

حاشا  
الرحمن الرحيم



دانشکده علوم ریاضی

رشته گروه آمار، گرایش آمار ریاضی

پایان نامه کارشناسی ارشد

# سازگاری قوی $M$ - برآوردها در مدل‌های خطی با خطاهای وابسته زبرجمعی منفی

نگارنده: حسین حیدری نژاد

استاد راهنما

دکتر نگار اقبال

استاد مشاور

دکتر حسین باغیشنی

بهمن ۱۳۹۷

پایان نامه خود را تقدیم می‌کنم به پدر و  
مادر و خانواده‌ام که در تمام سختی‌ها و  
مشکلات در کنارم بوده‌اند.

## سپاس‌گزاری...

خدا را بی‌نهایت سپاس‌گزارم به خاطر تمام نعمت‌هایی را که به من داده و از زحمات‌های خانواده‌ام که همیشه در کنار من بوده‌اند سپاس‌گزارم هم‌چنین از استاد گرامی سرکار خانم دکتر نگار اقبال و استاد محترم جناب آقای دکتر حسین باغیشنی به خاطر زحمات‌ها و راهنمایی‌هایی که در طول این پایان‌نامه برای من کشیده‌اند تقدیر و تشکر می‌کنم.

حسین حیدری نژاد

بهمن ۱۳۹۷

## تعهد نامه

اینجانب حسین حیدری نژاد دانشجوی کارشناسی ارشد رشته آمارریاضی دانشکده علوم ریاضی دانشگاه صنعتی شاهرود، نویسنده پایان نامه با عنوان سازگاری قوی M- برآوردها در مدل های خطی با خطاهای وابسته زبرجمعی منفی ، تحت راهنمایی نگار اقبال متعهد می شوم:

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های دیگر پژوهش گران، به مرجع مورد استفاده استناد شده است.
- مطالب این پایان نامه، تا کنون توسط خود، یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارایه نشده است.
- حقوق معنوی این اثر، به دانشگاه صنعتی شاهرود تعلق دارد، و مقالات مستخرج با نام “ دانشگاه صنعتی شاهرود “ یا “ Shahrood University of Technology “ به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آوردن نتایج اصلی پایان نامه تاثیرگذار بوده اند، در مقالات مستخرج از پایان نامه رعایت می گردد.
- در تمام مراحل انجام این پایان نامه، در مواردی که از موجود زنده (یا بافت های آنها) استفاده شده است، ضوابط و اصول اخلاقی رعایت شده است.
- در تمام مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته (یا استفاده شده است)، اصل رازداری و اصول اخلاق انسانی رعایت شده است.

حسین حیدری نژاد

بهمن ۱۳۹۷

### مالکیت نتایج و حق نشر

- تمام حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی، در تولیدات علمی مربوطه ذکر شود.
- استفاده از اطلاعات و نتایج موجود در این پایان نامه بدون ذکر منبع مجاز نمی باشد.

## چکیده

در این پایان نامه شرایط سازگاری قوی M- برآوردهای پارامترهای مدل خطی با خطاهای تصادفی وابسته زبرجمعی منفی (NSD) مورد بررسی قرار گرفته است. نتایج موجود بهبود شرایط گشتاوری و تعمیمی از روش های ارائه شده در حالت استقلال به خطاهای NSD می باشند.

کلمات کلیدی: سازگاری قوی، وابسته زبرجمعی منفی، رگرسیون استوار.

## پیشگفتار

همگرایی کامل نقش مهمی را در قضیه حد مرکزی و به دست آوردن مرتبه همگرایی یک دنباله از متغیرهای تصادفی ایفا می‌کند. متغیرهای تصادفی زبرجمعی منفی یک رده بسیار وسیع از دنباله‌های وابسته هستند که به عنوان مواردی خاص از این رده، می‌توان به دنباله متغیرهای مستقل و متغیرهای پیوندی منفی اشاره نمود. مفهوم متغیرهای تصادفی وابسته زبرجمعی منفی مبتنی بر رده توابع زبرجمعی است. از آنجا که وابستگی زبرجمعی منفی تعمیمی از وابستگی پیوندی منفی است، در نامساوی‌های گشتاوری و هم‌چنین نامساوی‌های احتمالی متعددی مفید واقع می‌شود. محققین این حوزه از همگرایی کامل متغیرهای تصادفی وابسته زبرجمعی منفی در بسیاری از زمینه‌های استنباط آماری، از جمله مدل‌های رگرسیونی، استفاده کرده‌اند. در اکثر موارد شرط مستقل بودن برای داده‌هایی که در اختیار داریم، برقرار نیست. بنابراین، در این پایان‌نامه علاوه بر بررسی برخی ویژگی‌های اساسی متغیرهای تصادفی وابسته زبرجمعی منفی، سازگاری قوی  $M$ -برآوردها در مدل‌های خطی با جملات خطای وابسته زبرجمعی منفی را تحت برخی شرایط مورد مطالعه قرار می‌دهیم. هم‌چنین در انتها با مطالعه شبیه‌سازی به ارزیابی نتایج نظری می‌پردازیم. محتوای مطالب این پایان‌نامه به صورت زیر تدوین شده است:

- در فصل اول به بیان برخی تعاریف و مفاهیم اولیه که در اثبات نتایج اصلی به آن‌ها نیاز داریم، می‌پردازیم.
- در فصل دوم مفهوم استواری و برخی روش‌های برآورد پارامترهای مدل رگرسیونی استوار معرفی می‌کنیم.
- در فصل سوم شرایط همگرایی کامل سازگاری قوی  $M$ -برآوردها با خطاهای NSD را بررسی می‌کنیم.
- در فصل چهارم با استفاده از ابزارهای شبیه‌سازی نتایج نظری همگرایی کامل فصل سوم را ارزیابی می‌کنیم.
- پیوست پایان‌نامه شامل کدهای نرم افزار R برای باز تولید نتایج شبیه‌سازی می‌باشد.

# فهرست مطالب

ف	فهرست تصاویر
ق	فهرست جداول
۱	۱ مفاهیم اولیه
۱	۱.۱ انواع همگرایی
۳	۲.۱ نابرابری‌ها
۴	۳.۱ انواع وابستگی
۴	۱.۳.۱ وابستگی زیرجمعی منفی
۵	۲.۳.۱ معرفی برخی دیگر از وابستگی‌ها
۹	۴.۱ رگرسیون
۹	۱.۴.۱ رگرسیون خطی
۱۰	۲.۴.۱ رگرسیون چندگانه
۱۳	۵.۱ نقاط پرت
۱۴	۶.۱ ترتیب‌های غیرتصادفی
۱۷	۲ روش‌های آماری استوار
۱۷	۱.۲ استواری
۱۹	۲.۲ برآورد استوار پارامتر مکان
۲۳	۳.۲ رگرسیون استوار
۲۶	۱.۳.۲ M-برآوردگر
۲۹	۲.۳.۲ L-برآوردگر
۳۰	۳.۳.۲ R-برآوردگر
۳۵	۳ سازگاری قوی M-برآوردها با خطاهای وابسته زیرجمعی منفی
۳۵	۱.۳ سازگاری قوی M-برآوردهای پارامترهای مدل رگرسیونی



۵۵	۴	مطالعات شبیه‌سازی
۵۶	۱.۴	توزیع نرمال چندمتغیره . . . . .
۵۷	۲.۴	توزیع تی چندمتغیره . . . . .
۵۹	۱.۲.۴	بحث و نتیجه‌گیری . . . . .
۶۱		مراجع
۶۷	آ	کدهای شبیه‌سازی فصل دو و چهار
۶۷	۱.آ	کدهای مربوط به مدل رگرسیون کمترین توان‌های دوم و رگرسیون استوار
۶۹	۱.۱.آ	کدهای مربوط به توزیع نرمال چندمتغیره . . . . .
۷۱	۲.۱.آ	کدهای مربوط به توزیع تی چندمتغیره . . . . .
۷۲	۳.۱.آ	کدهای مربوط به میانگین ضرایب . . . . .
۷۳	۴.۱.آ	کدهای مربوط به نمودارهای جعبه‌ای . . . . .

# فهرست تصاویر

۳۲	.....	کمترین توان‌های دوم با ۲۱ مشاهده	۱.۲
۳۳	.....	کمترین توان‌های دوم با ۱۷ مشاهده	۲.۲
۳۳	.....	رگرسیون استوار با ۲۱ مشاهده	۳.۲
۵۶	.....	سازگاری ضرایب با استفاده از نرمال چندمتغیره	۱.۴
۵۷	.....	سازگاری ضرایب با استفاده از چندمتغیره توزیع تی	۲.۴
۵۸	.....	نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۴۰	۳.۴
۵۸	.....	نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۲۰۰	۴.۴
۵۸	.....	نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۱۰۰۰	۵.۴

# فهرست جداول

۱۵	تعدادی از ترتیب‌های غیرتصادفی	۱.۱
۲۸	بعضی از توابعی که برای توزیع وزن مانده‌ها پیشنهاد شده‌اند	۱.۲
۵۹	میانگین مربوط به برآورد ضرایب برای حجم نمونه‌های مختلف	۱.۴

# فصل ۱

## مفاهیم اولیه

در این فصل برخی تعاریف و قضیه‌هایی که در فصل‌های بعدی به آن احتیاج داریم بیان می‌کنیم، برای گردآوری عمده مطالب این فصل از هو (۲۰۰۰)، گات (۱۹۹۴)، مازی و کاتز (۲۰۰۱)، پایان نامه ارشد پاشاکایی، مقاله اسدی، فلاح زاده، نوقایی و کتاب رگرسیون خطی عبدالرضا بازرگان لاری (۱۳۹۱) استفاده کرده‌ایم.

### ۱.۱ انواع همگرایی

همگرایی کامل نقش مهمی در احتمال، قضایای حدی، آمار ریاضی به ویژه در تعیین نرخ همگرایی دارد، این همگرایی اولین بار توسط هسو و رابینز (۱۹۴۷) بیان شد، به صورت زیر تعریف شد.

**تعریف ۱.۱.۱.** دنباله‌ای از متغیرهای تصادفی  $\{X_n, n \geq 1\}$  را همگرایی کامل<sup>۱</sup> به متغیر تصادفی  $X$  گویند، هرگاه به ازای هر  $\varepsilon > 0$  داشته باشیم

$$\sum_{n=1}^{+\infty} P(|X_n - X| > \varepsilon) < \infty$$

همچنین آن را با نماد  $X_n \xrightarrow{c.c.} X$  نشان می‌دهیم.

<sup>۱</sup>Complete Convergence

**تعریف ۲.۱.۱.** دنباله‌ای از متغیرهای تصادفی  $\{X_n, n \geq 1\}$  به متغیر تصادفی  $X$  را همگرای قریب به یقین<sup>۲</sup> گویند، هرگاه

$$P(\{\omega : X_n(\omega) \rightarrow X(\omega); n \rightarrow \infty\}) = 1$$

یا به طور معادل

$$P(\{\omega : X_n(\omega) \not\rightarrow X(\omega); n \rightarrow \infty\}) = 0$$

و آن را با نماد  $X_n \xrightarrow{a.s.} X$  نشان می‌دهیم.

**قضیه ۱.۱.۱.** فرض کنید  $\{X_n, n \geq 1\}$  دنباله‌ای از متغیرهای تصادفی و به طور کامل به متغیر تصادفی  $X$  همگرا باشد، این دنباله به طور قریب به یقین نیز به  $X$  همگرا می‌باشد.

**قضیه ۲.۱.۱.** فرض کنید  $\{X_n, n \geq 1\}$  دنباله‌ای از متغیرهای تصادفی و به طور قریب به یقین به ثابتی مثل  $C$  همگرا باشد، این دنباله به طور کامل نیز به ثابت  $C$  همگرا می‌باشد.

**لم ۱.۱.۱ (فاتو).** فرض کنید  $\{X_n, n \geq 1\}$  دنباله‌ای از متغیرهای تصادفی نامنفی باشند به شرط وجود امید ریاضی‌ها، آن‌گاه

$$E(\liminf_{n \rightarrow \infty} X_n) \leq \liminf_{n \rightarrow \infty} EX_n.$$

**تعریف ۳.۱.۱.** فرض کنید  $\{A_n, n \geq 1\}$  یک دنباله از پیشامدهای دلخواه باشد آن‌گاه

$$P(A_n \text{ i.o.}) = P(\limsup_{n \rightarrow \infty} A_n)$$

یعنی تعداد زیادی از  $A_n$  اتفاق بی‌افتد (تقریباً بی‌نهایت بار) که در این صورت لم زیر را داریم

**لم ۲.۱.۱.** لم برل کانتلی<sup>۴</sup> به دو حالت زیر می‌باشد

۱- فرض کنید  $\{A_n, n \geq 1\}$  یک دنباله از پیشامدهای دلخواه باشد، اگر

$$\sum_{n=1}^{+\infty} P(A_n) < +\infty$$

آن‌گاه

$$P(A_n; \text{ i.o.}) = 0.$$

۲- فرض کنید  $\{A_n, n \geq 1\}$  یک دنباله از پیشامدهای مستقل باشد

$$\sum_{n=1}^{+\infty} P(A_n) = +\infty$$

اگر و تنها اگر

$$P(A_n \text{ i.o.}) = 1.$$

<sup>۲</sup>Almost Surely

<sup>۳</sup>Infinity Often

<sup>۴</sup>Borel-Cantelli Lemmas

## ۲.۱ نابرابری‌ها

نابرابری‌ها نقش کلیدی در نظریه احتمال دارند. زیرا اگر نتوانیم مقدار دقیق احتمال‌ها و گشتاورها را محاسبه کنیم، با استفاده از نابرابری‌ها می‌توان کران‌هایی برای مقادیر مورد نظر پیدا کرد. یک نابرابری مناسب کلیدی جهت رفع مشکلات محسوب می‌شود. به عبارت دیگر هر چه کران به مقدار واقعی نزدیک‌تر باشد جواب نهایی قابل اعتمادتر است. در زیر برخی از نابرابری‌ها از کتاب گات (۱۹۹۴) را معرفی می‌کنیم.

۱- نابرابری مارکف<sup>۵</sup>: فرض کنید  $X$  متغیر تصادفی آن‌گاه برای هر عدد حقیقی مثبت  $r$  و  $x > 0$

$$P(|X| > x) \leq \frac{E|X|^r}{x^r}.$$

۲- نابرابری هافدینگ<sup>۶</sup>: فرض کنید  $X_1, X_2, \dots, X_n$  متغیرهای تصادفی مستقل باشند طوری که برای  $k = 1, 2, \dots, n$ ،  $P(a_k \leq X_k \leq b_k) = 1$ ، هم‌چنین فرض کنید  $S_n = \sum_{k=1}^n X_k$ ،  $n \geq 1$ ، مجموعه‌های جزئی باشد. آن‌گاه برای  $x > 0$

$$P(S_n - ES_n > x) \leq \exp \left\{ \frac{-2x^2}{\sum_{k=1}^n (b_k - a_k)^2} \right\}.$$

۴- نابرابری گشتاوری<sup>۷</sup>: فرض کنید  $X$  و  $Y$  متغیرهای تصادفی مستقل باشند طوری که  $E|X|^r < \infty$  و  $E|Y|^r < \infty$ ،  $r$  یک عدد حقیقی مثبت باشد، آن‌گاه

$$E|X + Y|^r \leq 2^r (E|X|^r + E|Y|^r).$$

۵- نابرابری هولدر<sup>۸</sup>: فرض کنید برای هر عدد حقیقی  $q > 1$  و  $p > 1$ ،  $p^{-1} + q^{-1} = 1$  اگر  $E|X|^p < \infty$  و  $E|Y|^q < \infty$  آن‌گاه

$$E|XY| \leq (E|X|^p)^{\frac{1}{p}} (E|Y|^q)^{\frac{1}{q}}.$$

۶- نابرابری کوشی شوارتز<sup>۹</sup>: در نابرابری هولدر اگر  $p = q = 2$  قرار دهیم آن‌گاه نابرابری کوشی شوارتز به صورت زیر به دست می‌آید:

$$E|XY| \leq (E|X|^2)^{\frac{1}{2}} (E|Y|^2)^{\frac{1}{2}}.$$

<sup>۵</sup>Markov's Inequality

<sup>۶</sup>Hoffding's Inequality

<sup>۷</sup>R-mean's Inequality

<sup>۸</sup>Holder's Inequality

<sup>۹</sup>Cauchy-Shwats Inequality

۷- نابرابری مینکوفسکی<sup>۱۰</sup>: فرض کنید  $X$  و  $Y$  متغیرهای تصادفی باشد و برای هر عدد حقیقی  $p > 1$ ،  $E|X|^p < \infty$  و  $E|Y|^p < \infty$  باشد. آن گاه

$$(E|X + Y|^p)^{\frac{1}{p}} \leq (E|X|^p)^{\frac{1}{p}} + (E|Y|^p)^{\frac{1}{p}}.$$

## ۳.۱ انواع وابستگی

در این بخش به معرفی انواع وابستگی‌ها که رده‌ی بزرگی از دنباله متغیرهای تصادفی را دربر می‌گیرند می‌پردازیم.

### ۱.۳.۱ وابستگی زبرجمعی منفی

متغیرهای تصادفی وابسته زبرجمعی منفی<sup>۱۱</sup> (NSD) نوعی از وابستگی‌ها است که توسط هو (۲۰۰۰) مطرح شد که در پایه آن از توابع زبرجمعی استفاده شده است

**تعریف ۱.۳.۱.** (کمپرن، ۱۹۷۷) تابع  $\phi: \mathbb{R}^n \rightarrow \mathbb{R}$  زبرجمعی نامیده می‌شود اگر برای هر  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$

$$\phi(\mathbf{x} \vee \mathbf{y}) + \phi(\mathbf{x} \wedge \mathbf{y}) \geq \phi(\mathbf{x}) + \phi(\mathbf{y}).$$

در رابطه بالا  $\vee$  نشان دهنده‌ی ماکسیمم مولفه‌ای<sup>۱۲</sup> و  $\wedge$  نشان دهنده‌ی مینیمم مولفه‌ای<sup>۱۳</sup> است، که به صورت زیر تعریف می‌شود.

$$\mathbf{x} \vee \mathbf{y} = (x_1 \vee y_1, x_2 \vee y_2, \dots, x_n \vee y_n)$$

و

$$\mathbf{x} \wedge \mathbf{y} = (x_1 \wedge y_1, x_2 \wedge y_2, \dots, x_n \wedge y_n).$$

کمپرن (۱۹۷۷) روشی را بیان کرد که می‌توان با استفاده از آن زبرجمعی بودن یا نبودن یک تابع را مشخص کرد.

**لم ۱.۳.۱.** فرض کنید تابع  $\phi$  دارای مشتق جزئی مرتبه دوم پیوسته باشد، آن گاه  $\phi$  زبرجمعی است هرگاه

$$\frac{\partial^2 \phi(\mathbf{x})}{\partial x_i \partial x_j} \geq 0 \quad 1 \leq i \neq j \leq n. \quad (1.1)$$

<sup>۱۰</sup>Mincowski Inequality

<sup>۱۱</sup>Negatively Superadditive Dependent

<sup>۱۲</sup>Maximum Componentwise

<sup>۱۳</sup>Minimum Componentwise

**تعریف ۲.۳.۱.** بردار تصادفی  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  را NSD گویند، هرگاه برای هر تابع زیرجمعی  $\phi$

$$E\phi(X_1, X_2, \dots, X_n) \leq E\phi(Y_1, Y_2, \dots, Y_n).$$

که  $Y_i$  ها متغیرهای تصادفی مستقل هستند، همچنین به ازای هر  $i = 1, 2, \dots, n$  و  $X_i$  و  $Y_i$  هم توزیع هستند.

**تعریف ۳.۳.۱.**  $\{X_n, n \geq 1\}$  را دنباله‌ای از متغیرهای تصادفی NSD گویند هرگاه برای هر  $(X_1, X_2, \dots, X_n), n \geq 1$  NSD باشد.

**لم ۲.۳.۱.** فرض کنید  $(X_1, X_2, \dots, X_n)$  NSD و توابع  $f_1, f_2, \dots, f_n$  نانزولی باشند آن گاه  $f_1(X_1), f_2(X_2), \dots, f_n(X_n)$  NSD می‌باشند.

برهان. بنابر معادله (۱.۱) برای هر تابع زیرجمعی  $\phi$ ، داریم  $\phi(f_1(x_1), f_2(x_2), \dots, f_n(x_n))$  نیز زیرجمعی است، چون

$$\begin{aligned} & \frac{\partial^2 \phi(f_1(x_1), f_2(x_2), \dots, f_n(x_n))}{\partial x_i \partial x_j} \\ &= \frac{\partial^2 \phi(f_1(x_1), f_2(x_2), \dots, f_n(x_n))}{\partial f_i(x_i) \partial f_j(x_j)} \cdot \frac{\partial f_i(x_i)}{\partial x_i} \cdot \frac{\partial f_j(x_j)}{\partial x_j} \geq 0. \end{aligned}$$

□

**ملاحظه ۱.۳.۱.** روابط بالا برای  $f_1, f_2, \dots, f_n$  ناصعودی باشند نیز برقرار است.

## ۲.۳.۱ معرفی برخی دیگر از وابستگی‌ها

**تعریف ۴.۳.۱.** بردار تصادفی  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  را پیوند منفی<sup>۱۴</sup> (NA) گویند اگر برای هر جفت زیرمجموعه‌های جدا از هم مانند A و B از  $\{1, 2, \dots, n\}$  داشته باشیم

$$Cov(f_1(\mathbf{X}_i, i \in A), f_2(\mathbf{X}_j, j \in B)) \leq 0. \quad (2.1)$$

که  $f_1$  و  $f_2$  توابع صعودی هستند که کواریانس آن‌ها موجود می‌باشد. یکی از مزیت‌های متغیرهای تصادفی NA این است که  $f_1$  و  $f_2$  در معادله (۲.۱) ممکن است شکل‌های مختلفی را داشته باشند از این رو به نامساوی‌های چند متغیره مفید زیادی منجر می‌شوند.

**تعریف ۵.۳.۱.** متغیرهای تصادفی X و Y را وابسته منفی<sup>۱۵</sup> (ND) گویند هرگاه برای هر  $x$  و  $y$  عضو  $\mathbb{R}$

$$P(X \leq x, Y \leq y) \leq P(X \leq x) P(Y \leq y). \quad (3.1)$$

<sup>۱۴</sup>Negatively Associate

<sup>۱۵</sup>Negatively Dependent



**تعریف ۶.۳.۱.** برای هر  $x, y \in \mathbb{R}$  مجموعه  $A$  دو به دو وابسته منفی<sup>۱۶</sup> (PND) گویند اگر برای هر جفت متغیر تصادفی در رابطه (۳.۱) برقرار است. با توجه به آنچه در رابطه (۳.۱) اشاره شده آن‌گاه

$$P(X > x, Y > y) \leq P(X > x) P(Y > y). \quad (۴.۱)$$

برای هر جفت  $x, y \in \mathbb{R}$ ، (۴.۱) به معنی (۳.۱) است از این‌رو (۴.۱) و (۳.۱) معادل هستند. ابراهیمی و قوش (۱۹۸۱) نشان دادند (۴.۱) و (۳.۱) برای مجموعه‌ای سه یا بیشتر از سه متغیر تصادفی معادل نیستند.

مثال‌هایی که در زیر آورده شده از مقاله هو (۲۰۰۰) و وو و جی یانگ (۲۰۱۱) می‌باشد.

**مثال ۱.۳.۱.** متغیرهای تصادفی  $X_1, X_2, X_3$  را در نظر بگیرید که مقادیر  $(1, 0, 1)$ ،  $(1, 1, 0)$ ،  $(0, 1, 1)$  و  $(0, 0, 0)$  هر کدام احتمال  $\frac{1}{4}$  دارند، برای هر جفت متغیرهای تصادفی  $X_1, X_2, X_3$  و دوجه دو مستقل و از این‌رو (۳.۱) و (۴.۱) برقرار است، بنابراین برای هر  $x_1, x_2, x_3$

$$P(X_1 > x_1, X_2 > x_2, X_3 > x_3) \leq P(X_1 > x_1) P(X_2 > x_2) P(X_3 > x_3)$$

$$P(X_1 \leq 0, X_2 \leq 0, X_3 \leq 0) = P(X_1 = 0, X_2 = 0, X_3 = 0) = P(0, 0, 0) = \frac{1}{4}$$

$$P(X_1 \leq 0) = P(X_1 = 0) = P(0, 1, 1) + P(0, 0, 0) = \frac{1}{4} + \frac{1}{4} = \frac{1}{2}$$

$$P(X_2 \leq 0) = P(X_2 = 0) = P(1, 0, 1) + P(0, 0, 0) = \frac{1}{4} + \frac{1}{4} = \frac{1}{2}$$

$$P(X_3 \leq 0) = P(X_3 = 0) = P(1, 1, 0) + P(0, 0, 0) = \frac{1}{4} + \frac{1}{4} = \frac{1}{2}$$

آن‌گاه

$$P(X_1 \leq 0, X_2 \leq 0, X_3 \leq 0) = \frac{1}{4} \neq \frac{1}{8} = P(X_1 \leq 0) P(X_2 \leq 0) P(X_3 \leq 0).$$

**مثال ۲.۳.۱.** فرض کنید  $X = (X_1, X_2, X_3, X_4)$  یک بردار تصادفی از متغیرهای تصادفی گسسته با تابع احتمال زیر باشد فرض کنید

		$(X_1, X_2)$					
تابع احتمال حاشیه‌ای		$(1, 1)$	$(1, 0)$	$(0, 1)$	$(0, 0)$		
$\frac{0}{24}$	$\frac{0}{577}$	$\frac{0}{623}$	$\frac{0}{623}$	$\frac{0}{577}$	$(0, 0)$	$(X_3, X_4)$	
$\frac{0}{26}$	$\frac{0}{623}$	$\frac{0}{677}$	$\frac{0}{677}$	$\frac{0}{623}$	$(0, 1)$		
$\frac{0}{26}$	$\frac{0}{623}$	$\frac{0}{677}$	$\frac{0}{677}$	$\frac{0}{623}$	$(1, 0)$		
$\frac{0}{24}$	$\frac{0}{577}$	$\frac{0}{623}$	$\frac{0}{623}$	$\frac{0}{577}$	$(1, 1)$		
		$\frac{0}{24}$	$\frac{0}{26}$	$\frac{0}{26}$	$\frac{0}{24}$	تابع احتمال حاشیه‌ای	

<sup>۱۶</sup>Pairwise Negatively Dependent

## انواع وابستگی ۷

$$(X_1, X_2, X_3, X_4) \stackrel{d}{=} (X_2, X_1, X_3, X_4) \stackrel{d}{=} (X_2, X_1, X_4, X_3) \stackrel{d}{=} (X_3, X_4, X_1, X_2)$$

بدون این که از کلیت مساله کم شود، تابعی زبرجمعی مانند  $\phi$  را در نظر می‌گیریم طوری که به ازای هر  $\mathbf{x} = (x_1, x_2, x_3, x_4)$

$$\phi(x_1, x_2, x_3, x_4) = \phi(x_2, x_1, x_3, x_4) = \phi(x_2, x_1, x_4, x_3) = \phi(x_1, x_2, x_4, x_3)$$

در واقع تابع زبرجمعی  $X$  نسبت به جایگشت متغیرهای تصادفی ثابت هستند با استناد به تعریف تابع زبرجمعی که در آن

$$\phi(\mathbf{x}) + \phi(\mathbf{y}) \leq \phi(\mathbf{x} \wedge \mathbf{y}) + \phi(\mathbf{x} \vee \mathbf{y})$$

در نتیجه

$$2\phi_{0001} \leq \phi_{0000} + \phi_{0011}, \quad 2\phi_{0111} \leq \phi_{0011} + \phi_{1111}, \quad 2\phi_{0101} \leq \phi_{0001} + \phi_{0111}$$

که در آن  $\phi_{ijkl} = \phi(i, j, k, l)$  به عنوان نمونه دو تابع  $\phi_{0010}$  و  $\phi_{0001}$  را در نظر بگیرید، برای حالت می‌نیمم مولفه‌ای در اولین مولفه به دلیل این که هر دو صفر هستند، بنابراین می‌نیمم صفر خواهد بود به همین ترتیب برای مولفه‌های بعدی هم‌چنین حالت ماکسیمم مولفه‌ای را به دست می‌آوریم بنابراین با استدلالی مشابه و با استفاده از روابط بالا داریم

$$26\phi_{0101} \leq 6\phi_{0000} + 12\phi_{0011} + 6\phi_{1111} + \phi_{0001} + \phi_{0111}$$

حال با توجه به اعداد جدول نابرابری فوق درست می‌باشد. در این صورت  $X$ ، NSD می‌باشد از طرفی با توجه به وابستگی پیوند منفی

$$P(X_i = 1; i = 1, 2, 3, 4) < P(X_1 = X_2 = 1)P(X_3 = X_4 = 1)$$

با توجه به این که

$$\text{cov}(f(\mathbf{X}_A), g(\mathbf{X}_B)) \leq 0, \quad f(\mathbf{X}_A) = I\{X_1 = X_2 = 1\}, g(\mathbf{X}_B) = I\{X_3 = X_4 = 1\}$$

بنابراین

$$\begin{aligned} E(f(\mathbf{X}_A)g(\mathbf{X}_B)) - E(f(\mathbf{X}_A))Eg(\mathbf{X}_B) &= P(X_1 = X_2 = X_3 = X_4 = 1) \\ &\quad - P(X_1 = X_2 = 1)P(X_3 = X_4 = 1) \quad (5.1) \\ &= 1/577 - 1/576 \not\leq 0. \end{aligned}$$

این در حالی است با جایگذاری از اعداد جدول ملاحظه می‌کنیم که نامساوی فوق برقرار نیست که نتیجه می‌گیریم  $X$ ، NA نخواهد بود که از این مثال به این نتیجه می‌رسیم که زبرجمعی منفی تعمیمی از وابستگی پیوندی منفی می‌باشد که این نتیجه مهم می‌تواند در برخی از نابرابری‌های احتمال و نابرابری گشتاوری نقش بسزایی را ایفا کند.

لم ۳.۳.۱. اگر  $(X_1, X_2, \dots, X_n)$  NSD باشد برای هر عدد حقیقی  $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$  آن گاه

$$\begin{aligned} P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n) &\leq P(X_1 \leq x_1)P(X_2 \leq x_2) \dots P(X_n \leq x_n) \\ &= \prod_{i=1}^n P(X_i \leq x_i). \end{aligned}$$

برهان. برای هر  $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$  با توجه به نزولی بودن تابع  $I\{X_i \leq x_i\}$  نسبت به  $x_i$  و زیرجمعی بودن تابع  $\phi(\mathbf{x}) = \prod_{i=1}^n I(X_i \leq x_i)$  و NSD بودن  $X_i$  ها داریم

$$\begin{aligned} P(X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n) &= E(I\{X_1 \leq x_1, X_2 \leq x_2, \dots, X_n \leq x_n\}) \\ &= E\left(\prod_{i=1}^n I\{X_i \leq x_i\}\right) \\ &\leq E\left(\prod_{i=1}^n I\{Y_i \leq x_i\}\right) \quad (۶.۱) \\ &= \prod_{i=1}^n E(I\{Y_i \leq x_i\}) \\ &= \prod_{i=1}^n P(X_i \leq x_i) \end{aligned}$$

□ که در رابطه فوق  $Y_i$  ها همان شرایط (NSD) را دارند.

لم ۴.۳.۱. اگر برای  $(X_1, X_2, \dots, X_n)$  NSD باشد برای هر عدد حقیقی  $(x_1, x_2, \dots, x_n) \in \mathbb{R}^n$  آن گاه

$$\begin{aligned} P(X_1 \geq x_1, X_2 \geq x_2, \dots, X_n \geq x_n) &\leq P(X_1 \geq x_1)P(X_2 \geq x_2) \dots P(X_n \geq x_n) \\ &= \prod_{i=1}^n P(X_i \geq x_i). \end{aligned}$$

برهان. با استدلال مشابه برهان لم قبل داریم:

$$\begin{aligned} P(X_1 \geq x_1, X_2 \geq x_2, \dots, X_n \geq x_n) &= E(I\{X_1 \geq x_1, X_2 \geq x_2, \dots, X_n \geq x_n\}) \\ &= E\left(\prod_{i=1}^n I\{X_i \geq x_i\}\right) \\ &\leq E\left(\prod_{i=1}^n I\{Y_i \geq x_i\}\right) \quad (۷.۱) \\ &= \prod_{i=1}^n E(I\{Y_i \geq x_i\}) \\ &= \prod_{i=1}^n P(X_i \geq x_i). \end{aligned}$$

□ که در رابطه فوق  $Y_i$  ها همان شرایط (NSD) را دارند.

## ۴.۱ رگرسیون

رگرسیون<sup>۱۷</sup> در لغت به معنی برگشت است. نخستین بار گالتن این واژه را به کار برد و با آن ارتباط بین میانگین طول قامت پدران و پسران را مورد مطالعه قرار داد. گالتن از روی مشاهداتش نتیجه گرفت که طول قامت پسران متعلق به والدین خیلی بلند قد (یا کوتاه)، روی هم‌رفته بلندتر (یا کوتاهتر) از طول قامت متوسط بوده است، ولی البته نه به بلندی (یا کوتاهی) قد والدینشان این نتیجه‌گیری در سال ۱۸۵۵ به عنوان برگشت قد ارثی حد متوسط منتشر شد.

### ۱.۴.۱ رگرسیون خطی

مدل ارتباطی (ضابطه ریاضی) حاکم بر متغیر پاسخ و مجموعه متغیرهای تبیینی، توسط افراد متخصص در زمینه مورد مطالعه، بر مبنای دانش یا قضاوت‌های عینی و ذهنی آن‌ها تعیین می‌شود. این مدل که می‌تواند پارامترهای نامعلوم زیادی را در بر داشته باشد، یک مدل پارامتری نامیده می‌شود. اگر در معادله رگرسیونی تنها یک متغیر تبیینی وجود داشته باشد، آن را مدل رگرسیونی خطی ساده می‌نامند. در یک مدل رگرسیونی، هدف بررسی اثر متغیرهای تبیینی بر روی متغیر پاسخ است. معمولاً متغیرهای تبیینی را با  $X$  (که می‌توان بعدی بزرگتر از یک داشته باشد) و متغیر پاسخ را با  $Y$  نمایش می‌دهند. هم‌چنین این ضابطه می‌تواند خطی یا غیرخطی باشد. باید توجه داشته باشیم که منظور از رابطه خطی یا غیرخطی، در مورد رابطه بین  $X_i$  و  $Y$  ها نیست بلکه در واقع پارامترهای رگرسیونی به طور خطی یا غیرخطی وارد معادله رگرسیون می‌شوند. به عنوان مثال هریک از روابط زیر خطی‌اند هر چند که ممکن است رابطه بین  $X$  و  $Y$  ممکن است خطی نباشد:

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

$$Y = \beta_0 + \beta_1 e^X + \varepsilon$$

$$Y = \beta_0 + \beta_1 \log X + \varepsilon$$

هم‌چنین  $\varepsilon$  جمله خطا می‌باشد که متغیری تصادفی و غیر قابل مشاهده است. مثال‌هایی از یک مدل رگرسیونی عبارتند از

- بررسی اثر تعداد قطعات لازم در ساخت یک دستگاه (متغیر تبیینی) بر مدت زمان لازم بر تولید آن (متغیر پاسخ)
- بررسی تاثیر سرانه خالص ملی (متغیر تبیینی) بر تولید خالص ملی (متغیر پاسخ)
- بررسی تاثیر سن (متغیر تبیینی) بر تعداد ضربان قلب (متغیر پاسخ)

<sup>۱۷</sup>Regression

در مدل رگرسیونی خطی، متغیر پاسخ  $Y$  یک متغیر تصادفی پیوسته است، در حالی که  $X$  تصادفی نبوده و توسط تحلیل گر کنترل و با خطای قابل اغماضی قابل اندازه‌گیری می‌شود. بنابراین به ازای هر مقدار ممکن  $X$  برای  $Y$  یک توزیع احتمال وجود دارد. به‌طور کلی، منظور از مدل رگرسیونی این است که  $E(Y|x)$  را بر حسب تابعی از  $X$ ، یا  $Y$  را بر حسب تابعی از  $X$ ، به همراه یک جمله خطا  $\varepsilon$ ، که امید ریاضی آن صفر فرض می‌شود، بنابراین

$$Y = \beta_0 + \beta_1 X + \varepsilon, \quad E(Y|x) = \beta_0 + \beta_1 X$$

که هر دو معادل هستند.

هر مدل آماری مبتنی بر پذیره‌هایی ساخته می‌شود. برای مدل رگرسیونی خطی نیز چهار پذیره در نظر گرفته می‌شود که به‌صورت زیر می‌باشند:

- خطی بودن ضابطه تابع رگرسیونی  $E(Y|x)$ ؛
- ثابت بودن واریانس جمله خطا؛
- ناهمبسته بودن مولفه‌های خطا؛
- (بر حسب نیاز) نرمال بودن خطاها.

## ۲.۴.۱ رگرسیون چندگانه

در حالت کلی ممکن است متغیر پاسخ به  $k$  متغیر رگرسیونی  $x_1, x_2, \dots, x_k$  مربوط باشد، بنابراین مدل رگرسیونی به‌صورت زیر است

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon, \quad i = 1, 2, \dots, n \quad (۸.۱)$$

را می‌توان ارائه کرد که در آن  $\varepsilon$ ها متغیرهای تصادفی کنترل‌ناپذیر می‌باشند و متغیرهای خطا نامیده می‌شود و فرض می‌شود دارای توزیع نرمال با میانگین صفر و واریانس  $\sigma^2$  و ناهمبسته هستند. پارامترهای  $\sigma^2$  و  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  مجهول هستند و باید با استفاده از داده‌ها برآورد شوند. فرض می‌شود داده‌ها عبارتند از  $Y_1, Y_2, \dots, Y_k$  که در آن  $Y_i$ ها پاسخ متناظر با  $k$  سطح از متغیرهای مستقل  $x_{i1}, x_{i2}, \dots, x_{ik}$  است، یعنی بنابر معادله (۸.۱) برای مقادیر  $i = 1, 2, \dots, n$  می‌توان نوشت

$$Y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i. \quad (۹.۱)$$

که هدف ما به دست آوردن برآوردهایی برای  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  به ترتیب  $b_0, b_1, \dots, b_k$  است در نتیجه به دست آوردن معادله‌ی

$$\hat{Y} = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_k x_k \quad (۱۰.۱)$$

برای برآورد رگرسیون، که در آن نشان دهنده‌ی مقدار برآورد در ازای  $x_1, x_2, \dots, x_k$  است. آن گاه معادله (۱۰.۱) به عنوان معادله‌ی پیش‌بینی کننده مورد استفاده قرار می‌گیرد. که روش کمترین توان‌های دوم روشی بسیار مفید برای برآورد پارامترهای رگرسیون خطی و خطی چندگانه می‌باشد.

برآوردهای  $b_0, b_1, \dots, b_k$  را به گونه‌ای انتخاب می‌کنیم که مجموع توان‌های دوم انحراف‌ها را کمینه کند یعنی آن‌ها را به گونه‌ای به دست می‌آوریم که در معادله زیر هنگامی که به ترتیب جایگزین  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  می‌شوند، کمترین مقدار ممکن را تولید کنند

$$S = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_k x_{ik})^2 \quad (11.1)$$

با استفاده از حساب دیفرانسیل و انتگرال، برآوردهای  $b_0, b_1, \dots, b_k$  با مشتق گرفتن از معادله‌ی (۱۱.۱) نسبت  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  و مساوی صفر قرار دادن آن‌ها، به دست می‌آیند. یعنی

$$\begin{aligned} \frac{\partial S}{\partial \beta_0} &= -2 \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_k x_{ik}) = 0 \\ \frac{\partial S}{\partial \beta_1} &= -2 \sum_{i=1}^n x_{i1} (Y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_k x_{ik}) = 0 \\ &\vdots \\ \frac{\partial S}{\partial \beta_k} &= -2 \sum_{i=1}^n x_{ik} (Y_i - \beta_0 - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_k x_{ik}) = 0 \end{aligned}$$

با جایگزین کردن  $b_0, b_1, \dots, b_k$  به ترتیب به جای  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  در معادله‌های بالا و مساوی صفر قرار دادن آن‌ها پس از مرتب کردن داریم

$$\begin{aligned} \sum_{i=1}^n Y_i &= nb_0 + b_1 \sum_{i=1}^n x_{i1} + b_2 \sum_{i=1}^n x_{i2} + \dots + b_k \sum_{i=1}^n x_{ik} \\ \sum_{i=1}^n x_{i1} Y_i &= b_0 \sum_{i=1}^n x_{i1} + b_1 \sum_{i=1}^n x_{i1}^2 + b_2 \sum_{i=1}^n x_{i1} x_{i2} + \dots + b_k \sum_{i=1}^n x_{i1} x_{ik} \\ &\vdots \\ \sum_{i=1}^n x_{ik} Y_i &= b_0 \sum_{i=1}^n x_{ik} + b_1 \sum_{i=1}^n x_{i1} x_{ik} + b_2 \sum_{i=1}^n x_{i2} x_{ik} + \dots + b_k \sum_{i=1}^n x_{ik}^2 \end{aligned}$$

ملاحظه می‌شود که برای حل این معادله‌های نرمال بهتر است که از روش ماتریسی استفاده شود که به صورت زیر تعریف می‌کنیم

$$\mathbf{Y} = \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} \quad \mathbf{X} = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix}$$

همچنین داریم

$$\varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \vdots \\ \beta_k \end{pmatrix}, \quad \mathbf{b} = \begin{pmatrix} b_0 \\ b_1 \\ b_2 \\ \vdots \\ b_k \end{pmatrix}$$

$Y$  یک بردار  $n \times 1$ ،  $X$  یک ماتریس  $n \times (k+1)$ ،  $\beta$  یک بردار  $(k+1) \times 1$  و  $\varepsilon$  یک بردار  $n \times 1$  هستند. به این ترتیب ملاحظه می‌شود که مدل رگرسیون خطی چندگانه (۹.۱) را می‌توان به صورت زیر نوشت

$$Y = X\beta + \varepsilon \quad (12.1)$$

همچنین معادله‌ی نرمال را می‌توان به صورت زیر نوشت

$$(X'X) \mathbf{b} = X'Y \quad (13.1)$$

زیرا

$$\begin{aligned} S &= \sum_{i=1}^n \varepsilon_i^2 = \varepsilon' \varepsilon \\ &= (Y - X\beta)' (Y - X\beta) \\ &= Y'Y - Y'X\beta - \beta'X'Y + \beta'X'X\beta \end{aligned}$$

چون  $\beta'X'Y$  یک ماتریس  $1 \times 1$  است و در نتیجه با ترانپوز خود برابر است، پس  $\beta'X'Y = Y'X\beta$  خواهیم داشت

$$S = \sum_{i=1}^n \varepsilon_i^2 = Y'Y - 2\beta'X'Y + \beta'X'X\beta \quad (14.1)$$

با مشتق گرفتن از (۱۴.۱) نسبت به بردار  $\beta$  و با جایگزین کردن  $\mathbf{b}$  به جای  $\beta$  و مساوی صفر قرار دادن آن، معادله‌های نرمال (۱۳.۱) به دست می‌آیند. ماتریس‌های  $X'X$  و  $X'Y$  عبارتند از

$$X'X = \begin{pmatrix} n & \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i2} & \cdots & \sum_{i=1}^n x_{ik} \\ \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i1}^2 & \sum_{i=1}^n x_{i1}x_{i2} & \cdots & \sum_{i=1}^n x_{i1}x_{ik} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \sum_{i=1}^n x_{ik} & \sum_{i=1}^n x_{i1}x_{ik} & \sum_{i=1}^n x_{i2}x_{ik} & \cdots & \sum_{i=1}^n x_{ik}^2 \end{pmatrix}, \quad X'Y = \begin{pmatrix} \sum_{i=1}^n Y_i \\ \sum_{i=1}^n x_{i1}Y_i \\ \vdots \\ \sum_{i=1}^n x_{ik}Y_i \end{pmatrix}$$

با فرض معکوس پذیر بودن ماتریس  $X'X$  داریم

$$\mathbf{b} = (X'X)^{-1} X'Y.$$

## ۵.۱ نقاط پرت

**تعریف ۱.۵.۱.** داده‌های پرت یا به عبارتی نقاط پرت به نقاطی گفته می‌شود که فاصله‌ی زیادی از سایر نقاط داشته باشند، که این گونه داده‌ها به دلایل مختلفی از جمله اشتباه در جمع‌آوری داده‌ها، ابزار اندازه‌گیری نامناسب، وجود افراد کم‌تجربه برای نمونه‌گیری و ... به وجود می‌آیند و در رگرسیون تعاریف مختلفی را دارند که در زیر به مواردی از آن‌ها اشاره می‌کنیم:

- نقاط دور افتاده‌ی رگرسیونی: نقاطی هستند که از برازش خطی  $n - 1$  نقطه‌ی دیگر فاصله‌ی زیادی را داشته باشند.
- نقاط دور افتاده‌ی باقیمانده‌ای: نقاطی هستند که قدرمطلق باقیمانده‌ی استیودنت شده‌ی بزرگی را داشته باشند یا به عبارتی استاندارد شده‌ی بزرگی را داشته باشند.
- نقاط دور افتاده از فضای  $(x, y)$ : نقاطی هستند که مختصات  $x$  و  $y$  آن‌ها از دیگر نقاط فاصله‌ی زیادی را داشته باشند.

با توجه به این که داده‌های پرت در تمام مراحل مربوط به آنالیز و تفسیر اطلاعات چه از لحاظ ساختاری و چه از لحاظ مفهومی تاثیرگذار هستند و بعضی موارد مکان نتیجه‌گیری منطقی از اطلاعات جمع‌آوری شده وجود ندارد و دچار خطاهای علمی آماری از لحاظ پایایی و روایی می‌شویم، بنابراین شناسایی و تشخیص داده‌های پرت و اقدام در جهت اصلاح آن‌ها امری ضروری در تمامی تحقیقات می‌باشد، که آماردانان روش‌های مختلفی را برای شناسایی این نقاط پرت ارائه دادند. از جمله این روش‌ها می‌توان به موارد زیر اشاره کرد:

- استفاده از باقیمانده‌های حذف شده استیودنت شده: باقیمانده‌های حذف شده استیودنت شده به باقیمانده‌هایی گفته می‌شود که در مدل رگرسیونی که در یک مجموعه داده‌ی  $i$ ام پرت به نظر می‌رسد با حذف مورد  $i$ ام باقیمانده‌ها محاسبه می‌شود، بنابراین برای پیش بینی مقدار پیش بینی مشاهده به صورت زیر استفاده می‌کنیم

$$\hat{Y}_{(-i)}(x_{i1}, x_{i2}, \dots, x_{in}) = \hat{\beta}_{0(-i)} + \hat{\beta}_{(-i)}x_{i1} + \dots + \hat{\beta}_{(-i)}x_{ik}$$

اگر تفاوت این مقدار برازش شده را از مقدار واقعی آن به دست آوریم و بر خطای استاندارد آن تقسیم کنیم باقیمانده‌های حذف شده استیودنت شده به دست می‌آید که به صورت زیر می‌باشد

$$T = \frac{Y_i - \hat{Y}_{(-i)}(x_{i1}, x_{i2}, \dots, x_{in})}{\frac{\hat{\sigma}_{(-i)}}{\sqrt{1-h_{ii}}}}$$

$h_{ii}$ ، همان عامل  $i$ ام در ماتریس  $\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$  که تمام مشاهدات  $\mathbf{X}$  را مشاهده می‌کنیم.  $T$  دارای توزیع  $t$ -استیودنت با  $n - k - 2 = (n - 1) - k - 1$  درجه آزادی می‌باشد، به همین دلیل به باقیمانده‌های حذف شده استیودنت شده یا  $t$ -باقیمانده



نیز می‌گویند که معمولاً اگر  $T$  بزرگتر از ۲ یا ۳ باشد نشان دهنده‌ی آن است که داده‌ی پرت وجود دارد و مورد نیاز است که علت را بررسی کنیم.

- استفاده از نمودار جعبه‌ای: برای تشخیص داده‌ی پرت با استفاده از نمودار جعبه‌ای برای هر مجموعه داده‌ای که مشاهدات خارج از دامنه نمودار قرار گیرند جزء داده‌های پرت به شمار می‌آیند.

- نمودار پراکنش: در نمودار پراکنش برای شناسایی نقاط پرت داده‌هایی را که خارج از محدوده‌ی سایر داده‌ها قرار بگیرد را جزء داده‌ی پرت در نظر می‌گیریم

- فاصله کوک<sup>۱۸</sup>: برای تشخیص داده‌ی پرت با استفاده از فاصله کوک از اندازه مربع فاصله بین  $\hat{\beta}$  برآورد حداقل مربعات روی تمام نقاط و  $\hat{\beta}_{(-i)}$  برآورد به دست آمده براساس حذف  $i$ امین نقطه را پیشنهاد کرده است که این اندازه‌ی فاصله‌ی به صورت زیر می‌باشد

$$D_i(M, c) = \frac{(\hat{\beta}_{(-i)} - \hat{\beta})' M (\hat{\beta}_{(-i)} - \hat{\beta})}{c}, \quad i = 1, 2, \dots, n \quad (15.1)$$

که در (۱۵.۱)،  $M$  و  $c$  به ترتیب برابر  $M = \mathbf{X}'\mathbf{X}$  و  $c = pMSE$  تعریف می‌شوند که معمولاً نقاطی را که  $D_i > 1$  باشد به عنوان نقطه‌ی پرت شناسایی می‌شوند.

در پایان این قسمت باید اشاره کنیم که روش‌های زیادی برای شناسایی نقاط پرت وجود دارد که ما در بالا فقط به چند مورد اشاره کردیم. از جمله روش‌های دیگری را که می‌توان نام برد استفاده از نمودار هیستوگرام، استفاده از مجموع مربعات موزون فاصله  $i$ امین نقطه از مرکز داده‌ها و ... هستند.

## ۶.۱ ترتیب‌های غیرتصادفی

ترتیب‌های غیرتصادفی را با  $o$  و  $O$  را نشان می‌دهند که نمادهایی برای توصیف مرتبه‌ی مجانبی کمیت‌های غیرتصادفی می‌باشند. ون در وارت (۱۹۹۸) تعاریفی از ترتیب‌های غیرتصادفی با توجه به ترتیب همگرایی در احتمال به همراه نمادهای مناسب ارائه داد که به شرح زیر می‌باشد.

**تعریف ۱.۶.۱.** دو دنباله از اعداد ثابت  $\{a_n; n \geq 1\}$  و  $\{b_n; n \geq 1\}$  را در نظر بگیرید. گوییم  $b_n = O(a_n)$  هرگاه برای هر  $\varepsilon > 0$ ،  $K(\varepsilon) > 0$  و عدد صحیح  $N(\varepsilon)$  وجود داشته باشند به طوری که برای هر  $n \geq N(\varepsilon)$ ، آن‌گاه

$$|b_n| < K(\varepsilon) |a_n|.$$

<sup>۱۸</sup>Cook Interval

**تعریف ۲.۶.۱.** دو دنباله از اعداد ثابت  $\{a_n; n \geq 1\}$  و  $\{b_n; n \geq 1\}$  را در نظر بگیرید. گوییم  $b_n = o(a_n)$  هرگاه

$$\lim_{n \rightarrow \infty} \left| \frac{b_n}{a_n} \right| = 0.$$

با استفاده از تعاریفی که در بالا به آن اشاره شد، برای هر ثابت حقیقی مثل  $C$ ، ترتیب‌های  $O(a_n)$  و  $o(a_n)$ ، که به ترتیب معادل با  $Ca_n O(1)$ ،  $Ca_n o(1)$  هم‌چنین اگر  $X_n = O(n^C)$ ، آن‌گاه  $X_n = O(n^{C+1})$  قرار می‌گیرد اما عکس رابطه برقرار نیست. برخی از ویژگی‌های ترتیب‌های غیرتصادفی در جدول زیر آورده شده است که از پایان نامه کارشناسی ارشد اسحاقی (۱۳۹۲) استفاده شده که در این جدول  $a$  و  $b$  اعداد حقیقی و  $k = \max\{a, b\}$  فرض می‌کنیم.

جدول ۱.۱: تعدادی از ترتیب‌های غیرتصادفی

عملگر ترکیب	عملگر جمع	عملگر ضرب	
$o(O(n^a)) = o(n^a)$	$o(n^a) + o(n^b) = o(n^k)$	$o(n^a) o(n^b) = o(n^{a+b})$	۱
$O(o(n^a)) = O(n^a)$	$O(n^a) + O(n^b) = O(n^k)$	$O(n^a) O(n^b) = O(n^{a+b})$	۲
$O(O(n^a)) = O(n^a)$	$O(n^a) + o(n^b) = O(n^k)$	$O(n^a) o(n^b) = o(n^{a+b})$	۳



## فصل ۲

# روش‌های آماری استوار

در این فصل به شرح استواری، روش‌های آماری استوار از جمله برآورد پارامترهای مکانی، مقیاسی، رگرسیون استوار و تاریخچه‌ی آن و مقایسه‌ی آن با کمترین توان‌های دوم در مورد نقاط پرت عمده مطالب این فصل از هوگ (۱۷۹۹)، پایان نامه کارشناسی ارشد اقبال (۱۳۸۴)، کتاب مقدمه‌ای بر تحلیل رگرسیون خطی داگلاس مونتگمری، الیزابت پک ترجمه سید ابراهیم رضوی پاریزی (۱۳۸۶) و کتاب تجزیه و تحلیل رگرسیون کاربردی دراپر (۱۹۹۸) می‌پردازیم.

### ۱.۲ استواری

روش‌های استوار<sup>۱</sup> در متون آماری، استوار بودن یک روش، به معنی معتبر بودن و مناسب بودن آن است به عبارت دیگر هرگاه ویژگی یک روش آماری تحت تاثیر انحراف کم از پذیره‌های اساسی قرار نگیرند، آن روش آماری را استوار گوییم، برای مثال  $\bar{x}$ ، میانگین نمونه، برآوردگری برای میانگین جامعه است، ولی استوار نیست. یعنی اگر حداقل یکی از اعضای نمونه مقدار خیلی بزرگی را داشته باشد و از جامعه‌ی مورد نظر نیامده باشد (داده‌ی پرت باشد)،  $\bar{x}$  بسیار متفاوت از میانگین جامعه است در مقابل میانه‌ی نمونه برآوردگری استوار برای پارامتر مکان (در صورت تقارن توزیع جامعه، برای میانگین جامعه) است. زیرا حتی اگر نقاط پرت به تعداد  $\left[\frac{n-1}{p}\right]$  نیز باشند، مقدار میانه تغییر نمی‌کند. استواری در مبحث بازه‌ی اطمینان و آزمون

<sup>۱</sup>Robust Method

فرضیه‌ها نیز مطرح می‌شود، برای مثال  $\bar{X} \pm t_{n-1}(\frac{\alpha}{2}) \frac{S}{\sqrt{n}}$  یک بازه اطمینان  $(1 - \alpha)$  درصد برای میانگین جامعه‌ی نرمال، استوار است.

این سوال مطرح می‌شود که نرمال نبودن مشاهدات بر دقت و کارایی بازه‌ی اطمینان چقدر تاثیر می‌گذارد؟ یعنی انحراف از پذیره‌ی نرمال بودن جامعه به میزان کم، به چه اندازه بر ضریب اطمینان واقعی بازه و به چه میزان بر متوسط طول بازه تاثیر می‌گذارد؟

جوابی را که می‌توان به این سوال داد این است که تاثیر نرمال نبودن جامعه در صورتی که جامعه متقارن باقی بماند بر ضریب اطمینان واقعی بسیار اندک است ولی اگر جامعه متقارن نباشد، ضریب اطمینان به شدت کاهش می‌یابد. بنابراین می‌توان گفت برآورد فاصله‌ای  $t -$  استیودنت مادامی که جامعه متقارن باشد، استوار و اگر توزیع از تقارن فاصله بگیرد، ناستوار است. بر این اساس روش‌های استواری برای اصلاح روش کمترین توان‌های دوم به گونه‌ای هستند، که نقاط دور افتاده تاثیر کمتری را بر روی برآوردگر نهایی دارد. از آنجا که یکی از اقسام رگرسیون، رگرسیون استوار می‌باشد (در مورد تجزیه و تحلیل داده‌های پرت)، توسط جورج باکس (۱۹۵۳) برای اولین بار معرفی گردید که مقالات و کتاب‌هایی در این زمینه به چاپ رسیده است که می‌توان از آنها استفاده کرد از جمله این کتاب‌ها جان توکی (۱۹۶۲) است که در مورد مکان و موقعیت داده‌ها توضیح می‌دهد، شاید بیشترین سهم را هوبر داشته باشد که مقاله‌های اساسی او در سال‌های ۱۹۶۴، ۱۹۷۲ و ۱۹۷۳ نقطه‌ی عطف در این زمینه هستند. هم‌چنین فرانک همپل از تاثیر منحنی در برآورد استواری که یک مفهوم مرکزی است صحبت می‌کند، از این رو اگر کسی علاقه‌ای به تاثیر منحنی داشته باشد می‌تواند به مقاله همپل (۱۹۷۴) مراجعه کند.

مدل خطی رگرسیون  $Y_i = X_i' \beta + e_i$  را در نظر بگیرید. وقتی مشاهدات  $Y_i$ ها دارای توزیع نرمال هستند برآورد خوبی از  $\beta$  را می‌دهد، اما اگر مشاهدات دارای توزیع نرمال نباشند، نمی‌تواند برآورد خوبی را ارائه دهد. زیرا در انتهای منحنی دارای مشاهداتی هستیم که منحنی نرمال دم پهن‌تر یا به عبارتی ضخیم‌تر از نرمال می‌باشد که روش کمترین توان‌های دوم کارا نیست که این شاخه‌های ضخیم توزیع را معمولاً نقاط پرت ایجاد می‌کنند. این نقاط پرت بر برآوردگرهای کمترین توان‌های دوم تاثیر می‌گذارند. داده‌های پرت در برآورد کمترین توان‌های دوم را در حد زیادی به سمت خود می‌کشد که در نتیجه تعیین و تشخیص این دور افتاده‌ها مشکل می‌شود زیرا باقیمانده‌ی مربوط به آن‌ها به طور ساختگی و مصنوعی کوچک می‌باشند. بنابراین باید دنبال راه‌حلی باشیم که این مشکل را برطرف کند که کاربران آماری رگرسیون استوار<sup>۲</sup> را پیشنهاد می‌دهند، برای کاهش اثر مشاهداتی به کار می‌رود که اگر روش کمترین توان‌های دوم تاثیر گذاری بالایی خواهند داشت یعنی اینکه روش استواری می‌خواهد باقیمانده‌های مرتبط با دور افتاده‌های بزرگ را کنار بگذارد که به این وسیله تشخیص نقاط پرت خیلی ساده‌تر می‌شود. رگرسیون استوار علاوه بر حساس نبودن نسبت به داده‌های پرت زمانی که مشاهدات دارای توزیع نرمال هستند رگرسیون استوار دارای کارایی ۹۰ تا ۹۵ درصد

<sup>۲</sup> Robust Regression

نسبت به کمترین توان‌های دوم می‌باشد. امروزه آماردانان بیشتر از روش‌های استواری و تعمیم آنها استفاده می‌کنند، که ما در این بخش به معرفی چند مورد از آنها می‌پردازیم از جمله M-برآوردگر<sup>۳</sup>، L-برآوردگرها<sup>۴</sup> و R-برآوردگرها<sup>۵</sup>. هدف اصلی ما در این پایان نامه بررسی برخی از روش‌های استواری اشاره شده است، روش‌هایی که تاکید می‌کنند این است که به وسیله برخی از این سازگاری‌ها می‌توان هر زمان کمترین توان‌های دوم یا تعمیم آن‌ها استفاده شود مورد استفاده قرار گیرد.

## ۲.۲ برآورد استوار پارامتر مکان

در یک توزیع با تابع چگالی احتمال  $f(x)$ ، و پارامتر مکان  $\theta$  نامعلوم  $-\infty < \theta < +\infty$  برای بدست آوردن تابع چگالی  $f(x - \theta)$ ، فرض کنید که  $X_1, X_2, \dots, X_n$  یک نمونه‌ی تصادفی از این توزیع را نشان می‌دهد، یکی از روش‌های مشهور برای برآورد پارامتر مکان استفاده از درست‌نمایی ماکسیمم است. اگر تابع درست‌نمایی را با  $L(\theta)$  نشان دهیم

$$\ln L(\theta) = \sum_{i=1}^n \ln f(x_i - \theta) = - \sum_{i=1}^n \rho(x_i - \theta) \quad (1.2)$$

که  $\rho(x) = -\ln f(x)$ ، که با مشتق گرفتن نتیجه به صورت زیر حاصل می‌شود

$$\frac{\partial \ln L(\theta)}{\partial \theta} = - \sum_{i=1}^n \frac{f'(x_i - \theta)}{f(x_i - \theta)} = \sum_{i=1}^n \psi(x_i - \theta) \quad (2.2)$$

اگر  $\rho'(x) = \psi(x)$  آن‌گاه

$$\sum_{i=1}^n \psi(x_i - \theta) = 0 \quad (3.2)$$

$L(\theta)$  را ماکسیمم می‌کند. به  $\theta$  ای که در رابطه بالا صدق کند برآوردگر درست‌نمایی ماکسیمم گوییم و آن را با  $\hat{\theta}$  نمایش می‌دهیم، به مثال‌های زیر توجه کنید:

۱- نرمال

$$\rho(x) = \frac{x^2}{\sigma^2} + c \quad (4.2)$$

در این صورت  $\psi(x) = x$  و

$$\sum_{i=1}^n (x_i - \theta) = 0 \implies \hat{\theta} = \bar{x} \quad (5.2)$$

<sup>۳</sup>M estimator

<sup>۴</sup>L estimator

<sup>۵</sup>R estimator

۲- نمایی دوگانه<sup>۶</sup>

$$\rho(x) = |x| + c \quad (۶.۲)$$

با توجه به این که  $\psi(x) = \begin{cases} -1 & x < 0 \\ 1 & x > 0 \end{cases}$  است، در این صورت  $\hat{\theta}$  میانه نمونه می‌باشد.

۳- کوشی<sup>۷</sup>

$$\rho(x) = \ln(1 + x^2) + c \quad (۷.۲)$$

و با توجه به اینکه  $\psi(x) = \frac{2x}{1+x^2}$  بنابراین  $\hat{\theta}$  با روش تکرار حل می‌شود.

توجه داشته باشید که تابع  $\psi$  در مثال‌های مربوط نمایی دوگانه و کوشی کراندار است همچنین در مثال مربوط به توزیع کوشی با افزایش  $x$  به طور مجانبی به صفر نزدیک می‌شود که این جواب‌ها خیلی تحت تاثیر نقاط پرت قرار نمی‌گیرند ولی از سوی دیگر برآوردگر کمترین توان دوم  $\bar{x}$  در مثال نرمال به شدت تحت تاثیر نقاط پرت قرار دارد، برآوردگر کمترین توان دوم  $\bar{x}$  به اندازه حالتی که توزیع دم پهن مانند کوشی در نظر گرفته شود، خوب نیست. بنابراین در برآورد استواری ما به دنبال برآوردگری هستیم که تقریباً کارا باشد یعنی کارایی (۹۰ تا ۹۵ درصدی)، برای حالتی که توزیع نرمال است، تحت فرضیه نرمال گاهی اوقات مقدار کمی از کارایی (تقریباً نزدیک به ۵ درصد) کاسته می‌شود.

برای یک دلیل نظری خاص (در واقع مینیمم کردن ماکسیمم واریانس مجانبی از برآوردگرهای مربوط به یک کلاس از توزیع‌ها)، هوبر (۱۹۶۴) پیشنهاد داد که برای برآوردگر استوار، برآورد کننده ماکسیمم درست نمایی از پارامتر مکان مربوط به چگالی مانند یک نرمال در مرکز و نمایی دوگانه در دم‌ها استفاده می‌شود. به طور خاص تابع  $\rho$  تابع هوبر است اگر

$$\rho(x) = \begin{cases} \frac{1}{4}x^2 & |x| \leq k \\ k|x| - \frac{k^2}{4} & k < |x| \end{cases} \quad (۸.۲)$$

همچنین تابع  $\psi$  مربوط به آن به صورت زیر می‌باشد

$$\psi(x) = \begin{cases} -k & x < -k \\ x & -k \leq x \leq k \\ k & k < x \end{cases} \quad (۹.۲)$$

که با روش تکراری حل می‌شود. یک برآوردگر از این نوع (لزوماً از این تابع  $\psi$  خاص نیست)، برآوردگر برای این حالت را با  $\hat{\theta}$  نمایش می‌دهیم که این را  $M$ -برآوردگر می‌نامیم، یکی دیگر از

<sup>۶</sup> Double Exponential

<sup>۷</sup> Cauchy

ویژگی های  $M$  - برآوردگرها به صورت زیر است.

فرض کنید  $\hat{\theta}$  یک برآوردگر برای نمونه خاص  $x_1, x_2, \dots, x_n$  باشد، سپس این موارد توسط بعضی از آنها جایگزین شده باشد به عنوان مثال انحراف از  $\hat{\theta}$  سه برابر شده باشد. این برآوردگر جدید  $\hat{\theta}$  با استفاده از نمونه تعدیل یافته لزوما یکسان نیست. برای به دست آوردن مقیاس ثابت از این برآوردگر ما می توانیم معادله زیر را حل کنیم

$$\sum_{i=1}^n \psi \left( \frac{x_i - \theta}{d} \right) = 0 \quad (10.2)$$

که  $d$  یک برآورد استوار برابر پارامتر مقیاس است. به طور خاص  $d$  یک آماره خوب استفاده شده در این راه حل است

$$d = \frac{\text{median}|x_i - \text{median}(x_i)|}{(0.6745)} \quad (11.2)$$

صورت کسر  $d$ ، میانه انحراف قدر مطلق تقسیم بر  $0.6745$  است. اگر  $n$  بزرگ باشد تقریباً  $d \approx \sigma$  در واقع نمونه از یک توزیع نرمال حاصل می شود. معمولاً انحراف معیار استاندارد نمونه  $s$  به عنوان یک مقدار  $d$  استفاده نمی شود زیرا خیلی تحت تاثیر نقاط دور افتاده قرار می گیرد و در نتیجه استوار نیست.

این طرح ویژه از انتخاب  $d$  مقدار مناسب را پیشنهاد می دهد. اگر توزیع پایه ای نرمال باشد، ثابت هموار ساز  $k$  باعث بالا بردن کارایی  $\hat{\theta}$  می شود. در حالت نرمال، ما بیشترین سوال ها را برای برآورد نابرابری خواهیم داشت

$$\left| \frac{x_i - \theta}{d} \right| \leq k \quad (12.2)$$

زیرا که

$$\psi \left( \frac{x_i - \theta}{d} \right) = \frac{x_i - \theta}{d} \quad (13.2)$$

در واقع اگر همه ی سوال ها از این نابرابری باشند سپس  $\hat{\theta} = \bar{X}$  به عنوان برآوردگری از توزیع نرمال است.

اگر  $d \approx \sigma$ ، آن گاه  $k$  معمولاً نزدیک به  $1/5$  است. وقتی  $k = 1/5$  است از روش هوبر استفاده می شود. اگر  $\sigma$  معلوم (  $d$  معلوم ) باشد، تحت فرض نرمال دارای کارایی بیش از  $95\%$  درصدی می باشد (هوبر ۱۹۶۴). اندروز و همکاران ( ۱۹۷۲ ) به این نتیجه رسیدند که در شرایط دم سنگین کارایی بهتر می شود، اما در بسیاری از موارد که توزیع ها غیر نرمال هستند و  $\sigma$  نامعلوم، پارامتر  $\sigma$  باید برآورد شود که این باعث می شود مقدار بسیار کمی از کارایی کاهش یابد زمانی که  $n \geq 10$  است.

توابع  $\psi$  دیگر که عموماً مورد استفاده قرار می گیرد در زیر آورده شده



۱.  $(a, b, c)$  همپیل<sup>۸</sup>

$$\psi(x) = (\text{sign}x) \begin{cases} |x| & 0 \leq |x| < a \\ a & a \leq |x| < b \\ a \frac{c-|x|}{c-b} & b \leq |x| < c \\ 0 & c \leq |x| \end{cases} \quad (14.2)$$

مقادیر خوب و ثابتی را که می‌توان برای ثابتها  $a, b, c$  انتخاب کرد به صورت زیر می‌باشد

$$a = 1/7 \quad b = 3/4 \quad c = 8/5. \quad (15.2)$$

۲.  $k$ - موج اندروز<sup>۹</sup> که به صورت زیر می‌باشد

$$\psi(x) = \begin{cases} \sin(\frac{x}{k}) & |x| \leq k\pi \\ 0 & |x| > k\pi \end{cases} \quad (16.2)$$

با مقادیر  $k = 1/5$ ، یا برابر ۲ است، در واقع اگر پارامتر مقیاس معلوم، و  $k = 1/339$ ، شرایط برای ما ایده‌آل است به عبارت دیگر مقدار کمی از کارایی کم می‌شود چیزی نزدیک به ۵ درصد.

۳.  $k$ - دو وزنی توکی<sup>۱۰</sup>

$$\psi(x) = \begin{cases} x \left(1 - \left(\frac{x}{k}\right)^2\right)^2 & |x| \leq k \\ 0 & |x| > k \end{cases} \quad (17.2)$$

با مقادیر  $k = 5$  یا ۶ است، در واقع اگر پارامتر مقیاس معلوم باشد، و  $k = 4/685$ ، شرایط برای ما ایده‌آل است به عبارت دیگر مقدار کمی از کارایی کم می‌شود چیزی نزدیک به ۵ درصد. لازم به ذکر است که موج اندروز و دو وزنی توکی بسیار شبیه به هم هستند و جایگزین مناسبی برای یکدیگر می‌باشند زیرا تابع  $\rho$  با این سه تابع  $\psi$  پیوند داده شده و این سه تابع محدب نیستند، اگرچه ممکن است مشکلات همگرایی خاصی در روش تکرار وجود داشته باشد با توجه به اینکه این روش موفقیت آمیز بوده اما باید تحت یک سری شرایط مورد استفاده قرار گیرد.

به عنوان مثال فرض کنید با روش تکرار ما جوابی را برای  $\hat{\theta}$  پیدا می‌کنیم یعنی  $\hat{\theta}$ ،  $M$ - برآوردگر باشد بطوریکه  $\sum_{i=1}^n \psi\left(\frac{x_i - \hat{\theta}}{d}\right) = 0$  برای هر تابع  $\psi$  فرد کراندار معادله آخر تقریباً آسان می‌شود

<sup>۸</sup>Hampel

<sup>۹</sup>(k) Wave of Andrews

<sup>۱۰</sup>(k) Biweight of Tukey

با جایگزین کردن اعضای سمت چپ توسط سری تیلور، بسط مقدار درستی درباره پارامتر  $\theta$  می‌باشد. از این تقریب زمانی که  $d \approx \sigma$

$$\sqrt{n}(\hat{\theta} - \theta) \approx \frac{\sigma [\sum_{i=1}^n \psi(\frac{x_i - \theta}{\sigma})] / \sqrt{n}}{[\sum_{i=1}^n \psi'(\frac{x_i - \theta}{\sigma})] / n} \quad (18.2)$$

و این عبارت دارای توزیع نرمال با میانگین صفر و واریانس زیر می‌باشد

$$\frac{\sigma^2 E \left[ \psi^2 \left( \frac{x - \theta}{\sigma} \right) \right]}{[E(\psi'(\frac{x - \theta}{\sigma}))]^2} \quad (19.2)$$

البته از آنجا که چگالی آن را نمی‌دانیم، ما باید تقریبی از مقدار مورد انتظار و  $\sigma$  که به صورت مجانبی است را به دست آوریم.

یک تقریب برای واریانس  $\sqrt{n}(\hat{\theta} - \theta)$  به صورت زیر است

$$s_1^2 = \frac{d^2 \left[ \frac{1}{n} \sum_{i=1}^n \psi^2 \left( \frac{x_i - \hat{\theta}}{d} \right) \right]}{\left[ \left( \frac{1}{n} \right) \sum_{i=1}^n \left( \psi' \left( \frac{x_i - \hat{\theta}}{d} \right) \right) \right]^2} \quad (20.2)$$

برای  $n$  های بزرگ  $\sqrt{n}(\hat{\theta} - \theta)/s_1$  که تقریباً دارای توزیع نرمال استاندارد می‌باشد. هوبر (۱۹۷۰) بررسی کرد توزیع تقریبی بهتری برای  $\sqrt{n-1}(\hat{\theta} - \theta)/s_1$  می‌توان با استفاده از عضوی از خانواده  $t$  با درجه آزادی  $n-1$  پیدا کرد یا حتی دارای درجه آزادی کمتر از  $n-1$  باشد. با یکی از این توزیع‌های تقریبی ما می‌توانیم در مورد  $\theta$  استنباط آماری انجام دهیم. گروس (۱۹۷۶) فواصل اطمینان را براساس این ایده هم‌چنین نتایج حاصل از طرح‌های دیگر را بررسی کرد و اعتبار استواری (ضریب اطمینان ۹۵ درصدی) و کارایی (ایجاد فواصل نسبتاً کوتاه) را پیدا کرد.

## ۳.۲ رگرسیون استوار

در حالتی که رگرسیون کلاسیک تحت تاثیر نقاط دور افتاده قرار می‌گیرند از این رو رگرسیون استوار با استفاده از روش‌های استوار تاثیر این نقاط دور افتاده را کم می‌کند مدل رگرسیون زیر را در نظر بگیرید

$$Y = X_i^T \beta + \varepsilon, \quad i = 1, 2, \dots, n \quad (21.2)$$

$Y$  برداری تصادفی  $n \times 1$ ،  $X$  ماتریس طرح است با بعد  $n \times p$  طوری که  $X^T X$  یک ماتریس رتبه کامل است،  $\beta$  یک بردار  $p \times 1$  از ضرایب مجهول است و  $\varepsilon$  بردار تصادفی  $n \times 1$  است که عناصر آن نمونه‌ای از یک توزیع متقارن حول صفر (مثلاً نرمال) هستند. برای مشابه رهیافت پارامتر مکان، ما می‌خواهیم مجموعه زیر را مینیمم کنیم

$$\sum_{i=1}^n \rho \left( \frac{Y_i - X_i^T \beta}{d} \right) \quad (22.2)$$

که در آن  $Y_i$ ،  $i$  امین عنصر از  $Y$  و  $X_i$ ،  $i$  مین سطر از ماتریس  $X$  است و  $d$  برآورد پارامتر مقیاس توزیع مربوط به  $\varepsilon$  است. معادله مشتقات جزئی مرتبه اول مربوط به عناصر  $\beta$  را، که با  $\beta_j$  نمایش می‌دهیم، برابر صفر قرار می‌دهیم. همانطور که مشاهده می‌کنیم این کار هم ارز با یافتن ماکسیم جواب از رابطه زیر می‌باشد

$$\sum_{i=1}^n x_{ij} \psi \left( \frac{Y_i - X_i^T \beta}{d} \right) = 0, \quad j = 0, 1, \dots, p \quad (23.2)$$

فرض کنید بخواهیم ابتدا برآورد  $\beta_0$  حاصل از  $\beta$  را به دست بیاوریم برای این کار به دو چیز نیاز داریم

- برآورد استوار  $d$  حاصل از پارامتر مقیاس

- نقطه شروع برای بدست آوردن  $\hat{\beta}$

اگر برآوردگر  $L_1$  (مینیم کردن مجموع قدر مطلق خطاها) بتواند ضرایب رگرسیونی را به خوبی پیدا کند که این کار ما را راحت می‌کند چیزی شبیه به میانه در یک نمونه واحد است. علاوه بر این برای برآورد پارامتر مقیاس، میانه مقادیر قدرمطلق باقیمانده‌های غیرصفر تقسیم بر  $1.6745$  مانند مورد پارامتر مکان می‌باشد. اگر چه آمار دانان تلاش زیادی در زمینه  $L_1$  برآوردگرها کردند اما با این حال ناراضی بودند، بنابراین برای برآورد پارامتر  $\beta$  و مقیاس به صورت همزمان سراغ الگوریتم معرفی شده توسط داتر (۱۹۷۷) می‌رویم، که این الگوریتم فقط برای تابع  $\psi$  در هوبر توضیح داده شده است. همان‌طور که مشاهده می‌کنیم این روش شبیه کمترین توان‌های دوم می‌باشد. البته باید به این نکته هم توجه کنیم که این روش فقط یکی از روش‌هایی است که در مقاله داتر ذکر شده است اجازه دهید با برخی از برآوردهای اولیه شروع کنیم،  $\beta_0$  و  $d_0$  ممکن است به خوبی برآوردهای معمولی برای پارامتر  $\beta$  و مقیاس باشند ما به صورت زیر عمل می‌کنیم

- باقیمانده‌ها را به صورت زیر محاسبه می‌کنیم

$$z_i = Y_i - X_i^T \beta_0, \quad i = 1, 2, \dots, n \quad (24.2)$$

- یک برآوردگر از پارامتر مقیاس به صورت زیر به دست می‌آوریم

$$d_1^2 = \frac{1}{(n-1)E(\psi^2)} \sum_i^n \left( \psi \left( \frac{z_i}{d_0} \right) \right)^2 d_0^2 \quad (25.2)$$

که در آن  $E(\psi^2)$ ، امید ریاضی مقادیر  $\psi^2(w)$  هوبر است و  $w$  یک متغیر تصادفی است که از توزیع نرمال استاندارد پیروی می‌کند.

- باقیمانده‌های وینزوریزه شده<sup>۱۱</sup> به صورت زیر تعیین می‌شوند

$$\Delta_i = \psi \left( \frac{z_i}{d_1} \right) d_1 \quad (26.2)$$

<sup>۱۱</sup>Winsorize the Residuals

توجه کنید که باقیمانده‌ها وینزوریده شده  $d_1 \psi\left(\frac{z_i}{d_1}\right)$  معادل  $z_i$  هستند، اگر  $\left|\frac{z_i}{d_1}\right| \leq k$  اما برابر است با  $kd_1$  اگر  $z_i < -kd_1$  و  $-kd_1$  اگر  $z_i > kd_1$ ، برای کسب اطلاعات بیشتر در مورد وینزوریده کردن به دیکسون و توکی (۱۹۶۸) مراجعه شود.

- برآورد کمترین توان‌های دوم<sup>۱۲</sup> ضرایب رگرسیونی به شرطی که باقیمانده‌های وینزوریده شده مشاهده شده باشند به صورت زیر می‌باشد

$$\hat{\xi}_0 = (X'X)^{-1} X'\Delta_0 \quad (27.2)$$

که  $\Delta_0$  یک بردار ستونی  $p \times 1$  حاصل از  $\Delta_1, \Delta_2, \dots, \Delta_n$  است.

- یک برآورد جدید از  $\beta$  محاسبه کنید یعنی

$$\beta = \beta_0 + q\hat{\xi}_0 \quad (28.2)$$

دائر دریافت یک انتخاب مناسب از فاکتور  $q$  به شکل زیر می‌باشد

$$q = \min \left[ \frac{1}{\Phi(k) - \Phi(-k)}, 1/9 \right] \quad (29.2)$$

که  $\Phi$  تابع توزیع نرمال استاندارد می‌باشد.

با برآوردهای جدید،  $\beta_1$  و  $d_1$  به عنوان مقادیر اولیه برای مراحل یک تا پنج تکرار می‌شوند. این روند تکراری را  $i = 1, 2, \dots, p$  ادامه می‌دهیم در این صورت داریم

$$|q\hat{\xi}_m^i| < \varepsilon d_{m+1}, \quad |d_{m+1} - d_m| < \varepsilon d_{m+1} \quad (30.2)$$

که در آن  $\varepsilon > 0$  یک سطح تحمل مناسب  $\hat{\xi}_m^i$ ،  $i$ -امین مولفه از  $\hat{\xi}_m$  و  $x_{ii}$ ،  $i$  امین عنصر قطری از  $(X'X)^{-1}$  است در این زمان تکرار را متوقف کنید و  $\beta$  و پارامتر مقیاس را با به کار بردن  $\beta_{m+1}$  و  $d_{m+1}$  برآورد کنید. خواننده باید دقیقاً مشخص کند که این روش برای کمترین توان‌های دوم است یا خیر.

البته مرحله چهار کمترین توان‌های دوم برای باقیمانده‌های وینزوریده شده است و مرحله پنج برآورد کمترین دوم را با  $\beta$  شامل  $q = 1$  و  $\Delta_0$ هایی برابر حاصل از باقیمانده‌های واقعی (غیر وینزوریده شده) برای هر برآورد اولیه  $\beta_0$  ارائه می‌دهد. هم‌چنین جالب است که برای محاسبه‌ی

$(X'X)^{-1}$  نیاز به محاسبه‌ی یک بار روند تکراری است که این خود باعث صرف جویی در محاسبات می‌شود، سپس یک برآورد استوار خوب از  $\beta_0$  و پارامتر مقیاس با استفاده از الگوریتم معرفی شده توسط دائر با روش‌های کمترین مقدار مطلق یا دیگر روش‌ها (برخی روش‌های ناپارامتری که ممکن است بسیار مناسب‌تر باشد) بدست می‌آوریم. ما می‌توانیم مشکل نقاط پرت را با به کار بردن برآوردهای استوار  $\tilde{d}_0$  و  $\tilde{\beta}_0$  و یک تابع صعودی  $\psi$  برطرف کنیم مانند موجی یا وزنی در این موارد کمترین توان‌های دوم موزون، می‌تواند جایگزین مناسبی برای استفاده باشد.

<sup>۱۲</sup>Least squares Estimates

### ۱.۳.۲ M-برآوردگر

معادله (۲۲.۲) را نسبت به پارامترهای  $j = 1, 2, \dots, k, \beta_j$  مینیمم کنیم با مشتق‌گیری از معادله (۲۲.۲) نسبت به تک به تک پارامترها منجر به  $p = k + 1$  معادله به شکل زیر می‌شود

$$\sum_{i=1}^n x_{ij} \psi \frac{(\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta})}{d} \quad (31.2)$$

این معادله‌ها در کل جواب واضحی ندارند و جواب عددی مکرر نیاز است. همانند بیتون و توکی (۱۹۷۴) وزن‌ها را به صورت زیر تعریف می‌کنیم

$$W_{i\beta} = \frac{\psi \left\{ \frac{(\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta})}{d} \right\}}{\frac{(\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta})}{d}} \quad (32.2)$$

و در صورتی که دقیقاً  $\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta}$  اتفاق بیافتد آن را با یک تعریف می‌کنیم از اینرو معادله (۳۱.۲) را می‌توان به صورت زیر بازنویسی کرد

$$\sum_{i=1}^n x_{ij} W_{i\beta} (\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta}) \quad j = 0, 1, 2, \dots, n \quad (33.2)$$

آن‌گاه

$$\sum_{i=1}^n x_{ij} W_{i\beta} \mathbf{X}_i^T \boldsymbol{\beta} = \sum_{i=1}^n x_{ij} W_{j\beta} \mathbf{Y}_i, \quad j = 0, 1, 2, \dots, n \quad (34.2)$$

که می‌توان به صورت ماتریسی زیر بازنویسی کرد

$$\mathbf{X}' W_{\beta} \mathbf{X} \boldsymbol{\beta} = \mathbf{X}' W_{\beta} \mathbf{Y} \quad (35.2)$$

که در روابط بالا  $W_{\beta} = W_{1\beta}, W_{2\beta}, \dots, W_{n\beta}$  این معادلات به وضوح به صورت معادلات نرمال کمترین توان‌های دوم تعمیم یافته هستند. (به طور دقیق‌تر آن‌ها معادلات نوع کمترین توان‌های دوم وزنی هستند زیرا  $W_{\beta}$  یک ماتریس قطری از وزن‌ها می‌باشد). مشکل حل کردن آن این است که  $W_{\beta}$  به  $\beta$  بستگی دارد. با استفاده از یک روش ساده قدیمی این مشکل را حل می‌نماییم به طریقی یک برآورد اولیه  $\hat{\beta}$  از  $\beta$  را می‌گیریم (شاید با استفاده از کمترین توان‌های دوم). مقدار  $W_{\beta}$  را محاسبه می‌کنیم، یعنی  $W_{\beta}$  برای همان  $\hat{\beta}$  و معادله (۳۵.۲) را برای رسیدن به جواب  $\hat{\beta}_1$  حل می‌کنیم. با استفاده از  $\hat{\beta}_1$  به  $W_1$  می‌رسیم. سپس با استفاده از  $W_1$  به  $\hat{\beta}_1$  می‌رسیم و به همین ترتیب ادامه می‌دهیم. معمولاً همگرایی به سرعت رخ می‌دهد. (روند می‌تواند بعد یک تعداد منتخبی از گام‌ها متوقف شود). تنها یک برنامه کمترین توان‌های دوم احتیاج است، مثلاً در MINITAB می‌تواند مکرر به صورت زیر نوشته شود

$$\hat{\beta}_{q+1} = (\mathbf{X}' W_q \mathbf{X})^{-1} \mathbf{X}' W_q \mathbf{Y} \quad (36.2)$$

و روند ممکن است زمانی که همه‌ی برآوردها کمتر از یک مقدار از پیش تعیین شده مثلا ۱۰ درصد یا ۰۱ درصد، تغییر کنند یا بعد از یک تعداد گام تعیین شده، متوقف می‌شود. از معادله (۳۲.۲) مشاهده می‌شود که وزن‌ها به مقدار  $\frac{(\partial \rho(x))}{\partial x}$  وابسته‌اند که در آن  $x = \frac{(Y_i - X_i^T \beta)}{d}$  می‌باشد. بنابراین می‌توانیم برای همه‌ی انتخاب‌های  $\rho(x)$  در جدول زیر که آورده شده به تابع  $W(x) = \frac{(\partial \rho(x))}{\partial x}$  نگاه کنیم. به وضوح انتخاب یک  $\rho(x)$  بخصوص اساس یک انتخاب از تابع وزنی است که کاربر برای اختصاص دادن به باقیمانده‌های مقیاس شده در انواع مقادیر مختلف نیاز دارد شخصی می‌تواند حتی به راحتی تابع وزن خود را برای  $\rho(x)$  تعریف کند. یادآوری می‌کنیم که وزن‌ها در (۳۲.۲) برحسب  $x = \frac{(Y_i - X_i^T \beta)}{d}$  تعریف شده‌اند و نیاز به برآورد مقیاس  $d$  دارد. یک انتخاب استوار تا حدی محبوبیت پیدا کرده به صورت زیر است

$$d = \frac{\text{median}|e_i - \text{median}(e_i)|}{0.6745} \quad (37.2)$$

اگر  $n$  به قدر کافی بزرگ و خطاها به صورت نرمال توزیع شده باشند برآوردگری تقریباً نارایب را از  $SdY_i = \sigma$  به دست خواهد داد. (این پیشنهاد از همپل با یک اشتباه چاپی در مخرج در اندروز و همکاران ۱۹۷۲ داده شده است. هم‌چنین گاهی در جاهای دیگر با مخرجی که در حال حاضر معکوس شده همانند  $1/4826$  نشان داده شده است). چندین عامل مقیاسی جایگزین نیز پیشنهاد و بررسی شده‌اند، برای مثال هیل و هولاند (۱۹۷۷) را ببینید انتخاب واقعی  $d$  اثری روی باقیمانده‌ها خواهد گذاشت، به این معنا که برآوردهای پارامتر رگرسیونی استوار بر انتخاب  $d$  ثابت نیستند.

هلند و والش (۱۹۷۷) مقایسه برآوردهای استوار حاصل از  $\lambda$  تابع  $\psi$  است از جمله این  $\lambda$  تابع برآورد بسته های آماری استوار که در مرکز کامپیوتری دفتر ملی تحقیقات اقتصادی Ins توسعه یافته است. برای مثال، از گزارش خودشان یک ثابت هموار ساز،  $k = 1/5$  برای برآورد موج مناسب است و در صورتی که  $d = \sigma$  و معلوم شده باشد دارای توزیع نرمال است، دارای کارایی بیش از ۹۵ درصد است. یکی از ویژگی‌های مطلوب تابع  $\psi$  مانند تابع موج اندروز یا تابع وزن دوتایی توکی برای شناسایی نقاط دور افتاده زمانی که ما از روش هوپر استفاده می‌کنیم بهتر می‌شوند و در بسیاری از موارد وزن صفر به نقاط پرت یا نقطه داده‌های بد داده می‌شود. البته هر زمان که روش‌های کمترین توان‌های دوم (تعمیم آن‌ها) مورد استفاده قرار می‌گیرند، به ظاهر امکان استفاده از روش‌های استواری وجود دارد. که شامل ANOVA، رگرسیون، سری زمانی، اسپلاین، تجزیه و تحلیل چند متغیره و تشخیص، برای اطلاعات بیشتر در مورد توابع  $\rho$  و توابع وزن به جدول زیر رجوع کنید

جدول ۱.۲: بعضی از توابعی که برای توزیع وزن مانده‌ها پیشنهاد شده‌اند

ردیف	معیار	$\rho(x)$	دامنه $\rho(x)$	$\psi(x) = \frac{\partial \rho(x)}{\partial x}$	$w(x) = \frac{\psi'(x)}{x}$	مقادیر ثابت‌های تنظیم کننده و توصیحات
۱	حفاظت مربعیات (توزیع ماندگه‌های نرمال)	$\frac{1}{2} x^2$	$-\infty \leq x \leq \infty$	$x$	۱	
۲	Huber	$\begin{cases} \frac{1}{2} x^2 \\ a x  - \frac{1}{2} a^2 \end{cases}$	$-a \leq x \leq +a$ $u < -a \text{ and } x > a$	$x$ $a * \text{sign}(x)$	$\frac{1}{ x }$	$a = 2$
۳	Ramsay	$\frac{\{1 - e^{a x } (1 + a x )\}}{a^2}$	$-\infty \leq x \leq \infty$	$ue^{a x }$	$e^{a x }$	$a = 0.3$
۴	Andrew	$\begin{cases} a \{1 - \cos(\frac{x}{a})\} \\ \frac{1}{2} a^2 \end{cases}$	$-a \leq x \leq +a$ $x < -a\pi, x > a\pi$	$\sin(\frac{x}{a})$	$\sin(\frac{x}{a}) \frac{x}{a}$	$a = 1.339$
۵	Tukey	$\begin{cases} \frac{1}{2} x^2 - \frac{x^3}{6a} \\ \frac{1}{2} a^2 \end{cases}$	$-a \leq x \leq +a$ $x < -a, x > a$	$x(1 - \frac{x^2}{a^2})$	$1 - \frac{3x^2}{a^2}$	$a = 5 \leq a \leq 6$
۶	Hampel	$\frac{\frac{1}{2} x^2 \left\{ \begin{aligned} & a x  - \frac{1}{2} a^2 \\ & \frac{a}{c} \left( \frac{a x  - \frac{1}{2} a^2}{c-b} \right) - \frac{1}{2} a^2 \end{aligned} \right\}}{a(b+c-a)}$	$-a \leq x \leq +a$ $-b \leq x \leq -a, a \leq x \leq b$ $-c \leq x \leq -b, b \leq x \leq c$ $x < -c, ux > c$	$x$ $a * \text{sign}(x)$ $c \text{Sign}(x) - (x)a/c$	$\frac{1}{ x }$ $(c/ x  - 1)(a/c - b)$	$a = 1.7, b = 3.4, c = 8.5$

## ۲.۳.۲ -L- برآوردگر

یک نمونه تصادفی از یک توزیع پیوسته با پارامتر مکان  $\theta$  در نظر بگیرید آماره‌های ترتیبی نمونه،  $X_{(1)}, X_{(2)}, \dots, X_{(n)}$  یک -L- برآوردگر ترکیب خطی از آماره‌های ترتیبی می‌باشد. که موارد زیر نمونه‌هایی از -L- برآوردگرها می‌باشند

۱ میانه نمونه

$$\bar{X}_\alpha = \frac{\sum_{i=[n\alpha]+1}^{n-[n\alpha]} X_{(i)}}{n - 2[n\alpha]}, \quad i = [n\alpha] + 1, \dots, n - [n\alpha] \quad (38.2)$$

۳- برآوردگر گست‌ویرث<sup>۱۳</sup> که یک میانگین وزنی با صدکهای  $\frac{1}{3}$ ،  $\frac{5}{6}$  و  $\frac{2}{3}$  با وزن‌های  $\frac{1}{3}$ ،  $\frac{1}{4}$  و  $\frac{1}{3}$  می‌باشد.

۳- توکی سه میانگین، که میانگین موزون اولین، دومین و سومین، چارک‌های مربوط به آن‌ها دارای وزن  $\frac{1}{3}$ ،  $\frac{1}{3}$  و  $\frac{1}{3}$  می‌باشند.

این و سایر -L- برآوردگرها توسط اندروز و همکاران (۱۹۷۲)، توضیح داده شده است که به طور کلی -L- برآوردگرها دارای وضعیت رگرسیون روشنی در مورد -M- برآوردگرها نیست زیرا با استفاده از  $\rho$  به صورت زیر می‌باشد

$$\rho(x) = |x| \quad (39.2)$$

که میانه را به عنوان یک برآوردگر (سطح میانه و سطح وضعیت رگرسیون) در نظر می‌گیرد. و این می‌تواند به آسانی تعدیل بیابد برای بدست آوردن سایر صدک‌ها تابع  $\rho$ ، به صورت زیر می‌باشد

$$\psi(x) = \begin{cases} -(1-p)x & x < 0 \\ p(x) & x \geq 0 \end{cases} \quad (40.2)$$

صدک  $(1-p)$ th در یک تک نمونه و برآوردی از سطح تراز صدک  $(1-p)$ th است، یا اینکه سطح وضعیت رگرسیون که برای اطلاعات بیشتر به کوکتر و باست (۱۹۷۸) مراجعه کنید. روشن است تعمیم (تعاریف) از برآوردها مانند آن‌ها از توکی و گست‌ویرث در مسائل رگرسیونی به کار برده می‌شود، علاوه بر این در بسیاری از موارد مانند اطلاعات آموزشی شامل پیش‌بینی از عملکرد دبیرستان، رتبه دبیرستان و نمرات SAT, ACT مورد استفاده قرار می‌گیرد، که علاوه بر این احتمال دارد برخی علاقه‌مند به برخی از صدک‌های دیگر باشند بنابراین برآوردهای صدکی می‌توانند به تنهایی هم‌چنین با سایر برای پیش‌بینی یک سطح یا سطح متوسط به کار برده شود.

<sup>۱۳</sup>Gastwirth's Estimator



### ۳.۳.۲ R-برآوردگر

برآوردگر رتبه‌ای علاوه بر M-برآوردگر که به طور مفصل درباره‌ی آن بحث شد روش دیگری برای رگرسیون استوار وجود دارد روش R-برآوردگر براساس رتبه‌ها می‌باشد. برای روشن‌تر شدن روش کلی، جانشین کردن یک عامل رتبه‌ای در تابع حداقل مربعات  $\sum_{i=1}^n (Y_i - X_i^T \beta)^2$  اگر R-برآوردگر رتبه  $(Y_i - X_i^T \beta)$ ، R-برآوردگر می‌گوییم. بنابراین رتبه‌ی  $R_i$  یک تابع از  $\beta$  می‌باشد. بنابراین داریم

$$\sum_{i=1}^n (Y_i - X_i^T \beta) R_i \quad (41.2)$$

که می‌توان با جایگزین کردن رتبه‌ها  $1, 2, \dots, n$  با نمرات  $a(1) \leq a(2) \leq \dots \leq a(n)$  تعمیم دهیم (41.2) که در اینصورت تابع هدف به صورت زیر می‌باشد

$$\min_{\beta} \sum_{i=1}^n (Y_i - X_i^T \beta) a R_i \quad (42.2)$$

البته دو مثال از نمره‌ها به صورت زیر می‌باشد

**مثال ۱.۳.۲.** اگر تابع امتیاز را با رتبه‌ها مساوی قرار بگیرد نمرات (رتبه‌ها) ویلکسون که به صورت زیر می‌باشد

$$a(i) = i \quad (43.2)$$

**مثال ۲.۳.۲.** میانه نمرات که به صورت زیر می‌باشد

$$a(i) = \begin{cases} -1 & i < \frac{(n+1)}{4} \\ 1 & i > \frac{(n+2)}{4} \end{cases} \quad (44.2)$$

جیکل (۱۹۷۲) ثابت کرد که این حداقل رساندن‌ها هم ارز با حل کردن  $p$  است

$$\sum_{i=1}^n x_{ij} a(R_i) = 0, \quad j = 1, 2, \dots, p \quad (45.2)$$

معادله (45.2) به صورت تقریبی حل می‌شود زیرا به دلیل ناپیوستگی در  $a(\cdot)$  و  $R_i$  علاوه بر این به خوبی معلوم است که نمرات خوب (داشتن خواص مجانبی مشخص) داده می‌شود توسط

$$a(i) = \phi \left[ \frac{i}{(n+1)} \right] \quad (46.2)$$

و هم‌چنین داریم

$$\phi(t) = \frac{[-f' F^{-1}(t)]}{f [F^{-1}(t)]} \quad (47.2)$$

مثال‌های مربوط به (46.2) و (47.2)

مثال ۳.۳.۲.  $f$  نرمال باشد آن گاه داریم

$$\phi(t) = \Phi^{-1}(t), \quad 0 < t < 1 \quad (48.2)$$

در این صورت نمرات نرمال می‌باشند.

مثال ۴.۳.۲. اگر  $f$  نمایی دو گانه باشد آن گاه

$$\phi(t) = \begin{cases} -1 & 0 < t < \frac{1}{2} \\ 1 & \frac{1}{2} < t < 1 \end{cases} \quad (49.2)$$

در این صورت میانه نمرات را می‌دهد.

مثال ۵.۳.۲.  $f$  لجستیک باشد آن گاه

$$\phi(t) = \Psi(t) - 1, \quad 0 < t < 1 \quad (50.2)$$

در این صورت نمرات ویلکسون را می‌دهد.

جور کاکووا (۱۹۷۷) ثابت کرد با نمرات مشخص  $a(\cdot)$  و تابع  $\psi$ ،  $R$ -برآوردگر و  $M$ -برآوردگر به طور مجانبی معادل خواهند بود از جمله شرایط دیگری که به آن نیاز داریم

$$\phi(t) = c_1 \psi [F^{-1}(t)] + c_2 \quad (51.2)$$

که در این صورت لازم است که  $c_1$  و  $c_2$  در (۵۱.۲) ثابت باشند که معادل باشند.

ملاحظه ۱.۳.۲. با توجه به (۵۱.۲) منطقی‌ترین این است که از  $M$ -برآوردگر استفاده کنیم زیرا هم محاسبات کمتری را احتیاج دارد و هم زمان کمتری صرف می‌شود. کاربرد برآورد  $L$ -برآوردگر در زمینه رگرسیون به سادگی  $M$ -برآوردگر و  $R$ -برآوردگر نمی‌باشد. دنی و لارسن رگرسیون قطعه قطعه را تشریح می‌کند که در آن برای یک متغیر رگرسیون داده‌ها را به گروه‌هایی تقسیم می‌کنند و به کارگیری مرکز نقل گروه‌ها خط مستقیم را برازش می‌دهند. تعمیم قدم به قدم این تکنیک برای رگرسیون چندگانه به کار می‌رود. موسا-هامودا و لئون (۱۹۷۴، ۱۹۷۷a) روش‌هایی را برای رگرسیون خطی ساده با مشاهدات تکراری  $y$  به ازای  $x$  پیشنهاد می‌کنند که مستلزم آراستن و کنار گذاشتن مقادیر حذف شده  $y$  می‌باشد.


هرگاه تحقیقات در مورد  $R$ -برآورد و  $L$ -برآورد ادامه یابد باور داریم که در حال حاضر  $M$ -برآوردگرها برای مسائل رگرسیونی قابل قبول‌تر می‌باشند. آن‌ها به سادگی از یک برنامه کامپیوتری حداقل مربعات موزون بدست می‌آیند و در آخرین تکرار وزن‌ها نقاط تاثیر گذار را مشخص می‌کنند و به دست آوردن  $R$  و  $L$  برآوردگر از نظر محاسباتی از  $M$ -برآوردگر مشکل‌تر هستند.

مثالی که در زیر آورده شده داده‌های آن مربوط به کاهش توده می‌باشد برای ارتباط بین مدل رگرسیون استوار و رگرسیون کلاسیک که چه موقع از رگرسیون استوار و چه موقع از رگرسیون کلاسیک استفاده کنیم.

**مثال ۶.۳.۲.** داده‌های کاهش توده که از یک کارخانه تبدیل اکسید آمونیاک به اسید نیتریک توسط دانیل و وود ۱۹۸۰ تشریح شده است که دارای ۲۱ مشاهده می‌باشند و سه متغیر مستقل (جریان هوا، حرارت آب خنک کننده ورودی و غلظت اسید)، رگرسیون خطی همراه با نمودار برای این مجموعه داده ارائه می‌دهیم، حالت اول کمترین توان‌های دوم برای ۲۱ مشاهده، حالت دوم ۲۱ مشاهده دارای چهار داده‌ی پرت می‌باشند که در این حالت چهار داده‌ی پرت را کنار می‌گذاریم و برای ۱۷ مشاهده باقیمانده رگرسیون خطی ساده را انجام می‌دهیم و حالت آخر برای ۲۱ مشاهده رگرسیون استوار استفاده شده، انجام می‌دهیم

- مدل رگرسیون خطی برای ۲۱ مشاهده تقریباً به صورت زیر می‌باشد و  $MSE = ۹/۳۵$  می‌باشد.


$$\hat{Y} = -۴۰ + ۰/۷X_1 + ۱/۳X_2 - ۰/۱۵X_3$$



شکل ۱.۲: کمترین توان‌های دوم با ۲۱ مشاهده

- مدل رگرسیونی خطی برای ۱۷ مشاهده که ۴ داده‌ی پرت به صورت زیر می‌باشد و اینکه  $MSE = ۳۴/۳۷$  است.


$$\hat{Y} = -۳۷/۷ + ۰/۸X_1 + ۰/۶X_2 - ۰/۰۷X_3$$



شکل ۲.۲: کمترین توان‌های دوم با ۱۷ مشاهده

- مدل رگرسیون استوار برای ۲۱ مشاهده به صورت زیر است و  $MSE = ۸/۵$  می‌باشد.

$$\hat{Y} = -۴۱ + ۰/۸X_1 + ۰/۹X_2 - ۰/۱۲X_3$$



شکل ۳.۲: رگرسیون استوار با ۲۱ مشاهده

همان‌طور که مشاهده می‌کنیم فرق سه مدل در این است که در حالت استوار که از روش  $M$  – برآوردگر با استفاده از نرم‌افزار R و پکیج MASS استفاده شده با خطای کمتری مواجه هستیم

نسبت به دو حالت دیگر شاید در ظاهر با حذف داده‌های پرت شکل بهتر باشد اما خطای زیادی را داریم چون داده‌هایی را که از مدل حذف می‌کنیم احتمالاً داده‌های مهمی هستند که نباید آن‌ها را حذف کنیم پس بهتر است از روشی استفاده کنیم که نتیجه‌ی بهتری را در بر داشته باشد که رگرسیون استوار این مشکلات را حل می‌کند.

## فصل ۳

# سازگاری قوی M-برآوردها با خطاهای وابسته زبرجمعی منفی

با توجه به وجود داده‌ی پرت در مدل نیاز داریم که از روش بهتری برای شناسایی آن‌ها استفاده کنیم که از روش M-برآورد استفاده می‌کنیم ولی بیشتر کارهایی که انجام شده برای متغیرهای تصادفی مستقل نتایج موجود است برای متغیرهای تصادفی وابسته خصوصاً متغیرهای تصادفی وابسته NSD.

### ۱.۳ سازگاری قوی M-برآوردهای پارامترهای مدل رگرسیونی

در این بخش که از مقاله وانگ و هو (۲۰۱۵) استفاده کردیم درباره سازگاری قوی M-برآوردها<sup>۱</sup> پارامترهای رگرسیونی در مدل خطی با خطاهای تصادفی زبرجمعی منفی وابسته بحث می‌کنیم که نتیجه‌ی آن بهبود شرایط گشتاوری و تعمیم نتایج موجود برای خطاهای تصادفی مستقل است.

مدل خطی رگرسیون زیر را در نظر بگیرید

---

<sup>۱</sup>strong consistency of M-estimates

$$\mathbf{Y}_i = \mathbf{X}_i^T \boldsymbol{\beta} + e_i, \quad i = 1, 2, \dots, n \quad (1.3)$$

که در (۱.۳) بردار  $\mathbf{x}_i$  بردار  $p \times 1$  معلوم می‌باشد، پارامتر مجهول رگرسیونی،  $e_i$  بردار خطاهای تصادفی هستند.  $\hat{\boldsymbol{\beta}}_n$  یک M-برآورد برای  $\boldsymbol{\beta}$  به صورت زیر تعریف می‌شود

$$\min \sum_{i=1}^n \rho(e_i) = \min_{\boldsymbol{\beta}} \sum_{i=1}^n \rho(\mathbf{Y}_i - \mathbf{X}_i^T \boldsymbol{\beta}) \quad (2.3)$$

در رابطه (۲.۳)،  $\rho$  تابعی محدب و غیریکنوا می‌باشد، برای نمونه می‌توان به موارد زیر اشاره کرد.

• هوبر

$$\rho(x) = \left( x^2 I\{|x| \leq c\} \right) / 2 + \left( c|x| - c^2 / 2 \right) I\{|x| > c\}, \quad c > 0,$$

• چارک‌های رگرسیونی<sup>۲</sup>

$$\rho(x) = \rho_{\alpha}(x) = \alpha x I\{x > 0\} - (1 - \alpha) x I\{x \leq 0\}, \quad 0 < \alpha < 1.$$

مقدار قابل توجهی از کار مربوط به ویژگی مجانبی M-برآوردها را هوبر (۱۹۷۳) و (۱۹۸۱) بررسی کرد، سازگاری ضعیف M-برآوردها ژائو، راثو و چن (۱۹۹۳) را مورد مطالعه قرار دادند، هی و شائو (۱۹۹۶) نمایشی از بهادر قوی برای یک کلاس عمومی M-برآوردها را مورد مطالعه قرار دادند، کول و سارگالیس (۲۰۰۰) یک مرتبه بالاتر از بسط مجانبی از یک کلاس M-برآوردها از پارامتر رگرسیونی زمانی که خطاها یک میانگین متحرک با طول عمر طولانی را تشکیل می‌دهند ارائه کردند، ژائو (۲۰۰۲) سازگاری قوی M-برآوردهای پایدار از ضرایب رگرسیون تحت برخی شرایط ضعیف را مورد مطالعه قرار داد، توزیع‌های مجانبی M-برآوردها با خطاهای مرتبط با حالت فضایی را کویی و هی (۲۰۰۴) استخراج کردند، وو (۲۰۰۷) خاصیت مجانبی M-برآوردها از پارامترهای رگرسیونی با خطاهایی که وابسته هستند، ضعف و نمایش بهادر قوی از M-برآوردها و یک قضیه حد مرکزی به دست آورد، گاو، لی و لین (۲۰۰۹) حرکت مجانبی M-برآوردها از پارامتر رگرسیونی در مدل خطی هنگامی که هریک از متغیرهای تصادفی در مدل ثابت،  $\alpha$ -آمیخته شده را بررسی کردند، وو و لیو (۲۰۰۹) خواص مجانبی بازگشتی M-برآوردها در ضرایب رگرسیونی استخراج کردند، وو (۲۰۱۱) سازگاری قوی M-برآوردها برای پارامترهای رگرسیونی با خطاهای تصادفی وابسته منفی مطالعه کرد، فان (۲۰۱۲) انحراف متوسط M-برآوردها با پارامتر رگرسیونی زمانی که خطا به صورت یک دنباله مانا  $\phi$  آمیخته باشد بررسی کرد، برای اطلاعات بیشتر می‌توان به

<sup>۲</sup>Regression Quantiles

مراجع زیر مراجعه کنید M-برآوردها با مراجعه به یوهای مارونا (۱۹۷۹)، چن و لی (۱۹۸۴)، چن و وو (۱۹۸۸)، راثو و ژائو، (۱۹۹۲a,b) بای راثو وو (۱۹۹۲)، چن ژائو (۱۹۹۵، ۱۹۹۶)، میا و وو (۱۹۹۶)، ژائو و شی (۱۹۹۷)، برلاینت، لیس و وجدا (۲۰۰۰)، ژائو (۲۰۰۰)، یانگ (۲۰۰۲)، وو (۲۰۰۵، ۲۰۰۶)، ویدرز و نادراجا (۲۰۰۱۴).

در ادامه به مطالعاتی که برای همبستگی‌ها انجام شده می‌پردازیم. هو (۲۰۰۰) با ارائه مثالی نشان داد که NSD به معنای پیوند منفی نیست، همچنین برخی از خواص پایه‌ای و سه قضیه اساسی برای NSD ارائه داد و نشان داد که تعدادی از توزیع‌های چند متغیره شناخته شده دارای خاصیت NSD هستند. NA توسط آلام و ساکسنا (۱۹۹۸) مطرح و این که NA اشاره به NSD دارد، نلسن (۲۰۰۶) خاصیت وابستگی را می‌توان برای کاربرد نظریه مفصل اعمال کرد، جاورکی، دارننه و هاردله (۲۰۱۳) با دید اقتصادی به متغیرهای تصادفی NSD نگاه کردند و بیشتر تمرکزشون روی کاربرد اقتصادی قرار دادن، چریستوفیتس و واگلاتو (۲۰۰۴) متغیرهای وابسته‌ای که NSD باشند دارای خاصیت NA نیز هستند مورد بررسی قرار دادند، اقبال، امینی و بزرگنیا (۲۰۱۰) قانون قوی اعداد بزرگ برای فرم‌های درجه دوم در متغیرهای تصادفی NSD تحت این فرض که این متغیرها نامنفی هستند، و یک دنباله  $\{X_n, n \geq 1\}$  با  $EX_n^r \leq \infty$  برای هر  $n \geq 1$  و  $r \geq 1$  مطرح کردند، همچنین آن‌ها (۲۰۱۱) نامساوی کلموگروف را برای فرم‌های درجه دوم در دنباله نامنفی از متغیرهای تصادفی کراندار یکنواخت NSD ارائه دادند. شن و همکاران (۲۰۱۳) قضیه ثابت همگرایی قریب به یقین و همچنین پایداری قوی برای مقادیر وزنی از متغیرهای تصادفی NSD را مورد مطالعه قرار دادند. در این پایان نامه  $\rho$  را یک تابع محدب و غیریکنوا فرض می‌کنیم که در  $\mathbb{R}$  بامشتقات چپ و راست  $\psi_-$  و  $\psi_+$  برای هر تابع  $\psi$ ،  $u \in \mathbb{R}$  و  $\psi_-(u) \leq \psi(u) \leq \psi_+(u)$

$$S_n = \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T, \quad d_n = \max_{1 \leq i \leq n} \mathbf{x}_i^T S_n^{-1} \mathbf{x}_i \quad (۳.۳)$$

که برای هر عدد طبیعی  $n_0$ ،  $S_{n_0} > 0$  است. در رابطه با سازگاری قوی M-برآورد از  $\hat{\beta}_n$  با حداقل رساندن رابطه (۳.۳) نتیجه به صورت زیر می‌باشد

**قضیه ۱.۱.۳.** فرض کنید که  $\{e_i, i \geq 1\}$  یک دنباله از متغیرهای تصادفی مستقل و هم‌توزیع و ثابت‌های مثبت  $l_1$  و  $l_2$  وجود داشته باشد، طوری که

$$E(\rho(\mathbf{e}_i + u) - \rho(\mathbf{e}_i)) \geq l_1 u^2, \quad |u| < l_2, i \geq 1 \quad (۴.۳)$$

و

$$E|\psi_+(\mathbf{e}_i \pm \Delta)|^m \leq h_m < \infty, \quad i \geq 1, m \geq 1, \\ d_n = O(n^{-\delta}) \quad (۵.۳)$$



برای برخی از ثابت‌های مثبت  $\Delta$ ،  $h_m$  ( $m = 1, 2, \dots$ ) و  $\delta$  آن‌گاه وقتی  $n \rightarrow \infty$ ،  $\hat{\beta}_n \xrightarrow{a.s.} \beta$ .

از این‌رو برای سازگاری قوی  $\hat{\beta}$  محدودیت اعمال شده توسط شرایط گشتاوری در قضیه (۱.۱.۳) خیلی قوی است، یانگ (۲۰۰۲) نشان داد که می‌توان با جایگزین کردن شرط زیر به جای (۵.۳) نتیجه را بهبود بخشید.

$$E |\psi_+(e_i \pm \Delta)|^{1/\delta} < \infty \quad 0 < \delta \leq 1$$

برای تعمیم نتایج بالا در حالت خطاهای NSD نیاز به معرفی برخی شرایط برای توابع  $\psi$  و  $\rho$  می‌باشد:

• A۱: مقادیر ثابت مثبت  $C_0$  و  $\Delta$  وجود دارد طوری که برای هر  $\psi$ ،  $h \in (0, \Delta)$  و  $u \in \mathbb{R}$  آن‌گاه

$$\psi(u+h) - \psi(u) \leq C_0.$$

• A۲:  $E(\psi(e_1)) = 0$  و ثابت‌های مثبت  $C_1$  و  $\Delta$  وجود دارد طوری که اگر  $|u| < \Delta$  آن‌گاه

$$|E\psi(e_1 + u)| \geq C_1 |u|.$$

• A۳: برای  $0 < \delta \leq 1$

$$d_n = O(n^{-\delta}).$$

• A۴: برای  $0 < \delta < 1$

$$E |\psi(e_1)|^{1/\delta} < \infty.$$

• A۵:  $\psi(u+h) - \psi(u)$  نسبت به  $u$  یکنوا باشد یا  $|\psi(u)| \leq C_2$  برای بعضی  $C_2 > 0$ ،

$$h \in (0, \Delta) \text{ و } u \in \mathbb{R}$$

**ملاحظه ۱.۱.۳.** شرایط A۱ تا A۴ استاندارد است و اغلب آن‌ها بررسی می‌کنند M-برآوردها از مدل‌های خطی زمانی که خطاها مستقل هستند برای مثال ژائو (۲۰۰۲) شرط A۱ محدودیت و مشکلی در خانواده M-برآوردها ایجاد نمی‌کند، و برقرار است که A۱ شامل حداقل کمترین انحراف مطلق و کمترین برآورد توان‌های دوم و همگی برآورد بین آن‌ها استوارتر از دیگر برآوردها می‌باشد برای مثال ژائو و رائو (۱۹۹۲b) و ژائو (۲۰۰۲) را مطالعه کنید.

**ملاحظه ۲.۱.۳.** شرط A۵ برای توزیع کردن به خطاهای وابسته و سازگاری قوی M-برآوردها مورد نیاز است. مثال‌هایی که در زیر آورده شده شرایط A۵ برای آن‌ها برقرار است و توابع  $\psi(x)$  که در مثال‌های زیر آورده شده شرایط A۱ و A۵ برقرار است.

مثال ۱.۱.۳. برآوردگر هوبر

$$\rho(x) = \frac{(x^2 I\{|x| \leq c\})}{2} + \left(c|x| - \frac{c^2}{2}\right) I\{|x| > c\}$$

مثال ۲.۱.۳. برآوردگر کمترین توان‌های دوم<sup>۳</sup> به صورت زیر می‌باشد

$$\rho(x) = x^2.$$

که تابع  $\psi(x)$  آن به صورت زیر می‌باشد:

$$\psi(x) = 2x.$$

مثال ۳.۱.۳. برآورد کمترین انحراف مطلق<sup>۴</sup> به صورت زیر می‌باشد

$$\rho(x) = |x|.$$

که تابع  $\psi(x)$  آن به صورت زیر می‌باشد:

$$\psi(x) = \text{sign}x.$$

مثال ۴.۱.۳. رگرسیون چندکی به صورت زیر می‌باشد

$$\rho(x) = \alpha x I\{x > 0\} - (1 - \alpha)x I\{x \leq 0\}$$

قبل از این که  $\psi(x)$  را بنویسیم لازم است به این نکات توجه کنیم

$$\alpha I\{x > 0\} = \begin{cases} \alpha & x > 0 \\ 0 & o.w. \end{cases} \quad (۶.۳)$$

$$(1 - \alpha) I\{x \leq 0\} = \begin{cases} 1 - \alpha & x \leq 0 \quad 0 < \alpha < 1 \\ 0 & o.w. \end{cases} \quad (۷.۳)$$

با توجه به (۶.۳) و (۷.۳) تابع  $\psi(x)$  به صورت زیر می‌باشد

$$\psi(x) = \alpha - I\{x \leq 0\}$$

قضیه زیر توسط ژائو (۲۰۰۲) تعمیمی از قضیه یانگ (۲۰۰۲) در شرایط گشتاوری است به صورت زیر بیان شد

<sup>۳</sup>Least Squares Estimator

<sup>۴</sup>absolute deviation estimator

**قضیه ۲.۱.۳.** فرض کنید  $\{e_i, i \geq 1\}$  دنباله‌ای از متغیرهای تصادفی مستقل و هم‌توزیع و شرایط  $A1$  تا  $A4$  برقرار باشد طوری که حداقل یک  $q > 1$ ،  $E|\psi(e_1)|^q < \infty$  و  $\delta = 1$  آن‌گاه وقتی  $\hat{\beta}_n \xrightarrow{a.s.} \beta, n \rightarrow \infty$ .

وانگ و همکاران (۲۰۱۴) یک نتیجه همگرایی کامل برای آرایه‌های هر سطر از متغیرهای تصادفی NSD مطرح کردند که هدف اصلی در این بخش سازگاری قوی M-برآوردها  $\hat{\beta}_n$  برای  $\beta$  در مدل (۱.۳) با خطای NSD است که ما فرض استقلال و محدودیت شرایط گشتاوری کم می‌کنیم بنابراین قضیه زیر داریم

**قضیه ۳.۱.۳.** در مدل (۱.۳) فرض کنید  $\{e_i, i \geq 1\}$  دنباله‌ای از متغیرهای تصادفی هم‌توزیع و NSD و شرایط  $A1$  تا  $A5$  برقرار باشد، آن‌گاه وقتی  $\hat{\beta}_n \xrightarrow{a.s.} \beta, n \rightarrow \infty$

قضیه (۲.۱.۳) و شرط  $E|\psi(e_1)|^q \leq \infty$  برای برخی  $q > 1$  هم‌چنین مورد نیاز است  $\delta = 1$  و قضیه (۳.۱.۳) بدون نیاز  $E|\psi(e_1)|^q \leq \infty, q > 1$  و  $\delta = 1$  از این رو قضیه (۳.۱.۳) و تعمیم دادن قضیه (۲.۱.۳) برای خطاهای تصادفی مستقل به صورت خطاهای تصادفی NSD تحت شرایط گشتاوری ضعیف‌تر اعمال می‌کنیم در این بخش این نمادها  $C, C_0, C_1, C_2, C_3, \dots$  ثابت‌های مثبت هستند که ممکن است در جاهای مختلف متفاوت باشند،  $I(A)$  تابع نشانگر مجموعه و  $[x]$  قسمت صحیح  $x$  را نشان می‌دهد. در زیر ابتدا سه لم را آوردیم توضیح می‌دهیم و لم‌های دیگری که مورد نیاز است در فصل یک توضیح داده شده برای اثبات قضیه‌ها این فصل

**لم ۱.۱.۳.** فرض کنید که  $\{X_n, n \geq 1\}$  یک دنباله از متغیرهای تصادفی NSD باشد طوری که برای هر  $n \geq 1$ ،  $EX_n = 0$  و  $a.s., |X_n| \leq b, b > 0$ . فرض کنید  $B_n^2 = \sum_{i=1}^n EX_i^2$  آن‌گاه برای هر  $\varepsilon > 0$

$$P\left(\left|\sum_{i=1}^n X_i\right| > \varepsilon\right) \leq 2 \exp\left\{-\frac{\varepsilon^2}{2(2B_n^2 + b\varepsilon)}\right\}. \quad (۸.۳)$$

لم زیر برگرفته از شن و همکاران (۲۰۱۳) می‌باشد. برای اطلاعات بیشتر به آن مراجعه کنید.

**لم ۲.۱.۳.** فرض کنید  $\{X_n, n \geq 1\}$  یک دنباله از متغیرهای تصادفی NSD باشد، آن‌گاه

۱- اگر برای هر  $n$ ،  $EX_n = 0$  و برخی  $p$ ،  $E|X_n|^p < \infty$  که  $1 < p \leq 2$  آن‌گاه  $\sum_{i=1}^n X_i$  همگرایی قریب به یقین می‌باشد.

۲- اگر  $X_n$ ها هم‌توزیع و  $E|X_1| < \infty$  آن‌گاه وقتی  $n \rightarrow \infty$

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{a.s.} EX_1$$

**لم ۳.۱.۳.** فرض کنید  $\{X_n, n \geq 1\}$  یک دنباله از متغیرهای تصادفی NSD و  $\{a_{nk}, n \geq 1, k \geq 1\}$  یک آرایه از اعداد حقیقی باشد هم‌چنین

۱- فرض کنید  $X_n$  ها هم توزیع و  $EX_n = 0$  هم چنین  $|a_{nk}| = O(n^{-1})$   $\max_{1 \leq k \leq n} |a_{nk}|$  وقتی  $n \rightarrow \infty$  آن گاه

$$\sum_{i=1}^n a_{nk} X_k \xrightarrow{a.s.} 0. \quad (9.3)$$

۲- فرض کنید که یک ثابت  $C > 0$  وجود دارد به طوری که برای هر  $t \geq 0$  و متغیر تصادفی

$$P(|X_n| > t) \leq CP(|X| > t), X,$$

فرض کنید برای بعضی  $1 < q \leq 2$  و  $0 < \mu < 1$   $E|X|^{q, \frac{1}{\mu}} < \infty$  و به علاوه فرض کنید برای هر  $n \geq 1$  و  $k \geq 1$  که  $|a_{nk}| \leq Dk^{-\mu}$  که  $D$  یک عدد حقیقی مثبت است و این که برای بعضی از  $\nu > 0$  و هر  $n \geq 1$   $\sum_{k=1}^{\infty} |a_{nk}|^q \leq Dn^{-\nu}$  که وجود آن در بالا فرض شود بزرگتر از یک است، برای مثال  $q \in (1, 2]$  بعلاوه فرض کنید  $EX_n = 0$  آن گاه برای هر  $n$

$$T_n = \sum_{k=1}^{\infty} a_{nk} X_k \xrightarrow{a.s.} 0, \quad n \rightarrow \infty. \quad (10.3)$$

برهان. بدون این که از کلیت مساله چیزی کم شود فرض کنید برای هر  $n \geq 1, k \geq 1$   $a_{nk} \geq 0$  به علاوه فرض کنید  $\varepsilon > 0$  داده شده باشد M را طوری انتخاب کنیم که  $E|X_1| < \varepsilon$  و تعریف می کنیم

$$X'_k = -MI(X_k < -M) + X_k I(|X_k| \leq M) + MI(X_k > M)$$

هم چنین  $X''_k = X_k - X'_k$  و تعریف می کنیم

$$Y'_k = X'_k - EX'_k, \quad Y''_k = X''_k - EX''_k$$

با توجه به این که  $EY'_k = 0$  و  $Y'_k$  به طور یکنواخت دارای کران  $2M$  به صورت زیر می باشد

$$|Y'_k| = |X'_k - E(X'_k)| \leq |X'_k| + |E(X'_k)| \leq |X'_k| + E|X'_k| \leq M + M$$

هم چنین  $a_{nk}$  دارای کران مشخصی می باشد تمام این کران ها را می بریم داخل یک C ثابت و با استفاده از نابرابری ها و  $e^x \leq 1 + x + \frac{1}{2}x^2 e^{|x|}$  برای هر  $x \in \mathbb{R}$  نتیجه به صورت زیر حاصل می شود

$$\begin{aligned} E \exp \{t a_{nk} Y'_k\} &\leq 1 + E \left\{ \frac{t^2}{2} a_{nk}^2 Y_k'^2 \exp(t a_{nk} |Y'_k|) \right\} \\ &\leq 1 + \frac{Ct^2}{n^2} \exp\left(\frac{Ct}{n}\right) \\ &\leq \exp\left\{ \frac{Ct^2}{n^2} \exp\left(\frac{Ct}{n}\right) \right\} \end{aligned}$$

که رابطه آخر از  $1 + x \leq e^x$  به دست می آید برای هر  $t > 0$  با استفاده از لم‌های ۲.۳.۱ و ۳.۳.۱ فصل یک که در مورد خاصیت NSD می باشد آن گاه برای هر  $u > 0$

$$E \left\{ \sum_{i=1}^n u X_i \right\} \leq \prod_{i=1}^n E \exp \{ u X_i \} \quad (11.3)$$

با قرار دادن  $t = \frac{\nu \log n}{\varepsilon}$  و با استفاده از (۱۱.۳) و نامساوی مارکف نتیجه به صورت زیر را حاصل می شود

$$\begin{aligned} \sum_{n=1}^{\infty} P \left( \sum_{k=1}^n a_{nk} Y'_k > \varepsilon \right) &\leq \sum_{n=1}^{\infty} \frac{E \exp \{ \sum_{k=1}^n a_{nk} t Y'_k \}}{e^{t\varepsilon}} \\ &\leq \sum_{n=1}^{\infty} \frac{\prod_{k=1}^n E \exp \{ \sum_{k=1}^n a_{nk} t Y'_k \}}{e^{t\varepsilon}} \\ &\leq \sum_{n=1}^{\infty} \exp \left\{ -t\varepsilon + n \left( \frac{Ct^\nu}{n^\nu} \exp \left( \frac{Ct}{n} \right) \right) \right\} \\ &= \sum_{n=1}^{\infty} \exp \left\{ -\nu \log n + \frac{C \log n}{\varepsilon^\nu} \exp \left\{ \frac{\nu C \log n}{n\varepsilon} \right\} \right\} \\ &= \sum_{n=1}^{\infty} \exp \{ -\nu \log n + C \} \\ &\leq C \sum_{n=1}^{\infty} \exp \{ -\nu \log n \} \\ &= C \sum_{n=1}^{\infty} \exp \left( \log n^{-\nu} \right) \\ &= C \sum_{n=1}^{\infty} n^{-\nu} < \infty \end{aligned}$$

□ با استفاده از لم برل کانتلی نتیجه می شود که که نابرابری به سمت صفر میل می کند.

برهان. فرض کنیم  $N = \lfloor \frac{\nu}{\varepsilon} + 1 \rfloor$  هم چنین تعریف می کنیم

$$\begin{aligned} X_k^{(1)} &= X_k I \left( X_k > \frac{\varepsilon_k k^\mu}{ND} \right) \\ X_{nk}^{(\nu)} &= X_k I \left( a_{nk} X_k \leq n^{\frac{-\nu}{\nu q}} \right) + a_{nk}^{(-1)} n^{\frac{-\nu}{\nu q}} I \left( a_{nk} X_k > n^{\frac{-\nu}{\nu q}} \right) \\ X_{nk}^{(\nu)} &= X_k - X_k^{(1)} - X_{nk}^{(\nu)} \\ T_n^{(1)} &= \sum_{k=1}^{\infty} a_{nk} X_k^{(1)} \\ T_n^{(i)} &= \sum_{k=1}^{\infty} a_{nk} X_{nk}^{(i)} \quad i = 2, 3 \end{aligned}$$

ملاحظه می‌کنید که حاصل مجموع  $T_n$  به صورت زیر حاصل می‌شود

$$T_n = T_n^{(1)} + T_n^{(2)} + T_n^{(3)}$$

$$\begin{aligned} T_n = T_n^{(1)} + T_n^{(2)} + T_n^{(3)} &= \sum_{k=1}^{\infty} a_{nk} X_k^{(1)} + \sum_{k=1}^{\infty} a_{nk} X_{nk}^{(2)} + \sum_{k=1}^{\infty} a_{nk} X_{nk}^{(3)} \\ &= \sum_{k=1}^{\infty} a_{nk} X_k^{(1)} + \sum_{k=1}^{\infty} a_{nk} X_{nk}^{(2)} + \sum_{k=1}^{\infty} a_{nk} (X_k - X_{nk}^{(1)} - X_{nk}^{(2)}) \end{aligned}$$

که بعد از ساده کردن نتیجه به صورت زیر حاصل می‌شود

$$T_n = \sum_{k=1}^{\infty} a_{nk} X_k$$

می‌توان نشان داد که  $\sum_{k=1}^{\infty} P(|X| > \frac{k^\mu \varepsilon}{ND}) < \infty$  برای هر  $\varepsilon > 0$  و  $E|X|^\mu < \infty$  بنابراین  $\varepsilon$  وابسته به  $k$  وجود دارد که با وقتی  $\varepsilon_k \downarrow 0$ ، مجموعه‌ی احتمال  $\sum_{k=1}^{\infty} P(|X_k| > \frac{k^\mu \varepsilon_k}{ND})$  متناهی می‌شود که با استفاده از لم برل کانتلی آن‌گاه

$$P\left(|X_k| > \frac{k^\mu \varepsilon_k}{ND}, \quad i.o.\right) = 0$$

با توجه به این که رابطه‌ی بالا همیشه رخ نمی‌دهد مگر در تعداد خیلی متناهی رخ دهد که رابطه‌ی زیر با بالا متناظر است پس در تعداد انگشت شماری رخ می‌دهد یعنی برای  $k$  خیلی محدودی رخ می‌دهد، بنابراین برای هر  $t > 0$

$$\sum_{k=1}^{\infty} |X_k|^t I\left(|X_k| > \frac{k^\mu \varepsilon_k}{ND}\right) < \infty \quad a.s. \quad (12.3)$$

سپس با استفاده از نامساوی کوشی شوارتز و به ازای  $q \in (0, 2)$  متناهی است بنابراین ضریب  $C$  را طوری انتخاب می‌کنیم که رابطه‌ی زیر برقرار باشد

$$\sum_{k=1}^{\infty} a_{nk}^2 \leq C \sum_{k=1}^{\infty} |a_{nk}|^q$$

آن‌گاه به ازای هر  $t$  مثبتی رابطه‌ی (۱۲.۳) متناهی است، آن‌گاه نامساوی آخر به سمت صفر میل می‌کند.

$$\begin{aligned} 0 \leq T_n^{(1)} &= \sum_{k=1}^{\infty} a_{nk} X_k^{(1)} \leq \left(\sum_{k=1}^{\infty} a_{nk}^2\right)^{\frac{1}{2}} \left(\sum_{k=1}^{\infty} X_k^2 I\left(X_k > \frac{k^\mu \varepsilon_k}{ND}\right)\right)^{\frac{1}{2}} \\ &\leq C \left(\sum_{k=1}^{\infty} |a_{nk}|^q\right)^{\frac{1}{q}} \left(\sum_{k=1}^{\infty} X_k^2 I\left(X_k > \frac{k^\mu \varepsilon_k}{ND}\right)\right)^{\frac{1}{2}} \quad (13.3) \\ &\leq C n^{-\frac{\nu}{2}} \left(\sum_{k=1}^{\infty} X_k^2 I\left(X_k > \frac{k^\mu \varepsilon_k}{ND}\right)\right)^{\frac{1}{2}} \rightarrow 0 \quad a.s. \end{aligned}$$

با در نظر گرفتن  $Y_{nk}$  برابر  $n^{\frac{\nu}{q}} a_{nk} X_{nk}^2$  داریم

$$Y_{nk} = n^{\frac{\nu}{q}} a_{nk} X_k I \left\{ a_{nk} \leq n^{-\frac{\nu}{q}} \right\} + I \left\{ a_{nk} X_k > n^{-\frac{\nu}{q}} \right\}$$

با توجه به این که  $Y_{nk}$  یک تابع صعودی از  $X_k$  است، لم ۲.۳.۱ و برای هر ثابت  $n \geq 1$ ،  $\{Y_{nk}, k \geq 1\}$  یک دنباله از متغیرهای تصادفی NSD است، چون  $X_k$ ، NSD و اگر  $f_1, f_2, \dots, f_n$  نازولی باشد، آن گاه  $f_1(X_1), f_2(X_2), \dots, f_n(X_n)$  NSD است بنابراین  $Y_{nk}$ ، NSD است. با استفاده از نابرابری  $e^y \leq 1 + 2|y|^q$  برای هر  $y \leq 1$  و  $0 < q \leq 1$  نتیجه می شود

$$E \exp(Y_{nk}) \leq 1 + 2E|Y_{nk}|^q \leq \exp(2E|Y_{nk}|^q).$$

توجه داشته باشید  $Y_{nk} \leq 1$  و  $EY_{nk} \leq 1$  وقتی  $1 < q \leq 2$  که براساس این نامساوی  $e^y \leq 1 + y + |y|^q$  برای  $y \leq 1$  و  $1 < q \leq 2$  نتیجه می شود که

$$\begin{aligned} E \exp(Y_{nk}) &\leq 1 + EY_{nk} + E|Y_{nk}|^q \\ &\leq 1 + 1 + E|Y_{nk}|^q \\ &\leq 1 + \exp\{E|Y_{nk}|^q\} \\ &\leq 2 \exp(E|Y_{nk}|^q) \\ &\leq 2 \exp(2E|Y_{nk}|^q). \end{aligned}$$

بنابراین برای  $0 < q \leq 2$  داریم

$$E \exp(Y_{nk}) \leq 2 \exp(2E|Y_{nk}|^q). \quad (14.3)$$

با توجه به اینکه  $X_{nk}^{(\nu)} \leq X_k$ ، هم چنین  $E|X_{nk}^{(\nu)}|^q \leq E|X_k|^q \leq CE|X|^q$  بنابراین با استفاده از شرایط لم ۱.۱.۱ که دنباله ای نامنفی از متغیرهای تصادفی می باشد،  $\exp$  با هر توانی نامنفی می باشد سپس از لم ۱.۱.۱ و (۱۱.۳) که در مورد خاصیت NSD می باشد، هم چنین (۱۴.۳) داریم آن گاه نتیجه به صورت زیر حاصل می شود

$$\begin{aligned} E \exp\left(n^{\frac{\nu}{q}} T_n^{(\nu)}\right) &= E \exp\left(n^{\frac{\nu}{q}} \sum_{k=1}^{\infty} a_{nk} X_{nk}^{(\nu)}\right) \\ &= E \liminf \exp\left(\sum_{k=1}^m Y_{nk}\right) \\ &\leq \liminf_{m \rightarrow \infty} \prod_{k=1}^m E \exp(Y_{nk}) \\ &\leq \liminf_{m \rightarrow \infty} 2 \exp\left(2Cn^{\frac{\nu}{q}} \sum_{k=1}^m |a_{nk}|^q E|X|^q\right) \\ &\leq 2 \exp\left(Cn^{\frac{\nu}{q}} . n^{-\nu}\right) \leq C. \end{aligned}$$

با توجه به این که  $\sum_{n=1}^{\infty} P(T_n^{(\nu)} \geq \varepsilon) \leq C \sum_{n=1}^{\infty} \exp(-n^{\frac{\nu}{q}} \varepsilon)$  چون سری متناهی است زیرا  $\sum_{n=1}^{\infty} \frac{1}{\exp n^\alpha}$  یک سری همگراست پس در نتیجه  $C \sum_{n=1}^{\infty} \frac{1}{\exp n^\alpha}$  یک سری همگرا و متناهی است آن گاه به ازای هر  $\varepsilon > 0$  رابطه‌ی زیر برقرار است

$$\sum_{n=1}^{\infty} P(T_n^{(\nu)} \geq \varepsilon) \leq \sum_{n=1}^{\infty} \exp(-n^{\frac{\nu}{q}} \varepsilon) E \exp(n^{\frac{\nu}{q}} T_n^{(\nu)}) \leq \infty$$

با استفاده از لم برل کانتلی نتیجه می‌شود برای هر  $\varepsilon > 0$

$$P\left(\limsup_{n \rightarrow \infty} T_n^{(\nu)} > \varepsilon\right) \leq P\left(T_n^{(\nu)} \geq \varepsilon, i.o.\right) = 0$$

بنابراین

$$\limsup_{n \rightarrow \infty} T_n^{(\nu)} \leq 0 \quad a.s. \quad (15.3)$$

یک عدد صحیح ثابت  $k$  را انتخاب می‌کنیم به طوری که  $\varepsilon_k < \frac{\varepsilon}{4}$  برای هر  $k > K$  از این شرط وجود دارد به ازای  $n \geq n_0$ ،  $\sum_{k=1}^{\infty} |a_{nk}|^q \leq Dn^{-\nu}$

$$\sum_{k=1}^K a_{nk} X_{nk}^{(\nu)} \leq (Dn^{-\nu})^{\frac{1}{q}} \sum_{k=1}^K \frac{\varepsilon_k}{ND} k^\mu < \frac{\varepsilon}{4}$$

برای هر  $n > n_0$  فرض کنید

$$D_n = \left\{ k \mid k > K, a_{nk} X_k \geq n^{\frac{\nu}{q}} \right\}$$

باید به این نکته توجه کنیم که برای ثابت  $n$ ،  $\sum_{k=1}^{\infty} a_{nk}^q E |X_k|^q < \infty$  و  $0 < q \leq 2$  و  $EX_k = 0$  برای  $1 < q \leq 2$  با استفاده از لم ۲.۱.۳ و قضیه (۲.۱۲.۲) از استوت (۱۹۷۴)، به دست می‌آید که  $T_n$  ها همگی متناهی و همگرای قریب به یقین هستند در نتیجه از آنجا که  $a.s. |T_n| < \infty$  هستند، بنابراین  $D_n$  یک مجموعه متناهی با احتمال یک هستند، تعدادی از عناصر  $d_n$  در  $D_n$  مشخص می‌کند بنابراین

$$\sum_{k=K+1}^{\infty} a_{nk} X_{nk}^{(\nu)} \leq \sum_{k \in D_n} Dk^{-\mu} \frac{k^\mu \varepsilon_k}{ND} \leq d_n \frac{\varepsilon}{2N}$$

بنابراین  $\sum_{k=K+1}^{\infty} a_{nk} X_{nk}^{(\nu)} \geq \frac{\varepsilon}{4}$  اشاره دارد که  $d_n \geq N$  ازین رو با توجه به این رابطه  $P(Y > \frac{\varepsilon}{4}) + P(X > \frac{\varepsilon}{4})$  و معادل این  $P(X + Y > \varepsilon) \leq P(X > \frac{\varepsilon}{4}) + P(Y > \frac{\varepsilon}{4})$ ، نامتناهی هستند پس ما قسمت اول نامساوی را در نظر می‌گیریم که نتیجه به صورت زیر حاصل می‌شود

$$P\left(T_n^{(\nu)} \geq \varepsilon\right) \leq P\left(\sum_k a_{nk} X_{nk}^{(\nu)} \geq \frac{\varepsilon}{4}\right)$$



سپس تعداد متناهی N وجود دارد با توجه به خاصیت NSD و احتمال توام کمتر مساوی حاصلضرب هم‌چنین با توجه به رابطه‌ی  $P(X_k > \varepsilon) \leq CP(X > \varepsilon)$  و نامساوی مارکف و متناهی بودن عبارت  $\sum_{n=1}^{\infty} a_{nk}^q \leq Dn^{-\nu}$  آن‌گاه نتایج به صورت زیر حاصل می‌شود

$$\begin{aligned} P\left(T_n^{(r)} \geq \varepsilon\right) &\leq P\left(\sum_k^K a_{nk} X_{nk}^{(r)} \geq \frac{\varepsilon}{r}\right) \\ &\leq P\left\{k > K, X_k > a_{nk}^{-1} n^{\frac{-\nu}{r}}\right\} \\ &\leq \sum_{1 \leq k_1 < k_2 < \dots < k_N \leq n} P\left(X_{k_1} > a_{nk_1}^{-1} n^{\frac{-\nu}{r}}, \dots, X_{k_N} > a_{nk_N}^{-1} n^{\frac{-\nu}{r}}\right) \\ &\leq \sum_{1 \leq k_1 < k_2 < \dots < k_N \leq n} \prod_{i=1}^N P\left(|X_{k_i}| > a_{nk_i}^{-1} n^{\frac{-\nu}{r}}\right) \\ &\leq \left(C \sum_{k=1}^n P\left(|X| > a_{nk}^{-1} n^{\frac{-\nu}{r}}\right)\right)^N \\ &\leq C \left(\sum_{k=1}^n a_{nk}^q n^{\frac{\nu}{r}} E|X|^q\right)^N \end{aligned}$$

از متناهی بودن رابطه‌ی  $\sum_{n=1}^{\infty} a_{nk}^q \leq Dn^{-\nu}$  نتیجه می‌شود

$$\sum_{n=1}^{\infty} a_{nk}^q n^{\frac{\nu}{r}} \leq Dn^{-\nu} n^{\frac{\nu}{r}} = Dn^{\frac{-\nu}{r}} \leq Cn^{\frac{-N\nu}{r}}.$$

با انتخاب N،  $\frac{N\nu}{r}$  بنابراین برای هر  $\varepsilon > 0$ ، آن‌گاه

$$\sum_{n=1}^{\infty} P\left(T_n^{(r)} \geq \varepsilon\right) < \infty$$

با توجه به لم برل کانتلی آن‌گاه نتیجه به صورت زیر حاصل می‌شود

$$\sum_{n=1}^{\infty} P\left(T_n^{(r)} \geq \varepsilon\right) = 0$$

□

### اثبات نتیجه‌ی اصلی

براساس لم‌ها و قضیه‌هایی که تا اینجا داشتیم سراغ اثبات نتیجه‌ی اصلی می‌رویم

برهان. قضیه (۳.۱.۳) فرض کنید  $\mathbf{x}_{ni} = S_n^{-\frac{1}{r}} \mathbf{x}_i$  و  $\beta_n = S_n^{\frac{1}{r}} \beta$  و اینکه  $\hat{\beta}_n^* = S_n^{\frac{1}{r}} \hat{\beta}_n$  آن‌گاه

$$\sum_{i=1}^n \mathbf{x}_{ni} \mathbf{x}_{ni}^T = I_p, \quad \sum_{i=1}^n \|\mathbf{x}_{ni}\|^2 = p, \quad d_n = \max_{1 \leq i \leq n} \|\mathbf{x}_{ni}\|^2 \quad (۱۶.۳)$$

که  $I_p$  یک ماتریس همانی  $p \times p$  و  $\|\cdot\|$  یک اندازه اقلیدوسی روی  $\mathbb{R}^p$  می‌باشد، که در این صورت می‌توانیم مدل (۱.۳) را به فرم زیر بازنویسی کنیم

$$Y_i = \mathbf{x}_{ni}^\top \beta_n + e_i, \quad i = 1, 2, \dots, n \quad (17.3)$$

آن‌گاه مجموع باقیمانده‌ها به صورت زیر می‌باشد

$$\sum_{i=1}^n \rho(Y_i - \mathbf{x}_{ni}^\top \hat{\beta}_n^*) = \min_{\beta} \sum_{i=1}^n \rho(Y_i - \mathbf{x}_{ni}^\top \hat{\beta}) \quad (18.3)$$

فرض کنید در مدل (۱.۳)  $\beta = \circ$  و در مدل (۱۷.۳)،  $\beta_n = \circ$  و اینکه  $u$  گوی واحد،  $\{\beta : \beta \in \mathbb{R}^p, \|\beta\| = 1\}$ ، که این پیروی می‌کند از شرط  $A^3$  که  $d_n \leq C_3 n^{-\delta}$  فرض کنید برای هر ثابت  $\varepsilon > \circ$  داده شده باشد، بدون از دست دادن کلیت مساله می‌توان فرض کرد  $\Delta < 2C_3\varepsilon$ ، تعریف می‌کنیم قبل از اینکه تعریف اصلی را بنویسیم احتیاج است به نکات زیر توجه کنیم

$$\begin{aligned} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma} \{\psi(e_i + t) - \psi(e_i)\} dt &= \sum_{i=1}^n \left\{ \rho(e_i + \omega_{ni}^\top \gamma) - \rho(e_i) \right\} - \sum_{i=1}^n \psi(e_i) \omega_{ni}^\top \gamma \\ &= \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma} \{\psi(e_i + t) - \psi(e_i)\} dt + \sum_{i=1}^n \psi(e_i) \omega_{ni}^\top \gamma \end{aligned}$$

آن‌گاه داریم

$$\begin{aligned} D_n(\beta) &= \sum_{i=1}^n \left\{ \rho(e_i - \mathbf{x}_{ni}^\top \beta) - \rho(e_i) \right\}, \quad \beta \in \mathbb{R}^p \\ D_n(\varepsilon n^{\frac{\delta}{\nu}} \gamma) &= \sum_{i=1}^n \left\{ \rho(e_i - \varepsilon n^{\frac{\delta}{\nu}} \mathbf{x}_{ni}^\top \gamma) - \rho(e_i) \right\} \\ &= \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma} \{\psi(e_i + t) - \psi(e_i)\} dt + \sum_{i=1}^n \omega_{ni}^\top \gamma \psi(e_i) \\ &= I_{1n}(\gamma) + I_{2n}(\gamma) \end{aligned}$$

جایی که  $\omega_{ni} = -\varepsilon n^{\frac{\delta}{\nu}} \mathbf{x}_{ni}$  و  $\gamma \in U$  هم‌چنین با توجه به افراز  $D_n(\varepsilon n^{\frac{\delta}{\nu}} \gamma)$  به مجموع دو تابع  $I_{1n}(\gamma)$  و  $I_{2n}(\gamma)$  و اینکه  $\sup | -I_{2n}(\gamma) | \leq \sup -I_{2n}(\gamma)$  آن‌گاه

$$\begin{aligned} \inf_{\gamma \in U} D_n(\varepsilon n^{\frac{\delta}{\nu}} \gamma) &\geq \inf_{\gamma \in U} I_{1n}(\gamma) + \inf_{\gamma \in U} I_{2n}(\gamma) \\ &= \inf_{\gamma \in U} I_{1n}(\gamma) - \sup_{\gamma \in U} -I_{2n}(\gamma) \\ &\geq \inf_{\gamma \in U} I_{1n}(\gamma) - \sup | I_{2n}(\gamma) | \end{aligned} \quad (19.3)$$

را به  $N$  بخش تقسیم می‌کنیم،  $U_1, U_2, \dots, U_N$  بنابراین قطر هر بخش کم می‌شود، سپس  $n^{-2}$  و  $N \leq (2n^2 + 1)^p$  قرار می‌گیرد، هم‌چنین فرض کنید  $T_j$  کوچکترین مجموعه محدب بسته  $U_j$  باشند که برای ثابت  $T_j$  سه مورد ذکر شده در یک همسایگی بسته تابع مقادیر  $\sup$  و

$\inf$  خود را اختیار می‌کند، و قسمت اول نامساوی که درباره‌ی  $\inf$  است چون بزرگتر مساوی صفر قرار می‌گیرد بنابراین دارای  $\inf$  می‌باشد و برای نامساوی بعدی هم  $\inf$  تبدیل شده  $\sup$  که بصورت زیر می‌باشد

• برای هر  $\gamma \in T_j$  اگر  $\omega_{ni}^T \gamma \geq 0$  وجود دارد  $\gamma_{ij} \in T_j$  طوری که

$$\omega_{ni}^T \gamma_{ij} = \inf \{ \omega_{ni}^T \gamma : \gamma \in T_j \}$$

• برای هر  $\gamma \in T_j$  اگر  $\omega_{ni}^T \gamma \leq 0$  وجود دارد  $\gamma_{ij} \in T_j$  طوری که

$$\omega_{ni}^T \gamma_{ij} = \sup \{ \omega_{ni}^T \gamma : \gamma \in T_j \}$$

• اگر  $\omega_{ni}^T \gamma_1 > 0$  برای  $\gamma_1 \in T_j$  و  $\omega_{ni}^T \gamma_2 < 0$  برای  $\gamma_2 \in T_j$  بنابراین وجود دارد  $\gamma_{ij} \in T_j$  طوری که

$$\sqrt{\gamma_1} \in T_j \quad \exists \quad \omega_{ni}^T \gamma_1 > 0 \implies \inf \{ \omega_{ni}^T \gamma, \gamma \in T_j \} = \omega_{ni}^T \gamma_{ij}$$

$$\sqrt{\gamma_2} \in T_j \quad \exists \quad \omega_{ni}^T \gamma_2 < 0 \implies \sup \{ \omega_{ni}^T \gamma, \gamma \in T_j \} = \omega_{ni}^T \gamma_{ij}$$

که با تبدیل کردن  $\sup$  به  $\inf$  برابر  $-\omega_{ni}^T \gamma_{ij}$  هم‌چنین از حاصل  $\sup + \inf$  نتیجه به صورت زیر حاصل می‌شود

$$\omega_{ni}^T \gamma_{ij} = 0$$

بنابراین تعریف می‌کنیم

$$G(t) = E\psi(e_i + t), \quad \Psi_i(t) = \psi(e_i + t) - \psi(e_i) - G(t), \quad t \in \mathbb{R}$$

با در نظر گرفتن یکنوایی  $\psi$  و اینکه  $1 \leq j \leq N$  و  $T_j$  کوچکترین مجموعه‌ی محدب بسته‌ی  $U$  می‌باشد و اجتماع  $T_j$  که  $U_1, U_2, \dots, U_N$  می‌باشد، پوشش بزرگتری برای  $U$  می‌باشد که در این صورت  $U \subseteq T_j$  یا  $U \subseteq \bigcup_j T_j$  هم‌چنین از طرفین  $\inf$  بگیریم نتایج به صورت زیر حاصل می‌شود

$$\begin{aligned} \inf_{\gamma \in U} I_{\lambda_n}(\gamma) &\geq \inf_{1 \leq j \leq N} \inf_{\gamma \in T_j} I_{\lambda_n}(\gamma) \\ &\geq \inf_{1 \leq j \leq N} \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} \{ \psi(e_i + t) - \psi(e_i) \} dt \\ &= \inf_{1 \leq j \leq N} \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt \left\{ \frac{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt + \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} \Psi_i(t) dt}{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt} \right\} \\ &= \inf_{1 \leq j \leq N} \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt \left\{ 1 + \frac{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} \Psi_i(t) dt}{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt} \right\} \\ &\geq \inf_{1 \leq j \leq N} \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt \left\{ 1 - \frac{\left| \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} \Psi_i(t) dt \right|}{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt} \right\} \end{aligned}$$

(۲۰.۳)

که در آخرین نامساوی (۲۰.۳) از ژائو (۲۰۰۰، p. ۱۴۲۵) است، فرض کنید  $\gamma_{ij} \in T_j$  و  $\gamma \in U_j$  باشد، با استفاده از (۱۶.۳) و تعاریفی که از  $T_j$  و  $U_j$  شده است برای  $n$  به اندازه کافی بزرگ داریم

$$\begin{aligned} \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma)^2 - \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma_{ij})^2 &\leq \left| \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma_{ij})^2 - \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma)^2 \right| \\ &= \left| \sum_{i=1}^n \gamma_{ij}^\top \mathbf{x}_{ni} \mathbf{x}_{ni}^\top \gamma_{ij} - \sum_{i=1}^n \gamma^\top \mathbf{x}_{ni} \mathbf{x}_{ni}^\top \gamma \right| \\ &= \left| \sum_{i=1}^n (\gamma_{ij} - \gamma)^\top \mathbf{x}_{ni} \mathbf{x}_{ni}^\top (\gamma_{ij} + \gamma) \right| \\ &\leq \sum_{i=1}^n \|\gamma_{ij} - \gamma\| \|\mathbf{x}_{ni}\|^2 (\|\gamma_{ij} - \gamma\| + 2\|\gamma\|) \\ &\leq \sum_{i=1}^n n^{-2} (n^{-2} + 2) \|\mathbf{x}_{ni}\|^2 \\ &\leq 3pn^{-2} \\ &< \frac{1}{4}. \end{aligned} \quad (21.3)$$

سپس برای  $1 < j \leq N$  و  $n$ های به اندازهی کافی بزرگ بدست می‌آوریم

$$\begin{aligned} \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma)^2 - \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma_{ij})^2 &\leq \frac{1}{4} \\ \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma_{ij})^2 &\geq \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma)^2 - \frac{1}{4} \\ &= \gamma^\top \left( \sum_{i=1}^n \mathbf{x}_{ni} \mathbf{x}_{ni}^\top \right) \gamma - \frac{1}{4} \\ &= \|\gamma\| - \frac{1}{4} \\ &= 1 - \frac{1}{4} \\ &= \frac{3}{4} \end{aligned} \quad (22.3)$$

با استفاده از (۱۳.۳) و انتخاب  $\varepsilon$  با توجه به اینکه  $d_n = \|\mathbf{x}_{ni}\|^2$  و  $\mathbf{x}_{ni} = S_n^{-1} \mathbf{x}_i$  آن‌گاه

$$d_n = \mathbf{x}_{ni}^\top S_n^{-1} \mathbf{x}_i = \mathbf{x}_i^\top \left( S_n^{-1} \right)^\top S_n^{-1} \mathbf{x}_i$$

چون که  $d_n = o(n^{-\delta})$  و  $\mathbf{x}_{ni}^\top$  از مرتبه  $o(n^{-\frac{\delta}{2}})$  می‌باشد بنابراین  $\mathbf{x}_{ni}^\top = o(n^{-\frac{\delta}{2}})$  که رابطه به صورت زیر قرار می‌گیرد

$$\mathbf{x}_i^\top S_n^{-1} \mathbf{x}_i \leq d_n = o(n^{-\delta})$$

مقدمات بالا برای برقراری نامساوی زیر لازم است

$$|\omega_{ni}^\top \gamma_{ij}| = |\varepsilon n^{\frac{\delta}{2}} \mathbf{x}_{ni}^\top \gamma_{ij}| \leq C_3 \varepsilon \|\gamma_{ij}\| \leq C_3 \varepsilon (1 + n^{-2}) < 2C_3 \varepsilon < \Delta \quad (23.3)$$

برای  $n$  های به اندازه کافی بزرگ و برای  $i = 1, 2, \dots, n$  هم‌چنین  $j = 1, 2, \dots, N$  با شرط  $A_2$  و (۲۲.۳) نتیجه به صورت زیر می‌باشد

$$\begin{aligned} \inf_{1 \leq j \leq N} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt &\geq \inf_{1 \leq j \leq N} C_1 \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} t dt \\ &= \inf_{1 \leq j \leq N} \frac{C_1 \varepsilon^2 n^\delta}{2} \sum_{i=1}^n \left( \mathbf{x}_{ni}^\top \gamma_{ij} \right)^2 \\ &\geq \frac{C_1 \varepsilon^2 n^\delta}{4} \end{aligned}$$

مجموعه  $Y_{ni}^{(j)} = \int_0^{\omega_{ni}^\top \gamma_{ij}} \Psi_i(t) dt$  برای  $1 \leq j \leq N$  آن‌گاه تعریف می‌کنیم

$$\begin{aligned} |Y_{ni}^{(j)}| &= \left| \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - \psi(e_i) - G(t)) dt \right| \\ &= \left| \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - \psi(e_i) - E\psi(e_i + t)) dt \right| \end{aligned} \quad (24.3)$$

هم‌چنین با توجه به (۲۴.۳) و رابطه  $\int (X - E(X)) dt$  که اگر  $X < C_0$  آن‌گاه  $X - E(X) < 2C_0$  می‌باشد و با توجه به کران‌هایی که دارند نامساوی‌هایی که در ادامه به بحث در درباره آن‌هایی می‌پردازیم برقرار است

• اگر  $\psi(e_i + t) - \psi(e_i)$  در  $e_i$  یکنوا باشد، و همچنین  $Y_{ni}^{(j)}$  در  $e_i$  برای  $1 \leq j \leq N$  نیز یکنوا باشد. بنابراین با شرط  $A_1$  و (۲۳.۳) یکی نتیجه به صورت زیر می‌باشد

$$|Y_{ni}^{(j)}| \leq 2C_0 |\omega_{ni}^\top \gamma_{ij}| < 2C_0 \cdot 2C_3 \varepsilon = 4C_0 C_3 \varepsilon = C_4$$

برای  $1 \leq j \leq N$  با توجه به قضیه ۹.۲ گات و شرط  $A_1$  چون عبارت نامنفی و انتگرال‌پذیر است نامساوی‌ها را به صورت زیر تعریف می‌کنیم

$$\begin{aligned} \sum_{i=1}^n \text{var} \left( Y_{ni}^{(j)} \right) &\leq \sum_{i=1}^n E \left\{ \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - \psi(e_i)) dt \right\}^2 \\ &= \sum_{i=1}^n E \left[ \left\{ \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - \psi(e_i)) dt \right\} \left\{ \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - \psi(e_i)) dt \right\} \right] \\ &\leq C_0 \sum_{i=1}^n |\omega_{ni}^\top \gamma_{ij}| \int_0^{\omega_{ni}^\top \gamma_{ij}} E\psi(e_i + t) - E\psi(e_i) dt \\ &= C_0 \sum_{i=1}^n |\omega_{ni}^\top \gamma_{ij}| \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \\ &\leq \frac{C_4}{2} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \end{aligned}$$

و پیشامد  $A_n$  را بصورت زیر تعریف می‌کنیم

$$A_n = \left\{ \sup_{1 \leq j \leq N} \frac{\left| \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} \Psi_i(t) dt \right|}{\sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt} \geq \frac{1}{2} \right\}$$

از  $N \leq (2n^2 + 1)^p$  و لم ۱.۱.۳ نتیجه می‌شود

$$\begin{aligned}
 P(A_n) &\leq \sum_{j=1}^N P \left( \left| \sum_{i=1}^n Y_{ni}^{(j)} \right| \geq \frac{1}{4} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right) \\
 &\leq 2 \sum_{j=1}^N \exp \left\{ - \frac{\frac{1}{4} \left( \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right)^2}{2 \left( 2 \times \frac{C_\epsilon}{4} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt + C_\epsilon \times \frac{1}{4} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right)} \right\} \\
 &= 2 \sum_{j=1}^N \exp \left\{ - \frac{1}{12 C_\epsilon} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right\} \\
 &\leq 2 (2n^2 + 1)^p \exp(-C_\delta n^\delta)
 \end{aligned} \tag{۲۵.۳}$$

• حالت دیگر این است زمانی که  $|\psi(x)| \leq C_\psi$  و اینکه

$$\begin{aligned}
 Y_{ni}^{(j)} &= \int_0^{\omega_{ni}^\top \gamma_{ij}} (\psi(e_i + t) - E\psi(e_i + t)) dt - \int_0^{\omega_{ni}^\top \gamma_{ij}} \psi(e_i) dt \\
 &= Y_{ni1}^{(j)} - Y_{ni2}^{(j)}
 \end{aligned}$$

توجه داشته باشید  $Y_{ni1}^{(j)}$  و  $Y_{ni2}^{(j)}$  در  $e_i$  یکنوا برای  $1 \leq j \leq N$  آن‌گاه مشاهده می‌کنیم

$$\begin{aligned}
 |Y_{ni1}^{(j)}| &\leq 2C_\psi |\omega_{ni}^\top \gamma_{ij}| \leq 4C_\psi C_\gamma \varepsilon = C_\gamma^\top, \quad l = 1, 2 \\
 \sum_{i=1}^n \text{var}(Y_{ni1}^{(j)}) &\leq \sum_{i=1}^n 4C_\psi^2 (\omega_{ni}^\top \gamma_{ij})^2 \\
 &\leq 4C_\psi^2 \varepsilon^2 n^\delta \sum_{i=1}^n (\mathbf{x}_{ni}^\top \gamma_{ij})^2 \\
 &\leq 4C_\psi^2 \varepsilon^2 n^\delta (n^{-2} + 1)^2 \\
 &\leq C \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt.
 \end{aligned}$$

به طور مشابه از اثبات (۲۵.۳) می‌توانیم نشان دهیم

$$\begin{aligned}
 P(A_n) &\leq \sum_{j=1}^N P \left( \left| \sum_{i=1}^n Y_{ni1}^{(j)} \right| \geq \frac{1}{4} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right) \\
 &\quad + \sum_{j=1}^N P \left( \left| \sum_{i=1}^n Y_{ni2}^{(j)} \right| \geq \frac{1}{4} \sum_{i=1}^n \int_0^{\omega_{ni}^\top \gamma_{ij}} G(t) dt \right) \\
 &\leq 4 (2n^2 + 1)^p \exp(-C'_\delta n^\delta).
 \end{aligned}$$

بدین ترتیب  $\sum_{i=1}^n P(A_n) < \infty$  با استفاده از لم بورل کانتلی نتیجه می‌شود که

$P(A_n, i.o.) = 0$ ، از این رو با احتمال یک برای  $n$  های به اندازه کافی بزرگ داریم

$$\sup_{1 \leq j \leq N} \frac{\left| \sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} \Psi_i(t) dt \right|}{\sum_{i=1}^n \int_0^{\omega_{ni}^T \gamma_{ij}} G(t) dt} < \frac{1}{2}$$

با توجه به رابطه‌ی (۲۰.۳) با احتمال یک برای  $n$  های به اندازه‌ی کافی بزرگ آن گاه

$$\inf_{\gamma \in U} I_n(\gamma) \geq \frac{C_1 \varepsilon^2 n^\delta}{\lambda} \quad (26.3)$$

اکنون ما از تعاریف زیر استفاده خواهیم کرد

$$\mathbf{x}_{ni} = \begin{pmatrix} x_{ni1} \\ x_{ni2} \\ \vdots \\ x_{nip} \end{pmatrix} \quad \gamma = \begin{pmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_p \end{pmatrix} \quad a_{ni} = \begin{cases} \frac{x_{nik}}{n^{\frac{\delta}{p}}} & 1 \leq i \leq n \quad k = 1, 2, \dots, p \\ 0 & i \geq n \end{cases}$$

ترکیب (۱۶.۳) و (۵.۳) و با ثابت  $k = 1, 2, \dots, p$  و  $|x_{nik}| \leq \|\mathbf{x}_{ni}\| \leq d_n^{\frac{1}{p}} \leq \sqrt{C_3 n^{-\delta}}$ ، اینک  $\sum_{i=1}^n x_{nik}^2 = 1$  می‌بینیم که

$$|a_{ni}| \leq \sqrt{C_3} n^{-\delta}, \quad n \geq 1 \quad (27.3)$$

برای  $\delta = 1$  توسط قسمت اول از ۳.۱.۳ و (۲۷.۳)  $e_i$  ها NSD هستند و اینک تابع  $\psi$  یکنوا می‌باشد پس  $\psi(e_i)$  نیز NSD می‌باشد بنابراین شرایط (۹.۳) برقرار است که نتیجه به صورت زیر حاصل می‌شود

$$n^{-\frac{1}{p}} \sum_{i=1}^n x_{nik} \psi(e_i) = \sum_{i=1}^n a_{ni} \psi(e_i) \rightarrow 0 \quad a.s.$$

و برای  $\delta \leq \frac{1}{p}$  نتیجه به صورت زیر حاصل می‌شود

$$\sum_{i=1}^n a_{ni}^2 = \frac{1}{n^\delta} \sum_{i=1}^n x_{nik}^2 = n^{-\delta} \quad (28.3)$$

برای  $\frac{1}{p} < \delta < 1$  و اینک از نامساوی کوشی شوارتز استفاده می‌کنیم نتیجه به صورت زیر حاصل می‌شود

$$\sum_{i=1}^n |a_{ni}|^{\frac{1}{\delta}} = \frac{1}{n^{\frac{\delta}{p}}} \sum_{i=1}^n |x_{nik}|^{\frac{1}{\delta}} \leq n^{\frac{1}{p}} \left( \frac{1}{n} \sum_{i=1}^n x_{nik}^2 \right)^{\frac{1}{\delta}} = n^{-\frac{1}{p\delta} + \frac{1}{p}} \quad (29.3)$$

از قسمت دوم لم ۳.۱.۳ شرط  $C_4$   $e_i$  ها NSD هستند و اینک تابع  $\psi$  یکنوا می‌باشد پس  $\psi(e_i)$  نیز NSD می‌باشد بنابراین شرایط لم (۳.۱.۳) برقرار است، و فرمول (۲۷.۳) تا (۲۹.۳) نتیجه به صورت زیر می‌شود

$$n^{-\frac{\delta}{p}} \sum_{i=1}^n x_{nik} \psi(e_i) = \sum_{i=1}^n a_{ni} \psi(e_i) \rightarrow 0 \quad a.s.$$

بنابراین برای  $1 > \delta > 0$  که در ادامه نامساوی از نامساوی کوشی شوارتز استفاده می‌کنیم آن‌گاه

$$\begin{aligned} n^{-\delta} \sup_{\gamma \in U} |I_{\gamma n}(\gamma)| &= n^{-\delta} \sup_{\gamma \in U} \left| \sum_{i=1}^n \omega_{ni}^{\top} \gamma \psi(e_i) \right| \\ &= n^{-\delta} \sup_{\gamma \in U} \left| \sum_{i=1}^n \varepsilon n^{\frac{\delta}{\nu}} \mathbf{x}'_{ni} \gamma \psi(e_i) \right| \\ &= \varepsilon n^{-\frac{\delta}{\nu}} \sup_{\gamma \in U} \left| \sum_{i=1}^n \sum_{k=1}^p x_{nik} \gamma_k \psi(e_i) \right| \\ &\leq \varepsilon n^{-\frac{\delta}{\nu}} \sup_{\gamma \in U} \sqrt{\sum_{k=1}^p \left( \sum_{i=1}^n x_{nik} \psi(e_i) \right)^2} \cdot \sqrt{\sum_{k=1}^p \gamma_k^2} \\ &\leq \varepsilon \sqrt{\sum_{k=1}^p \left( n^{-\frac{\delta}{\nu}} \sum_{i=1}^n x_{nik} \psi(e_i) \right)^2} \rightarrow 0 \quad a.s. \end{aligned}$$

که نشان می‌دهد با احتمال یک برای  $n$ های به اندازه‌ی کافی بزرگ نتیجه به صورت زیر می‌باشد

$$\sup_{\gamma \in U} |I_{\gamma n}(\gamma)| \leq \frac{C_3 \varepsilon^2 n^{\delta}}{16} \quad (30.3)$$

با ترکیب (۱۹.۳)، (۲۶.۳) و (۳۰.۳) با احتمال یک برای  $n$ های به اندازه‌ی کافی بزرگ نتیجه به صورت زیر است

$$\inf_{\gamma \in U} D_n(\varepsilon n^{\frac{\delta}{\nu}} \gamma) \geq \frac{C_3 \varepsilon^2 n^{\delta}}{16}$$

از محدب بودن  $D_n(\circ)$  دانستن  $D_n(\circ) = 0$  هم‌چنین با استفاده از تعریف (۱۸.۳) برای  $\hat{\beta}_n^*$  نتیجه‌ی زیر حاصل می‌شود

$$\left\{ \inf_{\gamma \in U} D_n(\varepsilon n^{\frac{\delta}{\nu}} \gamma) > 0 \right\} \subset \left\{ \|\hat{\beta}_n^*\| \leq \varepsilon n^{\frac{\delta}{\nu}} \right\}.$$

در نتیجه برای هر  $\varepsilon > 0$  داده شده با احتمال یک برای  $n$ های به اندازه‌ی کافی بزرگ

$$\|\hat{\beta}_n^*\| \leq \varepsilon n^{\frac{\delta}{\nu}}$$

که نتیجه به صورت زیر حاصل می‌شود

$$n^{-\frac{\delta}{\nu}} \|\hat{\beta}_n^*\| \rightarrow 0 \quad a.s. \quad (31.3)$$

توجه داشته باشید  $\xi(A)$  کوچکترین مقدار ویژه ماتریس متناهی  $A$  است ما از این نتیجه استفاده می‌کنیم که اگر  $A$  و  $B$  دو ماتریس متناهی از مرتبه  $p$  باشند آن‌گاه

$$\text{tr}(AB) \geq \mu(A) \xi(B)$$



جایی که  $\mu(A)$  بزرگترین مقدار ویژه از A که با مراجعه به چن و ژائو (۱۹۹۵) ببینید. اکنون با در نظر گرفتن  $M = n_0$  و  $n > n_0$  طوری که  $S_n \geq S_M > 0$  آن گاه

$$\begin{aligned} \xi(S_M) (\xi(S_n))^{-1} &= \xi(S_M) \mu(S_n^{-1}) \\ &\leq \text{tr}(S_n^{-1} S_M) \\ &= \sum_{i=1}^M \mathbf{x}_i' S_n^{-1} \mathbf{x}_i \\ &\leq M d_n \\ &\leq M C_3 n^{-\delta} \end{aligned}$$

در نتیجه یک ثابت مثبت  $C_6$  وجود دارد طوری که  $C_6 n^{-\frac{\delta}{2}} \leq \left( \xi \left( \mathbf{S}_n^{\frac{1}{2}} \right) \right)^{-1}$  بنابراین نتیجه زیر بدست می آید

$$\|\hat{\beta}_n\| \leq \left( \xi \left( \mathbf{S}_n^{\frac{1}{2}} \right) \right)^{-1} \|\mathbf{S}_n^{\frac{1}{2}} \hat{\beta}_n\| \leq C_6 n^{-\frac{\delta}{2}} \|\mathbf{S}_n^{\frac{1}{2}} \hat{\beta}_n\| = C_6 n^{-\frac{\delta}{2}} \|\hat{\beta}_n^*\| \rightarrow 0 \quad a.s$$

□

# فصل ۴

## مطالعات شبیه‌سازی

شبیه‌سازی یک ابزار قدرتمند برای طراحی و تحلیل سیستم‌ها یا فرایندهای پیچیده مهندسی است که به استفاده کنندگان این امکان را می‌دهد که آزمایش‌هایی را انجام دهند که در عمل غیرممکن یا دارای هزینه‌ی بسیار زیادی می‌باشند.

به عنوان مثال قبل از پرتاب یک ماهواره عملیات پرتاب بارها شبیه‌سازی می‌شود. مثال‌های زیادی را مطرح کرده‌اند بلند شدن یک هواپیما، شلیک یک موشک و... . فرآیند شبیه‌سازی در علم آمار از قرن بیستم مطابق با شروع انتشار رادیو و تلویزیون آغاز گردید:

همانطور که استفاده از این وسایل در زندگی هر کسی معمول و متداول شده است، استفاده از شبیه‌سازی در بسیاری از شاخه‌های آماری گسترش یافته است.

از کاربردهای شبیه‌سازی در آمار می‌توان به تولید داده‌های تصادفی از توزیع‌های گسسته و پیوسته، تولید اعداد شبه تصادفی، محاسبه انتگرال‌ها و ... اشاره کرد هم‌چنین برای پاسخ به سوالاتی که نظریه آمار برای آن‌ها جواب ندارد می‌توان از شبیه‌سازی استفاده کرد و جواب تجربی به دست آورد در این پایان‌نامه برای ارزیابی سازگاری برآوردگرهای معرفی شده با استفاده از یک مدل شبیه‌سازی، مدل رگرسیون خطی زیر را در نظر بگیرید.

$$Y_i = -1 + 0.6X + e_i, \quad i = 1, 2, \dots, n$$

مطالعات شبیه‌سازی با نرم افزار R انجام گرفته و از پکیج MASS و mvtnorm استفاده شده است که کدهای مربوط به شبیه‌سازی در پیوست آمده است. مشاهدات شبیه‌سازی شده براساس مدل رگرسیون خطی و  $e_i$  های NSD هستند. برای این که توزیع خطاها NSD باشد از


دو توزیع نرمال چندمتغیره و یا تی چندمتغیره استفاده کرده‌ایم. براساس مقاله هو (۲۰۰۰) باید درایه‌های غیر قطر اصلی ماتریس کواریانس توزیع نرمال و ماتریس مقیاس تی منفی باشد در توزیع نرمال و تی چند متغیره ماتریس کواریانس مقیاس در مراحل شبیه سازی به صورت زیر می باشد

$$\sigma_{ii} = 1 \quad \sigma_{ij} = -\frac{1}{n-1}$$

بعد از این که داده‌های NSD را تولید کردیم مرحله‌ی بعدی سراغ مدل رگرسیون استوار می‌رویم. همان‌طور که اشاره شد در فصل دو و سه برای مدل رگرسیونی استوار احتیاج به تابع  $\rho(x)$  داریم. ما در این شبیه‌سازی تابع هوبر را در نظر گرفته‌ایم. از مدل رگرسیونی استوار در R براساس rlm استفاده می‌کنیم و حجم نمونه‌ها را  $n = 20, 40, 60, 80, 100, 150, 200, 500, 1000$  در نظر می‌گیریم. نتیجه شبیه سازی به صورت زیر می باشد

## ۱.۴ توزیع نرمال چندمتغیره

با توجه به منحنی برازش شده واضح است که برای حجم نمونه‌های کم MSE<sup>۱</sup> زیاد است ولی با افزایش حجم نمونه‌ها MSE کاهش می‌یابد، در نتیجه منحنی برازش شده به مقدار واقعی نزدیک‌تر می‌شود و برآورد قابل قبول‌تری را نسبت به حجم نمونه‌های کم می‌دهد.




شکل ۱.۴: سازگاری ضرایب با استفاده از نرمال چندمتغیره

<sup>۱</sup>Mean Square Error


## ۲.۴ توزیع تی چندمتغیره

همان طور که مشاهده می‌کنیم توزیع تی چندمتغیره دارای MSE نسبتاً زیادی می‌باشند ولی باز با افزایش حجم نمونه MSE کاهش می‌یابد و تمام شرایطی که در بالا به آن اشاره کردیم برای توزیع تی نیز برقرار است که سازگاری  $\hat{\beta}$  را نشان می‌دهد و چون ما دنبال نتیجه ایده‌آل‌تری می‌باشیم پس بهتر است از توزیع نرمال چند متغیره استفاده کنیم زیرا سازگاری بهتری را به ما می‌دهد و منحنی هموارتر است یعنی از یک مرحله‌ای به بعد سازگاری بهتر و مهم‌تر از همه، برازش منحنی بهتر می‌شود، که نمودار آن به صورت زیر می‌باشد




شکل ۲.۴: سازگاری ضرایب با استفاده از چندمتغیره توزیع تی


نمودار جعبه‌ای که در زیر آمده برای نمونه‌های  $n = 40, 200, 1000$  همان طور که مشاهده می‌کنید در مدل رگرسیون استوار با افزایش حجم نمونه به مقدار واقعی ضرایب نزدیک می‌شود که داده‌هایی که خارج از فواصل اطمینان هستند نشان دهنده‌ی داده‌ی پرت می‌باشند که یعنی در مدل هیچ تأثیری ندارند



شکل ۳.۴: نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۴۰



شکل ۴.۴: نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۲۰۰



شکل ۵.۴: نمودار باکس پلات مربوط به برآورد ضرایب برای حجم نمونه ۱۰۰۰

جدول ۱.۴: میانگین مربوط به برآورد ضرایب برای حجم نمونه‌های مختلف

تعداد	$\beta_0$	$\beta_1$
$n = 20$	$-0/9860$	$0/6195$
$n = 40$	$-0/9919$	$0/5257$
$n = 60$	$-1/0201$	$0/5919$
$n = 80$	$-0/9850$	$0/6065$
$n = 100$	$-0/9913$	$0/5966$
$n = 150$	$-1/0034$	$0/5909$
$n = 200$	$-0/9897$	$0/5785$
$n = 500$	$-0/9963$	$0/6008$
$n = 1000$	$-0/9969$	$0/5908$
$n = 10000$	$-0/99605$	$0/5925$

میانگین برآورد ضرایب در مدل رگرسیون استوار برای حجم نمونه‌های مختلف که در جدول (۱.۴) آورده شده برآورد میانگین ضرایب برای حجم نمونه‌های کم تقریباً برابر ضرایب رگرسیون مدل خطی کمترین توان‌های دوم است ولی هرچه حجم نمونه را افزایش می‌دهیم این برآوردها تقریباً به طور کامل به ضرایب مدل رگرسیونی خطی کمترین توان‌های دوم نزدیک می‌شود، همانطور که مشاهده با افزایش حجم نمونه و تکرار زیاد حلقه تقریباً به مقدار واقعی نزدیک شدن که این همون مفهوم سازگاری را می‌رساند.

## ۱.۲.۴ بحث و نتیجه‌گیری

- در این پایان نامه یک مدل رگرسیون استوار را فرض کردیم هم‌چنین جمله‌ی خطاها را متغیرهای تصادفی وابسته با ساختار وابستگی NSD می‌باشد که هدف ما در این مدل رگرسیونی استوار نشان دادن سازگاری قوی  $\beta_n$  بوده که این نتیجه تضمینی برای همگرایی کامل در مدل رگرسیون استوار می‌باشد، که با استفاده از مطالعات شبیه‌سازی این سازگاری را نشان دادیم.
- روش استوار در متون آماری، به معنی معتبر بودن و مناسب بودن آن است در حالت کلی می‌توان حساس نبودن به انحراف کم از پذیره‌ها کم را استواری تعریف کرد. رگرسیون استوار علاوه بر حساس نبودن نسبت به داده‌های پرت زمانی که مشاهدات دارای توزیع نرمال هستند دارای کارایی ۹۰ تا ۹۵ درصدی نسبت به کمترین توان‌های دوم می‌باشد.

- رده وابستگی NSD یک رده‌ی بسیار بزرگ از وابستگی‌هاست که متغیرهای تصادفی NA و مستقل را شامل می‌شود بنابراین نتیجه‌ارایه شده برای این دو رده از متغیرها برقرار می‌باشد که می‌توان جمله خطا در مدل رگرسیونی با این دو نوع متغیر تصادفی از نظر همگرایی کامل نتیجه‌گرفت که بررسی همگرایی کامل برآوردگر رگرسیون استوار برای سایر رده‌های وابستگی موضوعی است که در آینده می‌توان از آن استفاده کرد.

# مراجع

- [۱] اسحاقی، ا، (۱۳۹۲)، پایان نامه ارشد: ”مدل های نیمه پارامتری تحلیل بقا برای داده های بازگشتی با روش هسته”، دانشکده ریاضی، دانشگاه صنعتی شاهرود.
- [۲] اقبال ن، (۱۳۸۴)، پایان نامه ارشد: ”روش های استواری ” دانشکده ریاضی، دانشگاه فردوسی مشهد.
- [۳] لاری ع، (۱۳۹۱)، ”رگرسیون خطی کاربردی” چاپ سوم، انتشارات دانشگاه شیراز.
- [۴] مونتگمری د، پک ا، ترجمه سید ابراهیم رضوی پاریزی، (۱۳۸۶)، ”مقدمه ای بر تحلیل رگرسیون خطی” چاپ سوم، انتشارات دانشگاه شهید باهنر کرمان.
- [۵] ولیپور پاشاکایی م، (۱۳۹۲)، پایان نامه ارشد: ”مدل بندی داده های نرخ و نسبت با رگرسیون بتا”، دانشکده ریاضی، دانشگاه صنعتی شاهرود.
- [۶] فریبا ا، حسین ف، الهام خ. نشریه دانشجویی آمار (ندا) – سال سیزدهم – شماره اول، ”روش های شناسایی و تحلیل داده های پرت در تحلیل رگرسیون”، دانشگاه بیرجند، دانشکده ریاضی، گروه آمار.

[7] Alam, K. and Saxena, K.M.L. (1981). ”Positive dependence in multivariate distributions. Positive dependence in multivariate distributions” **Comm Statist Theor Meth.** A10, pp 1183–1196.

[8] Bai, Z.D., Rao, C.R. and Wu, Y. (1992). ”M-estimation of multivariate linear regression parameters under a convex discrepancy function” **Statist. Sinica** 2, pp 237–254.

[9] Beaton, A. E. and Tukey, J. W. (1974). ”The fitting of power series, meaning polynomials, illustrated on band spectroscopic data,” **Technometrics**, 16, pp 147-185.

[10] Berlinet, A., Liese, F. and Vajda, I. (2000). ”Necessary and sufficient conditions for consistency of M estimates in regression models with general errors. ” **J. Statist. Plann. Infer.** 89, pp 243–267.



- [11] Box, G. E.P. (1953). "Non-Normality and Tests on Variances," **Biometrika**, 40, pp 318-335.
- [12] Chen, X.R. and Wu, Y.H. (1988). "Strong consistency of M-estimates in linear models." **J. Multi. Anal.** 27, pp 116–130.
- [13] Chen, X.R. and Zhao, L.C. (1995). "Strong consistency of M-estimates of multiple regression coefficients." **J. Syst. Sci. Complex.** 8, pp 82–87.
- [14] Cheng, C.S. and Li, K.C. (1984). "The strong consistency of M-estimators in linear models." **J. Multi. Anal.** 15, pp 91–98.
- [15] Christofides, T.C. and Vaggelatos, E. (2004). "A connection between supermodular ordering and positive/negative association." **J. Multi. Anal.** 88, pp 138–151.
- [16] Cui, H.J., He, X.M. and Ng, K.W. (2004). "M-estimation for linear models with spatially-correlated errors." **Statist. Probab. Lett.** 66, pp 383–393.
- [17] Ebrahimi, N. and Ghosh, M. (1981). "Multivariate negative dependence." **Commun. Statist. Theor. Meth.** A 10, pp 307–337.
- [18] Eghbal, N. Amini, M. and Bozorgnia, A. (2010). "Some maximal inequalities for quadratic forms of negative superadditive dependence random variables." **Statist. Probab. Lett.** 80, pp 587–591.
- [19] Eghbal, N., Amini, M. and Bozorgnia, A. (2011). "On the Kolmogorov inequalities for quadratic forms of dependent uniformly bounded random variables." **Statist. Probab. Lett.** 81, pp 1112–1120.
- [20] Daniel, C. and Wood, F. S. (1980). **Fitting Equations to Data**, 2nd ed., Wiley, Newyork
- [21] Derper, N.R. and Smith, H. (1998). "**Applied regression analysis**", Johan wiley and Sons
- [22] Dixon, W. J. and Tukey, J. W. (1968). "Approximate Behavior of the Distribution of Winsorized t (Trimming/Winsorization 2)," **Technometrics**, 10, pp 83-98.
- [23] Dutter, R. (1977 ). "Numerical Solution of Robust Regression Problems: Computational Aspects, a Comparison," **Journal of Statistical Computation and Simulation**, 5, pp 207-238.
- [24] Gao J.T. and Shi, P.D. (1997). "M-type smoothing spline in nonparametric and semiparametric regression models." **Statist. Sinica** 7, pp 1155–1169.

- [25] Gao, J.T., Li, D.G. and Lin, Z.Y. (2009). "Robust estimation in parametric time series models under long-and short-range-dependent structures." **Aust. N. Z. J. Stat.** 51, pp 161–181.
- [26] Gut, A. (1994). **Probability: A Graduate Course** , Spring T Stat, Sweden.
- [27] Hampel, F. R. (1974). "The Influence Curve and Its Role in Robust Estimation", **Journal of the American Statistical Association**, 69, pp 383-393.
- [28] He, X.M. and Shao, Q.M. (1996). "A general Bahadur representation of M-estimators and its application to linear regression with nonstochastic designs." **Ann. Statist.** 18, pp 2608–2630.
- [29] Hill, R. W. and Holland, P. W. (1977). "Two robust alternatives to least squares regression," **Journal of the American Statistical Association**, 72, pp 828-833.
- [30] Hogg, R. E. (1999). "statistical robustness: One view of its use in applications today," **The American Statistician**. 33:3, pp 108-115.
- [31] Holland, P. W. and Welsch R. E. (1977). "Robust Regression Using Iteratively Reweighted Least-Squares," **Communications in Statistics**, A6, pp 813-828.
- [32] Hsu, P. and Robbins, H. (1947). "Complete convergence and the law of large numbers," **Proc Natl Acad Sci USA**, 33, 25–31.
- [33] Hu, T.Z. (2000). "Negatively supperadditive dependence of random variables with applications." **Chinese J. Appl. Probab. Statist.** 16, pp 133–144.
- [34] Huber, P.J. (1981). **Robust Statistics**, New York: John Wiley.
- [35] Huber, P. J. (1964), "Robust Estimation of a Location Parameter." **Annals of Mathematical Statistics**, 35, pp 73-101.
- [36] Huber, P. J. (1972). "Robust Statistics: A Review," **Annals of Mathematical Statisticz**, 43, pp 1041-1067.
- [37] Huber, P. J. (1973). "Robust Regression: Asymptotics, Conjectures, and Monte Carlo," **Annals of Statistics**, 1, pp 799-821.
- [38] Jaeckel, L.A. (1972). "Estimating Regression Coefficients by Minimizing the Dispersion of the Residuals," **Annals of Mathematical Statistics**, 43, pp 1449-1458.

- 
- [39] Jaworski, P., Durante, F. and Hardle, W.K. (2013). "Copulae in Mathematical and Quantitative Finance." **Heidelberg: Springer-Verlag.**
- [40] Jureckova, J. (1977). "Asymptotic Relations of M-estimates and R-estimates in Linear Regression Models," **Annals of Statistics**, 5, pp 464-472.
- [41] Kemperman, J.H.B. (1977). "On the FKG-inequalities for measures on a partially ordered space." **Proc. Akad. Wetenschappen Ser. A.** 80, pp 313–331.
- [42] Koenker, R. and Bassett, G. (1978). "Regression Quantities," **Econometrics**, 46, pp 33-50.
- [43] Koul, H.L. and Surgailis, D. (2000). "Second-order behavior of M-estimators in linear regression with long-memory errors." **J. Statist. Plann. Infer.** 91, pp 399–412.
- [44] Mari, D. D. and Kotz, S. (2001). "Correlation And Dependence", **Imp Coll Press London.**,
- [45] Miao, B.Q. and Wu, Y. (1996). "Limiting behavior of recursive M-estimators in multivariate linear regression models." **J. Multi. Anal.** 59, pp 60–80.
- [46] Miao, B.Q., Wu, Y. and Liu, D. (2009). "Limiting behavior of recursive M-estimators in multivariate linear regression models and their asymptotic efficiencies." **Acta Math. Sci.** 29B, pp 1–11.
- [47] Moussa-Hamouda, E. and Leon, F. C. (1977a). "The robustness of efficiency of abjusted trimmed estimators in linear regression." **Technometrics**.19, pp 19-34.
- [48] Moussa-Hamouda, E. and Leon, F. C. (1974). "The 0-blue estimators for complete and censored samples in liner regression." **Technometrics**.16, pp 441-446.
- [49] Nelsen, R.B. (2006). **An Introduction to Copulas.** New York: Springer Science + Business Media.
- [50] Rao, C.R. and Zhao, L. C. (1992a). "On the consistency of M-estimate in a linear model obtained through an estimating equation." **Statist. Probab. Lett.** 14, pp 79–84.
- [51] Rao, C.R. and Zhao, L. C. (1992b). "Linear representation of M-estimates in linear models. Canad." **J. Statist.** 20, pp 359–368.
- [52] Shen Y., Wang X.J., Yang W.Z. and Hu S.H. (2013). "Almost sure convergence theorem and strong stability for weighted sums of NSD random variables." **Acta. Math. Sinica English Ser.** 29, pp 743–756.

- [53] Stout, W.F. (1974). "Almost Sure Convergence." **New York: Academic Press.**
- [54] Tukey, J. W. (1962). "The Future of Data Analysis," **Annals of Mathematical Statistics**, 33, pp 1-67.
- [55] Wang, X. and Hu, S. (2015). "On the strong consistency of M-Estimates in linear models for negatively superadditive dependent errors," **Australian And New Zealand Journal of Statistics**, 57(2), pp 259-274.
- [56] Wang, X.J., Deng, X., Zheng L.L. and Hu S.H. (2014). "Complete convergence for arrays of rowwise negatively superadditive-dependent random variables and its applications." **Statistics** 48, pp 834–850.
- [57] Withers, C.S. and Nadarajah, S. (2014). "Asymptotic properties of M-estimators in linear and nonlinear multivariate regression models." **Metrika** 77, pp 647–673.
- [58] Wu, Q.Y. (2006). "Strong consistency of M estimator in linear model for negatively associated samples." **J. Syst. Sci. Complex.** 19, pp 592–600.
- [59] Wu, Q.Y. and Jiang Y.Y. (2011). "The strong consistency of M- estimator in a linear model for negatively dependent random samples," **Communications in statistics theory and methods**.40, pp 467–491.
- [60] Wu, Q.Y. (2007). "M-estimation of linear models with dependent errors." **Ann. Statist.** 35, pp 495–521.
- [61] Wu, Q.Y. (2011). The strong consistency of M estimator in a linear model for negatively dependent random samples. *Commun. Statist. Theor. Meth.* 40, 467–491.
- [62] Yang, S.C. (2002). "Strong consistency of M-estimator in linear model." **Acta Math. Sinica** 45, pp 21–28.(in Chinese).
- [63] Yohai, V.J. and Maronna, R.A. (1979). "Asymptotic behavior of M-estimators for the linear model." **Ann. Statist.** 7, pp 258–268.
- [64] Zhao, L.C. (2000). "Some contributions to M-estimation in linear models." **J. Statist. Plann. Infer.** 88, pp 189–203.
- [65] Zhao, L.C. (2002). "Strong consistency of M-estimates in linear models." **China Ser. A** 45, pp 1420–1427.



# پیوست آ

## کدهای شبیه سازی فصل دو و چهار

### ۱.آ کدهای مربوط به مدل رگرسیون کمترین توان های دوم و رگرسیون استوار

```
rm(list=ls())
library(MASS)
library(HoRM)
data <- read.csv("G:/data1.csv")
Y <- c(data$Y)
X0 <- c(rep(1,21))
X1 <- c(data$X1)
X2 <- c(data$X2)
X3 <- c(data$X3)
X <- matrix(c(Y,X1 ,X2 ,X3 ), nrow = 21, ncol = 4)
X
Xls <- matrix(c(X0,X1 ,X2 ,X3 ), nrow = 21, ncol = 4)
LS <- lm(Y ~. , data=data)
```

```

summary(LS)
names(LS)
beta1 <- c(LS$coefficients)
beta01 <- as.matrix(beta1)
Y01 <- as.matrix(Y)
dim(t(Y01))
dim(Y01)
dim(t(beta01))
dim(t(X1s))
SSE_b0 <- t(Y01)%*%Y01 - t(beta01)%*%t(X1s)%*%Y01
MSE_b0 <- (SSE_b0)/(21-3)
MSE_b0
se.ls <- LS$residuals
plote<-qqnorm(se.ls)
qqline(se.ls, col="red",lWd=3)
names(LS)
data_o <- X[-c(1,3,4,21),]
data_o
da <- as.data.frame(data_o)
LS1 <- lm(V1 ~. , data=da)
summary(LS1)
se.LS1<-LS1$residuals
Yhat <- (-37.6)+(0.8*X1)+(0.58*X2)+((-0.07)*X3)
resi <- Y-Yhat
resi
beta2 <- c(LS1$coefficients)
beta02 <- as.matrix(beta2)
SSE_b2 <- t(Y01)%*%Y01 - t(beta02)%*%t(X1s)%*%Y01
MSE_b02 <- (SSE_b2)/(21-3)
MSE_b02
plote<-qqnorm(se.LS1)
qqline(se.LS1, col="red",lWd=4)
#####
mod.bisq1 <- rlm(Y ~., data=data, method="M")

```

```
names(mod.bisq1)
summary(mod.bisq1)
se.M <- mod.bisq1$residuals
plote<-qqnorm(se.M)
qqline(se.M, col="red",lWd=4)
beta5 <- c(mod.bisq1$coefficients)
beta05 <- as.matrix(beta5)
SSE_b5 <- t(Y01)%*%Y01 - t(beta05)%*%t(X1s)%*%Y01
MSE_b05 <- (SSE_b5)/(21-3)
MSE_b05
```

## ۱.۱.آ کدهای مربوط به توزیع نرمال چندمتغیره

```
library(MASS)
library(mvtnorm)
remove(list=ls())
set.seed(2314)
gen.data<-function(beta0, beta1, n){
### generating NSD errors from a multivariate normal dist.
  a=-1/(n-1)
  M=a*matrix(rep(1,n*n),ncol=n)
  diag(M)=rep(1,n)
  eigen(M)$values
  epsilon<-as.vector(rmvnorm(1, mean=rep(0, nrow(M)), sigma=100*M))
### generating covariate x
  x=rnorm(n)
### generating data from a linear model with NSD errors
  y = beta0 + beta1*x+ epsilon
##
  dt = data.frame(cbind(x,y))
return(dt)
}
dt = gen.data(beta0=-1, beta1=.6, n=100)
### M-estimation of the model
```



```
#fit = rlm(y~x, psi= psi.huber, data=dt, method='M', scale.est="Huber")
#summary(fit)
#fit$coef
MSE <- function(B, n){
  Est = matrix(NA, nrow=B, ncol=2)
  bias = mse = rep(NA, 2)
  beta0 = -1; beta1 = 0.6
  for (i in 1:B){
dt <- gen.data(beta0=beta0, beta1=beta1, n=n)
fit = rlm(y~x, psi= psi.huber, data=dt, method='M', scale.est="Huber")
Est[i,] = fit$coef
  }
  bias = apply(Est, 2, mean)-c(beta0, beta1)
  mse = apply((Est-c(beta0, beta1))^2, 2, mean)
return(list(Est=Est, bias=bias, mse=mse))
}
n = c(20, 40, 60, 80, 100, 150, 200, 500, 1000)
res.n20 = MSE(n=n[1], B=500)
res.n40 = MSE(n=n[2], B=500)
res.n60 = MSE(n=n[3], B=500)
res.n80 = MSE(n=n[4], B=500)
res.n100 = MSE(n=n[5], B=500)
res.n150 = MSE(n=n[6], B=500)
res.n200 = MSE(n=n[7], B=500)
res.n500 = MSE(n=n[8], B=500)
res.n1000 = MSE(n=n[9], B=500)
par(mfrow=c(1,2))
plot(c(res.n20$mse[1], res.n40$mse[1], res.n60$mse[1],
res.n80$mse[1], res.n100$mse[1], res.n150$mse[1], res.n200$mse[1],
res.n500$mse[1], res.n1000$mse[1]), type="l", ylab="MSE",
  xlab="sample size", main=expression(beta[0]))
plot(c(res.n20$mse[2], res.n40$mse[2], res.n60$mse[2],
res.n80$mse[2], res.n100$mse[2], res.n150$mse[2],
res.n200$mse[2], res.n500$mse[2], res.n1000$mse[2]),
```

```
type="l", ylab="MSE", xlab="sample size", main=expression(beta[1]))
```

## ۲.۱.آ کدهای مربوط به توزیع تی چندمتغیره

```
library(MASS)
library(mvtnorm)
remove(list=ls())
set.seed(2314)
gen.data<-function(beta0, beta1, n){
### generating NSD errors from a multivariate normal dist.
  a=-1/(n-1)
  M=a*matrix(rep(1,n*n),ncol=n)
  diag(M)=rep(1,n)
  eigen(M)$values
  epsilon<-as.vector(rmvt(1, sigma=100*M, df=3))
### generating covariate x
  x=rnorm(n)
### generating data from a linear model with NSD errors
  y = beta0 + beta1*x+ epsilon
##
  dt = data.frame(cbind(x,y))
return(dt)
}
dt = gen.data(beta0=-1, beta1=.6, n=100)
### M-estimation of the model
#fit = rlm(y~x, psi= psi.huber, data=dt, method='M', scale.est="Huber")
#summary(fit)
#fit$coef
MSE <- function(B, n){
  Est = matrix(NA, nrow=B, ncol=2)
  bias = mse = rep(NA, 2)
  beta0 = -1; beta1 = 0.6
  for (i in 1:B){
dt <- gen.data(beta0=beta0, beta1=beta1, n=n)
```

```

fit = rlm(y~x, psi= psi.huber, data=dt, method='M', scale.est="Huber")
Est[i,] = fit$coef
}

bias = apply(Est, 2, mean)-c(beta0, beta1)
mse = apply((Est-c(beta0, beta1))^2, 2, mean)
return(list(Est=Est, bias=bias, mse=mse))
}

n = c(20, 40, 60, 80, 100, 150, 200, 500, 1000)
res.n20 = MSE(n=n[1], B=500)
res.n40 = MSE(n=n[2], B=500)
res.n60 = MSE(n=n[3], B=500)
res.n80 = MSE(n=n[4], B=500)
res.n100 = MSE(n=n[5], B=500)
res.n150 = MSE(n=n[6], B=500)
res.n200 = MSE(n=n[7], B=500)
res.n500 = MSE(n=n[8], B=500)
res.n1000 = MSE(n=n[9], B=500)
par(mfrow=c(1,2))
plot(c(res.n20$mse[1], res.n40$mse[1], res.n60$mse[1],
res.n80$mse[1], res.n100$mse[1], res.n150$mse[1], res.n200$mse[1],
res.n500$mse[1], res.n1000$mse[1]), type="l", ylab="MSE", xlab="sample size",
main=expression(beta[0]))
plot(c(res.n20$mse[2], res.n40$mse[2], res.n60$mse[2],
res.n80$mse[2], res.n100$mse[2], res.n150$mse[2],
res.n200$mse[2], res.n500$mse[2], res.n1000$mse[2]),
type="l", ylab="MSE", xlab="sample size", main=expression(beta[1]))

```

### ۳.۱.آ کدهای مربوط به میانگین ضرایب

```

res.n20 = MSE(n=n[1], B=500)
mean(res.n20$Est[,1])
mean(res.n20$Est[,2])
res.n40 = MSE(n=n[2], B=500)
mean(res.n40$Est[,1])

```

```
mean(res.n40$Est[,2])
res.n60 = MSE(n=n[3], B=500)
mean(res.n60$Est[,1])
mean(res.n60$Est[,2])
res.n80 = MSE(n=n[4], B=500)
mean(res.n80$Est[,1])
mean(res.n80$Est[,2])
res.n100 = MSE(n=n[5], B=500)
mean(res.n100$Est[,1])
mean(res.n100$Est[,2])
res.n150 = MSE(n=n[6], B=500)
mean(res.n150$Est[,1])
mean(res.n150$Est[,2])
res.n200 = MSE(n=n[7], B=500)
mean(res.n200$Est[,1])
mean(res.n200$Est[,2])
res.n500 = MSE(n=n[8], B=500)
mean(res.n500$Est[,1])
mean(res.n500$Est[,2])
res.n1000 = MSE(n=n[9], B=500)
mean(res.n1000$Est[,1])
mean(res.n1000$Est[,2])
res.n10000 = MSE(n=n[9], B=1000)
mean(res.n10000$Est[,1])
mean(res.n10000$Est[,2])
```

#### آ.۱.۴ کدهای مربوط به نمودارهای جعبه‌ای

```
res.n40 = MSE(n=n[2], B=50)
boxplot(res.n40$Est)
res.n200 = MSE(n=n[7], B=500)
boxplot(res.n200$Est)
res.n1000 = MSE(n=n[9], B=500)
boxplot(res.n1000$Est)
```

## **Abstract**

In this thesis we discuss the strong consistency of M-estimates of the regression parameters in a linear model with negatively superadditive dependent (NSD) random errors. The result improves the moment condition and generalises the case of independent random errors to that of NSD random errors.

**key words:** Strong consistency, Negatively superadditive dependent, Robust regression.



**Shahrood University of Technology**

**Faculty Of Mathematical Sciences**

**MSc Thesis in: Mathematical Statistic**

**On the strong consistency of  $M$ -estimates in  
linear models for negatively superadditive  
dependent errors**

**By: Hossein Heidari Nezhad**

**Supervisor**

**Negar Eghbal**

**Advisor**

**Hossein Baghishani**

**January 2019**