

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِيْمِ



بسمه تعالیٰ
مشخصات پایان نامه تحصیلی دانشجویان
دانشگاه فردوسی مشهد

عنوان پایان نامه : تکنیک های پیشرفته رگرسیون

استاد راهنما: دکتر ناصر رضا ارقامی	نویسنده: احسان زمان زاده
گروه: آمار	دانشکده: علوم ریاضی
تاریخ دفاع: ۸۷/۶/۱۶	رشته تحصیلی: آمار ریاضی
تعداد صفحات: ۲۱۳ صفحه	مقطع تحصیلی: کارشناسی ○ کارشناسی ارشد ● دکتری ○

چکیده:

اینکه یک مدل رگرسیون به مجموعه ایی از متغیرها برازش خوبی نداشته باشد اما به تبدیلاتی از آن ها برازش خوبی داشته باشد، مساله ایی غیر معمول نیست. باکس و کاکس (1964) به بررسی تبدیلات متغیر پاسخ، با تأکید بر روی تبدیلات توانی، که به تبدیلات باکس-کاکس معروف گشت، پرداختند. هر چند از این روش در عمل بسیار مفید است اما روش باکس-کاکس دارای این محدودیت است که تنها به یک خانواده از تبدیلات پارامتری محدود شده است و به تبدیل متغیر های پیش‌بین نمی پردازد.

اما در سال های اخیر با در دسترس قرار گرفتن رایانه های سریع و ارزان قیمت، تکنیک های ناپارامتری برازش منحنی از مقبولیت خاصی برخوردار گشته اند. برآورد تبدیلات بهینه یکی از روش های اصلی هموارسازی است که دارای فرضیات بسیار کمی روی شکل منحنی رگرسیون می باشد. این روش هموارسازی را می توان به طور کلی به دو قسمت تقسیم کرد. دسته اول روش هایی هستند که تنها تبدیل روشی متغیرهای پیش بین انجام می شود و دسته دوم، آن هایی هستند که هم تبدیل روی متغیر پاسخ و هم روی متغیرهای پیش بین انجام می گردد.

در این رساله به معرفی و بیان و بررسی خواص هر دو دسته از این روش ها خواهیم پرداخت. از دسته اول، بیشتر روی روش هایی همانند رگرسیون اسپلاین، رگرسیون خطی موضعی، هموار کننده برتر، LOESS و نسخه استوار آن یعنی LOEWSS تمرکز خواهیم کرد. و در دسته دوم، بر روی دو الگوریتم کارآمد، یعنی الگوریتم امید ریاضی شرطی جایگزین (ACE) و الگوریتم جمع پذیری و ثبات واریانس (AVAS) تمرکز خواهیم کرد همچینین با تمرکز بیشتر بر روی این دو الگوریتم، به برخی از ناهنجاری ها و معایب آن ها، هنگامی که از آن ها بدون دقت به عنوان ابزاری در رگرسیون استفاده کنیم، خواهیم پرداخت.

واژه های کلیدی:

امضای استاد راهنما:	اسپلاین هموارساز، رگرسیون خطی موضعی، هموار کننده برتر، LOESS، LOEWSS
تاریخ	الگوریتم امید ریاضی شرطی جایگزین، الگوریتم جمع پذیری و ثبات واریانس

۱	پیشگفتار
۶	فصل اول
۶	رگرسیون خطی
۶	۱- رگرسیون خطی ساده
۶	۱-۱- برازش مدل رگرسیون خطی ساده
۸	۲-۱- خطر برون یابی در رگرسیون
۹	۳-۱- اندازه‌ای از کیفیت برازش خط راست
۱۲	۲-۱- رگرسیون خطی چندگانه
۱۲	۱-۲- برازش الگو در رگرسیون چندگانه
۱۶	۲-۲- ضریب تعیین در رگرسیون چندگانه
۱۷	۳-۲- هم خطی و اثرات آن در رگرسیون چندگانه
۲۰	۳-۳- * رگرسیون خطی بدون عرض از مبدا
۲۰	۱-۳- مقدمه
۲۰	۲-۳- یک مثال واقعی
۲۳	۳-۳- رگرسیون خطی بدون عرض از مبدا
۲۵	۳-۳- ۱ مقایسه VIF_j و \tilde{VIF}_j
۲۸	فصل دوم
۲۸	هموارسازی برای داده‌های تک بعدی
۲۸	۱-۲- مقدمه
۲۸	۲-۲- میانگین متحرک و فیلتر دوجمله‌ای
۳۵	۳-۲- رگرسیون چندجمله‌ای
۴۰	۴-۲- رگرسیون خطی موضعی
۴۸	۵-۲- اسپلاین هموارساز گستته
۵۴	فصل سوم
۵۴	هموارسازی داده‌های با یک متغیر پیش‌بین
۵۴	۱-۳- مقدمه
۶۲	۲-۳- برآوردهای ندارایا-واتسون
۶۸	۳-۳- رگرسیون چندجمله‌ای موضعی
۷۹	۴-۳- اسپلاین درون یاب، اسپلاین طبیعی و اسپلاین هموارساز
۷۹	۱-۴-۳- اسپلاین درون یاب و اسپلاین طبیعی
۹۴	۲-۴-۳- اسپلاین هموارساز
۱۰۲	۳-۴-۳- هموارسازی اسپلاین وزنی
۱۰۴	۴-۴-۳- اعتباریابی متقابل برای هموارسازی وزنی

۱۰۴LOESS ۵-۳
۱۱۰LOWESS ۶-۳
۱۱۷	۷-۳ هموارسازی هنگامی که در داده ها گره وجود دارد
۱۱۹	۸-۳ برآورد واریانس جمله خطای
۱۲۰	۱-۸-۳ تفاضلی کردن موضعی
۱۲۰	۲-۸-۳ مجموع مربعات باقی مانده های منحنی برآش شده
۱۲۲فصل چهارم
۱۲۲هموارسازی داده ها با چند متغیر پیش بین
۱۲۲	۱-۴ مقدمه
۱۲۲	۲-۴ رگرسیون چندجمله ای موضعی با چند متغیر پیش بین
۱۲۴	۳-۴ اسپلاین صفحه نازک
۱۲۵	۱-۳-۴ اندازه گیری همواربودن یک سطح
۱۲۶	۲-۳-۴ تعریف اسپلاین صفحه نازک
۱۲۸	۳-۳-۴ درون یابی با اسپلاین صفحه نازک
۱۳۰	۴-۳-۴ اسپلاین هموارساز صفحه نازک
۱۳۲	۵-۳-۴ اسپلاین صفحه نازک با بیش از ۲ متغیر پیش بین
۱۳۴	۴-۴ LOWESS و هموارکننده برتر با چند متغیر پیش بین
۱۳۶فصل پنجم
۱۳۶	برآورد ناپارامتری تبدیلات بهینه در رگرسیون
۱۳۶	با استفاده از الگوریتم امید ریاضی شرطی جایگزین
۱۳۶	۱-۵ مقدمه
۱۳۷	۲-۵ معرفی الگوریتم امید ریاضی شرطی جایگزین(ACE)
۱۳۷	۱-۲-۵ معرفی تبدیلات بهینه
۱۴۰	۲-۲-۵ ACE الگوریتم
۱۴۴	۳-۵ بررسی برخی از مسائل نظری مربوط به الگوریتم امید ریاضی شرطی جایگزین
۱۴۷	۱-۳-۵ بررسی نحوه عملکرد الگوریتم ACE به صورت نظری
۱۵۱	۴-۵ استفاده از الگوریتم امید ریاضی شرطی جایگزین در عمل
۱۶۰	۵-۵ برخی از خواص و ویژگی های الگوریتم ACE
۱۶۰	۱-۵-۵ الگوریتم ACE از دیدگاه نظری: مفهوم همبستگی ماکسیمال چیست؟
۱۶۲	۲-۵-۵ آیا بهترین تبدیلات به صورت غیر مبهمی تعریف شده اند؟
۱۶۴	۳-۵-۵ استفاده از تبدیلات بهینه بدون استفاده از تجربیات شخصی
۱۶۹	۴-۵-۵ عملکرد الگوریتم ACE هنگامی که همبستگی میان متغیرها ضعیف است
۱۷۲	۵-۵-۵ عملکرد الگوریتم ACE وقتی که داده ها متعلق به دو دسته مختلف باشند
۱۷۴	۶-۵-۵ ** الگوریتم ACE به ترتیب ورود متغیرهای پیش بین حساس است

۷-۵-۵ در حالت با یک متغیر پیش بین، الگوریتم ACE نسبت به X و Y متقارن است.....	۱۷۶
۸-۵-۵ الگوریتم ACE همیشه تبدیلات مدل را تولید نمی کند.....	۱۷۶
۹-۵-۵ الگوریتم ACE تحت تبدیلات یکنوازی متغیرهای پیش بین پایا نیست.....	۱۷۸
۶-۵ پیش بینی با استفاده از الگوریتم ACE.....	۱۷۹
۱-۶-۵ روش برآورد مستقیم.....	۱۷۹
۲-۶-۵ روش برآورد هموار شده.....	۱۷۹
۳-۶-۵ روش برآورد آلوده شده.....	۱۸۰
فصل ششم	
برآورد ناپارامتری تبدیلات بهینه در رگرسیون.....	۱۸۱
با استفاده از الگوریتم جمع پذیری و ثبات واریانس.....	۱۸۱
۱-۶ مقدمه.....	۱۸۱
۲-۶ معرفی الگوریتم جمع پذیری و ثبات واریانس(AVAS).....	۱۸۲
۳-۶ ویژگی ها خواص الگوریتم AVAS.....	۱۸۷
۱-۳-۶ استفاده از الگوریتم AVAS در عمل.....	۱۸۷
۲-۳-۶ خوش های جدا از هم.....	۱۹۰
۳-۶ ** الگوریتم AVAS به ترتیب ورود متغیرهای پیش بین حساس است.....	۱۹۸
۴-۳-۶ در حالت با یک متغیر پیش بین، الگوریتم AVAS نسبت به X و Y متقارن نیست.....	۱۹۸
۵-۳-۶ الگوریتم AVAS تبدیلات مدل را تولید می کند.....	۱۹۹
۶-۳-۶ الگوریتم AVAS تحت تبدیلات یکنوازی متغیرهای پیش بین پایا است.....	۲۰۰
ضمیمه ۱: مثال هایی از برنامه های R	۲۰۱
ضمیمه ۲: مراجع	۲۱۲

Equation Section 1

فصل اول

رگرسیون خطی

۱-۱ رگرسیون خطی ساده

۱-۱-۱ برازش مدل رگرسیون خطی ساده

چنانچه اشاره کردیم، تحلیل رگرسیون یک روش آماری برای بررسی و الگو بندی رابطه بین متغیرهاست. در ساده ترین حالت رگرسیون خطی فرض می شود که متغیرها بوسیله یک معادله خط راست در ارتباط اند، لذا با مرواری از خط راست شروع می کنیم. شکل کلی یک خط راست بصورت $Y = \beta_0 + \beta_1 X$ است که در آن β_0 را عرض از مبدا و β_1 را شیب خط می نامند. در این قسمت به مطالعه حالت ساده رابطه بین یک متغیر پاسخ Y و یک متغیر پیش‌بین X می پردازیم. این الگوی رگرسیون خطی ساده عبارت است از

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad i = 1, 2, \dots, n \quad (1.1)$$

که در آن ε یک جمله خطاست که متغیری است تصادفی و غیر قابل مشاهده. در ضمن $E(\varepsilon) = 0$ و $Var(\varepsilon) = \sigma^2$ فرض می شود و علاوه بر آن ε ها ناهمبسته فرض می شوند. ثابت کنید که متغیر پاسخ Y یک متغیر تصادفی پیوسته است در حالی که X تصادفی نبوده و توسط تحلیل گر کنترل و با خطای قابل اغماضی اندازه گیری می شود. بنابراین در هر مقدار ممکن X برای Y یک توزیع احتمال وجود دارد. چون X تصادفی نیست، لذا می توان نوشت

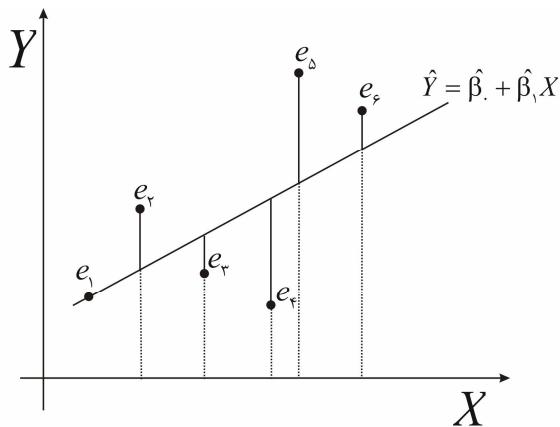
$$E(Y) = \beta_0 + \beta_1 X$$

و می گوئیم رگرسیون Y بر X خطی است. پارامترهای β_0 و β_1 را معمولاً ضرایب رگرسیون می نامند و در واقع پارامترهایی هستند که باید براورد شوند.

این ضرایب اغلب تعبیر ساده و مفیدی دارند. β_1 در واقع میزان افزایش در میانگین Y است هنگامی که یک واحد افزایش در متغیر پیش‌بین (X) رخ می دهد. در صورتی که دامنه داده ها شامل $X = 0$ باشد در آن صورت β_0 میانگین متغیر پاسخ Y به ازای $X = 0$ است در غیر این صورت β_0 هیچگونه تعبیر عملی ندارد.

اولین سوالی که در مسئله رگرسیون خطی ساده مطرح می شود، این است که چگونه با داشتن یک نمونه Y_1, Y_2, \dots, Y_n همراه با مقادیر متناظر متغیر X یعنی X_1, X_2, \dots, X_n ، ضرایب β_0 و β_1 را براورد کنیم؟

استفاده از روش کمترین مربعات، یک روش ساده و منطقی برای پاسخ دادن به این سوال است. در این روش بهترین خط راست برازش شده خطی است که مجموع توانهای دوم خطاهای (توان دوم طول قطعه خطهای عمودی رسم شده در نمودار پراکنش شکل ۱-۱) را مینیمم کند. ایده اصلی در اینجا این است که هر چه انحرافات مقادیر مشاهده شده از این خط کمتر باشد خط برازش شده به داده ها نزدیک تر است. بنابراین در این روش $\hat{\beta}_0$ و $\hat{\beta}_1$ را طوری تعیین می کنیم که مجموع توانهای دوم خطاهای یعنی $\sum_{i=1}^n e_i^2 = e_1^2 + e_2^2 + \dots + e_n^2$ مینیمم شود، که در آن e_i تفاوت بین مقدار واقعی Y_i و خطها یعنی $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_i$ است.



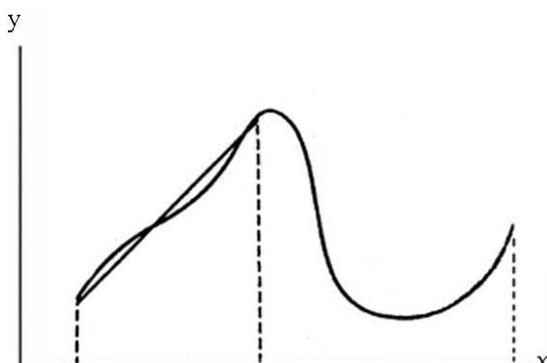
شکل ۱-۱ برازش خط رگرسیون با استفاده از روش کمترین توانهای دوم

برای بدست آوردن $\hat{\beta}_1$ و $\hat{\beta}_0$ ، کافی است از $\sum_{i=1}^n e_i$ نسبت به $\hat{\beta}_1$ و $\hat{\beta}_0$ مشتق گرفته و مساوی صفر قرار دهیم. در این صورت به دست خواهیم آورد:

$$\hat{\beta}_1 = \bar{Y} - \hat{\beta}_0 \bar{X} \quad \hat{\beta}_0 = \frac{\sum_{i=1}^n X_i Y_i - n \bar{X} \bar{Y}}{\sum_{i=1}^n X_i^2 - n \bar{X}^2} \quad (2.1)$$

۲-۱-۱ خطر برون یابی در رگرسیون

نکته مهمی که باید به آن توجه داشت این است که چون معادلات رگرسیون تنها تقریبی از رابطه واقعی X و Y هستند، لذا این معادلات عموماً فقط در ناحیه‌ای که مقادیر متغیرهای پیش‌بین مشاهده شده اند معتبر هستند، و نمی‌توان در خارج از این ناحیه، از این معادلات استفاده کرد. به عنوان مثال فرض کنید که داده‌های (x, y) در بازه $x_1 \leq x \leq x_2$ جمع آوری شده باشند. در این بازه معادله رگرسیون خطی یک تقریب خوب از رابطه واقعی میان X و Y است. حال فرض کنید که بخواهیم از این معادله خط رگرسیون برآورده شده برای پیش‌بینی مقدار Y در بازه $x_2 \leq x \leq x_3$ استفاده کنیم، واضح است که این معادله خط رگرسیون برآورده شده عملکرد خوبی در این ناحیه از مقادیر x را به دلیل خطای تشخیص نامناسب الگو ندارد. (شکل ۱-۲).



شکل ۱-۲ خطر برون یابی در رگرسیون

۱-۳-۱ اندازه‌ای از کیفیت برآورد خط راست

به محض اینکه خط کمترین توان‌های دوم تعیین شد می‌خواهیم ارزیابی کنیم که آیا خط برآورد شده واقعاً در تخمین Y به ما کمک می‌کند یا خیر و اگر کمک می‌کند این کمک به چه میزان است. برای این منظور اگر فرض کنیم

$$x_i = X_i - \bar{X} \quad \text{انحراف از میانگین } X \text{ ها}$$

$$y_i = Y_i - \bar{Y} \quad \text{انحراف از میانگین } Y \text{ ها}$$

$$\hat{y}_i = \hat{Y}_i - \bar{Y} \quad \text{انحراف از میانگین } \hat{Y} \text{ ها}$$

می‌توان نوشت:

$$\sum_{i=1}^n x_i^2 = \sum_{i=1}^n (X_i - \bar{X})^2 = SS_x \quad \text{پراکندگی کل:}$$

$$\sum_{i=1}^n y_i^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 = SS_y = SS_T \quad \text{پراکندگی تبیین شده:}$$

$$\sum_{i=1}^n \hat{y}_i^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = SS_{\hat{y}} = SS_R \quad \text{پراکندگی تبیین نشده:}$$

با این نمادها در قضیه ۱-۱ نشان می‌دهیم که:

$$SS_T = SS_R + SS_{\text{Res}} \quad (3.1)$$

یکی از منابع پراکندگی SS_y ملاحظه می‌کنیم که $SS_{\hat{y}}$ است که عامل این پراکندگی صرفاً متغیر پیش‌بین X است و چون \hat{Y} یکتابع خطی از X است، لذا $SS_{\hat{y}}$ را می‌توان قسمتی از پراکندگی Y که به وسیله X قابل توجیه است نامید به همین دلیل $SS_{\hat{y}}$ را پراکندگی بیان شده (تبیین شده)^۱ یا نوسانات بیان شده (تبیین شده) متغیر وابسته می‌نامند. از طرفی با توجه به رابطه (۱-۳) پراکندگی Y به اندازه $SS_{\hat{y}}$ بیش از پراکندگی \hat{Y} است، بنابراین $SS_{\hat{y}}$ سهمی از پراکندگی Y است که توسط تغییرات X قابل توجیه نمی‌باشد و معلول اثر متغیرهای دیگری است که بر Y موثرند و در الگو لحظه نشده‌اند. به این دلیل $SS_{\hat{y}}$ را پراکندگی یا نوسانات بیان نشده (تبیین نشده)^۲ می‌نامیم. مجموع مربعات تبیین شده^۳ و مجموع مربعات خطأ^۴ به ترتیب نام‌های دیگر $SS_{\hat{y}}$ و SS_{Res} می‌باشند.

¹ Explained variations

² Unexplained variations

³ Explained sum of squares

⁴ Error sum of squares

رابطه (۱-۳) به رابطه تجزیه واریانس موسوم است. واضح است که $\frac{SS_{\hat{Y}}}{SS_Y} \leq 1$ و می‌تواند معیار

خوبی برای میزان دقیق رابطه خطی Y با X باشد و چون مثبت است می‌توان آن را با R^* نشان داد که آن را ضریب تعیین می‌نامند بنابراین

$$R^* = \frac{SS_{\hat{Y}}}{SS_Y} = \frac{SS_R}{SS_T}$$

$$= \frac{\text{پراکندگی بیان شده به وسیله}}{\text{پراکندگی کل}}$$

توجه می‌کنیم که هر چه مقدار ضریب تعیین R^* به یک نزدیک‌تر باشد به معنای برازش بهتر خط رگرسیون بوده و هر چه مقدار R^* به صفر نزدیک باشد دال بر خوب نبودن برازش است. می‌توان گفت مقدار ضریب تعیین R^* درصدی از تغییرات متغیر وابسته Y است که به وسیله متغیر پیش‌بین X تبیین و توجیه می‌شود.

در مساله‌ای اگر $R^* = 0.9$ شود، به این معنی است که ۹۰ درصد از تغییرات متغیر وابسته Y توسط متغیر پیش‌بین X قابل توجیه است. ده درصد باقیمانده در واقع معلول عواملی است که در رگرسیون لحاظ نشده‌اند. بنابراین در این مثال متغیر پیش‌بین قادر به تبیین تمام تغییرات متغیر وابسته Y نمی‌باشد. فرض کنید Y (تولید) و X (سرمایه) است و یک رابطه خطی ساده نیز بین این دو متغیر برقرار است و فرض کنید بر اساس مشاهدات مربوط به Y و X مقدار ضریب تعیین برابر $R^* = 0.95$ شده است. می‌توان گفت سرمایه ۹۵ درصد از تغییرات تولید را تولید می‌کند و پنج درصد باقیمانده معلول متغیرهای دیگری است که در معادله رگرسیون لحاظ نشده‌اند.

قضیه ۱-۱ (رابطه تجزیه واریانس)

پراکندگی متغیر پاسخ Y را می‌توان به دو منبع پراکندگی تبیین شده و پراکندگی تبیین نشده تجزیه کرد یعنی:

$$SS_Y = SS_{\hat{Y}} + SS_e$$

برهان

$$\begin{aligned} SS_{\hat{Y}} &= \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 = \sum_{i=1}^n ((\hat{\beta}_0 + \hat{\beta}_1 X_i) - \bar{Y})^2 \\ &= \sum_{i=1}^n (\bar{Y} - \hat{\beta}_0 \bar{X} + \hat{\beta}_1 X_i - \bar{Y})^2 \end{aligned}$$

$$= \sum_{i=1}^n \hat{\beta}_1' (X_i - \bar{X}) = \hat{\beta}_1' \sum_{i=1}^n x_i' = \hat{\beta}_1' S S_X$$

از طرفی می توان نوشت:

$$\begin{aligned} \sum_{i=1}^n e_i' &= \sum_{i=1}^n (Y_i - \hat{Y}_i)' = \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)' \\ &= \sum_{i=1}^n (Y_i - \bar{Y} + \hat{\beta}_0 \bar{X} - \hat{\beta}_1 X_i)' \\ &= \sum_{i=1}^n ((Y_i - \bar{Y}) - \hat{\beta}_1 (X_i - \bar{X}))' \\ &= \sum_{i=1}^n (y_i - \hat{\beta}_1 x_i)' = \sum_{i=1}^n y_i' - \hat{\beta}_1 \sum_{i=1}^n x_i y_i + \hat{\beta}_1 \sum_{i=1}^n x_i' \\ &= \sum_{i=1}^n y_i' - \hat{\beta}_1 \left(\hat{\beta}_0 \sum_{i=1}^n x_i' \right) + \hat{\beta}_1 \sum_{i=1}^n x_i' \\ &= \sum_{i=1}^n y_i' - \hat{\beta}_1' \sum_{i=1}^n x_i' \\ \sum_{i=1}^n e_i' &= \sum_{i=1}^n y_i' - \sum_{i=1}^n \hat{y}_i' \end{aligned}$$

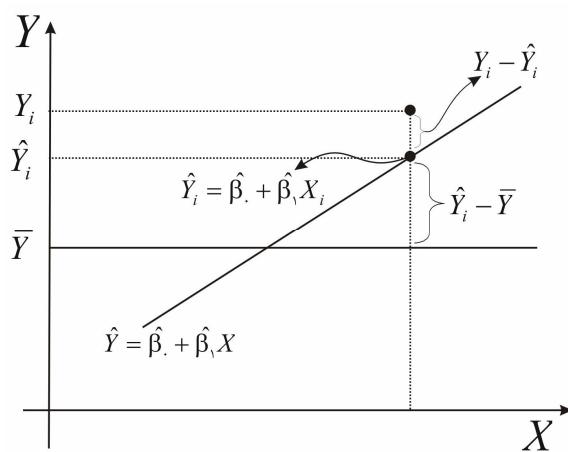
در نتیجه

و یا

$$\sum_{i=1}^n y_i' = \sum_{i=1}^n \hat{y}_i' + \sum_{i=1}^n e_i'$$

و حکم ثابت شده است.

در شکل زیر مقادیر $e_i = Y_i - \hat{Y}_i$ و $\hat{y}_i = \hat{Y}_i - \bar{Y}$ ، $y_i = Y_i - \bar{Y}$ ، \hat{Y}_i ، Y_i نشان داده شده اند.



شکل ۳-۱

۱-۲ رگرسیون خطی چندگانه

۱-۲-۱ برازش الگو در رگرسیون چندگانه

فرض کنید قد پسر به قد مادر و قد پدر مرتبط است. الگوی رگرسیون چندگانه ای که این رابطه را بیان می کند، بصورت زیر است:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon \quad (4.1)$$

که در آن Y قد پسر و X_1 قد مادر و X_2 قد پدر است. این یک الگوی رگرسیون خطی چندگانه با دو متغیر پیش‌بین X_1 و X_2 می‌باشد. علت آنکه این الگو را خطی می‌گوئیم، این است که معادله فوق $X_1 = X_2 = 0$ یک تابع خطی از پارامترهای مجھول $\beta_0, \beta_1, \beta_2$ می‌باشد. در صورتی که داده‌ها شامل $X_1 = X_2 \neq 0$ باشد، β_0 در واقع میانگین Y ، وقتی که $X_1 = X_2 = 0$ است، می‌باشد. در غیر اینصورت β_0 هیچ گونه تعبیری ندارد. تغییر مورد انتظار در Y را به ازاء یک واحد تغییر در X_1 در صورت ثابت بودن X_2 نشان می‌دهد و همینطور پارامتر β_1 تغییر مورد انتظار در Y را به ازاء یک واحد تغییر در X_2 در صورت ثابت بودن X_1 نشان می‌دهد.

در حالت کلی متغیر پاسخ Y ممکن است با k متغیر پیش‌بین رابطه داشته باشد که در این صورت داریم:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (5.1)$$

و این را الگوی رگرسیون خطی چندگانه با k متغیر پیش‌بین می‌نامند. پارامترهای $\beta_0, \beta_1, \dots, \beta_k$ را ضرایب رگرسیون می‌نامند. پارامتر β_j تغییر مورد انتظار در متغیر پاسخ Y را به ازاء یک واحد تغییر از X_j نشان می‌دهد هر گاه تمام متغیرهای پیش‌بین دیگر ثابت تلقی شوند.

توجه داریم که رابطه تابعی واقعی بین Y و متغیرهای پیش‌بین X_1, X_2, \dots, X_k معلوم نیست، ولی روی دامنه‌ای از متغیرهای پیش‌بین می‌توانیم الگوی رگرسیون خطی را بعنوان یک تقریب مناسب برای تابع مجھول مورد نظر پیدا کنیم. بنابراین الگوی رگرسیون خطی اغلب به عنوان الگوهای تجربی مورد استفاده قرار می‌گیرند. می‌دانیم که مقادیر ضرایب رگرسیون و واریانس خطای σ^2 معلوم نیستند و بایستی با توجه به داده‌های نمونه برآورد شوند.

در رگرسیون چندگانه داده‌های ما بصورت

$$(Y_1, X_{11}, \dots, X_{k1}), (Y_2, X_{12}, \dots, X_{k2}), \dots, (Y_n, X_{1n}, \dots, X_{kn})$$

بوده و می‌خواهیم یک رابطه خطی مانند $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \dots + \hat{\beta}_k X_k$ را به این داده‌ها برازش دهیم.

مناسب تر است که وقتی با رگرسیون چندگانه سروکار داریم از نماد ماتریسی استفاده کنیم، لذا الگوی رگرسیون نمونه را بصورت زیر می نویسیم:

$$\mathbf{Y} = \mathbf{X}\hat{\boldsymbol{\beta}} + \mathbf{e} \quad (6.1)$$

که در آن:

$$\begin{array}{lllll} \text{بردار} & \text{ضرایب} & \text{رگرسیون} & \text{مشاهدات} & \text{متغیر} \\ \text{بردار} & \text{رگرسیون} & \left[\hat{\beta}_0 \quad \hat{\beta}_1 \quad \cdots \quad \hat{\beta}_k \right]_{n \times (k+1)} & \text{متغیر} & \text{وابسته} \\ \mathbf{Y}' = [Y_1 \quad Y_2 \quad \cdots \quad Y_n]_{n \times 1} \end{array}$$

$$\mathbf{X} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1k} \\ 1 & X_{21} & X_{22} & \cdots & X_{2k} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{nk} \end{bmatrix}_{n \times (k+1)}$$

ماتریس مشاهدات متغیرهای پیش‌بین (ماتریس طرح)

$$\text{بردار مقادیر پیش‌بینی شده متغیر وابسته مانده ها (خطا)} \quad \hat{\mathbf{Y}}' = [\hat{Y}_1 \quad \hat{Y}_2 \quad \cdots \quad \hat{Y}_n]_{n \times 1}$$

$$\mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}_{n \times 1}$$

بنابراین رابطه $\hat{\mathbf{Y}} = \mathbf{X}\hat{\boldsymbol{\beta}}$ نوشته ضمن $i=1, 2, \dots, n$ را می‌توان بصورت $\hat{Y}_i = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \dots + \hat{\beta}_k X_{ik}$ خواهد بود. می‌توان نوشت:

$$\begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_n \end{bmatrix}_{n \times 1} = \begin{bmatrix} 1 & X_{11} & \cdots & X_{1k} \\ 1 & X_{21} & & X_{2k} \\ \vdots & \vdots & & \vdots \\ 1 & X_{n1} & \cdots & X_{nk} \end{bmatrix}_{n \times (k+1)} \times \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_k \end{bmatrix}$$

در مورد خطاهای نیز می‌توان نوشت:

$$\begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} - \begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_n \end{bmatrix}$$

حال اگر بخواهیم مجموع توان‌های دوم خطاهای را مینیمم کنیم، داریم:

$$\begin{aligned}\sum_{i=1}^n e_i^r &= \mathbf{e}' \mathbf{e} = (\mathbf{Y} - \hat{\mathbf{Y}})' (\mathbf{Y} - \hat{\mathbf{Y}}) = (\mathbf{Y}' - \hat{\mathbf{Y}}')(\mathbf{Y} - \hat{\mathbf{Y}}) \\ &= \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\hat{\mathbf{Y}} - \hat{\mathbf{Y}}'\mathbf{Y} + \hat{\mathbf{Y}}'\hat{\mathbf{Y}} = \mathbf{Y}'\mathbf{Y} - \mathbf{Y}'\mathbf{X}\hat{\beta} - \hat{\beta}'\mathbf{X}'\mathbf{Y} + \hat{\beta}'\mathbf{X}'\mathbf{X}\hat{\beta}\end{aligned}$$

چون $\hat{\beta}'\mathbf{X}'\mathbf{Y}$ یک اسکالر است لذا با ترانهاده خود یعنی $\mathbf{Y}'\mathbf{X}\hat{\beta}$ برابر است لذا خواهیم داشت:

$$\begin{aligned}\mathbf{e}' \mathbf{e} &= \sum_{i=1}^n e_i^r = \mathbf{Y}'\mathbf{Y} - 2\mathbf{X}'\mathbf{Y}\hat{\beta} + \hat{\beta}'\mathbf{X}'\mathbf{X}\hat{\beta} \\ \frac{\partial \mathbf{e}' \mathbf{e}}{\partial \hat{\beta}} &= -2\mathbf{X}'\mathbf{Y} + 2\mathbf{X}'\mathbf{X}\hat{\beta} = . \quad \text{بنابراین} \\ \mathbf{X}'\mathbf{X}\hat{\beta} &= \mathbf{X}'\mathbf{Y} \quad \text{یا}\end{aligned}$$

$$\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} \quad (7.1)$$

مالحظه می کنیم که برای بدست آوردن برآورد ضرایب لازم است ابتدا وارون ماتریس $\mathbf{X}'\mathbf{X}$ و سپس بردار $\mathbf{X}'\mathbf{Y}$ را محاسبه نموده در هم ضرب کنیم. اگر متغیرهای پیش‌بین مستقل خطی باشند یعنی هیچ ستون ماتریس \mathbf{X} یک ترکیب خطی از ستون‌های دیگر نباشد در آن صورت $(\mathbf{X}'\mathbf{X})^{-1}$ وجود خواهد داشت. ضمناً بدیهی است که اگر $n < k+1$ باشد آنگاه $\mathbf{X}'\mathbf{X}$ وارون پذیر نخواهد بود، یعنی یک شرط لازم برای وجود برآوردهای می‌نیموم مربعات ضرائب رگرسیون خطی این است که حجم نمونه بزرگ‌تر از تعداد متغیرهای پیش‌بین باشد.

ماتریس $\mathbf{H} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ ^۵ را ماتریس برازش می‌نامند و این ماتریس نقش مهمی در تحلیل رگرسیون دارد. بردار مانده‌های (خطاهای) \mathbf{e} را با استفاده از ماتریس \mathbf{H} بصورت زیر می‌توان نوشت:

$$\mathbf{e} = \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\beta} = \mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \mathbf{Y} - \mathbf{HY}$$

یا

$$\mathbf{e} = (\mathbf{I} - \mathbf{H})\mathbf{Y}$$

با ضرب طرفین رابطه فوق در \mathbf{X}' (از سمت چپ) داریم

$$\begin{aligned}\mathbf{X}'\mathbf{e} &= \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{X}\hat{\beta} \\ &= \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{Y} = .\end{aligned}$$

که معادل است با

^۵ Hat Matrix

$$\left\{ \begin{array}{l} \sum_{i=1}^n e_i = 0 \\ \sum_{i=1}^n e_i X_{i1} = 0 \\ \sum_{i=1}^n e_i X_{i2} = 0 \\ \vdots \\ \sum_{i=1}^n e_i X_{ik} = 0 \end{array} \right. \quad (A.1)$$

در رگرسیون چند گانه، نیز همانند رگرسیون ساده، رابطه تجزیه واریانس برقرار است. که آن را در قضیه زیر بیان می کنیم.

قضیه ۲-۱

در رگرسیون چند گانه نیز رابطه تجزیه واریانس برقرار است، یعنی:

$$\sum_{i=1}^n y_i^r = \sum_{i=1}^n \hat{y}_i^r + \sum_{i=1}^n e_i^r$$

برهان

می توان نوشت:

$$\begin{aligned} \sum_{i=1}^n (Y_i - \bar{Y})^r &= \sum_{i=1}^n (Y_i - \hat{Y}_i + \hat{Y}_i - \bar{Y})^r = \sum_{i=1}^n ((\hat{Y}_i - \bar{Y}) + (Y_i - \hat{Y}_i))^r \\ &= \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^r + \sum_{i=1}^n (Y_i - \hat{Y}_i)^r + 2 \sum_{i=1}^n (\hat{Y}_i - \bar{Y})(Y_i - \hat{Y}_i) \end{aligned}$$

حال اگر نشان دهیم جمله سوم طرف راست تساوی فوق صفر است حکم ثابت می شود. اما می

توان نوشت:

$$\begin{aligned} \sum_{i=1}^n (\hat{Y}_i - \bar{Y})(Y_i - \hat{Y}_i) &= \sum_{i=1}^n e_i (\hat{Y}_i - \bar{Y}) \\ &= \sum_{i=1}^n e_i \hat{Y}_i - \bar{Y} \sum_{i=1}^n e_i = 0 \end{aligned}$$

و برهان کامل است.

۱-۲-۱ ضریب تعیین در رگرسیون چندگانه

مطابق تعریف می دانیم که ضریب تعیین (R^r) حاصل تقسیم پراکندگی بیان شده به پراکندگی کل است لذا داریم،

$$R^r = \frac{\hat{\beta} \mathbf{X}' \mathbf{Y} - n \bar{Y}^r}{\mathbf{Y}' \mathbf{Y} - n \bar{Y}^r} \quad (9.1)$$

قضیه ۳-۱:

با افزایش متغیرهای پیش‌بین، ضریب تعیین دست کم کاهش نمی‌یابد.

برهان

فرض کنید ضریب تعیین رگرسیون Y بر k متغیر پیش‌بین X_1, \dots, X_k را با R^r و مجموع توان‌های دوم خطای آن را با $\sum_{i=1}^n e_i^r$ نشان دهیم و ضریب تعیین رگرسیون Y بر $k+1$ متغیر پیش‌بین X_1, \dots, X_k, X_{k+1} را با R_1^r و مجموع توان‌های دوم خطای آن را با $\sum_{i=1}^n e_{i1}^r$ نشان دهیم، باید ثابت کنیم که: $R_1^r \leq R^r$

و یا به عبارتی دیگر باید نشان دهیم که:

$$R_1^r = 1 - \frac{\sum_{i=1}^n e_{i1}^r}{\sum_{i=1}^n y_i^r} < 1 - \frac{\sum_{i=1}^n e_i^r}{\sum_{i=1}^n y_i^r}$$

و یا به طور معادل:

$$\sum_{i=1}^n e_{i1}^r \geq \sum_{i=1}^n e_i^r$$

اما این رابطه به وضوح برقرار است، زیرا اگر تعريف کنیم:

$$\Phi(\beta_0, \beta_1, \dots, \beta_k, \beta_{k+1}) = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_{i1} - \dots - \beta_k X_{ik} - \beta_{k+1} X_{i(k+1)})^r$$

در این صورت:

$$\sum_{i=1}^n e_{i1}^r = \text{Min}_{\beta_0, \beta_1, \dots, \beta_k, \beta_{k+1}} \Phi(\beta_0, \beta_1, \dots, \beta_k, \beta_{k+1}) \leq \text{Min}_{\beta_0, \dots, \beta_k} \Phi(\beta_0, \beta_1, \dots, \beta_k, \cdot) = \sum_{i=1}^n e_i^r$$

۱-۲-۳ هم خطی و اثرات آن در رگرسیون چندگانه

غالبا تفسیر و استفاده از الگوی رگرسیون چندگانه به برآورد تک تک ضرایب رگرسیون بستگی دارد. به عنوان مثال برخی از استنباط هایی که در رگرسیون چندگانه اعمال می شود، عبارتست از:

۱- تشخیص اثرات نسبی متغیرهای پیش‌بین

۲- پیش‌بینی و برآورد

۳- انتخاب یک مجموعه مناسب از متغیرها برای مدل

اگر هیچ رابطه خطی میان متغیرهای پیش‌بین وجود نداشته باشد، این متغیرها متعامد^۶ نامیده می شوند. هنگامی که متغیرهای پیش‌بین متعامد باشند، استنباط هایی همانند استنباط های فوق، به سادگی می توانند اتخاذ شوند. اما متأسفانه در بسیاری از موارد در عمل، متغیرهای پیش‌بین متعامد نیستند. گاهی اوقات، عدم وجود تعامد در متغیرهای پیش‌بین مساله بسیار حادی نیست. اما اگر در یک الگوی رگرسیون متغیرهای پیش‌بین به صورت کامل و یا تقریباً کامل، وابسته خطی باشند، در این صورت ممکن است استنباط بر اساس این الگوی رگرسیون تاحد بسیاری گمراه کننده و پراستبهای باشد. در این هنگام می گوییم که میان متغیرها در الگوی رگرسیون همخطی^۷ وجود دارد.

اگر یکی از متغیرهای پیش‌بین یک تابع دقیق خطی از یک یا چند متغیر پیش‌بین دیگر باشد گوئیم رگرسیون دارای **همخطی کامل**^۸ است. همخطی ناقص وقتی اتفاق می افتد که یکی از متغیرهای پیش‌بین بطور تقریبی یک تابع خطی از یک یا چند متغیر پیش‌بین دیگر باشد. به عبارت دیگر همخطی کامل زمانی رخ می دهد که ($\text{لاقل به ازای یک } j = R_j^r$) و همخطی ناقص زمانی پیش می آید که ($\text{لاقل به ازای یک } j \approx R_j^r$ ، که R_j^r ضریب تعیین رگرسیون خطی r بر سایر متغیرهای پیش‌بین است. بعنوان مثال فرض کنید که استحکام یک مفتول را به دو متغیر قطر مقطع و محیط مقطع وابسته بدانیم. در این حالت واضح است که متغیر پیش‌بین محیط مقطع تابعی از متغیر پیش‌بین قطر مقطع است و لذا همخطی کامل وجود دارد و این همخطی بنیادی است یعنی مربوط به نمونه نمی باشد. البته توجه داریم که همخطی بنیادی عموماً در عمل رخ نمی دهد زیرا همواره با خطای اندازه گیری مواجه هستیم. هم خطی کامل در عمل هنگامی رخ می دهد که کاربر به اشتباه در الگوی رگرسیون یکی از متغیرها را تابعی خطی از متغیر دیگر قرار دهد و یا وقتی تعداد متغیرهای پیش‌بین بیشتر از تعداد مشاهدات باشد نیز مساله همخطی کامل به وجود می آید. با این قبیل الگوها معمولاً در علوم رفتاری و پژوهشی مواجه می شویم، زیرا که ممکن است فقط تعداد کمی از واحدهای نمونه وجود داشته باشد و اطلاعات برای تعداد زیادی از

⁶Orthogonal

⁷Collinearity

⁸Exact collinearity

متغیرهای پیش‌بین روی هر آزمودنی گردآوری شود. در این قبیل موارد راه حل این است که بعضی از متغیرهای پیش‌بین را حذف کنیم.

همچنین منابع اصلی همخطی ناقص را می‌توان به سه دسته تقسیم نمود:

- (۱) انتخاب روش گردآوری داده‌ها
- (۲) گذاشتن قیدهایی روی الگو یا در جامعه
- (۳) شناسایی الگو

هنگامی که تحلیل گر تنها از یک زیرفضای ناحیه متغیرهای پیش‌بین نمونه گیری می‌کند روش گردآوری داده‌ها ممکن است مساله همخطی را به وجود آورد. همخطی حاصل از روش نمونه گیری در الگو یا در جامعه ای که از آن نمونه گرفته شده است ذاتی نیست.

همچنین قیدهایی روی الگو یا در جامعه ای که از آن نمونه گیری شده می‌تواند همخطی را به وجود آورد. برای مثال فرض کنید در می‌خواهیم اثر میزان شکر (X_1) و میزان آبلیمو (X_2) را روی مقدار شیرینی یک لیوان شربت آبلیمو بررسی کنیم در این صورت همخطی صرف نظر از روش نمونه گیری انتخاب شده وجود خواهد داشت. این قیدها عموماً در مسائلی نظیر تولید یک محصول و یا فرآیندهای شیمیایی رخ می‌دهند، هنگامی که متغیرهای پیش‌بین مولفه‌های تشکیل دهنده متغیر پاسخ هستند.

انتخاب الگو نیز سبب همخطی می‌شود. از مبحث الگوی رگرسیون چندجمله‌ای می‌دانیم که وقتی مرتبه چندجمله‌ای زیاد می‌شود ماتریس \mathbf{X} دچار بدشرطی می‌شود، بدین معنی که محاسبه وارون ماتریس نادقيق خواهد بود و در برآورد پارامترها خطای قابل ملاحظه ای به وجود می‌آیند. علاوه بر این اگر دامنه X کوچک باشد افزودن جمله X^3 می‌تواند همخطی معنی داری را حاصل کند. زیرا ممکن است در یک بازه کوچک، رابطه میان X و X^3 تقریباً خطی باشد. اغلب وقتی با این وضعیت مواجه می‌شویم که دو یا چند متغیر پیش‌بین تقریباً وابسته خطی باشند و نگاهداشتن تمام این متغیرها ممکن است موجب همخطی شود. در این موارد از نقطه نظر همخطی انتخاب زیرمجموعه ای از متغیرها معمولاً ترجیح داده می‌شود.

گاهی اوقات ملاحظه آماره F برای معنی داری رگرسیون همراه با آماره t (یا F جزیی) وجود همخطی را نشان می‌دهد. اگر آماره F کلی معنی دار باشد (آزمون معنی داری کلی رگرسیون) ولی آماره‌های t همگی معنی دار نباشند، می‌تواند دال بر وجود همخطی ناقص باشد. متأسفانه بسیاری از مجموعه داده‌هایی که همخطی معنی داری دارند این رفتار را نشان نمی‌دهند و لذا سودمندی این معیار همخطی سوال برانگیز است.

اثرات همخطی

همخطی ناقص باعث می شود که دترمینان ماتریس $\mathbf{X}'\mathbf{X}$ بسیار کوچک شود و در نتیجه ماتریس $(\mathbf{X}'\mathbf{X})^{-1}$ ، دارای اعضايی باشند که از لحاظ قدرمطلق بسیار بزرگ هستند و چون $Var(\hat{\beta}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$ لذا واریانس های برآوردهای $\beta_1, \beta_2, \dots, \beta_k$ بسیار بزرگ می شود. یعنی $\hat{\beta}_k$ که به طریق کمترین توان های دوم از فرمول $\hat{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$ بدست می آیند برآوردهای دقیقی از ضرایب $\beta_1, \beta_2, \dots, \beta_k$ نمی باشند. به عبارت دیگر دقت برآورد ضرایب رگرسیون بسیار کم می شود. علاوه بر این $\hat{\beta}$ ناپایدار است. یعنی با تغییر کوچکی در مقادیر متغیرهای پیش بین، مقادیر موجود در $\hat{\beta}$ تغییرات زیادی پیدا می کنند و در نتیجه محاسبه $\hat{\beta}$ توسط دو کامپیوتر متفاوت (با دو روش روند کردن متفاوت) ممکن است جواب های کاملاً متفاوتی برای $\hat{\beta}$ به دست دهند. همچنین در صورت وجود همخطی کامل ماتریس $(\mathbf{X}'\mathbf{X})$ وارون پذیر نبوده (زیرا این ماتریس تمام رتبه نمی شود) و در نتیجه برای برآورد ضرایب جواب یکتا وجود نخواهد داشت.

عامل تورم واریانس

یکی از معیارهای رایج و پراستفاده برای تشخیص همخطی در مدل رگرسیون، عامل تورم واریانس است.

این معیار به صورت $VIF_j = \frac{1}{1-R_j^2}$ تعریف می شود که در آن R_j ضریب تعیین رگرسیون X_j بر سایر

متغیرهای پیش بین است.

برای برآوردهای ضرایب مدل رگرسیون $Y = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k + \epsilon$ ، ثابت می شود که:

$$Var(\hat{\beta}_j) = \frac{\sigma^2}{nS_j^2} VIF_j, \quad j \geq 1 \quad (10.1)$$

که در آن $\hat{\beta}_j$ برآورد کمترین مربعات β_j و σ^2 واریانس جمله خطا و S_j^2 واریانس نمونه متغیر پیش بین j است.

واضح است که (به ازای مقادیر ثابتی برای S_j^2) هرچه قدر VIF_j بیشتر باشد، مقدار واریانس $\hat{\beta}_j$ بیشتر خواهد شد به عبارت دیگر اگر $1 \rightarrow R_j \rightarrow 1$ در این صورت $VIF_j \rightarrow \infty$ و لذا $Var(\hat{\beta}_j) \rightarrow \infty$.

یک مقدار بزرگ R_j این گونه تفسیر می شود که X_j رابطه خطی تقریباً کامل با سایر متغیرهای پیش بین دارد و معمولاً $VIF_j \geq 10$ به عنوان قابل اغماض نبودن مساله همخطی تفسیر می شود.