

استفاده از ماکسیمم آنترופی تی سالیس تعمیم یافته برای برآورد پارامتر رگرسیون ستیغی

منیژه صانعی طبس^۱

تاریخ دریافت: ۱۴۰۱/۱۲/۰۱

تاریخ پذیرش: ۱۴۰۲/۰۲/۰۸

چکیده:

تحلیل رگرسیون به روش کمترین توان‌های دوم مستلزم برقراری فرضیات زیربنایی است. یکی از مسائلی که تحلیل رگرسیون به این روش را با مشکلات عمده مواجه می‌سازد وجود هم خطی در بین متغیرهای رگرسیونی است. روش‌های زیادی برای حل مشکلات ناشی از وجود هم خطی معرفی شده‌اند. یکی از این روش‌ها رگرسیون ستیغی است. در این مقاله یک برآورد جدید برای پارامتر ستیغی به کمک ماکسیمم آنترופی تی سالیس تعمیم یافته ارائه داده و آن را برآوردگر ستیغی ماکسیمم آنترופی تی سالیس مرتبه دو تعمیم یافته می‌نامیم. برای مجموعه داده‌های سیمان پرتلند که از هم خطی قوی برخوردار هستند و از سال ۱۳۳۲، برآوردگرهای مختلفی برای این داده‌ها ارائه شده است این برآوردگر را محاسبه و با برآوردگر ستیغی ماکسیمم آنترופی تعمیم یافته و برآوردگر کمترین توان‌های دوم مقایسه می‌کنیم.

واژه‌های کلیدی: رگرسیون ستیغی، ماکسیمم آنترופی تعمیم یافته، آنترופی تی سالیس، ماکسیمم آنترופی تی سالیس تعمیم یافته

۱ مقدمه

از دیدگاه کلاسیک این موضوع را مورد نظر قرار داده‌اند. تیسستد [۱۸] مسئله هم خطی را از دیدگاه نظریه تصمیم بررسی کرد. اغلب توصیه شده است که این مشکل با یک سری اطلاعات اضافی مدل قابل جبران است، اما اینکه چه میزان اطلاعات لازم است تا مشکلات ناشی از هم خطی را جبران کند، مشخص نیست. روش رگرسیون ستیغی از جمله روش‌هایی است که برای مقابله با مشکل هم خطی در رگرسیون به کار گرفته شده است. این روش توسط ارل و کنارد [۸] معرفی شد که یک روش رایج برای برآورد پارامترهای مدل است، بدون اینکه لازم باشد برخی از متغیرهای رگرسیونی را از مدل حذف کنیم. این روش با اضافه کردن یک ثابت نامنفی کوچک (که اغلب از آن به نام پارامتر ستیغی یاد می‌شود) به قطر ماتریس همبستگی متغیرهای توضیحی این امکان را می‌دهد که واریانس برآوردگر کمترین مربعات از طریق اعمال مقداری اریبی به مدل کاهش داده شود. اگرچه برآوردگرهای حاصل اریب هستند، ولی این اریبی آنقدر کوچک است که دقت این برآوردگرها از دقت برآوردگرهای نااریب بیشتر است. روش ماکسیمم آنترופی تعمیم یافته^۲ (GME) با یک زیربنای اقتصادی توسط جاج و گلان [۵] معرفی شد. روش (GME) برای برآورد پارامترهای مدل رگرسیونی خطی و غیرخطی بدون اعمال هیچ شرطی روی توزیع احتمال

روش برآورد حداقل مربعات بهترین برآوردگر نااریب خطی را در صورتی که فرضیات زیربنایی زیر برقرار باشند به دست می‌دهد: ۱- جملات خطا دارای توزیع نرمال با میانگین صفر باشند. ۲- جملات خطا دارای واریانس ثابت باشند. ۳- متغیرهای پیشگو مستقل خطی باشند. برقرار نبودن هر یک از فرضیات ذکر شده در بالا ما را در استفاده از روش OLS با مشکل مواجه می‌سازد. اگر هیچ رابطه خطی بین متغیرهای رگرسیونی برقرار نباشد، گفته می‌شود متعامند. اگر متغیرهای رگرسیونی برهم عمود باشند، استنباط‌هایی نسبتاً ساده صورت می‌گیرد. هنگامی که ارتباط خطی نزدیکی بین متغیرهای پیشگو وجود دارد، گفته می‌شود هم خطی چندگانه وجود دارد. در رگرسیون چندگانه یکی از فرض‌های اساسی که بین متغیرهای پیشگو باید برقرار باشد فرض عدم وجود هم خطی است اما در صورتی که این فرض برقرار نباشد تحلیل رگرسیون را با مشکل مواجه می‌کند. اگر متغیرهای پیشگو دارای وابستگی زیاد باشند، واریانس برآوردگرها زیاد شده و دیگر برآوردگر حداقل مربعات برآورد خوبی نیست. محققین زیادی از جمله فرار و گلویر [۴] ارل و کنارد [۸] و ویلان و واتس [۲۱] بلیزلی [۲] و ...

^۱ گروه آمار، دانشکده ریاضی آمار و علوم کامپیوتر، دانشگاه سیستان و بلوچستان (نویسنده مسئول: manijesanei@math.usb.ac.ir)

^۲ Generalized Maximum Entropy

$\alpha = 2$ روش ماکسیمم آنتروپی تعمیم یافته را با قرار دادن آنتروپی تی سالیس مرتبه دو به جای آنتروپی شانون تعمیم داده و مجموع آنتروپی تی سالیس مرتبه دو هر دو جمله آنتروپی و جمله خطا را ماکسیمم کرده اند. برآوردهای به دست آمده از این روش را برآوردهای ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته (GME_{T2}) نامیده اند. به دلیل اهمیت مسئله هم خطی صناعی و محتشمی [۱۷] به کمک برآوردهای GME_{T2} برآورد جدیدی از پارامتر ستیغی ارائه دادند. آن‌ها با ترکیب اثر ستیغی و برآوردهای ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته، برآورد جدیدی از پارامتر ستیغی به نام برآورد ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته $Ridge - GME_{T2}$ معرفی کردند. در ادامه این مقاله بعد از معرفی روش GME_{T2} و برآوردهای GME_{T2} برای یک مدل رگرسیونی که از هم خطی بالایی برخوردار است برآوردهای GME_{T2} را محاسبه و با برآوردهای OLS و GME مقایسه می‌کنیم. در ادامه برای یک مجموعه داده که از هم خطی بالایی برخوردار هستند این روش را اعمال نموده و برآوردهای رگرسیونی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته $Ridge - GME_{T2}$ را محاسبه می‌کنیم.

۲ برآوردهای رگرسیون ستیغی

در این بخش برآوردهای رگرسیون ستیغی^۳ مورد نظر قرار می‌گیرد. مدل رگرسیون خطی

$$Y = X\beta + e \quad (1)$$

که در رابطه (۱)، Y بردار $N \times 1$ از مشاهدات و β یک بردار $K \times 1$ از پارامترهای مجهول و X یک ماتریس $(N \times K)$ از متغیرهای توضیحی و معلوم است. e نیز بردار $(N \times 1)$ خطاهای تصادفی است. به طوری که

$$E(e|X) = 0, E(ee'|X) = \sigma^2 I$$

که I ماتریس همانی $(N \times N)$ است. برآوردهای کمترین توان‌های دوم β به صورت

$$\hat{\beta}_{OLS} = (X'X)^{-1}X'Y \quad (2)$$

و برآوردهای رگرسیون ستیغی که توسط ارل و کنارد [۸] پیشنهاد شد عبارت است از:

$$\hat{\beta}_{RR} = (X'X + \eta I)^{-1}X'Y \quad (3)$$

خطاها مورد استفاده واقع شده است. این روش که بر اساس ماکسیمم آنتروپی شانون و اصل ماکسیمم آنتروپی جینز [۹] پایه گذاری شده است مدل خطی را به گونه ای باز نویسی می‌کند که پارامترها و خطاهای مجهول را به شکل احتمالات در نظر گرفته و آنان را برآورد می‌کند. مزیت روش GME این است که در این روش لازم نیست هیچ گونه فرض یا توزیع احتمالی را برای باقیمانده‌ها (حتی در مواقعی که نمی‌خواهیم استنباط آماری انجام دهیم) در نظر بگیریم. در رگرسیون متغیر کیفی نیز این روش کاربرد خود را پیدا کرده است. مرکانی و همکاران [۱] روش ماکسیمم آنتروپی تعمیم یافته را در رگرسیون لوژیستیک اعمال کرده اند. همان طور که پیش تر گفته شد مدت های طولانی است که رگرسیون ستیغی به عنوان راه حلی برای مشکل هم خطی و برآورد پارامترهای مدل رگرسیونی مطرح شده است. ماسدو و همکاران [۱۱] بر اساس روش GME برآوردهای رگرسیونی ماکسیمم آنتروپی تعمیم یافته را ارائه داده اند. اشکال اساسی اغلب روش های سنتی که برای برآورد پارامتر ستیغی به کار رفته اند، وابستگی پارامترهای مجهولی است که از روی داده ها باید برآورد شوند اما در روش ماکسیمم آنتروپی تعمیم یافته، این وابستگی از بین می رود چون این روش مستلزم برقراری هیچ فرضی نیست. GME پارامترهای مدل رگرسیونی را بدون اینکه هیچ محدودیتی روی جملات احتمالی و خطا در نظر بگیرد برآورد می‌کند. اما بعد از شانون [۱۵] تاکنون اندازه های آنتروپی تعمیم یافته زیادی معرفی گردید که هر کدام در حالت خاص آنتروپی شانون را در بر می‌گیرند. از جمله پرکاربردترین آن‌ها آنتروپی تی سالیس [۱۹] است. اصل ماکسیمم آنتروپی که تکبیه بر آنتروپی شانون دارد توزیع های نمایی را نتیجه می‌دهد. آن گونه که مطالعات تجربی نشان می‌دهد در بسیاری از مواقع توزیع جامعه تحت بررسی از نوع توزیع های توانی بوده (بسیاری از مدل های اقتصادی) بنابراین استفاده از آنتروپی تی سالیس به عنوان یک رده کلی تر، به جای آنتروپی شانون پیشنهاد شده و موضوع آنتروپی تی سالیس ماکسیمم بررسی شده است. بر این اساس می‌توان با جایگزین کردن آنتروپی تی سالیس به جای آنتروپی شانون در روش ماکسیمم آنتروپی تعمیم یافته، این روش را برای آنتروپی مرتبه α تعمیم داده و رده دیگری از برآوردها به نام GME_{α} را معرفی کرد؛ به عبارت دیگر مجموع آنتروپی تی سالیس مرتبه α دو جمله احتمالی و جمله خطا را ماکسیمم کنیم. با توجه به کاربردهای زیاد آنتروپی تی سالیس و به خصوص آنتروپی تی سالیس مرتبه دو در بسیاری از علوم از جمله شیمی، فیزیک، زیست آزمایشگاهی و اقتصاد صناعی و محتشمی [۱۶] برآوردهای ماکسیمم آنتروپی تی سالیس تعمیم یافته، معرفی کردند. آن‌ها با قرار دادن

³Ridge regression

۱.۳ برآوردگر ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته

برای به دست آوردن برآوردگر GME_{T2} همانند روش یافتن GME ، مدل خطی (۱) را دوباره بازنویسی می‌کنیم به طوری که برآوردها و خطاهای مجهول به فرم احتمالات نوشته می‌شوند زیرا عناصر تابع ماکسیمم آنتروپی، احتمالات هستند. فرض کنید هر β_k یک متغیر تصادفی گسسته با M برآمد ممکن $(z_{k1}, z_{k2}, \dots, z_{kM})$ هر یک با احتمال متناظر $(p_{k1}, p_{k2}, \dots, p_{kM})$ باشد به طوری که $\sum_{m=1}^M p_{km} = 1$. بر این اساس هر پارامتر β_k را می‌توان به صورت زیر نوشت:

$$\beta_k = \sum_{m=1}^M z_{km} p_{km}, \quad k = 1, 2, \dots, K, \quad M \geq 2, \quad (6)$$

تکیه‌گاه پارامتری یا مقادیر بردار Z_k بر اساس اطلاع پیشین و یا تجارب قبلی تعیین می‌شود. به طور مشابه برای برآورد توزیع خطاها نیز می‌توان به این ترتیب عمل کرد که فرض می‌کنیم تکیه‌گاه خطا شامل $J \geq 2$ نقطه و ν نیز یک ماتریس $(T \times T \times J)$ از نقاط تکیه‌گاه بوده و W نیز یک بردار $1 \times T \times J$ از وزن‌های متناظر نقاط تکیه‌گاه باشند به طوری که $\sum_{j=1}^J w_{tj} = 1$. در این صورت هر بردار e_t به صورت زیر بازنویسی می‌شود:

$$e_t = \sum_{j=1}^J \nu_{tj} w_{tj}, \quad t = 1, 2, \dots, T, \quad J \geq 2, \quad (7)$$

برای تعیین کران‌های تکیه‌گاه خطاها، گلان و همکاران [۶] از قانون 3σ که توسط پولکیشم [۱۴] مطرح شده بود استفاده کردند. آن‌ها کران پایین را -3σ قرار داده و برای کران بالا از $+3\sigma$ استفاده کردند که مقدار σ نیز همان انحراف معیار نمونه‌ای بردار Y می‌باشد. بر این اساس هر پارامتر β_k و e_t به ترتیب به صورت (۶) و (۷) بازنویسی می‌شوند. پس مسئله ماکسیمم آنتروپی تی سالیس تعمیم یافته به صورت:

$$\begin{aligned} \max_{P, W} H(P, W) &= -P'(P' - 1) - W'(W' - 1) \\ &= -\sum_{k=1}^K \sum_{m=1}^M p_{km} (p_{km} - 1) \\ &\quad - \sum_{t=1}^T \sum_{j=1}^J w_{tj} (w_{tj} - 1), \end{aligned} \quad (8)$$

به طوری که

که $\eta \geq 0$ نشان دهنده پارامتر ستیغی است. وقتی که $\eta \rightarrow 0$ برآوردگر RR به برآوردگر OLS نزدیک می‌شود در حالی که وقتی $\eta \rightarrow \infty$ برآوردگر RR به بردار صفر میل می‌کند. پس یک افزایش و کاهش بین واریانس و اریبی لازم است. آن‌ها نشان دادند که برآوردگر RR برای یک دامنه مقادیر η (وقتی که ملاک مقایسه دو برآوردگر MSE باشد) یک کران بالا برای برآوردگر کمترین توان‌های دوم است. مقدار MSE برآوردگر RR عبارت است از:

$$MSE(\hat{\beta}_{RR}) = \sigma^2 \sum_{i=1}^k \frac{\lambda_i}{(\lambda_i + \eta)^2} + \eta^2 \beta' (X'X + \eta I)^{-2} \beta \quad (9)$$

که در (۹) λ_i ها مقادیر ویژه ماتریس همبستگی $X'X$ هستند.

۳ برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته

آنتروپی تی سالیس مرتبه α یکی از اشکال تعمیم یافته آنتروپی شانون است که وقتی $\alpha \rightarrow 1$ همان آنتروپی شانون را نتیجه می‌دهد. به ازای $\alpha = 2$ آنتروپی تی سالیس مرتبه ۲ حاصل شده که کاربردهای خاص خودش را در بسیاری از علوم پیدا کرده است.

تعریف ۱.۳. برای متغیر تصادفی X با تابع احتمال مربوطه $P = (p_1, \dots, p_n)$ آنتروپی تی سالیس و آنتروپی تی سالیس مرتبه دو به ترتیب عبارت‌اند از:

$$\begin{aligned} T_\alpha(P) &= \frac{1}{\alpha - 1} \left[\sum_{i=1}^n p_i^\alpha (x_i) - 1 \right], \quad \alpha > 0, \alpha \neq 1 \\ T_2(P) &= \sum_{i=1}^n p_i^2 (x_i) - 1 = \sum_{i=1}^n p(x_i) [p(x_i) - 1]. \end{aligned} \quad (5)$$

روش GME بر اساس آنتروپی شانون تعریف شده است. [۱۶] ضمن جایگزینی آنتروپی شانون با آنتروپی تی سالیس مرتبه دو روش GME را تعمیم داده و یک خانواده جدید از برآوردگرهای نظریه اطلاع معرفی و آن را برآوردگرهای ماکسیمم آنتروپی تی سالیس تعمیم یافته GME_{T2} نام‌گذاری کردند. روش یافتن این برآوردگرها همانند برآوردگر GME بوده با این تفاوت که به جای آنتروپی شانون از آنتروپی تی سالیس مرتبه دو استفاده می‌شود. در این مقاله بر اساس برآوردگر GME_{T2} برآوردگر دیگری برای پارامتر ستیغی معرفی کرده و آن را با سایر برآوردگرهای ستیغی ذکر شده در بخش قبل مقایسه می‌کنیم. بدین منظور ابتدا روش یافتن برآوردگرهای GME_{T2} توضیح داده می‌شود.

$$\begin{cases} \sum_{k=1}^K \sum_{m=1}^M x_{tk} z_{km} p_{km} + \sum_{j=1}^J w_{tj} \nu_{tj} = Y_t, & t = 1, 2, \dots, T. \\ \sum_{m=1}^M p_{km} = 1, & k = 1, 2, \dots, K. \\ \sum_{j=1}^J w_{tj} = 1, & t = 1, 2, \dots, T. \end{cases} \quad (9)$$

۴ مثال عددی

در این بخش بر اساس برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته که در بخش قبل ارائه شد برآوردگر رگرسیون ستیغی را برای مجموعه داده سیمان پرتلند که از درجه هم خطی بالایی برخوردار است محاسبه می کنیم. با توجه به وجود هم خطی در این داده ها بعد از وود و همکاران [۲۲] برآوردهای مختلفی برای برآورد پارامتر ستیغی ارائه شده است از جمله می توان به هالد [۷] کاکرانلار، [۱۰]، لیو [۱۳] و مونیز و کبیریا [۱۲] اشاره کرد. در این مجموعه برای اندازه گیری میزان سختی سیمان پرتلند متغیر پاسخ Y (میزان گرمای آزاد شده از هر گرم سیمان) تعریف شده است که خود تحت تأثیر چهار متغیر رگرسیونی X_1 : (آلومینات تری کلسیم)، X_2 : (سیلیکات تری کلسیم)، X_3 (آلومینو فریت تتراکلسیم) و X_4 (بتا دی کلسیم سیلیکات) است و به ترتیب چهار ستون ماتریس X را تشکیل می دهند. این مجموعه داده در زیر ارائه شده است.

مدل رگرسیونی

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + e. \quad (12)$$

را به این مجموعه داده ها برازش داده و برآوردهای OLS محاسبه شده اند. بر اساس اطلاعات جدول ۱ هیچ یک از ضرایب در سطح α مقدار ۰/۰۵٪ معنی دار نبوده و مقدار $\hat{\sigma}^2$ برابر ۵/۹۸۲۹ به دست آمده است. همچنین مقدار R^2 برابر ۰/۹۸۲۴ است که نشان می دهد ۹۸/۲۴ درصد تغییرات توسط متغیرهای رگرسیونی پیشگو توضیح داده می شود. مقادیر ویژه برای ماتریس X در جدول ۲ آورده شده اند.

بنابراین عدد شرطی که جذر تقسیم کوچک ترین مقدار ویژه بر بزرگ ترین مقدار ویژه است، در این مجموعه داده برابر ۸۲/۷۷ است. بزرگ بودن عدد شرطی ناشی از وجود هم خطی زیاد بین متغیرهای رگرسیونی است. بازه ستیغی را به صورت [۰، ۱] تعریف کرده و برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته ($\hat{\eta}$) را به دست می آوریم. برای محاسبات از نرم افزار متلب کمک می گیریم. الگوریتم محاسبه برآوردهای $Ridge - GME$ و $Ridge - GMET_2$ به این صورت است که ابتدا مقادیر برآوردهای GME و $GMET_2$ را محاسبه

است. برای حل مسئله بهینه سازی (۸) با توجه به محدودیت های ذکر شده معادله لاگرانژ را تشکیل داده که حل این معادله نتایج زیر:

$$\hat{p}_{km} = \frac{1-M}{M} + \frac{1}{2M} \sum_{t=1}^T \lambda_t x_{tk} \sum_{m=1}^M z_{km} - \frac{1}{2} \sum_{t=1}^T \lambda_t x_{tk} z_{km}, \quad (10)$$

$$m = 1, 2, \dots, M, k = 1, 2, \dots, K.$$

$$\hat{w}_{tj} = -\frac{1}{2} \lambda_t \nu_{tj} + \frac{1}{2} \lambda_t \left(\sum_{j=1}^J \nu_{tj} \right), \quad j = 1, \dots, J.$$

را داریم. با جایگذاری جواب های \hat{p}_{km} و \hat{w}_{tj} به ترتیب در هر یک از معادلات (۶) و (۷) برآوردهای ماکسیمم آنتروپی تی سالیس تعمیم یافته $GMET_2$ به صورت زیر حاصل می شوند:

$$\beta_k^{GMET_2} = \sum_{m=1}^M \hat{p}_{km} z_{km}, \quad k = 1, 2, \dots, K,$$

$$e_t^{GMET_2} = \sum_{j=1}^J \hat{w}_{tj} \nu_{tj}, \quad t = 1, 2, \dots, T.$$

۲۰۳ برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته

بر اساس برآوردگر $GMET_2$ که در بالا به دست آمد، برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس تعمیم یافته $(Ridge - GMET_2)$ به صورت:

$$\hat{\eta}_{Ridge - GMET_2} = \min_{\eta \in [a_1, a_2]} \|Z\hat{P} - (X'X + \eta I)^{-1} X'Y\|_{\infty} \quad (11)$$

تعریف می شوند. بردار \hat{P} در رابطه (۱۱)، همان بردار رابطه (۱۰) به دست آمده از روش $GMET_2$ که رابطه (۸) را ماکسیمم می کند است. بازه ستیغی در نظر گرفته شده بازه $[a_1, a_2]$ است که در آن a_1 و a_2 به ترتیب کران های بالا و پایین این بازه هستند.

می‌شود. سپس با مینیم کردن رابطه روی بازه ستیغی [۰, ۱] به ازای مقادیر برآورد شده مقدار $\hat{\eta}$ را که این بازه را مینیم می‌کند، تعیین می‌کنیم. به ازای این مقدار مینیم کننده، برآورد $Ridge - GME$ و $Ridge - GMET_2$ محاسبه می‌شود. این برآوردها در جدول ۳ آورده شده‌اند. مقادیر MSE مربوط به هر سه نوع برآوردگر OLS ، $Ridge - GME$ و $Ridge - GMET_2$ در جدول ۴ خلاصه شده است.

$$X = \begin{bmatrix} 7 & 26 & 6 & 60 \\ 1 & 29 & 15 & 52 \\ 11 & 56 & 8 & 20 \\ 11 & 31 & 8 & 47 \\ 7 & 52 & 6 & 33 \\ 11 & 55 & 9 & 22 \\ 3 & 71 & 17 & 6 \\ 1 & 31 & 22 & 44 \\ 2 & 54 & 18 & 22 \\ 21 & 47 & 4 & 26 \\ 1 & 40 & 23 & 34 \\ 11 & 66 & 9 & 12 \\ 10 & 68 & 8 & 12 \end{bmatrix}, \sum_{i=1}^4 x_i = \begin{bmatrix} 99 \\ 97 \\ 95 \\ 97 \\ 98 \\ 97 \\ 97 \\ 98 \\ 96 \\ 98 \\ 98 \\ 98 \\ 98 \\ 98 \end{bmatrix}, Y = \begin{bmatrix} 78/5 \\ 74/3 \\ 104/3 \\ 87/6 \\ 95/9 \\ 109/2 \\ 102/7 \\ 72/5 \\ 93/1 \\ 115/9 \\ 83/8 \\ 113/3 \\ 109/4 \end{bmatrix}$$

جدول ۱: جدول آنالیز واریانس داده‌های سیمان پرتلند به روش کمترین توان‌های دوم

جمله	پارامتر	خطای معیار	آماره‌های توزیع تی	مقادیر بحرانی آزمون
β_0	۶۲/۴۰۵۴	۷۰/۰۷۱۰	۰/۸۹	۰/۳۹۹۱
β_1	۱/۵۵۱۱	۰/۷۴۴۸	۲/۰۸	۰/۰۷۰۸
β_2	۰/۵۱۰۲	۰/۷۲۳۸	۰/۷۰	۰/۵۰۰۹
β_3	۰/۱۰۱۹	۰/۷۵۴۷	۰/۱۴	۰/۸۹۵۹
β_4	-۰/۱۴۴	۰/۷۰۹۱	-۰/۲	۰/۸۴۴۱

جدول ۲: مقادیر ویژه

λ_5	λ_4	λ_3	λ_2	λ_1
۰/۰۳۴۹	۱۰/۲۶۷۴	۲۸/۴۵۹۷	۷۷/۲۳۶۱	۲۱۱/۳۶۷۵

[۱۷] برای یک مجموعه داده شبیه‌سازی شده مقادیر میانگین مربعات خطا را برای هر سه نوع برآوردگر $Ridge - GME$ و $Ridge - GMET_2$ و برآورد حداقل مربعات محاسبه کرده و نتیجه این شده است که $Ridge - GME$ کمترین میانگین مربعات خطا را داراست. در این مقاله برای مجموعه داده یک مثال عددی مثال داده‌های سیمان پرتلند $ridge - GMET_2$ محاسبه و با دو نوع برآوردگر دیگر مقایسه می‌شود.

جدول ۳: برآوردهای OLS ، $Ridge - GME$ ، $Ridge - GMET\gamma$

پارامتر	OLS	$Ridge - GME$	$Ridge - GMET\gamma$
β_0	۶۲/۴۰۵	۳۱/۲۳۳۹	۳۴/۲۷۵۷
β_1	۱/۵۵۱	۱/۸۶۸۵	۱/۸۴۰۵
β_2	۰/۵۱۰	۰/۸۳۲۴	۰/۸۰۰۱
β_3	۰/۱۰۲	۰/۴۲۷۱	۰/۳۹۷۹
β_4	-۰/۱۴۴	۰/۱۷۱۴	۰/۱۴۰۱

جدول ۴: مقادیر MSE برآوردهای مختلف ستیغی .

OLS	$Ridge - GME$	$Ridge - GMET\gamma$
۵/۹۸	۶/۹۸۰۷	۷/۴۲۶۱

سالیس مرتبه دو تعمیم یافته از دو برآوردگر دیگر کمتر است نتایج کامل در [۱۷] ارائه شده است. یک مجموعه داده سه نوع برآوردگر ستیغی ماکسیمم آنتروپی تعمیم یافته، حداقل مربعات و برآوردگر ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته را محاسبه و مقادیر MSE شان را برآورد کرده ایم اگرچه مقدار MSE روش OLS نسبت به دو روش $Ridge - GME$ و $Ridge - GMET\gamma$ کمتر به دست آمده ولی این تفاوت ناچیز و با توجه به اینکه مشکل هم خطی در داده ها وجود دارد و از طرف دیگر کوچک بودن حجم نمونه در این مثال (کارایی روش GME و نیز $GMET\gamma$ در حالتی که حجم نمونه کوچک است در [۱۶] مورد بحث و بررسی قرار داده ایم) و روش ماکسیمم آنتروپی تعمیم یافته مستلزم برقراری فرضیات زیربنایی نیست این اختلاف ناچیز قابل چشم پوشی بوده و این دو برآوردگر جدید را ترجیح می دهیم.

۵ بحث و نتیجه گیری

علیرغم توانایی بالای روش ماکسیمم آنتروپی، روش ماکسیمم آنتروپی تعمیم یافته با چارچوب رگرسیونی مطرح شد. وجود هم خطی بالا بین متغیرهای توضیحی یکی از مشکلات عمده ای است که در تحلیل رگرسیونی با آن مواجه می شویم. یکی از روش هایی که برای مقابله با این مشکل مطرح گردیده است، روش رگرسیون ستیغی است. محققین برآوردهای زیادی برای پارامتر ستیغی ارائه داده اند. در این مقاله بر اساس برآورد ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته برآورد دیگری برای پارامتر ستیغی یافته و آن را برآورد ستیغی ماکسیمم آنتروپی تی سالیس مرتبه دو تعمیم یافته نامیده ایم. قبلاً به کمک شبیه سازی هر سه برآوردگر ذکر شده در جدول ۴ را محاسبه و نشان دادیم که میانگین مربعات خطا برای برآوردگر ستیغی ماکسیمم آنتروپی تی

مراجع

- [۱] مرکانی، مهسا. صناعی طبس، منیژه. نادری، حبیب. احمدزاده، حامد و جمالزاده، جواد. برآورد پارامترهای مدل رگرسیونی لوژستیک به کمک ماکسیمم آنتروپی تعمیم یافته، اندیشه آماری، سال بیست و ششم، شماره ۲ پاییز زمستان، شماره ۵۲، ۱۴۰۰، ص ۱-۸
- [2] Akdeniz, F., Cabuk, A. and Guler, H. (2011), Generalized maximum entropy estimators: applications to the Portland Cement data set. *The Open Statistics and Probability Journal*, **3**, 13-20.
- [3] Belsley, D.A. (1982), Assessing the presence of harmful collinearity and other forms of weak data through a test for signal-to-noise. *Journal of Econometrics*, **20**, 211-253.

- [4] Farrar, d. E. and Glauber, R. R. (1967). Multicollinearity in Regression analysis: the problem revisited. *Review of Economics and Statistics*, **49**, 92-107.
- [5] Judge, G. G. and Golan, A. (1992), *Recovering information in the case of ill-posed inverse problems with noise*, Mimo Department Of Agricultural And Natural Resources, University of California, Berekely, CA.
- [6] Golan, A., Judge, G. and Miller, D. (1996), *Maximum Entropy Econometrics: Robust estimation with limited data*, John wiley Sons, New york.
- [7] Hald, A. (1952), *Statistical Theory with Engineering Applications*, John Wiley Sons, New York.
- [8] Horel, A. E. and Kenard. R. W. (1970), Ridge Regression: Applications to Nonorthogonal Problems, *Technometrics*, **12**, 69-82.
- [9] Jaynes, E. T. (1957), Information theory and statistical mechanics. *Physical Reviews*, **106**, 620-630.
- [10] Kacranlar, S., Sakallioğlu, S., Akdeniz, F., Styan, G. P. H. and Werner, H. J. (1999), A new biased estimator in linear regression and a detailed analysis of the widely-analysed dataset on Portland cement, *The Indian Journal of Statistics, Series B, Senkhiya*, **61**, 443-459.
- [11] Macedo, P., Scotto, M. and Silva, E. (2010), On the Choice of the Ridge Parametr: A Maximum Entropy Approach, *Communication in Statistics Simulations and Computations*, **39**, 1628-1638.
- [12] Muniz, G. and Kibria, B. M. G. (2009), On some ridge regression estimator: an emperical comparisons, *Communication in Statistics Simulations and Computations*, **38**, 621-630.
- [13] Liu, K. (2003), Using Liu-type estimator to combat collinearity, *Communications in Statistics- Theory and Methods*, **32**, 1009-1020.
- [14] Pukelsheim, F. (1994), The three-sigma Rule, *The American statistician*, **48**, 4, 88-91.
- [15] Shannon, C. E. (1948), A Mathimatical Theory Of Communication. *Bell System Tech.*, **27**, 379-423.
- [16] Sanei Tabass, M. and Mohtashami Borzadaran, GH. R. (2017), The Generalized Maximum Tsallis Entropy Estimators and Applications to the Portland Cement Data set, *Communications in Statistics - Simulation and Computation* , **46**, 3284-3293.
- [17] Sanei Tabass, M. and Mohtashami Borzadaran, GH. R. (2022), On the choice of the Ridge parameter: a generalized maximum Tsallis entropy approach, *Communications in Statistics - Simulation and Computation* , DOI: 10.1080/03610918.2022.2082475.
- [18] Thisted, R.A. (1982). Decision-theoretic regression diagnostics. *Statistical Decision Theory and Related Topics III*, **2**, 363-382.
- [19] Tsallis, C. (1988). Possible generalizations of Boltzmann-Gibbs statistics. *Journal of Statistical Physics*, **52**, 479-487.
- [20] Renyi, A. (1961). On measures of entropy and information. *Proc. Berekely Symposium, Statist. Probability*, **1**, 547-561.
- [21] Willan. A.R. and D.G. Watts. (1978). Meaningful multicollinearity measures. *Technometrics*, **20**, 407-412.
- [22] Woods, H. Steinor, H. and Starke, H. (1932). Effect of composition of Portland cement on heat evolved during hardening. *Induserial and Engineering Chemistry*, **24**, 1207-1214.

Using the generalized maximum Tsallis entropy for estimating the Ridge regression parameter

Manije Sanei Tabas¹

Abstract:

Regression analysis using the method of least squares requires the establishment of basic assumptions. One of the problems of regression analysis in this way faces major problems is the existence of collinearity among the regression variables. Many methods to solve the problems caused by the existence of the same have been introduced linearly. One of these methods is ridge regression. In this article, a new estimate for the ridge parameter using generalized maximum Tsallis entropy is presented and we call it the Ridge estimator of generalized maximum Tsallis entropy. For the cement dataset Portland, which have strong collinearity and since 1332, different estimators have been presented for these data, this estimator is calculated and We compare the generalized maximum Tsallis entropy ridge estimator, generalized maximum entropy ridge estimator and the least squares estimator.

Keywords: Ridge Regression, Generalized Maximum Entropy, Tsallis Entropy, Generalized Maximum Tsallis Entropy.

¹ foot print