

* Estimação robusta

situações que justifiquem estimadores robustos:

→ Presença de medições incompatíveis (outliers)

→ Dados que não se ajustam mais de um modelo.

Os métodos que são capazes de lidar com estas situações são estudados em "estatística robusta".

Alguns deles são estudados aqui.

a) M-estimadores (M vem de máxima verossimilhança)

Função de custo:

$$V(\mathbf{z}, \theta) = \sum_{k=1}^N \rho(r_k)$$

r_k : resíduos. ρ é uma função simétrica, positiva definida, cujo $\rho(0) = 0$ é o único valor para o qual ρ é nula. r_k é o k -ésimo resíduo:

$$r_k = y_k - f(x_k, \theta).$$

Procura-se portanto

$$\hat{\theta} = \arg \min_{\theta} V(\mathbf{z}, \theta).$$

Mas, $\hat{\theta}$ satisfaz a:

$$\left. \frac{\partial V(\mathbf{z}, \theta)}{\partial \theta} \right|_{\theta = \hat{\theta}} = \sum_{k=1}^N \psi(r_k) \cdot \left. \frac{\partial r_k}{\partial \theta} \right|_{\theta = \hat{\theta}} = 0$$

com $\psi(r_k) = \frac{\partial \rho(r_k)}{\partial r_k}$ sendo a chamada função de influência. (na verdade, ψ é proporcional à função de influência).

A função ψ indica como as medidas influenciam no processo de estimação. Por exemplo, com $\rho(r_k) = \frac{r_k^2}{2}$, temos o critério soma dos quadrados. Sendo

$$\psi(r_k) = r_k \Rightarrow \text{Ponto de ruptura } 0,$$

que mostra que cada medida tem influência na estimação. Já, se for usada a função de Huber:

$$\rho(r_k) = \begin{cases} r_k^2/2, & \text{se } |r_k| \leq c.s. \\ c.s. (|r_k| - c.s./2), & \text{caso contrário} \end{cases}$$


com $c = 1,345$ se o "bom erro" for Gaussiano, e s é uma estimativa de escala. Geralmente usa-se


$$s = \text{MAD}(r) = \text{med}_i \{ |r_i - \text{med}_j(r_j)| \}$$

} Mostrar como é robusto se comparado à média (median) e desvio padrão (MAD)


Tem-se então que

$$\psi(r_k) = \begin{cases} r_k, & \text{se } |r_k| \leq c.s. \\ c.s. \cdot \text{sign}(r_k), & \text{caso contrário} \end{cases}$$

$|r_k|:$ 

$\frac{d|r_k|}{dr_k} = \begin{cases} 1 & \text{for } r_k > 0 \\ -1 & \text{for } r_k < 0 \end{cases}$ 

Portanto




ou ainda, tem-se a função Tukey biweight:

$$\rho(r_k) = \begin{cases} \frac{(c.s.)^2}{6} (1 - [1 - (r_k/c.s.)^2]^3), & |r_k| \leq c.s. \\ \frac{(c.s.)^2}{6}, & \text{caso contrário} \end{cases}$$

que leva a

$$\psi(r_k) = \begin{cases} r_k \cdot [1 - (r_k/c.s.)^2]^2, & |r_k| \leq c.s. \\ 0, & \text{c.c.} \end{cases}$$



Intervalo de influência

o que mostra que $|r_k| \geq c.s$ não tem influência na estimativa.

A resolução do problema pode ser através de um método iterativo por exemplo lidando com um problema não linear, ou por mínimos quadrados ponderados iterativos. O princípio é simples:

Seja

$$w(r_k) = \frac{\psi(r_k)}{r_k} \quad \text{é peso associado a } r_k$$

então

$$\sum_{k=1}^N \psi(r_k) \cdot \frac{\partial r_k}{\partial \theta} \Big|_{\theta=\hat{\theta}} = \sum_{k=1}^N w(r_k) \cdot r_k \cdot \frac{\partial r_k}{\partial \theta} \Big|_{\theta=\hat{\theta}} = 0$$

que é o mesmo problema de

$$\hat{\theta} = \arg \min_{\theta} \sum_{k=1}^N w(r_k) \cdot \frac{r_k^2}{2}$$

que é o de mínimos quadrados ponderados.

Assim, o algoritmo se escreve como

(i) inicializa todos os pesos $w(r_k)$. Alternativas:

a) $w(r_k) = 1$ (sem info $\hat{\theta}_0$ a priori)

b) $w(r_k) = \frac{\psi(r_k)}{r_k}$ (com $\hat{\theta}_0$ a priori)

(ii) resolve o problema de mínimos quadrados ponderados:

$$\hat{\theta} = \arg \min_{\theta} \sum_{k=1}^N w(r_k) \cdot \frac{r_k^2}{2} \quad \left. \begin{array}{l} \text{solução fechada} \\ p(r_k, \theta) = p_k^T \cdot \theta \end{array} \right\}$$

(iii) recalcule $w(r_k)$ considerando a nova estimativa.

(iv) verifica se condições de paradas são satisfeitas.

Caso não, retorne p_i o passo (ii).

Como exemplo, $w(r_k)$ pode ser:

• P/ $p(r_k) = \frac{r_k^2}{2}$ (mínimos quadrados), $w(r_k)$

$$w(r_k) = 1.$$

• P/ $p(r_k)$ sendo a função de Huber, então

$$w(r_k) = \begin{cases} 1, & |r_k| \leq c.s. \\ \frac{c.s.}{|r_k|}, & c.c. \end{cases}$$

$$= \min \left\{ 1, \frac{c.s.}{|r_k|} \right\}$$

• P/ $p(r_k)$ sendo Tukey's' biweight

$$w(r_k) = \begin{cases} [1 - (r_k/c.s.)^2]^2, & |r_k| \leq c.s. \\ 0, & c.c. \end{cases}$$

b) Mediana mínima dos quadrados (least Median of Squares, ou LMedS)*


No LMedS, estamos interessados em resolver o seguinte problema

$$\hat{\theta} = \arg \min_{\theta} \operatorname{med}_k r_k^2, \quad k=1, \dots, N.$$

com $r_k = y_k - f(x_k, \theta)$. No caso, foi mostrado que o ponto de ruptura é dado por

$$\frac{\frac{N}{2} - d + 2}{N}$$

que, com $N \rightarrow \infty$ leva a 50% independente do número d de parâmetros. Mas, se considerarmos o problema de regressão linear p/ $d=2$ (reta), tem-se que o ponto de ruptura é 50%! Esse argumento é fácil de se aceitar, bastando considerar o histograma dos resíduos:



* Alguns autores denominam LMS, mas pode ser confundido com

O problema agora consiste em encontrar $\hat{\theta}_1$, ou seja, resolver o problema de otimização proposto pelo LMeds. Deve-se observar que o critério LMeds não é diferenciável. Portanto, não podemos usar os métodos Newtonianos. O seguinte algoritmo é então proposto:

Seja $Z = (x_1, y_1) \dots (x_N, y_N)$ N conjuntos de medição.

1. Para $s=1$ até S , faça:

- Amoshe um subconjunto de d amostras do conjunto Z sem reposição Z_s
- Resolva o problema para Z_s usando, por exemplo, mínimos quadrados:

$$\hat{\theta}_s = \arg \min_{\theta} \sum_{(x_i, y_i) \in Z_s} (y_i - f(x_i, \theta))^2$$
- Calcule $m_s = \text{med } r_k^2$ com $r_k = y_k - f(x_k, \hat{\theta}_s)$, $k=1, \dots, N$

2. Escolha como estimativa $\hat{\theta}_{\text{LMeds}}$ aquela associada à menor mediana dentre as S amostras anteriores.

O algoritmo acima faz uso de amostragem para determinar a estimativa $\hat{\theta}_{\text{LMeds}}$. Um ponto a ser resolvido consiste em determinar o número de amostras S , que deve ser grande o suficiente de forma que seja grande a chance de se amostrar pelo menos um subconjunto com "outliers". Sendo p a proporção de outliers no processo, a probabilidade de se ter pelo menos um outlier no conjunto de S amostras é

$$P_i = 1 - (1-p^d)^S$$

do qual observar que

(7)

p^d : Probabilidade de todos os pontos de um subconjunto z_s de d amostras serem "inliers"

$1-p^d$: Probabilidade de se ter quando pelo menos um "outlier" em z_s .

$(1-p^d)^S$: Probabilidade de todos os subconjuntos z_s terem pelo menos um "outlier"

P_i : Probabilidade de pelo menos um subconjunto z_s não possuir "outliers".

O número S pode então ser obtido como

$$S = \frac{\ln(1-P_i)}{\ln(1-p^d)}$$

Para se ter uma ideia, seja $d=2$ (reta), $p=0,5$ (o mais robusto possível) e $P_i=0,999$, teríamos $S \approx 25$, que é um número razoável. Esse critério considera que a amostragem é realmente aleatória.

Por outro lado $\hat{\sigma}_{LMeds}$ é ineficiente na presença de ruído Gaussiano (ver literatura), de forma que ele é mais utilizado para determinar os "inliers". Para tanto, sendo M_{LMeds} a mediana correspondente a $\hat{\sigma}_{LMeds}$, usa-se a seguinte estimativa de desvio-padrão para os "inliers"

$$\hat{\sigma}_{LMeds} = 1,4826 \cdot \left\{ 1 + \frac{S}{N-d} \right\} \cdot \sqrt{M_{LMeds}}$$

e estas, obtêm-se como estimativa a solução (8)

$$\hat{\theta} = \arg \min_{\theta} \sum_{k=1}^N w_k \cdot (y_k - f(x_k, \theta))^2$$

com $w_k = \begin{cases} 1, & \text{se } |y_k - f(x_k, \hat{\theta}_{LHeds})| \leq 2,5 \cdot \hat{\sigma}_{LHeds} \\ 0, & \text{caso contrário} \end{cases}$

