \Psi \end{pmatrix} = I_n \otimes \Psi \text{ (Kronecker 乘积)}.$$

IRLS: (1)给定 τ^2, σ^2 时, GLS求解 β ; 计算残差 $e_{1j}, e_{2j}, j = 1, 2, \dots$

(2)给定 β , 求解 τ^2, σ^2 有些繁琐, 可构造简单(不必最好)的估计:

$$\tau^2 = S_{12} = \sum (e_{1j} - \bar{e}_1)(e_{2j} - \bar{e}_2) / n,$$

$$\sigma^2 = (S_{11} + S_{22}) / 2 - S_{12}, \quad S_{11} = \sum (e_{1j} - \bar{e}_1)^2 / n$$

$$\text{var} \begin{pmatrix} \varepsilon_{1j} \\ \varepsilon_{2j} \end{pmatrix} = \begin{pmatrix} \tau^2 + \sigma^2 & \tau^2 \\ \tau^2 & \tau^2 + \sigma^2 \end{pmatrix}$$

纵向数据(longitudinal data): 每个个体 i 有多次测量 $(y_{ik}, \mathbf{x}_{ik}), k = 1, \dots, n_i$,
(每个个体类似于方差分析中的区组, 前述成对数据可看作是最简单的纵向数据), 假设混合效应线性模型(既有随机效应, 也有固定效应)

$$y_{ik} = \alpha_i + \beta^\top \mathbf{x}_{ik} + \varepsilon_{ik}, \varepsilon_{ik} \text{ iid} \sim (0, \sigma^2), k = 1, \dots, n_i$$

其中 α_i 其个体 i 的效应(~区组效应), 代表个个体之间的差异, 同一个个体 i 的所有观测都与 α_i 有关。若 α_i 为参数, 称为固定效应; 若假设 α_i 为随机变量, 比如通常假设 $\alpha_i \sim N(\alpha, \tau^2)$, 称为随机效应。 β 通常是固定的。

很多问题的优化目标函数可写成加权LS的形式:

$$\min_{\boldsymbol{\beta}, \boldsymbol{\theta}} \sum w_i(\boldsymbol{\beta}, \boldsymbol{\theta}) (y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2, \text{ 权与 } \boldsymbol{\beta}, \boldsymbol{\theta} \text{ 有关}$$

假设分别优化 $\boldsymbol{\beta}$ 和 $\boldsymbol{\theta}$ 比较容易, 可以转化为IRLS:

$$\boldsymbol{\beta}^{(k)} = \arg \min_{\boldsymbol{\beta}} \sum w_i(\boldsymbol{\beta}^{(k-1)}, \boldsymbol{\theta}^{(k-1)}) (y_i - \mathbf{x}_i^\top \boldsymbol{\beta})^2$$

- 给定 $\boldsymbol{\theta} = \boldsymbol{\theta}^{(k-1)}$, $\boldsymbol{\beta} = \boldsymbol{\beta}^{(k-1)}$, 计算 $w_i(\boldsymbol{\beta}^{(k-1)}, \boldsymbol{\theta}^{(k-1)})$, WLS方法更新 $\boldsymbol{\beta} = \boldsymbol{\beta}^{(k)}$;
- 使用更新的 $\boldsymbol{\beta} = \boldsymbol{\beta}^{(k)}$, 使用残差更新 w_i 中或 G 中的未知参数 $\boldsymbol{\theta}$ 的估计。

线性模型的M估计方法 (稳健回归): 模型: $\mathbf{y} = X \boldsymbol{\beta} + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim (0, \sigma^2 I_n)$,

$$\min \sum \rho(y_i - \mathbf{x}_i^\top \boldsymbol{\beta}), \rho(\cdot) \geq 0 \text{ 关于 } 0 \text{ 对称}, \rho(0) = 0.$$

当 $\rho(t) = |t|$ 时称为最小一乘法或LAD (least absolute deviation).

对于LAD方法, 改写目标函数:

$$\sum |y_i - \mathbf{x}_i^\top \boldsymbol{\beta}| = \sum w_i(\boldsymbol{\beta}) |y_i - \mathbf{x}_i^\top \boldsymbol{\beta}|^2, \text{ 其中 } w_i(\boldsymbol{\beta}) = |y_i - \mathbf{x}_i^\top \boldsymbol{\beta}|^{-1}.$$

$$\text{IRLS: } w_i(\boldsymbol{\beta}) = |y_i - \mathbf{x}_i^\top \boldsymbol{\beta}|^{-1}, \boldsymbol{\beta}^{(k+1)} = \arg \min_{\boldsymbol{\beta}} \sum w_i(\boldsymbol{\beta}^{(k)}) |y_i - \mathbf{x}_i^\top \boldsymbol{\beta}|^2.$$
