

رویکرد رگرسیون ریج در مدل‌های خطی جزئی با خطاهای همبسته

مهدی روزبه^۱، جلال چاچی^۱، فاطمه حمیدی^۳

^۱استادیار دانشگاه سمنان

^۲دانشجوی کارشناسی ارشد دانشگاه سمنان

چکیده: در تجزیه و تحلیل مسائل رگرسیونی و بویژه مدل بندی آماری در داده های اقتصادی، روانشناسی، علوم اجتماعی، حیاتی، مهندسی و ... با مشکل همخطی در میان متغیرهای پیشگو و اتوهمبستگی در خطاها مواجه هستیم. در چنین مواقعی برآوردگر کمترین مربعات معمولی منجر به برآوردهای نادقیق از لحاظ مقدار و علامت شده و فواصل اطمینان پهنی را برای پارامترها نتیجه می دهد. هدف از این مقاله، بررسی مشکلات همخطی چندگانه و غلبه بر آن با معرفی برآوردگر رگرسیون ریج تفاضلی محدودشده تعمیم یافته و مقایسه آن با برآوردگر کمترین مربعات تعمیم یافته معمولی است. این برآوردگر، یک برآوردگر تفاضلی محدودشده تعمیم یافته است که از مینیمم کردن مجموع توان های دوم مانده ها و با در نظر گرفتن یک محدودیت کروی روی فضای پارامتر تولید شده است. تابع مخاطره برآوردهای پیشنهاد شده از تابع زیان متعادل محاسبه می شود. سرانجام عملکرد برآورگر جدید با استفاده از داده های شبیه سازی شده ارزیابی می شود. واژه های کلیدی: برآوردگر تفاضلی، برآوردگر ریج، تابع زیان متعادل، مدل خطی جزئی، محدودیت های خطی.

کد موضوع بندی ریاضی (۲۰۱۰): 62J07, 62G08, 62J05.

۱ مقدمه

یک مدل رگرسیون ناپارامتری را در نظر بگیرید

$$y_i = f(t_i) + \epsilon_i, \quad i = 1, 2, \dots, n \quad (1.1)$$

که در آن y_i ها مشاهدات هستند و $f(\cdot)$ یک تابع نامعلوم است. فرض می کنیم ϵ_i ها متغیرهای تصادفی مستقل هم توزیع با میانگین صفر و واریانس σ^2 می باشند و t_i دارای یک دامنه چگال روی بازه ای به طول واحد می باشد و به ترتیب صعودی مرتب شده اند یعنی $t_1 \leq t_2 \leq \dots \leq t_n$ که تعداد مشاهدات در نمونه می باشد. همه آنچه در مورد تابع $f(\cdot)$ می دانیم این است که اولین مشتق $f(\cdot)$

^۳ نام ارائه دهنده مقاله: فاطمه حمیدی fhfh1986@gmail.com

توسط یک ثابت که L نامیده می‌شود، کران‌دار شده است. روش مرسوم در برآورد σ^2 چنین است که ابتدا تابع $f(\cdot)$ را برآورد نموده و سپس با استفاده از ماتریس هموار سازی یا هت، σ^2 را بصورت زیر برآورد می‌کنیم:

$$\sigma_Q^2 = \frac{y'Qy}{tr(Q)} \quad (2.1)$$

بطوریکه $Q = (I - H)'(I - H)$ که H یک ماتریس هموار سازی است. به این نوع برآوردها برآوردهای براساس مانده می‌گوئیم. برآوردهای براساس مانده، به ماتریس هموار سازی وابسته‌اند و انتخاب پارامتر هموار سازی یک مساله عملی مشکل است. در نوع دیگر برآوردها که به برآوردهای تفاضلی مشهور می‌باشند ابتدا روندی را که توسط تابع $f(\cdot)$ در داده‌ها بوجود می‌آید حذف نموده و سپس به برآورد σ^2 می‌پردازیم. در این روش به برآورد تابع $f(\cdot)$ نیاز نداشته و بطور مستقیم σ^2 را برآورد می‌کنیم.

هم‌خطی چندگانه به‌عنوان وجود همبستگی خطی نزدیک میان ستون‌های ماتریس طرح X در مدل خطی $y = X\beta + \epsilon$ تعریف می‌شود که y یک بردار $n \times 1$ پاسخ مشاهدات است، X ماتریس مشاهدات از متغیرهای مستقل با ابعاد $n \times p$ است و فرض می‌شود که X رتبه کامل p است، همچنین β یک پارامتر مجهول است و ϵ یک بردار خطاست. وجود هم‌خطی چندگانه ممکن است فاصله اطمینان عریضی را برای پارامترهای تکی یا ترکیب خطی از پارامترها به‌وجود آورد و یا ممکن است برآوردهایی با علامت‌های اشتباه تولید کند و غیره. بهترین راه بررسی وجود هم‌خطی چندگانه جستجو در مقادیر ویژه و بردارهای ویژه $X'X$ است. مفهوم رگرسیون ریب در سال ۱۹۷۰ توسط هورل وکنارد برای مقابله با هم‌خطی در مسائل رگرسیون پیشنهاد شده است. از آن زمان بسیاری از نویسندگان و محققان این روش را برای توسعه برآوردها اصلی مطالعه نمودند.

نیکویی برازش مدل، معیاری برای قضاوت در مورد عملکرد برآوردهاست که اغلب به طور کلی نادیده گرفته می‌شود. از جمله مزیت‌های نیکویی برازش به تابع زیان این است که اگر برآوردها ناریب استفاده شده باشد نیکویی برازش مینیمم می‌شود. به عبارت دیگر، نیکویی برازش یک جریمه روی کم برآورد تحمیل می‌کند. اما زلنر (۱۹۹۴) با در نظر گرفتن ترکیب توأم نیکویی برازش و دقت برآورد در تابع زیان، تابع زیان متعادل را معرفی کرد. آهتانی و همکاران (۱۹۹۷)، شالاب (۲۰۰۱) و تنبورگ (۲۰۰۵) به مقایسه عملکرد برآوردها با استفاده از تابع مخاطره پرداخته‌اند. بیشتر محققان عملکرد برآوردهای ریب را براساس تمرکز برآورد اطراف مقدار واقعی پارامتر مورد قضاوت قرار داده‌اند. ما در این مقاله، عملکرد برآوردها را با استفاده از تابع مخاطره تحت تابع زیان متعادل بررسی می‌کنیم. در ادامه این مقاله، در بخش ۲، مدل ورویکرد تفاضلی بیان می‌شود. بخش ۳، شامل تعریف برآوردها ریب تفاضلی تعمیم یافته است و تابع مخاطره آن در بخش ۴ مطرح می‌شود. در بخش ۵، برآوردها با یکدیگر مقایسه شده‌اند و سرانجام، برخی تفسیر نتایج بیان شده است.

۲ معرفی مدل

مشاهدات مستقل $(y_1, x_1, t_1) \dots (y_n, x_n, t_n)$ که در آن t و y اسکالر و x یک بردار p بعدی است، را در نظر بگیرید. با استفاده از شکل بردار و ماتریس، مدل‌های خطی جزئی به شکل کلی زیر تعریف می‌شوند:

$$y = X\beta + f(t) + \epsilon \quad (1.2)$$

که در آن $y = (y_1, y_2, \dots, y_n)'$ بردار $n \times 1$ از متغیرهای وابسته، $X = (x_1, x_2, \dots, x_n)'$ یک ماتریس $n \times p$ با p متغیر مستقل و n تکرار برای هر یک، $\beta = (\beta_1, \beta_2, \dots, \beta_p)'$ بردار پارامترهای مجهول است، $f(t) = (f(t_1), \dots, f(t_n))'$ بردار $n \times 1$

اثر غیر خطی و $\epsilon = (\epsilon_1, \dots, \epsilon_n)'$ بردار $n \times 1$ از مؤلفه‌های خطای تصادفی می‌باشد. در حالت کلی فرض می‌کنیم ϵ بردار خطا با $E(\epsilon) = 0$ و $E(\epsilon'\epsilon) = \sigma^2 V$ باشد. از آنجا که مدل‌های خطی جزئی یک مؤلفه پارامتری و یک مؤلفه ناپارامتری دارند از مدل‌های رگرسیون خطی منعطف‌تر هستند. در واقع استفاده از این مدل زمانی که متغیر وابسته y بطور خطی با متغیر مستقل x و بطور غیر خطی با متغیر مستقل t رابطه داشته باشد. مفید است. **ونگ و همکاران (۲۰۰۷)** ثابت کردند که با استفاده از روش تفاضلی با مرتبه زیاد، برآوردگر قسمت خطی بطور مجانبی کارا شده و برآوردگر غیر خطی دارای نرخ همگرایی مینیماکس خواهد بود.

فرض کنید m مرتبه تفاضلی کردن و d_0, \dots, d_m وزن‌های تفاضلی با شرایط زیر باشند:

$$\sum_{j=0}^m d_j = 0, \quad \sum_{j=0}^m d_j^2 = 1 \quad (۲.۲)$$

اکنون با استفاده از این وزن‌ها ماتریس تفاضلی مرتبه m را به صورت زیر تعریف می‌کنیم:

$$D = \begin{pmatrix} d_0 & d_1 & \dots & d_m & 0 & 0 & \dots & 0 \\ 0 & d_0 & d_1 & \dots & d_m & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \dots & 0 & d_0 & d_1 & \dots & d_m \end{pmatrix}$$

استفاده از ماتریس تفاضلی به مدل ۱.۲ اجازه برآورد مستقیم اثر پارامتری را می‌دهد.

با ضرب ماتریس تفاضلی D در طرفین مدل رگرسیونی ۱.۲ خواهیم داشت:

$$Dy = DX\beta + Df(t) + D\epsilon \quad (۳.۲)$$

اکنون می‌توان به نقش شرط ۲.۲ پی برد، نخستین محدودیت در این شرط تضمین می‌کند با نزدیک بودن t_i ها به هم، اثر تابع ناپارامتری پس از تفاضلی کردن از بین می‌رود. بنابراین می‌توانیم معادله ۳.۲ را به صورت

$$Dy = DX\beta + D\epsilon$$

یا

$$\tilde{y} = \tilde{X}\beta + \tilde{\epsilon} \quad (۴.۲)$$

بازنویسی کنیم که در آن $\tilde{y} = Dy$ ، $\tilde{X} = DX$ ، $\tilde{\epsilon} = D\epsilon$ و هستند. با توجه به تعریف D ، $\tilde{\epsilon}$ یک بردار $(n - m)$ تایی با $E(\tilde{\epsilon}\tilde{\epsilon}') = \sigma^2 V_D$ و $E(\tilde{\epsilon}) = 0$ می‌باشد، بطوریکه $V_D = DVD' \neq I_{n-m}$. برای برآورد پارامتر β با استفاده از ضرایب تفاضلی مرتبه دلخواه در معادله ۲.۲ **باتچیو (۱۹۹۷)** برآوردگر تفاضلی β را برای مدل نیمه پارامتری زمانی که $V = I_n$ بصورت زیر تعریف کرد:

$$\hat{\beta} = (\tilde{X}'\tilde{X})^{-1}\tilde{X}'\tilde{y} \quad (۵.۲)$$

بنابراین با روش تفاضلی می‌توان β را بدون در نظر گرفتن مؤلفه ناپارامتری $f(t)$ در مدل ۱.۲ برآورد کرد.

برای ارزیابی پارامتر β در معادله ۱.۲ ما برآوردگر اصلاح شده σ^2 را به صورت زیر معرفی می‌کنیم:

$$\hat{\sigma}^2 = \frac{\tilde{y}'V_D^{-1}(I - P)V_D^{-1}\tilde{y}}{tr(D'(I - P)D)} \quad (۶.۲)$$

که ماتریس افکنش P به صورت زیر تعریف می‌شود:

$$P = V_D^{-1} \bar{X} (\bar{X}' V_D^{-1} \bar{X})^{-1} \bar{X}' V_D^{-1} \quad (۷.۲)$$

۳ برآوردگر تفاضلی ریح محدود شده تعمیم یافته

با توجه به مدل ۴.۲ برآوردگر شناخته شده و نااریب پارامتر β که برآوردگر تفاضلی تعمیم یافته نامیده می‌شود، به صورت زیر است:

$$\hat{\beta}_{GD} = C_D^{-1} \bar{X}' V_D^{-1} \bar{y} \quad (۱.۳)$$

که در آن $C_D = \bar{X}' V_D^{-1} \bar{X}$ می‌باشد. از معادله ۱.۳ مشاهده می‌شود که برآوردگر تفاضلی تعمیم یافته β وابستگی شدیدی به ماتریس مشاهدات C_D دارد. اگر ماتریس C_D دچار بد شرطی شده باشد (وابستگی نزدیک میان ستون‌های ماتریس C_D)، $\hat{\beta}_{GD}$ بی دلیل دارای واریانس بزرگ خواهد شد. علاوه بر این، ممکن است برخی از ضرایب رگرسیونی با علامت اشتباه برآورد شوند و استنباط آماری برای محقق سخت شود. به عنوان یک چاره، بنا بر هورل و کنارد (۱۹۷۰) می‌توان از برآوردگر تفاضلی ریح تعمیم یافته زیر استفاده کرد.

$$\hat{\beta}_{GD}(k) = T_k \hat{\beta}_{GD}, \quad T_k = (k C_D^{-1} + I_p)^{-1} \quad (۲.۳)$$

که $k \geq 0$ در آن پارامتر ریح است.

اکنون محدودیت غیر تصادفی و خطی زیر را در نظر می‌گیریم:

$$R\beta = r \quad (۳.۳)$$

بطوریکه R ماتریس $(q \times p)$ با رتبه $q < p$ و r یک بردار $q \times 1$ تایی معلوم می‌باشند. فرض رتبه کامل بودن R برای راحتی در محاسبات و با توجه به این واقعیت که هر معادله خطی سازگار می‌تواند به یک معادله خطی با ماتریس ضرایب دارای رتبه کامل سطری تبدیل شود در نظر گرفته شده است. با در نظر گرفتن فرضیه خطی ۳.۳، برآوردگر تفاضلی محدود شده تعمیم یافته برابر است با:

$$\hat{\beta}_{GRD} = \hat{\beta}_{GD} - C_D^{-1} R' (R C_D^{-1} R')^{-1} (R \hat{\beta}_{GD} - r). \quad (۴.۳)$$

بنا بر سوامی (۱۹۷۸) و سوامی و مهتا (۱۹۷۷) می‌توان برآوردگر تفاضلی ریح تعمیم یافته جهت بهبود فرم غیر ریح را با مینیم کردن مجموع توان‌های دوم مانده‌ها با در نظر گرفتن محدودیت کروی $\beta' \beta \leq \rho^2$ ، که این محدودیت یک محدودیت اجباری برای غلبه بر مشکل هم‌خطی است، بدست آورد. بنا بر ژانگ و یانگ (۲۰۰۷) برای بدست آوردن برآوردگر مورد نظر، باید مساله بهینه سازی زیر را حل نماییم:

$$\begin{aligned} \min_{\beta} \quad & [(\bar{y} - \bar{X}\beta)' V_D^{-1} (\bar{y} - \bar{X}\beta)], \\ \text{s.t.} \quad & \beta' \beta \leq \rho^2 \\ & R\beta = r \end{aligned} \quad (۵.۳)$$

پس از حل مسئله فوق به روش لاگرانژ، برآوردگر ریح تفاضلی محدود شده تعمیم یافته را بصورت

$$\hat{\beta}_{GRD}(k) = \hat{\beta}_{GD}(k) - C_D^{-1}(k) R' [(R C_D^{-1}(k) R')]^{-1} (R \hat{\beta}_{GD}(k) - r). \quad (۶.۳)$$

بدست می‌آوریم که $C_D(k) = \bar{X}' V_D^{-1} \bar{X} + k I_p$ و $\hat{\beta}_{GD}(k) = C_D^{-1}(k) \bar{X}' V_D^{-1} \bar{Y}$ برای $k \geq 0$ می‌باشند. به سادگی می‌توان نشان داد $\hat{\beta}_{GRD}$ و $\hat{\beta}_{GRD}(k)$ با قید $R\beta = r$ مطابقت دارند. همچنین واضح است که برای $k = 0$ ، رابطه $\hat{\beta}_{GRD}(0) = \hat{\beta}_{GRD}$ برقرار است.

۴ ارزیابی توابع مخاطره

در این بخش، ما تابع مخاطره را برای برآوردگرهای پیشنهاد شده در بخش قبل محاسبه می‌کنیم. برای محاسبه توابع مخاطره ابتدا باید تابع زیان مورد استفاده را معرفی نماییم. فرض کنید β^* یک برآوردگر دلخواه برای β در مدل ۵.۲ باشد. زلتر (۱۹۹۴) با نظر گرفتن ترکیب توأم نیکویی برازش و دقت برآورد در تابع زیان، هردو معیار را برای قضاوت در مورد نحوه عملکرد برآوردگر مورد نظر لحاظ نمود و تابع زیان متعادل (BLF) را که یک ترکیب محدب از دو معیار فوق می‌باشد را به صورت زیر معرفی کرد:

$$L(\beta^*, \beta) = \omega(\bar{X}\beta^* - \bar{y})'(\bar{X}\beta^* - \bar{y}) + (1 - \omega)(\bar{X}\beta^* - \bar{X}\beta)'(\bar{X}\beta^* - \bar{X}\beta) \quad (1.4)$$

که در آن $0 \leq \omega \leq 1$ یک وزن غیر تصادفی است.

حالا، فرض می‌کنیم $S(p)$ فضای ماتریس‌های معین مثبت باشد. در این مقاله، تابع زیان متعادل وزنی را به شکل زیر تعریف می‌کنیم:

$$L(\beta^* \beta) = \omega(\bar{X}\beta^* - \bar{y})' V_D^{-1} (\bar{X}\beta^* - \bar{y}) + (1 - \omega)(\bar{X}\beta^* - \bar{X}\beta)' V_D^{-1} (\bar{X}\beta^* - \bar{X}\beta) \quad (2.4)$$

که در آن $S(p)$ یک ماتریس وزن است. تابع مخاطره مربوط به BLF معادله ۲.۴ بصورت زیر می‌باشد:

$$R(\beta^*, \beta) = E[L(\beta^*, \beta)] \quad (3.4)$$

قبل از محاسبه تابع مخاطره $\hat{\beta}_{GRD}(k)$ ما فرمول جدیدی برای $\hat{\beta}_{GRD}(k)$ بدست می‌آوریم که نقش بسزایی در محاسبه تابع مخاطره دارد.

$$\hat{\beta}_{GRD}(k) = M_D(k) \bar{X}' V_D^{-1} \bar{Y} - M_D(k) C_D(k) \beta_0 + \beta_0 \quad (4.4)$$

که $\beta_0 = R'(RR')^{-1}r$ و $M_D(k) = C_D^{-1}(k) - C_D^{-1}(k)R'(RC_D^{-1}(k)R')^{-1}RC_D^{-1}(k)$ می‌باشند. اکنون با استفاده از روابط بدست آمده و این واقعیت که $R\beta = r$ و $R\beta_0 = r$ دلالت بر تساوی $(\beta - \beta_0)' C_D(k) (\beta - \beta_0) = (\beta - \beta_0)' M_D(k) C_D(k) (\beta - \beta_0)$ دارد، براحتی می‌توان اریبی و ماتریس کواریانس $\hat{\beta}_{GRD}(k)$ را محاسبه کرد.

$$E(\hat{\beta}_{GRD}(k) - \beta) = -k M_D(k) \beta \quad (5.4)$$

و

$$Cov(\hat{\beta}_{GRD}(k)) = \sigma^2 M_D(k) C_D M_D(k) \quad (6.4)$$

با جایگذاری $\bar{Y} \doteq \bar{X}\beta + \bar{\epsilon}$ در معادله ۲.۴، تابع مخاطره برآوردگر $\hat{\beta}_{GRD}(k)$ بصورت زیر محاسبه خواهد شد:

$$R(\hat{\beta}_{GRD}(k), \beta) = \sigma^2 (1 - 2\omega)(p - q) + k \sigma^2 (2\omega - 1) tr(M_D(k))$$

$$-k\sigma^2 \text{tr}(M_D^{\vee}(k)C_D) + k^2\beta'(M_D(k) - kM_D^{\vee}(k))\beta + \omega\sigma^2(n - m). \quad (7.4)$$

همچنین با مساوی صفر قرار دادن k در عبارت فوق مخاطره $\widehat{\beta}_{GRD}$ بصورت زیر بدست می‌آید:

$$R(\widehat{\beta}_{GRD}, \beta) = \sigma^2(1 - 2\omega)(p - q) + \omega\sigma^2(n - m). \quad (8.4)$$

۵ مقایسه نتایج

در این قسمت شرایط لازم و کافی برای اینکه برآوردگر $\widehat{\beta}_{GRD}(k)$ بر $\widehat{\beta}_{GRD}$ برتری داشته باشد را فراهم می‌کنیم. به این معنا که $R(\widehat{\beta}_{GRD}(k), \beta) \leq R(\widehat{\beta}_{GRD}, \beta)$ اکنون با استفاده از روابط ۷.۴ و ۸.۴ می‌توان گفت $\widehat{\beta}_{GRD}(k)$ بر $\widehat{\beta}_{GRD}$ تحت تابع زیان متعادل برتری دارد هرگاه به ازای هر $\beta \in R^p$ داشته باشیم:

$$\begin{aligned} \Delta &= R(\widehat{\beta}_{GRD}, \beta) - R(\widehat{\beta}_{GRD}(k), \beta) \\ &= k\sigma^2 \text{tr}(M_D^{\vee}C_D) + k\sigma^2(1 - 2\omega)\text{tr}(M_D(k)) + k^2\beta'(kM_D^{\vee} - M_D(k))\beta \geq 0 \end{aligned} \quad (1.5)$$

همان‌طور که دیده می‌شود Δ دارای یک فرم بسته از k نیست. لذا مقایسه دو برآوردگر را با استفاده از شبیه‌سازی و رسم نمودارهایی به شکل عددی ادامه می‌دهیم.

۱.۵ شبیه سازی نمونه

در این زیر بخش، کارایی برآوردگرهای پیشنهادی را مقایسه می‌کنیم. این آزمایش‌ها برای ترکیب مقادیر مختلف $k = \{0, 1, 2, \dots, 8\}$ و $w = \{0, 0.1, 0.3, 0.5, 0.7, 0.9\}$ انجام می‌شود. در این مطالعه، متغیر پاسخ را از مدل زیر به حجم $n = 100$ با 10^3 تکرار تولید می‌کنیم:

$$Y_i = x_{1i}\beta_1 + x_{2i}\beta_2 + x_{3i}\beta_3 + x_{4i}\beta_4 + x_{5i}\beta_5 + f(t_i) + \epsilon_i, i = 1, \dots, n$$

که در آن

$$\beta = (1/5, 2, 3, -5, 4)'$$

$$x_i \sim N_{\Delta}(\mu, \Sigma_x), \mu = \begin{pmatrix} -2 \\ 1 \\ 2 \\ 3 \\ 2 \end{pmatrix}, \Sigma_x = \begin{pmatrix} 0.81 & 0.4 & 0.3 & -0.2 & -0.1 \\ 0.4 & 2.25 & 0.4 & 0.3 & -0.2 \\ 0.3 & 0.4 & 1 & 0.4 & 0.3 \\ -0.2 & 0.3 & 0.4 & 0.64 & 0.4 \\ -0.1 & -0.2 & 0.3 & 0.4 & 0.49 \end{pmatrix}$$

$$f(t_i) = \sqrt{t_i(1 - t_i)} \sin\left(\frac{2.1\pi}{t_i + 0.5}\right), t_i = (i - 0.5)/n$$

$$\epsilon \sim N(0, \sigma_{\epsilon}^2 V), \sigma_{\epsilon}^2 = 0.1, v_{ij} = \left(\frac{1}{n}\right)^{|i-j|+1}$$

در این شبیه سازی ابتدا پارامتر خطی را با حذف تابع ناپارامتری به روش تفاضلی مرتبه چهارم برآورد کرده و سپس با جایگزینی برآورد بدست آمده برای آن، تابع ناپارامتری $f(\cdot)$ را با استفاده از تکنیک هموارسازی کرنل و بکار بردن کرنل نرمال، برآورد می کنیم. ضرایب تفاضلی بهینه از مرتبه چهار عبارتند از $d_0 = 0.8873$ ، $d_1 = -0.3099$ ، $d_2 = -0.2464$ ، $d_3 = -0.1901$ و $d_4 = -0.1409$. همچنین، ماتریس محدودیت خطی R و بردار r را بصورت زیر در نظر می گیریم:

$$R = \begin{pmatrix} 1 & -2 & 1 & 4 & 5 \\ -1 & 2 & -1 & -3 & 0 \\ 1 & 2 & -1 & -2 & 3 \\ 2 & -1 & 3 & -2 & 0 \end{pmatrix} \Rightarrow r = \begin{pmatrix} 0.5 \\ 14 \\ 24 \\ 20 \end{pmatrix}.$$

بحث و نتیجه گیری

در این مقاله، دو برآوردگر در مدل جزئی خطی هنگامی که خطاها همبسته بوده و برخشی محدودیت های خطی روی فضای پارامتر خطی وجود داشته باشد، پیشنهاد شد. سپس با حضور هم خطی میان ستون های ماتریس طرح، برآوردگر جدید تفاضلی ریح محدود شده تعمیم یافته یعنی $\hat{\beta}_{GRD}(k)$ در مقابل فرم غیر ریح آن را در مدل جزئی خطی معرفی نمودیم. در ادامه برای مقایسه دو برآوردگر جدید معرفی شده، توابع مخاطره آن ها را تحت تابع زیان متعادل وزنی محاسبه کرده و به دلیل اینکه تفاضل توابع مخاطره دارای صورت بسته ای از k نبود، مقایسه را با استراتژی شبیه سازی برای مقادیر مختلف پارامتر ریح و ضریب وزنی تابع زیان متعادل وزنی دنبال نمودیم. نتایج بدست آمده از شبیه سازی گویای این مطلبند که برای همه ترکیبات k و زمانی که $k < a$ ، $\hat{\beta}_{GRD}(k)$ از $\hat{\beta}_{GRD}$ بهتر است، که در آن a یک تابع نزولی از ω است. به عنوان مثال، به ازای $\omega = 0.1$ ، $\hat{\beta}_{GRD}(k)$ از $\hat{\beta}_{GRD}$ بهتر است، هرگاه $a = 0.33$ باشد ولی برای $\omega = 0.9$ اگر $a = 0.782$ باشد آنگاه $\hat{\beta}_{GRD}(k)$ از $\hat{\beta}_{GRD}$ بهتر است.

مراجع

- Hoerl A.E. and Kennard R.W. (1970), *Ridge regression biased estimation for nonorthogonal problems*, Technometrics 12, pp. 69–82.
- Ohtani K., Giles D.E.A. and Giles J.A. (1997), *The exact risk performance of a pre-test estimator in a heteroskedastic linear regression model under the balanced loss function*, Econ. Rev. 16 (1997), pp. 119–133.
- Shalabh (2001), *Least squares estimators in measurement error models under the balanced loss function*, Test 10, pp. 301–308.
- Swamy P.A.V.B., Mehta J.S. and Rappoport P.N. (1978), *Two methods of evaluating Hoerl and Kennard's ridge regression*, Commun. Statist. 12, pp. 1133–1155.

- Swamy P.A.V.B. and Mehta J.S. (1977), *A note on minimum average risk estimator for coefficient in linear models*, Commun. Statist. 6, pp. 1161–1186. Adv. Appl. Probab., pp. 476–495.
- Tothenberg H. and Shalabh (2005), *Estimation of regression coefficients subject to exact linear restrictions when some observations are missing and quadratic error balanced loss function is used*, Test 14, pp. 385–396. 129 (2002), pp. 455–467.
- Wang L., Brown L. D., and Cai T. T. (2007), *A difference based approach to semiparametric partial linear model*, Tech. Rep., Department of Statistics, The Wharton School, University of Pennsylvania.
- Yatchew A. (1997), *An elementary estimator of the partial linear model*, Econ. Lett. 57, pp. 135–143.
- Zellner A. (1986), *Bayesian estimation and prediction using asymmetric loss functions*, J. Am. Stat. Assoc. 81, pp. 446–451.
- Zellner A. (1994), Bayesian and non-Bayesian estimation using balanced loss function, in *Statistical Decision Theory and Related Topics*, S.S. Gupta and J.O. Berger, eds., Springer Verlag, Berlin, pp. 377–390.
- Zhong Z. and Yang H. (2007), *Ridge estimation to the restricted linear model*, Commun. Stat. Theory Methods 36, pp. 2099–2115.