





# ROBUST REGRESION

رگرسیون نیرومند

ارائه دهندگان:

نیلوفر شاه میوه

مریم داوری

مدل خطی ساده:

$$Y = X\beta + \varepsilon$$


$$\rightarrow \varepsilon \sim N(0, \delta I)$$

$$\rightarrow Y \sim N(X\beta, \delta I)$$

که در این مدل خطی دارای توزیع نرمال و مشاهدات  $Y$  نیز به صورت نرمال توزیع شده اند بنابراین از روش حداقل مربعات برای برآورد  $\beta$  استفاده می کنیم

$$\hat{\beta} = (X'X)^{-1}XY$$






◀ اگر مشاهدات توزیع غیر نرمال داشته باشند به خصوص که شافه انتهایی منحنی طویل تر یا ضمیمه تر از نرمال باشد ممکن است روش حداقل مربعات مناسب نباشد

◀ شافه های ضمیمه معمولاً نقاط دور افتاده ایجاد می کند که این نقاط دور افتاده بر برآورد حداقل مربعات تاثیر می گذارد. دور افتاده ها برآزش حداقل مربعات را تا حد زیادی به سمت خود می کشاند و در نتیجه تعیین و تشخیص این دور افتاده ها مشکل می شود

به روش حداقل مربعات مسئله رگرسیون نرم- $L_2$  نیز گفته میشود.



◀ رگرسیون نیرومند برای کاهش اثر مشاهداتی به کار می رود که اگر روشن حداقل مربعات به کار گرفته شود اثر بالایی خواهند داشت.

◀ رگرسیون نیرومند باقی مانده های مرتبط با دور افتاده های بزرگ را کنار می گذارد که بدین وسیله تشخیص دور افتاده ها خیلی ساده تر می شود.

◀ یک رگرسیون نیرومند علاوه بر حساس نبودن نسبت به دور افتاده ها وقتی مشاهدات توزیع نرمال دارد دارای کارایی ۹۰-۹۵ درصد نسبت به روش برآورد حداقل مربعات می باشد.


نمودار پراکنش

مانده های  
استیودنت  
شده

راه های تشخیص  
داده پرت:

آماره کوچک





شکل ۱-۳ نمودارهای احتمال نرمال: (a) قابل قبول؛ (b) توزیع با دم کلفت؛ (c) توزیع با دم باریک؛ (d) عدم تقارن مثبت؛ (e) عدم تقارن منفی.

آماره کوک را به فرم زیر تعریف می کنیم:

$$D_i = \frac{r_i^2}{2} \times \frac{h_{ii}}{1 - h_{ii}}$$

اگر داشته باشیم

$$D_i < 1$$

$$D_i > \frac{4}{n-2}$$

داده پرت  
است



که در آن:

$$h_{ii} = \frac{1}{n} + \frac{(x_i - \bar{x})^2}{S_{xx}}$$


$$r_i = \frac{e_i}{\sqrt{MS_E [1 - (h_{ii})]}}$$

که در آن متوسط مجموع مربعات خطا به صورت زیر بدست می آید:

$$MS_E = \frac{SS_E}{n - 2} = \frac{\sum_{i=1}^n e_i^2}{n - 2}$$

باقی مانده های استیودنت شده را به فرم زیر داریم:

$$r_i = \frac{e_i}{\sqrt{MS_E[1 - (h_{ii})]}}$$



علت وجود داده پرت:

اندازه گیری غلط و ثبت یا انتقال نادرست داده ها—از کار افتادن وسیله اندازه گیری و ...

نقاط اهرمی:


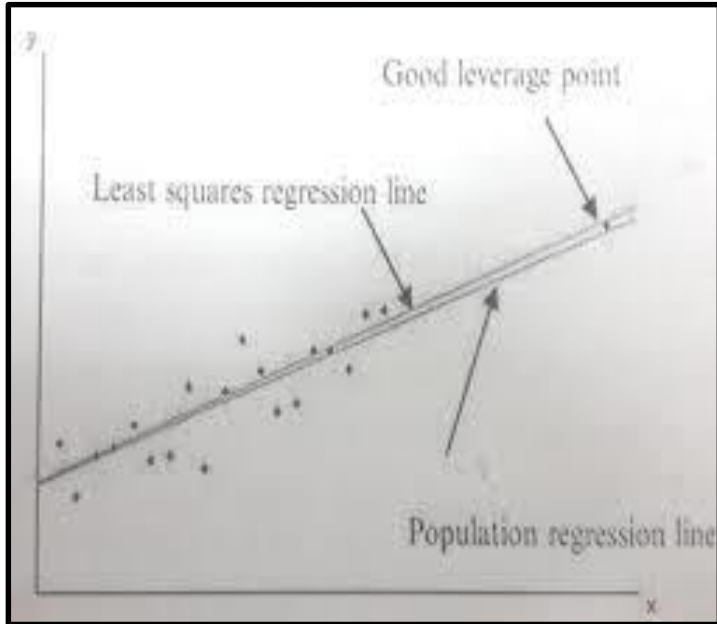
زمانی که داده ها دارای چند مولفه غیر طبیعی  $X$  باشند به این داده ها نقاط اهرمی گفته می شود.

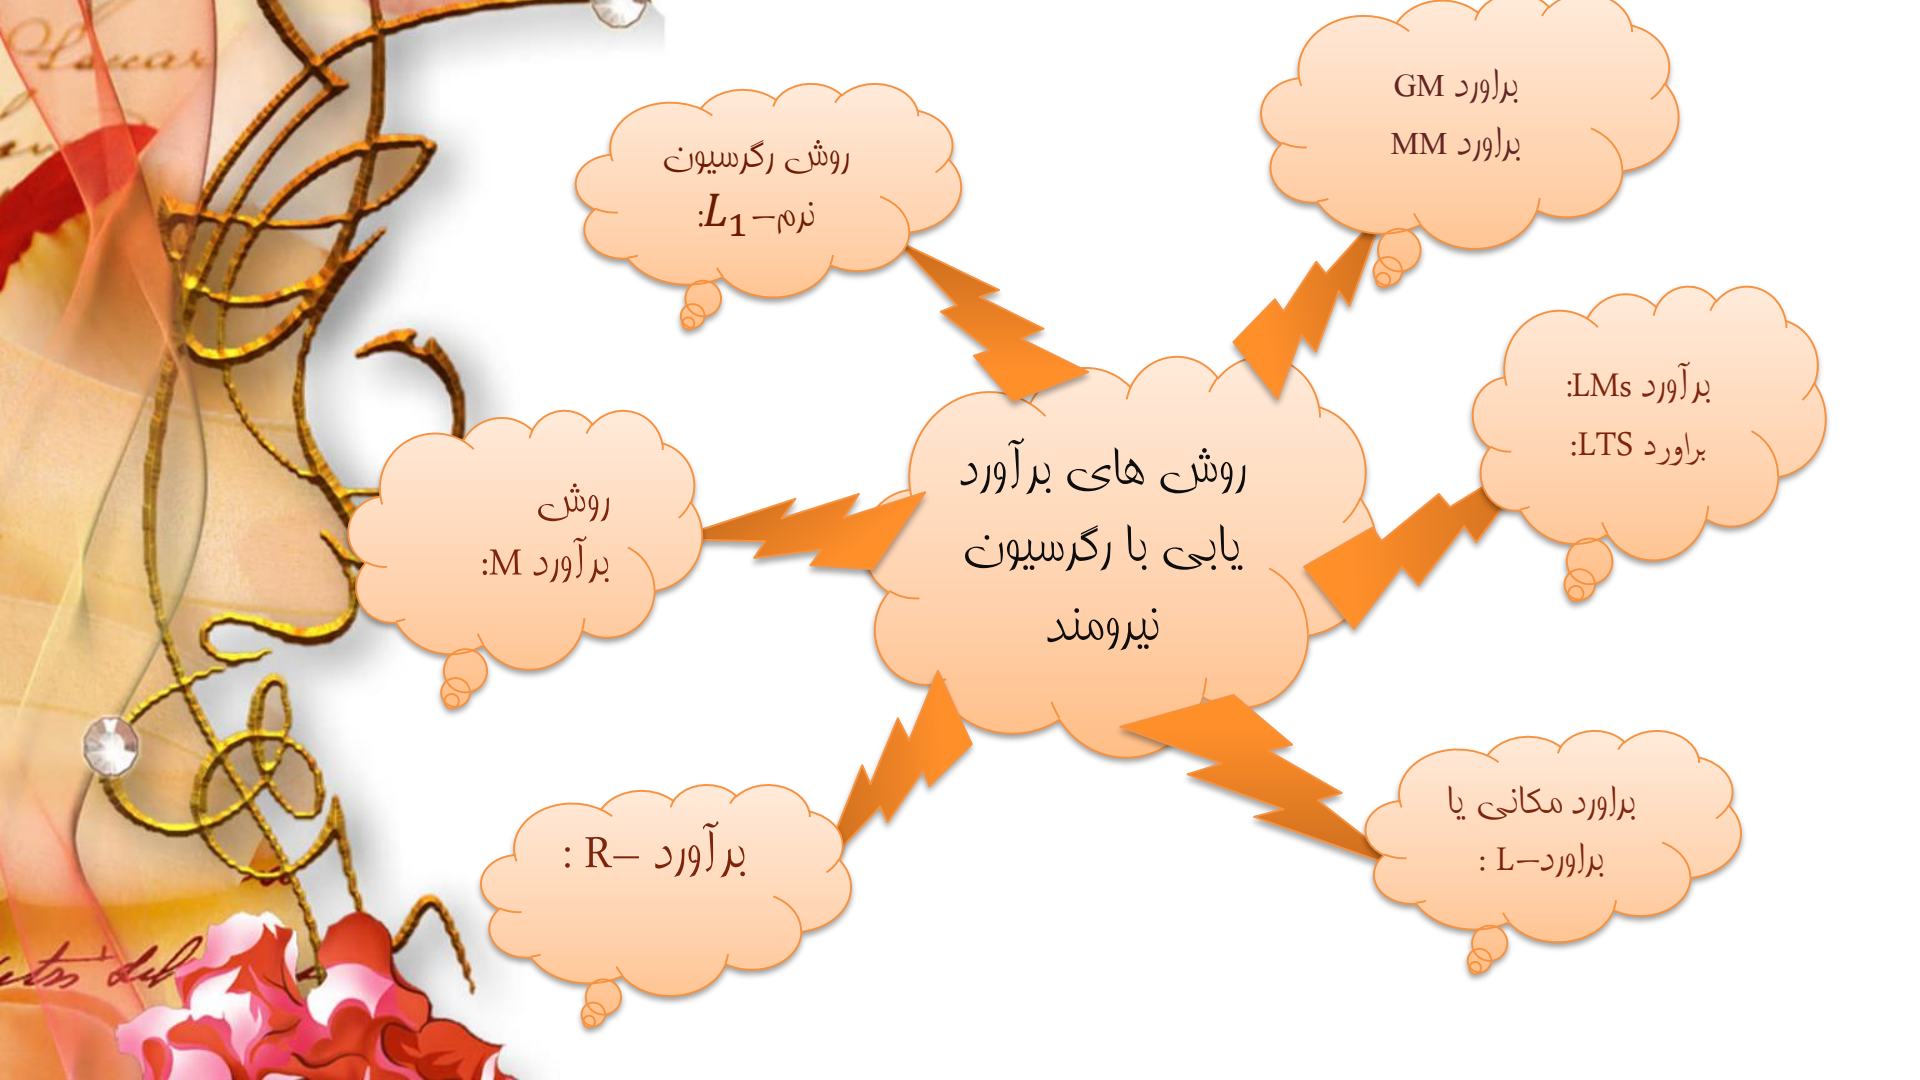
نقاط اهرمی خوب: از طرح کلی داده ها پیروی می کند یعنی در جهت  $X$  پرت است.

نقاط اهرمی بد: از طرح کلی داده ها پیروی نمی کند و در جهت  $y$  پرت است.



نقاط اهرمی بد مانند اهرم عمل کرده و خط کمترین مربعات نظرا به شکل قابل توجهی تحت تاثیر خود قرار می دهد.





روشن‌های برآورد  
یابی با رگرسیون  
نیرومند

روشن رگرسیون  
نرم- $L_1$ :

برآورد  
GM  
برآورد  
MM

برآورد  
LMs:  
برآورد  
LTS:

روشن  
برآورد  
M:

برآورد  
R- :

برآورد مکانی یا  
برآورد-L :

## روش رگرسیون نرم- $L_1$ :

◀ حالت فاصی از رگرسیون نرم  $L_p$  می باشد که در آن پارامترهای مدل طوری انتخاب می شوند که  $\sum_{i=1}^n |\varepsilon_i|^p$  ( $1 \leq p \leq 2$ ) می نیمم شود. یعنی برای  $p=1$  به جای مینیمم کردن  $\varepsilon_i^2$  از قدر مطلق  $|\varepsilon_i|$  استفاده می شود.

$$\min \sum_{i=1}^n |\varepsilon_i|$$

✽ قدر مطلق  $|\varepsilon_i|$  در مقابل  $\varepsilon_i^2$  حساسیت کمتری دارد.

◀  $p=1.5$  یک انتخاب قراردادی است که منجر به برآورد هایی می شود که وقتی فضاها نرمال نیستند از برآورد حداقل مربعات بهتر است. وقتی هم که فضاها نرمال باشند به کار گیری  $p=1.5$  برآوردگرهایی را با کارایی به اندازه ۹۰٪ حداقل مربعات می دهد. اما نمی توان روش  $L_1$  را به عنوان جایگزین برای حداقل مربعات در نظر گرفت زیرا به شدت تحت تاثیر مشاهده پرت در جهت  $X$  است.



# روش برآورد M:

متداول ترین روش برآورد رگرسیون نیرومند روش M است  
در حالت کلی می توان دسته ای از برآورد گر های نیرومند را تعریف کرد که یک تابع  $\rho$  از  
باقی مانده ها را می نیمم می کند. یعنی به جای  $\varepsilon_i^2$  از یک تابع  $\rho(\varepsilon_i)$  استفاده کنیم.  
مدل فنی زیر را در نظر بگیرید:

$$y_i = \beta_0 + \beta_2 x_{i2} + \dots \dots \dots \beta_k x_{ik} + \varepsilon_i$$

که در آن

$$e_i = y_i - \hat{y}_i$$

با توجه به برآورد M داریم:

$$\min \sum_{i=1}^n \rho(e_i) = \min \sum_{i=1}^n \rho(y_i - \hat{x}_i \beta)$$

که در آن  $x_i$  نشان دهنده  $i$  امین سطر از ماتریس  $X$  می باشد این گونه برآورد گر یک برآورد گر  $M$  نامیده می شود که در آن  $M$  برای درست نمایی ماکزیمم قرار داده می شود بدین معنی که تابع  $\rho$  به تابع درستنمایی برای انتخاب مناسب توزیع فضا بستگی دارد. برای مثال اگر روشن حداقل مربعات به کار برده شود (نتیجه گرفته می شود که توزیع فضا نرمال است) در این صورت:

$$\rho(z) = \frac{1}{2} z^2, \quad -\infty < z < \infty$$

فضا برازش شده است  $z = \sum_{i=1}^n (c_i + d_i)$  که  $c_i$  و  $d_i$  انحرافات مثبت و منفی حول

برازش شده  
 $z = \sum_{i=1}^n (c_i + d_i)$  که  $c_i$  و  $d_i$  انحرافات مثبت و منفی حول نقطه

یک  $\rho$  قابل قبول باید شرایط زیر را داشته باشد:

۱- همواره نامنفی است  $\rho(e) \geq 0$

۲-  $\rho(0) = 0$

۳- متقارن است  $\rho(e) = \rho(-e)$

۴- یکنوا است  $\text{if } e_i \geq e'_i \text{ then } \rho(e_i) \geq \rho(e'_i)$

برآورد گر  $M$  لزوماً پایا مقیاس نیست (یعنی اگر باقی مانده های  $y_i - x_i\beta$  در یک ثابت ضرب شوند جواب جدید

مانند جواب قدیم نباشد).  
 $\min \sum_{i=1}^n \rho(e_i) = \min \sum_{i=1}^n \rho(y_i - x_i\beta)$  ممکن است



برای بدست آوردن شکل جدید پایا مقیاس از برآورد گر معمولاً معادله زیر را حل می کنیم .

$$\min \sum_{i=1}^n \rho\left(\frac{e_i}{s}\right) = \min \sum_{i=1}^n \rho\left(\frac{y_i - \hat{x}_i \beta}{s}\right)$$

که در آن  $s$  یک برآورد گر نیرومند مقیاس است و برابر است با:

$$s = \frac{\text{median}|e_i - \text{median}(e_1, \dots, e_n)|}{0.675}$$

تعریف می کنیم تابع  $\psi = \dot{\rho}$  مشتق تابع  $\rho$  نسبت به  $(j = 0, 1, \dots, k)$

برای مینیمم کردن  $\sum_i^n \rho\left(\frac{y_i - \hat{x}_i \beta}{s}\right)$  مشتق  $\rho$  نسبت به  $\beta$  را مساوی صفر قرار می دهیم.

$$\sum_i^n x_{ij} \psi\left(\frac{y_i - \hat{x}_i \beta}{s}\right) = 0$$

که  $\psi = \rho'$

تعریف می کنیم :

$$w_{i0} \begin{cases} \frac{\psi[(y_i - \hat{x}_i \hat{\beta}_0)/s]}{(y_i - \hat{x}_i \hat{\beta}_0)/s} & y_i \neq \hat{x}_i \hat{\beta}_0 \\ 1 & y_i = \hat{x}_i \hat{\beta}_0 \end{cases}$$

بنابراین :

$$\begin{aligned} & \sum_i^n x_{ij} \psi\left(\frac{y_i - \hat{x}_i \beta}{s}\right) \\ &= \sum_{i=1}^n \frac{x_{ij} \psi\left\{\left[\frac{(y_i - \hat{x}_i \beta_0)}{s}\right] / \frac{(y_i - \hat{x}_i \beta_0)}{s}\right\} (y_i - \hat{x}_i \beta_0)}{s} = 0 \end{aligned}$$

پس:

$$\sum_{i=1}^n x_{ij} w_{i0} (y_i - \hat{x}_i \beta) = 0 \quad , \quad j = 0, 1, \dots, k$$

که با نماد ماتریسی به صورت زیر می شود:

$$\hat{X} W_0 X \beta = \hat{X} W_0 y$$

که در آن  $W_0$  یک ماتریس قطری  $n \times n$  از وزن ها با اعضای قطر  
 $W_{10}, W_{20}, \dots, W_{n0}$  است  
برآورد قدم اول عبارتست از:

$$\widehat{\beta}_1 = (XW_0X)^{-1} XW_0y$$






در قدم بعدی وزن ها را بار دیگر مناسبه می کنیم اما  $\widehat{\beta}_1$  را به جای  $\widehat{\beta}_0$  به کار می  
بریم و به طور کلی می توان گفت:

$$\widehat{\beta}_{j+1} = (XW_jX)^{-1} XW_jy$$




## شکل زیر تعدادی از توابع محک نیرومند معروف را ارائه میدهد

Criterion	$\rho(z)$	$\psi(z)$	$w(z)$	Range
Least squares	$\frac{1}{2}z^2$	$z$	1.0	$ z  < \infty$
Huber's $t$ function $t=2$	$\frac{1}{2}z^2$ $ z t - \frac{1}{2}t^2$	$z$ $t \text{ sign}(z)$	1.0 $\frac{t}{ z }$	$ z  \leq t$ $ z  > t$
Ramsay's $E_a$ function $a=0.3$	$a^{-2}[1 - \exp(-a z )] \cdot (1 + a z )$	$z \exp(-a z )$	$\exp(-a z )$	$ z  < \infty$
Andrew's wave function $a=1.339$	$a[1 - \cos(z/a)]$ $2a$	$\sin(z/a)$ 0	$\frac{\sin(z/a)}{z/a}$ 0	$ z  \leq a\pi$ $ z  > a\pi$
Hampel's 17A function $a=1.7$ $b=3.4$ $c=8.5$	$\frac{1}{2}z^2$ $a z  - \frac{1}{2}a^2$ $\frac{a(c z  - \frac{1}{2}z^2)}{c-b} - (7/6)a^2$ $a(b+c-a)$	$z$ $a \text{ sign}(z)$ $\frac{a \text{ sign}(z)(c -  z )}{c-b}$ 0	1.0 $a/ z $ $\frac{a(c -  z )}{ z (c-b)}$ 0	$ z  \leq a$ $a <  z  \leq b$ $b <  z  \leq c$ $ z  > c$



نمودار توابع  
مک های  
نیرومند نیز در  
شکل مقابل  
ارائه شده:

شکل ۹-۶ توابع تاثیر نیرومند: (a) حداقل مربعات، (b) تابع t-هویرت، (c) تابع  $E_a$ -رامسی، (d) تابع موج اندرو و (e) تابع 17A هامبل



در جدول های بعدی میتوانید مثال هایی که به روش  
مداخله مربعات و رگرسیون نیرومند ارزیابی شده اند را  
مشاهده کنید:



Observation $i$	$y_i$	$\hat{y}_i$	$e_i$	Weight
1	.166800E+02	.217081E+02	-.502808E+01	.100000E+01
2	.115000E+02	.103536E+02	.114639E+01	.100000E+01
3	.120300E+02	.120798E+02	-.497937E-01	.100000E+01
4	.148800E+02	.995565E+01	.492435E+01	.100000E+01
5	.137500E+02	.141944E+02	-.444398E+00	.100000E+01
6	.181100E+02	.183996E+02	-.289574E+00	.100000E+01
7	.800000E+01	.715538E+01	.844624E+00	.100000E+01
8	.178300E+02	.166734E+02	.115660E+01	.100000E+01
9	.792400E+02	.718203E+02	.741971E+01	.100000E+01
10	.215000E+02	.191236E+02	.237641E+01	.100000E+01
11	.403300E+02	.380925E+02	.223749E+01	.100000E+01
12	.210000E+02	.215930E+02	-.593041E+00	.100000E+01
13	.135000E+02	.124730E+02	.102701E+01	.100000E+01
14	.197500E+02	.186825E+02	.106754E+01	.100000E+01
15	.240000E+02	.233288E+02	.671202E+00	.100000E+01
16	.290000E+02	.296629E+02	-.662928E+00	.100000E+01
17	.153500E+02	.149136E+02	.436360E+00	.100000E+01
18	.190000E+02	.155514E+02	.344862E+01	.100000E+01
19	.950000E+01	.770681E+01	.179319E+01	.100000E+01
20	.351000E+02	.408880E+02	-.578797E+01	.100000E+01
21	.179000E+02	.205142E+02	-.261418E+01	.100000E+01
22	.523200E+02	.560065E+02	-.368653E+01	.100000E+01
23	.187500E+02	.233576E+02	-.460757E+01	.100000E+01
24	.198300E+02	.244029E+02	-.457285E+01	.100000E+01
25	.107500E+02	.109626E+02	-.212584E+00	.100000E+01

$$\hat{\beta}_0 = 2.3412$$

$$\hat{\beta}_1 = 1.6159$$

$$\hat{\beta}_2 = 0.014385$$



Observation	$y_i$	$\hat{y}_i$	$e_i$	Weight
1	.166800E+02	.217651E+02	-.508511E+01	.639744E+00
2	.115000E+02	.109809E+02	.519115E+00	.100000E+01
3	.120300E+02	.126296E+02	-.599594E+00	.100000E+01
4	.148800E+02	.105856E+02	.429439E+01	.757165E+00
5	.137500E+02	.146038E+02	-.853800E+00	.100000E+01
6	.181100E+02	.186051E+02	-.495085E+00	.100000E+01
7	.800000E+01	.794135E+01	.586521E-01	.100000E+01
8	.178300E+02	.169564E+02	.873625E+00	.100000E+01
9	.792400E+02	.692795E+02	.996050E+01	.327017E+00
10	.215000E+02	.193269E+02	.217307E+01	.100000E+01
11	.403300E+02	.372777E+02	.305228E+01	.100000E+01
12	.210000E+02	.216097E+02	-.609734E+00	.100000E+01
13	.135000E+02	.129900E+02	.510021E+00	.100000E+01
14	.197500E+02	.188904E+02	.859556E+00	.100000E+01
15	.240000E+02	.232828E+02	.717244E+00	.100000E+01
16	.290000E+02	.293174E+02	-.317449E+00	.100000E+01
17	.153500E+02	.152908E+02	.592377E-01	.100000E+01
18	.190000E+02	.158847E+02	.311529E+01	.100000E+01
19	.950000E+01	.845286E+01	.104714E+01	.100000E+01
20	.351000E+02	.399326E+02	-.483256E+01	.672828E+00
21	.179000E+02	.205793E+02	-.267929E+01	.100000E+01
22	.523200E+02	.542361E+02	-.191611E+01	.100000E+01
23	.187500E+02	.233102E+02	-.456023E+01	.713481E+00
24	.198300E+02	.243238E+02	-.449377E+01	.723794E+00
25	.107500E+02	.115474E+02	-.797359E+00	.100000E+01

$$\hat{\beta}_0 = 3.3736$$

$$\hat{\beta}_1 = 1.5282$$

$$\hat{\beta}_2 = 0.013739$$

Observation $i$	$y_i$	$\hat{y}_i$	$e_i$	Weight
1	.166800E+02	.218009E+02	-.512091E+01	.388862E+00
2	.115000E+02	.112454E+02	.254584E+00	.953571E+00
3	.120300E+02	.128682E+02	-.838215E+00	.857082E+00
4	.148800E+02	.108415E+02	.403846E+01	.474482E+00
5	.137500E+02	.147670E+02	-.101696E+01	.829548E+00
6	.181100E+02	.186905E+02	-.580544E+00	.898687E+00
7	.800000E+01	.826846E+01	-.268460E+00	.952527E+00
8	.178300E+02	.170677E+02	.762255E+00	.868454E+00
9	.792400E+02	.682279E+02	.110121E+02	.131649E+00
10	.215000E+02	.194307E+02	.206932E+01	.682987E+00
11	.403300E+02	.369364E+02	.339359E+01	.535303E+00
12	.210000E+02	.216035E+02	-.603534E+00	.895015E+00
13	.135000E+02	.132081E+02	.291877E+00	.947139E+00
14	.197500E+02	.189862E+02	.763769E+00	.868651E+00
15	.240000E+02	.232651E+02	.734923E+00	.873345E+00
16	.290000E+02	.291901E+02	-.190116E+00	.964755E+00
17	.153500E+02	.154431E+02	-.931215E-01	.983506E+00
18	.190000E+02	.160129E+02	.298707E+01	.576113E+00
19	.950000E+01	.875713E+01	.742875E+00	.871123E+00
20	.351000E+02	.395347E+02	-.443471E+01	.440968E+00
21	.179000E+02	.205893E+02	-.268928E+01	.609354E+00
22	.523200E+02	.534802E+02	-.116016E+01	.806251E+00
23	.187500E+02	.232921E+02	-.454212E+01	.432732E+00
24	.198300E+02	.243045E+02	-.447455E+01	.437999E+00
25	.107500E+02	.117882E+02	-.103817E+01	.826364E+00

$$\hat{\beta}_0 = 3.8021$$

$$\hat{\beta}_1 = 1.4894$$

$$\hat{\beta}_2 = 0.013523$$



Observation	$y_i$	$\hat{y}_i$	$e_i$	Weight
1	.166800E+02	.216430E+02	-.496300E+01	.427594E+00
2	.115000E+02	.116923E+02	-.192338E+00	.998944E+00
3	.120300E+02	.131457E+02	-.111570E+01	.964551E+00
4	.148800E+02	.114549E+02	.342506E+01	.694894E+00
5	.137500E+02	.152191E+02	-.146914E+01	.939284E+00
6	.181100E+02	.188574E+02	-.747381E+00	.984039E+00
7	.800000E+01	.890189E+01	-.901888E+00	.976864E+00
8	.178300E+02	.174040E+02	.425984E+00	.994747E+00
9	.792400E+02	.660818E+02	.131582E+02	0.
10	.215000E+02	.192716E+02	.222839E+01	.863633E+00
11	.403300E+02	.363170E+02	.401296E+01	.597491E+00
12	.210000E+02	.218392E+02	-.839167E+00	.980003E+00
13	.135000E+02	.135744E+02	-.744338E-01	.999843E+00
14	.197500E+02	.189979E+02	.752115E+00	.983877E+00
15	.240000E+02	.232029E+02	.797080E+00	.981854E+00
16	.290000E+02	.286336E+02	.366350E+00	.996228E+00
17	.153500E+02	.158247E+02	-.474704E+00	.993580E+00
18	.190000E+02	.164593E+02	.254067E+01	.824146E+00
19	.950000E+01	.946384E+01	.361558E-01	.999956E+00
20	.351000E+02	.387684E+02	-.366837E+01	.655336E+00
21	.179000E+02	.209308E+02	-.303081E+01	.756603E+00
22	.523200E+02	.523766E+02	-.566063E-01	.999908E+00
23	.187500E+02	.232271E+02	-.447714E+01	.515506E+00
24	.198300E+02	.240095E+02	-.417955E+01	.567792E+00
25	.107500E+02	.123027E+02	-.155274E+01	.932266E+00

$$\hat{\beta}_0 = 4.6532$$

$$\hat{\beta}_1 = 1.4582$$

$$\hat{\beta}_2 = 0.012111$$

## برآورد $R$ - :

روش برآورد  $R$  بر اساس رتبه هایش می باشد.

اگر  $R_i$  رتبه  $y_i - x_i\beta$  باشد در این صورت  $\sum_{i=1}^n (y_i - x_i\beta) R_i$  می نیمم میشود.

رتبه ها را که اعداد صحیح می باشند با  $i = 1, 2, \dots, n$   $a(i)$  جانشین می کنیم و بنابراین تابع هدف چنین می شود.

$$\min \sum_{i=1}^n (y_i - x_i\beta) a(R_i)$$

اگر تابع امتیاز را با رتبه برابر قرار دهیم یعنی  $a(i) = i$  نتیجه نمره های ویلکسون می شود.





امکان دیگر به کار گیری امتیاز میانه است یعنی:

$$a(i) = -1 \text{ اگر } i < (n + 1)/2$$

$$a(i) = 1 \text{ اگر } i > (n + 1)/2$$

برآورد  $R$  از نظر معاسباتی از برآوردگر  $M$  مشکل تر است اما به طور مجانبی

با برآوردگر  $M$  معادل است.

## برآورد مکانی یا برآورد-L :

برآوردگرهای L- براساس آماره های مرتب پایه گذاری شده اند. برای مثال اگر بخواهیم پارامتر مکانی یک توزیع را با استفاده از نمونه تصادفی  $x_1, x_2, \dots, x_n$  برآورد کنیم آماره های مرتب این نمونه عبارتند از:

$$x_{[1]} \leq x_{[2]} \leq \dots \leq x_{[n-1]} \leq x_{[n]}$$

میانۀ نمونه یک برآورد گر-L خواهد بود زیرا میانۀ بر اساس این آماره مرتب یک اندازه مکانی است.



برآورد LMس:

در این روش میانه توان دوم خطا حداقل می شود.

$$\hat{\beta} = \min \text{med}(y_i - \hat{x}_i \beta)^2$$



## برآورد LTS:

$$\hat{\beta} = \min \sum_{i=1}^n r_i(\beta)^2$$

$$r_i(\beta) = y_i - \hat{x}_i\beta$$

$$r_i(\beta)^2 \leq \dots \leq r_q(\beta)^2$$

$$q = \left(\frac{n}{2} + 1\right)$$

که در آن:

برآورد GM :

از حل معادله زیر بدست می آید:

$$\sum_{i=1}^n w_i \psi \left( \frac{r_i(\hat{\beta})}{\hat{\sigma}} \right) x_i = 0$$

که در آن:

$$\psi(e) = \dot{\rho}(e) \quad , \quad w_i = \sqrt{1 - h_i}$$

$h_i \rightarrow i$  نفوذ مشاهده

## برآورد MM:

برآورد MM از حل معادله زیر به دست می آید.

$$L(\beta) = \sum_{i=1}^n \rho_i \left( \frac{r_i(\beta)}{\hat{\sigma}_n} \right)$$

که در آن:

$$r_i(\beta) = y_i - x_i \beta$$



در این برآورد اگر:


$$\rho < \rho_0 \rightarrow L(\hat{\beta}) \leq L(\beta_0)$$





## یک مثال در R:

```
> y=incom<-c(62,72,75,55,64,21,64,80,67,72)
> x=education<-c(86,76,92,90,86,84,93,100,87,86)
> model<-lm(y~x)
> plot(y~x)
```





```
> fitH <- rlm(y~ x, k2 = 1.345)
> fitLMS <- lqs(y ~ x, method = "lms")
> fitLTS <- lqs(y ~ x, method = "lts")
> fitS <- lqs(y ~ x, method = "S")
> fitMM <- rlm(y ~ x, method = "MM")
> plot(y~x)
> abline(fitH, col = 2)
> abline(fitLTS, col = 1)
> abline(fitLMS, col = 3)
> abline(fitS, col = 4)
> abline(fitMM, col = 5)
```





## منابع:

- 1- مقدمه ای بر تحلیل رگرسیون فطی: داگلاس مونت کمری
- 2- شناسایی نقاط دور افتاده در داده های نرمال بر اساس مقادیر  $Z$  اصلاح شده :  
محمد ولی احمدی و مجید سرمدی (دانشگاه فردوسی مشهد)

### 3-Robust Linear Regression: A Review and Comparison

Chun Yu<sup>1</sup>, Weixin Yao<sup>1</sup>, and Xue Bai<sup>1</sup>

<sup>1</sup>Department of Statistics,

Kansas State University, Manhattan, Kansas, USA 66506-0802

### 4-Robust Fitting of Parametric Models

**Based on M-Estimation**

Andreas Ruckstuhl \*

IDP Institute of Data Analysis and Process Design

ZHAW Zurich University of Applied Sciences in Winterthur

Version 2016<sup>†</sup>

### 5-Robust Regression

John Fox & Sanford Weisberg

October 8, 2013

- 7- پروژه **outlier** از خانم مینا فورشیدی و مرضیه روزبهانی سال ۹۵



فوشن امد گل و ز آن فوشتر نباشد  
که در دستت به جز ساغر نباشد  
زمان فوشن دلی دریاب و دریاب  
که داریم در صدف گوهر نباشد

با سپاس فراوان از توجه تان