

رگرسیون فازی مبتنی بر کمترین قدرمطلق انحرافات

مریم کلکین نما^۱، سید محمود طاهری^۱

m – kelkinnama@math.iut.ac.ir, taheri@cc.iut.ac.ir

چکیده

در این مقاله به مدل رگرسیونی با متغیرهای ورودی دقیق و خروجی فازی پرداخته شده است. رویکرد پیشنهادی به این مساله، استفاده از روش کمترین قدرمطلق خطأ است که با معرفی واستفاده از یک متر در محیط اعداد فازی صورت گرفته است. به علاوه، یک شاخص تطبیق برای بررسی نیکویی برآشن مدل‌های رگرسیونی فازی معرفی شده است. روش پیشنهادی با مثال عددی تشریح شده و نشان داده شده است که در مدل‌سازی داده‌های شامل داده پرت عملکرد خوبی دارد.

واژه‌های کلیدی: رگرسیون فازی، کمترین قدرمطلق انحرافات، نیکویی برآشن، داده پرت، فضای متری.

۱ مقدمه

کلمینس [۶] در سال ۱۹۸۷ ارائه شد که با استفاده از روش کمترین مربعات به بررسی و برآشن مدل رگرسیون فازی می‌پردازد و می‌توان آن را تعمیم یافته رگرسیون کمترین مربعات معمولی دانست. مبنای این روش، استفاده از یک فاصله روى مجموعه اعداد فازی است که براساس آن، مجموع مربعات فواصل مقادیر خروجی فازی مشاهده شده و مقادیر برآورد فازی آن‌ها، مینیمم می‌شود.

تاکنون افراد مختلفی به بررسی انواع روش‌های رگرسیون امکانی و رگرسیون کمترین مربعات، تحت شرایط و حالت‌های مختلف، پرداخته‌اند. چند نمونه از مطالعات جدید در مورد رگرسیون امکانی را می‌توانید در [۱۲] و [۱۴] ببینید. همچنین برای مطالعه چند تحقیق اخیر درباره رگرسیون کمترین مربعات فازی به [۵] و [۱۱] مراجعه کنید. منابع بیشتر را همراه با مرور برخی تحقیقات می‌توانید در [۳] ببینید.

یکی از موضوعات مهم در رگرسیون، مدل‌سازی مجموعه

از زمان ارائه‌ی نظریه مجموعه‌های فازی توسط پروفسور زاده، استفاده از این نظریه در بخش‌های وسیعی از علم آمار در حال گسترش است. یکی از مهم‌ترین و کاربردی‌ترین این بخش‌ها، رگرسیون است.

اولین بارتاناکا و همکاران [۱۵] در سال ۱۹۸۲ موضوع رگرسیون فازی را مطرح کردند. آن‌ها مدل رگرسیون خطی با مشاهدات دقیق و پارامترهای فازی را مورد توجه قرار دادند. در رهیافت آن‌ها، که به‌نام «رگرسیون امکانی» نیز شناخته شده است، برآشن مدل رگرسیون خطی فازی به صورت مینیمم کردن مجموع ابهام در مقدار برآورد شده مشاهدات انجام می‌شود با توجه به این قید که میزان عضویت مقدار مشاهده شده خروجی (دقیق) در مقدار برآورد شده فازی متناظر آن، حداقل به میزان η باشد. این مساله عموماً معادل با یک مساله برنامه‌ریزی خطی (و گاهی غیرخطی) می‌شود که با حل آن، مدل بهینه رگرسیون فازی به دست می‌آید.

رهیافت دیگر در زمینه رگرسیون فازی توسط دایاموند [۹] و

^۱دانشکده علوم ریاضی، دانشگاه صنعتی اصفهان

مشاهده شده و برآورد آن‌ها را مینیمم کردند و برای مدل با ورودی و خروجی فازی ابتدا با غیرفازی‌سازی همه متغیرها، رگرسیون کمترین قدرمطلق خطای معمولی را اجرا کرده و سپس با تعریف یک عبارت خطای فازی، قدرمطلق فاصله بین اعداد فازی حاصل را مینیمم کردند.

آن‌چه که در این مقاله صورت گرفته است، ارایه یک مترجدید مبتنی بر قدرمطلق در مجموعه اعداد فازی است و براساس آن روشی برای انجام رگرسیون کمترین قدرمطلق انحرافات برای مدل با ورودی دقیق و خروجی فازی ارایه شده است. سپس با معرفی یک شاخص تطبیق و با به کارگیری آن در یک مثال عددی به بررسی این روش رگرسیونی پرداخته شده است. نتیجه شده است که روش پیشنهادی برای مدل‌سازی مجموعه داده‌های شامل داده‌های پرت، عملکرد مناسبی دارد.

۲ مفاهیم اولیه

فرض کنید X یک مجموعه مرجع باشد. یک مجموعه فازی \tilde{A} از X توسطتابع عضویت آن $[0, 1] \rightarrow X$ $\rightarrow 0 < \alpha \leq 1$ تعريف می‌شود. مجموعه α -برش \tilde{A} به صورت $\{x : \tilde{A}(x) \geq \alpha\}$ ، تعريف می‌شود.

تعريف ۱ هر مجموعه فازی نرمال از \mathbb{R} را که α -برش‌های آن به صورت بازه‌های بسته باشد، عدد فازی می‌نامیم.

تعريف ۲ عدد فازی \tilde{M} را عدد فازی LR گوییم اگر اعداد حقیقی m, α, β, γ باشند به طوری که

$$M(x) = \begin{cases} L\left(\frac{m-x}{\alpha}\right), & x < m \\ R\left(\frac{x-m}{\beta}\right), & x \geq m \end{cases}$$

که برای $x \geq 1$ $L(x) = R(x) = 1$ و برای $x \leq 0$ $L(x) = R(x) = 0$.

داده‌هایی است که در آن‌ها یک یا چند داده پرت وجود دارد. رویکرد متقابل در رگرسیون آماری، استفاده از روش کمترین مربعات است که به ویژه زمانی که توزیع خطاهای نرمال باشد، دارای خواص بهینه مناسبی است. اما زمانی که در مجموعه داده‌ها، داده‌های پرت که ناشی از توزیع‌های خطای دم سنگین هستند، وجود داشته باشند، معمولاً اثرات نامناسبی بر برآوردهای حاصل از روش کمترین مربعات خواهند گذاشت. در این موارد می‌توان از روش‌های نیرومند (استوار) استفاده کرد تا اثر داده‌های پرت را بربرا آوردهای ضرایب کمتر کند. یکی از روش‌های نیرومند، روش کمترین قدرمطلق خطای (Least Absolute Deviations : LAD) به خصوص زمانی که توزیع خطای دم سنگین داشته باشد، کارایی بالایی داشته و به طور وسیعی مورد استفاده قرار گرفته است [۱۰].

در عمل ممکن است در مجموعه‌ی داده‌های فازی نیز داده‌ی پرت وجود داشته باشد. لذا بررسی روش‌های رگرسیون فازی نیرومند نیز ضروری می‌نماید. به عنوان تعمیمی از رگرسیون کمترین قدرمطلق خطای معمولی، برخی محققان به بررسی رگرسیون کمترین قدرمطلق خطای فازی (FLAD) نیز پرداخته‌اند. چانگ ولی [۷] در سال ۱۹۹۴ با استفاده از یک روش رتبه‌بندی اعداد فازی، به مینیمم کردن قدرمطلق تفاضل رتبه اعداد فازی مشاهده شده و اعداد فازی برآورده شده متناظر آن‌ها پرداختند. ترابی و بهبودیان [۱۶] در سال ۲۰۰۷ روشی را برای انجام رگرسیون کمترین قدرمطلق انحرافات فازی با استفاده از اصل تجزیه برای مدلی با ورودی و خروجی فازی ارایه نمودند. چوی و باکلی [۸] در سال ۲۰۰۸ به بررسی دو مدل رگرسیون فازی به دو شیوه مختلف پرداختند. در مدل با متغیر ورودی غیرفازی و متغیر خروجی فازی، قدرمطلق تفاضل کران‌های پایین (و بالای) α -برش‌های اعداد فازی

از روش کمترین مجموع مربعات خطای است. این روش به علت راحتی محاسبات و داشتن ویژگی‌های مطلوب به ویژه در موقعیت که توزیع خطاهای نرمال باشد، بسیار مورد استفاده قرار می‌گیرد. اما هنگامی که در مجموعه داده‌ها، یک یا چند داده پرت وجود داشته باشد، ممکن است استفاده از روش کمترین مربعات روش مناسبی نباشد، چرا که نتایج تحلیل‌ها ممکن است بهشت تاثیر داده‌های پرت قرار گیرد. یک راه برای کاهش اثر این گونه داده‌ها، استفاده از معیار قدر مطلق خطای به جای مجدد خطای است.

برآوردهای روش‌های کمترین قدر مطلق و کمترین مربعات خطاهای برآورد ضرایب مدل رگرسیونی، عضو رده برآوردهای L_p هستند که توسط مینیمم کردن آن‌چه که به نام متر مینکووسکی^۲ یا $-L_P$ نرم معروف است

$$\left\{ \sum |\epsilon_i|^p \right\}^{1/p}, \quad p \geq 1$$

به دست می‌آیند. اگر $p = 1$ ، متر قدر مطلق (L_1 – نرم) را خواهیم داشت و مینیمم‌سازی این فاصله، روش رگرسیونی کمترین قدر مطلق خطای نامیده می‌شود. اگر $p = 2$ ، این معیار به متر اقلیدسی تبدیل می‌شود که مینیمم‌سازی مبتنی بر آن، منجر به روش کمترین مربعات خطای می‌شود.^[۱۰]

در عمل ممکن است در مجموعه داده‌های فازی نیز، داده پرت وجود داشته باشد. لذا شاید مناسب‌تر باشد که برای مدل سازی فازی داده‌های شامل داده پرت نیز از رگرسیون قدر مطلق انحرافات استفاده کیم.

در این بخش به معروفی یک فاصله بین اعداد فازی می‌پردازیم که مبتنی بر قدر مطلق بیان می‌شود و پس از بررسی ویژگی‌های آن، رگرسیون کمترین قدر مطلق انحرافات فازی را براساس این فاصله انجام می‌دهیم.

در این صورت \tilde{M} را به صورت $\tilde{M} = (m, \alpha, \beta)_{LR}$ نمایش می‌دهیم که m مرکز، α و β به ترتیب پهنای چپ و راست نامیده می‌شوند. اگر $L(x) = R(x) = 1 - x$ ، آن‌گاه \tilde{M} را عدد فازی مثلثی می‌نامیم و آن را با $\tilde{M} = (m, \alpha, \beta)_T$ نشان می‌دهیم به ویژه، اگر $\beta = \alpha$ ، آن‌گاه \tilde{M} را عدد فازی مثلثی متقارن نامیده و به صورت $(m, \alpha)_T$ نشان می‌دهیم.

حساب اعداد فازی از جمله اعمال جبری مانند ضرب اسکالر و جمع و ضرب بر اعداد فازی، براساس اصل گسترش تعریف می‌شود. برای مطالعه بیشتر در این زمینه به [۱۸] مراجعه کنید. برای اهداف این مقاله قضیه زیر را در مورد ضرب اسکالر و جمع دو عدد فازی LR بیان می‌کنیم.

قضیه ۱ فرض کنید \tilde{N}, \tilde{M} دو عدد فازی LR به صورت $\lambda \in \mathbb{R}$ باشد آن‌گاه $\tilde{N} = (n, \gamma, \delta)_{LR}$ و $\tilde{M} = (m, \alpha, \beta)_{LR}$ داریم

$$\begin{aligned} \lambda \otimes \tilde{M} &= \tilde{M} \otimes \lambda \\ &= \begin{cases} (\lambda m, \lambda \alpha, \lambda \beta)_{LR}, & \lambda > 0 \\ (\lambda m, -\lambda \beta, -\lambda \alpha)_{RL}, & \lambda < 0 \end{cases} \end{aligned}$$

$$\begin{aligned} \tilde{M} \oplus \tilde{N} &= (m, \alpha, \beta)_{LR} \oplus (n, \gamma, \delta)_{LR} \\ &= (m + n, \alpha + \gamma, \beta + \delta)_{LR} \end{aligned}$$

۳ رگرسیون کمترین قدر مطلق انحرافات فازی

مدل رگرسیونی $y = X\beta + \epsilon$ را در نظر بگیرید که در آن بردار مقادیر متغیر وابسته، X ماتریس مشاهدات متغیرهای مستقل، β بردار ضرایب مجھول و ϵ برداری از y ها، یعنی خطای بین مقدار مشاهده شده y_i و مقدار برآورد آن است. روش متداول برای برآورد ضرایب این مدل رگرسیونی، استفاده

Minkowsky^۲

$$\begin{aligned} |m_x - m_z| &\leq |m_x - m_y| + |m_y - m_z| \\ |(m_x - l \alpha_x) - (m_z - l \alpha_z)| &\leq |(m_x - l \alpha_x) - (m_y - l \alpha_y)| + |(m_y - l \alpha_y) - (m_z - l \alpha_z)| \\ |(m_x + r \beta_x) - (m_z + r \beta_z)| &\leq |(m_x + r \beta_x) - (m_y + r \beta_y)| + |(m_y + r \beta_y) - (m_z + r \beta_z)| \end{aligned}$$

با جمع کردن طرف‌های چپ این سه نامساوی و نیز طرف‌های راست آن‌ها، ملاحظه می‌شود که شرط چهارم نیز برقرار است. \square

قضیه ۳ $(\mathcal{F}_{LR}(\mathbb{R})$ و D_{LR}) یک فضای متری کامل است.

اثبات فرض کنید $\{\tilde{X}_n = (m_{x_n}, \alpha_{x_n}, \beta_{x_n})_{LR}; n \geq 1\}$ یک دنباله کوشی در $\mathcal{F}_{LR}(\mathbb{R})$ باشد. اگر $i, j \rightarrow \infty$ داریم $\{m_{x_n}\}_{n=1}^{\infty}$. لذا دنباله یک دنباله کوشی در \mathbb{R} است. در نتیجه با توجه به کامل بودن

$$m_{x_n} \rightarrow m_x, \mathbb{R}$$

نیز اگر $i, j \rightarrow \infty$ آن‌گاه

$$|(m_{x_i} - l \alpha_{x_i}) - (m_{x_j} - l \alpha_{x_j})| \leq D_{LR}(\tilde{X}_i, \tilde{X}_j) \rightarrow 0$$

پس دنباله $\{m_{x_n} - l \alpha_{x_n}\}_{n=1}^{\infty}$ یک دنباله کوشی در \mathbb{R} می‌باشد.

چون $\{m_{x_n}\}_{n=1}^{\infty}$ یک دنباله کوشی و یک عدد ثابت است،

نتیجه می‌شود که $\{\alpha_{x_n}\}_{n=1}^{\infty}$ نیز یک دنباله کوشی است.

پس $\alpha_{x_n} \xrightarrow{n \rightarrow \infty} \alpha_x$. به‌طور مشابه می‌توان ثابت کرد که

$$\beta_{x_n} \xrightarrow{n \rightarrow \infty} \beta_x$$

تمام موارد بالا نتیجه می‌دهند که $D_{LR}(\tilde{X}_n, \tilde{X}) \rightarrow 0$. پس

$$\square. \tilde{X} = (m_x, \alpha_x, \beta_x)_{LR} \text{ که } \tilde{X}_n \xrightarrow{n \rightarrow \infty} \tilde{X}$$

۲.۳ رگرسیون فازی مبتنی بر کمترین قدر مطلق انحرافات

فرض کنید مجموعه داده‌های $\{(x_i, \tilde{y}_i), i = 1, \dots, n\}$ را در اختیار داریم که در آن $x_i = (x_{i0}, x_{i1}, \dots, x_{ip})$ با $x_{i0} = 1$ بردار مشاهدات ورودی غیرفازی (دقیق) و غیرمنفی

۱.۳ معرفی یک متر جدید برای اعداد فازی

تعريف ۳ فرض کنید $\tilde{Y} = (m_y, \alpha_y, \beta_y)_{LR}$ و $\tilde{X} = (m_x, \alpha_x, \beta_x)_{LR}$ ، دو عدد فازی LR باشند، آن‌گاه فاصله بین دو عدد فازی \tilde{X} و \tilde{Y} به صورت زیر تعریف می‌شود

$$D_{LR}(\tilde{X}, \tilde{Y}) = |m_x - m_y| + |(m_x - l \alpha_x) - (m_y - l \alpha_y)| \quad (1)$$

$$- |(m_x + r \beta_x) - (m_y + r \beta_y)|$$

$$. l = \int_0^1 L^{-1}(w) dw \text{ و } r = \int_0^1 R^{-1}(w) dw$$

این فاصله بین اعداد فازی در تمام خواص یک متر صدق می‌کند.

قضیه ۲ اگر $(\mathcal{F}_{LR}(\mathbb{R}), D_{LR})$ مجموعه همه اعداد فازی از مجموعه اعداد حقیقی \mathbb{R} باشد، آن‌گاه $(\mathcal{F}_{LR}(\mathbb{R}), D_{LR})$ یک فضای متری است.

اثبات کافی است نشان دهیم که چهار ویژگی زیر برقرار است

$$\forall \tilde{X}, \tilde{Y} \in \mathcal{F}_{LR}, \quad D_{LR}(\tilde{X}, \tilde{Y}) \geq 0 \quad (1)$$

$$D_{LR}(\tilde{X}, \tilde{Y}) = 0 \Leftrightarrow \tilde{X} = \tilde{Y} \quad (2)$$

$$\forall \tilde{X}, \tilde{Y} \in \mathcal{F}_{LR}, \quad D_{LR}(\tilde{X}, \tilde{Y}) = D_{LR}(\tilde{Y}, \tilde{X}) \quad (3)$$

$$\forall \tilde{X}, \tilde{Y}, \tilde{Z} \in \mathcal{F}_{LR}, \quad (4)$$

$$D_{LR}(\tilde{X}, \tilde{Z}) \leq D_{LR}(\tilde{X}, \tilde{Y}) + D_{LR}(\tilde{Y}, \tilde{Z})$$

شرط‌های اول و دوم به‌وضوح برقرار هستند، برای اثبات شرط

سوم توجه کنید که

$$\begin{aligned} D_{LR}(\tilde{X}, \tilde{Y}) &= |m_x - m_y| + |(m_x - l \alpha_x) - (m_y - l \alpha_y)| + \\ &+ |(m_x + r \beta_x) - (m_y + r \beta_y)| \\ &= |m_y - m_x| + |(m_y - l \alpha_y) - (m_x - l \alpha_x)| + |(m_y + r \beta_y) - (m_x + r \beta_x)| = D(\tilde{Y}, \tilde{X}) \end{aligned}$$

برای بررسی شرط چهارم نیز با استفاده از نامساوی مثلثی داریم

$$\text{که } |m_{y_i} - \sum_{j=0}^p m_j x_{ij}| = d_i^{m\downarrow} + d_i^{m\uparrow}$$

$$m_{y_i} - \sum_{j=0}^p m_j x_{ij} = d_i^{m\downarrow} - d_i^{m\uparrow}$$

به طور مشابه با استفاده از متغیرهای غیرمنفی $d_i^{L\downarrow}$ و $d_i^{L\uparrow}$

و $d_i^{R\downarrow}$ دو قدرمطلق دیگر را نیز به صورت زیر می‌نویسیم

$$|m_{y_i} - \frac{1}{\gamma} \alpha_{y_i} - (\sum_{j=0}^p m_j x_{ij} - \frac{1}{\gamma} \sum_{j=0}^p \alpha_j x_{ij})| = d_i^{L\downarrow} + d_i^{L\uparrow}$$

$$m_{y_i} - \frac{1}{\gamma} \alpha_{y_i} - (\sum_{j=0}^p m_j x_{ij} - \frac{1}{\gamma} \sum_{j=0}^p \alpha_j x_{ij}) = d_i^{L\downarrow} - d_i^{L\uparrow}$$

$$|m_{y_i} + \frac{1}{\gamma} \beta_{y_i} - (\sum_{j=0}^p m_j x_{ij} + \frac{1}{\gamma} \sum_{j=0}^p \beta_j x_{ij})| = d_i^{R\downarrow} + d_i^{R\uparrow}$$

$$m_{y_i} + \frac{1}{\gamma} \beta_{y_i} - (\sum_{j=0}^p m_j x_{ij} + \frac{1}{\gamma} \sum_{j=0}^p \beta_j x_{ij}) = d_i^{R\downarrow} - d_i^{R\uparrow}$$

سرانجام مساله مینیمم‌سازی بالا به صورت زیر صورت بندی می‌شود

$$Z = \sum_{i=1}^n (d_i^{m\downarrow} + d_i^{m\uparrow} + d_i^{R\downarrow} + d_i^{R\uparrow} + d_i^{L\downarrow} + d_i^{L\uparrow})$$

s.t.

$$m_{y_i} - \sum_{j=0}^p m_j x_{ij} = d_i^{m\downarrow} - d_i^{m\uparrow},$$

$$m_{y_i} - \frac{1}{\gamma} \alpha_{y_i} - (\sum_{j=0}^p m_j x_{ij} - \frac{1}{\gamma} \sum_{j=0}^p \alpha_j x_{ij}) = d_i^{L\downarrow} - d_i^{L\uparrow},$$

$$m_{y_i} + \frac{1}{\gamma} \beta_{y_i} - (\sum_{j=0}^p m_j x_{ij} + \frac{1}{\gamma} \sum_{j=0}^p \beta_j x_{ij}) = d_i^{R\downarrow} - d_i^{R\uparrow},$$

$$d_i^{m\downarrow}, d_i^{m\uparrow}, d_i^{R\downarrow}, d_i^{R\uparrow}, d_i^{L\downarrow}, d_i^{L\uparrow} \geq 0,$$

$$\alpha_j \geq 0, \beta_j \geq 0, j = 0, \dots, p.$$

مساله برنامه‌ریزی خطی بالا با استفاده از نرم‌افزارهایی مانند *GAMS* و *LINGO* قابل حل می‌باشد. با حل مساله فوق، مراکز و پهنهای اعداد فازی مثلى \tilde{A}_j ها (یعنی ضرایب فازی مدل) به دست می‌آیند.

$$, i = 1, \dots, n, \tilde{y}_i = (m_{y_i}, \alpha_{y_i}, \beta_{y_i})_{LR} \quad (x_{ij} \geq 0, \forall i, j)$$

قدار خروجی مشاهده شده فازی باشد.

اکنون می‌خواهیم مدل زیر را به این داده‌ها برازش دهیم

$$\begin{aligned} \tilde{Y}_i &= (\tilde{A}_0 \otimes x_{i0}) \oplus (\tilde{A}_1 \otimes x_{i1}) \oplus (\tilde{A}_2 \otimes x_{i2}) \\ &\quad \oplus \dots \oplus (\tilde{A}_p \otimes x_{ip}), \quad i = 1, \dots, n \end{aligned}$$

که در آن $\tilde{A}_j = (m_j, \alpha_j, \beta_j)_{LR}$, $j = 0, \dots, p$, ضرایب مدل، به صورت اعداد فازی LR هستند.

در بین انواع اعداد فازی، اعداد فازی مثلى به دلیل راحتی محاسبات، بیشتر استفاده می‌شوند. لذا ما نیز در ادامه \tilde{A}_j, \tilde{y}_i را اعداد فازی مثلى در نظر می‌گیریم.

با استفاده از روابط موجود بین ضرب و جمع اعداد فازی LR در قضیه ۱، معلوم می‌شود که \tilde{Y}_i یک عدد فازی مثلى

به صورت زیر خواهد بود

$$\tilde{Y}_i = (\sum_{j=0}^p m_j x_{ij}, \sum_{j=0}^p \alpha_j x_{ij}, \sum_{j=0}^p \beta_j x_{ij})_T, i = 1, \dots, n.$$

برای برازش مدل رگرسیونی کمترین قدرمطلق خطای فازی، مجموع فاصله بین \tilde{Y}_i و \tilde{y}_i را بر اساس متر (۱) مینیمم می‌کنیم. یعنی

$$\begin{aligned} \sum_{i=1}^n D_T(\tilde{y}_i, \tilde{Y}_i) &= \sum_{i=1}^n \left\{ |m_{y_i} - \sum_{j=0}^p m_j x_{ij}| \right. \\ &\quad \left. + |(m_{y_i} - \frac{1}{\gamma} \alpha_{y_i}) - (\sum_{j=0}^p m_j x_{ij} - \frac{1}{\gamma} \sum_{j=0}^p \alpha_j x_{ij})| \right. \\ &\quad \left. + |(m_{y_i} + \frac{1}{\gamma} \beta_{y_i}) - (\sum_{j=0}^p m_j x_{ij} + \frac{1}{\gamma} \sum_{j=0}^p \beta_j x_{ij})| \right\} \end{aligned}$$

برای این که بتوان مساله مینیمم‌سازی بالا را به صورت یک مساله برنامه‌ریزی خطی نوشت تا به راحتی قابل حل باشد، به شیوه زیر عمل می‌کنیم

با استفاده از متغیرهای غیرمنفی $d_i^{m\downarrow}$ و $d_i^{m\uparrow}$ ، تعریف می‌کنیم

۴ نیکویی برازش

اثبات بهوضوح می‌توان دید که ویژگی‌های اول و سوم در مورد این شاخص برقرار است.

ویژگی دوم: طرف (\rightarrow) بهوضوح برقرار است، برای اثبات طرف (\leftarrow) توجه کنید که

$$I_{UI}(\tilde{A}, \tilde{B}) = 1 \Rightarrow Card(\tilde{A} \cap \tilde{B}) = Card(\tilde{A} \cup \tilde{B})$$

بنا بر این (در حالت پیوسته)

$$\int_R [(\tilde{A} \cup \tilde{B})(x) - (\tilde{A} \cap \tilde{B})(x)] dx = 0$$

از آنجایی که $\tilde{A} \cap \tilde{B} \subseteq \tilde{A} \cup \tilde{B}$ لذا نتیجه می‌شود که

$$\tilde{A} = \tilde{B} \quad \text{و این یعنی } \tilde{A} \cap \tilde{B} = \tilde{A} \cup \tilde{B}$$

ویژگی چهارم

فرض کنید $\tilde{A} \cup \tilde{C} = \tilde{B} \cup \tilde{C} = \tilde{C}$ ، لذا $\tilde{A} \subseteq \tilde{B} \subseteq \tilde{C}$ و نیز

$$\tilde{A} \cap \tilde{C} \subseteq \tilde{B} \cap \tilde{C}$$

با استفاده از روابط بالا داریم

$$\begin{aligned} I_{UI}(\tilde{A}, \tilde{C}) &= \frac{Card(\tilde{A} \cap \tilde{C})}{Card(\tilde{A} \cup \tilde{C})} \\ &\leq \frac{Card(\tilde{B} \cap \tilde{C})}{Card(\tilde{A} \cup \tilde{C})} \\ &= \frac{Card(\tilde{B} \cap \tilde{C})}{Card(\tilde{B} \cup \tilde{C})} \\ &= I_{UI}(\tilde{B}, \tilde{C}) \end{aligned}$$

واز طرف دیگر داریم

ولذا

$$\begin{aligned} I_{UI}(\tilde{A}, \tilde{C}) &= \frac{Card(\tilde{A} \cap \tilde{C})}{Card(\tilde{A} \cup \tilde{C})} \\ &= \frac{Card(\tilde{A} \cap \tilde{B})}{Card(\tilde{A} \cup \tilde{C})} \\ &\leq \frac{Card(\tilde{A} \cap \tilde{B})}{Card(\tilde{A} \cup \tilde{B})} \\ &= I_{UI}(\tilde{A}, \tilde{B}) \end{aligned}$$

بنا بر این

در بررسی مدل‌های رگرسیون فازی، باید معیاری در دست داشت تا به وسیله آن، مدل‌های مختلف را با هم مقایسه کرد. در واقع باید برای هر مدل نیکویی برازش مقدار برآورده شده به مقدار مشاهده شده متناظر آنها را اندازه‌گیری کرد تا بدین وسیله معیاری برای سنجش خوبی یک مدل به دست آید. در راستای رسیدن به این هدف، در این بخش به معرفی یک شاخص می‌پردازیم.

تعريف ۴ اگر \tilde{A} و \tilde{B} دو عدد فازی باشند، مقدار مشابهت آن‌ها را به صورت زیر تعریف می‌کنیم

$$I_{UI}(\tilde{A}, \tilde{B}) = \frac{Card(\tilde{A} \cap \tilde{B})}{Card(\tilde{A} \cup \tilde{B})} \quad (2)$$

که در آن (با فرض وجود مجموع یا انتگرال)

$$Card(\tilde{A}) = \begin{cases} \sum_x \tilde{A}(x) & \text{گسسته} \\ \int_x \tilde{A}(x) dx & \text{پیوسته} \end{cases}$$

و اشتراک و اجتماع نیز بر اساس عملگرهای \max و \min هستند.^۳

قضیه ۴ شاخص تطبیق I_{UI} دارای ویژگی‌های زیر است

$$0 \leq I_{UI}(\tilde{A}, \tilde{B}) \leq 1 \quad (1)$$

$$\tilde{A} = \tilde{B} \Leftrightarrow I_{UI}(\tilde{A}, \tilde{B}) = 1 \quad (2)$$

$$I_{UI}(\tilde{A}, \tilde{B}) = I_{UI}(\tilde{B}, \tilde{A}) \quad (3)$$

$$\tilde{A} \subseteq \tilde{B} \subseteq \tilde{C} \implies \quad (4)$$

$$I_{UI}(\tilde{A}, \tilde{C}) \leq \min\{I_{UI}(\tilde{A}, \tilde{B}), I_{UI}(\tilde{B}, \tilde{C})\}. \quad \square$$

$$I_{UI}(\tilde{A}, \tilde{C}) \leq \min\{I_{UI}(\tilde{A}, \tilde{B}), I_{UI}(\tilde{B}, \tilde{C})\}$$

^۳ U^3 مخفف I Union و C Intersection است.

$$\tilde{Y} = -17/229 \oplus (-0/1855, 0/1490, 0) \otimes x_1 \oplus \\ -0/936x_2 \oplus (1/6185, 0/0368, 0/0827) \otimes x_3$$

جدول ۱. داده‌های مربوط به مثال.

شماره		های دقیق	ورودی	خروجی فازی
	x_1	x_2	x_3	
۱	۲/۰۰	۰/۰۰	۱۵/۲۵	(۵/۸۳ و ۳/۵۶)
۲	۰/۰۰	۵/۰۰	۱۴/۱۳	(۰/۸۵ و ۰/۵۲)
۳	۱/۱۳	۱/۵۰	۱۴/۱۳	(۱۳/۹۳ و ۸/۵۰)
۴	۲/۰۰	۱/۲۵	۱۳/۶۳	(۴/۰۰ و ۲/۴۴)
۵	۲/۱۹	۳/۷۵	۱۴/۷۵	(۱/۶۵ و ۱/۰۱)
۶	۰/۲۵	۳/۵۰	۱۳/۷۵	(۱/۵۸ و ۰/۹۶)
۷	۰/۷۵	۵/۲۵	۱۵/۲۵	(۸/۱۸ و ۴/۹۹)
۸	۴/۲۵	۲/۰۰	۱۳/۵۰	(۱/۸۵ و ۱/۱۲)

مقایسه نیکویی برازش دو مدل

معیار چوی و باکلی برای مقایسه دو مدل، مجموع خطای بین مقدار مشاهده شده و مقدار برآورد شده، است که برای هر مشاهده به صورت تفاضل تابع عضویت آنها تعریف می‌شود، یعنی،

$$error(\tilde{y}_i, \tilde{Y}_i) =$$

$$\begin{cases} \frac{\int_{-\infty}^{\infty} |\tilde{y}_i(x) - \tilde{Y}_i(x)| dx}{\int_{-\infty}^{\infty} \tilde{y}_i(x) dx} & \int_{-\infty}^{\infty} \tilde{y}_i(x) dx > 1 \\ \int_{-\infty}^{\infty} |\tilde{y}_i(x) - \tilde{Y}_i(x)| dx & \int_{-\infty}^{\infty} \tilde{y}_i(x) dx \leq 1 \end{cases}$$

در جدول ۲ مقادیر خطای برای دو مدل درج شده است.

جدول ۲. مقادیر خطای برای دو مدل

شماره	روش چوی و باکلی	روش پیشنهادی
۱	۰/۷۷۷۶	۰/۴۰۸۸
۲	۰/۲۳۱۵	۱/۲۳۲۰
۳	۱/۱۱۰۱	۱/۱۹۷۰
۴	۰/۶۹۳۳	۰/۲۵۷۱
۵	۱/۶۰۳۳	۱/۲۱۷۲
۶	۰/۲۲۹۹	۱/۹۴۷۶
۷	۱/۱۹۰۸	۱/۳۶۹۱
۸	۰/۰۰۰۰	۱/۴۸۵۲
مجموع	۶/۰۳۶۵	۹/۶۱۴۱

هم‌چنان که آشکار است مجموع مقادیر خطای روش چوی و باکلی کمتر پیشنهادی از مجموع مقادیر خطای روش چوی و باکلی است.

تعريف ۵ برای مدل رگرسیون با ضرایب فازی، MCI (میانگین شاخص‌های تطبیق^۴) به صورت زیر تعریف می‌شود

$$MCI = \frac{1}{n} \sum_{i=1}^n I_{UI}(\tilde{y}_i, \tilde{Y}_i)$$

واضح است که $0 \leq MCI \leq 1$. از بین چند مدل، هر چه مقدار MCI برای یک مدل به یک نزدیک‌تر باشد، می‌توان نتیجه گرفت که مدل مورد نظر بهتر به مجموعه داده‌ها برازش شده است. نیز، مقدار نزدیک به صفر این معیار برای یک مدل، نشان دهنده برازش ضعیف آن مدل به داده‌ها است.

۵ مثال عددی

در این بخش مثالی را که چوی و باکلی [۸] ارائه کرده و از آن استفاده نموده‌اند، مورد توجه و بررسی قرار می‌دهیم. مجموعه داده‌های استفاده شده توسط آنها در جدول (۱) درج شده است. در این مجموعه داده‌ها، مقادیر مشاهده شده متغیر خروجی، به صورت اعداد فازی متقارن مثلثی هستند.

چوی و باکلی ادعا کرده‌اند که در این مجموعه داده‌ها، یک داده پرت (داده شماره ۳) وجود دارد و نشان داده‌اند که مدل رگرسیونی کمترین قدر مطلق خطای فازی (به شیوه‌ای که در مقدمه به آن اشاره شد) در مورد این داده‌ها بهتر از روش رگرسیونی کمترین مربعات خطای فازی عمل می‌کند. استفاده از مدل چوی و باکلی برای مدل‌سازی داده‌های جدول (۱) منجر به مدل زیر می‌شود

$$\tilde{Y} = -2/8273 \oplus (-0/3878, 0/2132, 0) \otimes x_1 \oplus \\ -1/0125x_2 \oplus (0/6185, 0/0368, 0/2112) \otimes x_3$$

از سوی دیگر، با به کارگیری شیوه معرفی شده در این مقاله در مدل‌سازی داده‌های جدول (۱) به مدل زیر دست می‌یابیم

جدول (۳). مقادیر شاخص تطبیق برای دو مدل

روش پیشنهادی شماره	روش چوی و باکلی	روش پیشنهادی
۱	۰/۲۴۷۳	۰/۵۹۱۲
۲	۰/۶۱۰۷	۰/۲۹۶۸
۳	۰/۰۰۰۰	۰/۰۰۹۷
۴	۰/۲۳۶۹	۰/۷۴۷۶
۵	۰/۱۱۲۴	۰/۲۷۸۴
۶	۰/۷۰۲۲	۰/۱۶۰۴
۷	۰/۰۰۲۲	۰/۰۰۹۳
۸	۱/۰۰۰۰	۰/۳۱۹۹
میانگین	۰/۳۷۶۵	۰/۳۰۱۶

است.

از سوی دیگر می‌توان دو مدل را برپایه شاخص تطبیق (۲) نیز مقایسه نمود. در جدول (۳) مقادیر شاخص تطبیق برای دو مدل درج شده‌اند.

واضح است که براساس این معیار نیز، مدل مبتنی بر روش پیشنهاد شده در مقاله، برازش بهتری به داده‌ها دارد.

مراجع

- [۱] اخلاقی، سعید؛ تقی‌زاده کاخکی، حسین؛ ارقامی، ناصررضا، رگرسیون حداقل مربعات فازی، اندیشه آماری ۹ (۱۳۸۳)، ۶۲-۵۳.
- [۲] ماشین‌چی، ماشا...، رگرسیون با استفاده از پایگاه اطلاعاتی مشکک، اندیشه آماری ۵ (۱۳۷۹)، ۱۹-۱۳.
- [۳] طاهری، سید محمود، آمار فازی: مروری بر گذشته و چشم اندازهای آینده، اندیشه آماری ۷ (۱۳۸۱)، ۷۲-۵۸.
- [4] Arabpour A.R., Tata M. (2008), *Estimating the parameters of a fuzzy linear regression model*, Iranian Journal of Fuzzy Systems, (to appear).
- [5] Bargiela A., Pedrycz W., Nakashima T. (2007), *Multiple regression with fuzzy data*, Fuzzy Sets and Systems, 158: 2169-2188.
- [6] Celmins A. (1987), *Least squares model fitting to fuzzy vector data*, Fuzzy Sets and Systems, 22: 260-269.
- [7] Chang P.T., Lee C.H. (1994), *Fuzzy least absolute deviations regression based on the ranking of fuzzy numbers*, Proc. of IEEE World Congress on Computational Intelligence, pp: 1365-1369.
- [8] Choi S.H., Buckley J.J. (2008), *Fuzzy regression using least absolute deviation estimators*, Soft Comput., 12: 254-263.
- [9] Diamond P. (1987), *Least squares fitting of several fuzzy variables*, Proc. of Second IFSACongress, Tokyo, pp: 20-25.
- [10] Dodge Y. (1987), *An introduction to statistical data analysis L1-norm based*, In: Statistical Data Analysis Based on the L1-Norm and Related Methods, pp: 1-22.

- [11] D'Urso P., Santoro A. (2006), *Goodness of fit and variable selection in the fuzzy multiple linear regression*, Fuzzy Sets and Systems, 157: 2627-2647.
- [12] Guo, P., Tanaka, H. (2006), Dual models for possibilistic regression analysis, *Comput. Stat. and Data Anal.* 51: 253-266.
- [13] Mohammadi J., Taheri S.M. (2004), *Pedomodels fitting with fuzzy least squares regression*, *Iranian Journal of Fuzzy Systems*, 1(2): 45-61.
- [14] Nasrabadi M.M., Nasrabadi E., Nasrabadi A.R. (2005), *Fuzzy linear regression analysis a multi-objective programming approach*, *Applied Math. and Comp.* 163: 245-251.
- [15] Tanaka H., Vejima S., Asai K. (1982), *Linear regression analysis with fuzzy model*, *IEEE Trans. System Man Cybernet*, 12: 903-907.
- [16] Torabi H., Behboodian J. (2007), *Fuzzy least-absolute estimates in linear models*, *Communications in Statistics-Theory and Methods*, 36: 1935-1944.
- [17] Yang M.S., Ko C.H. (1997), *On cluster-wise fuzzy regression analysis*, *IEEE Trans Systems Man Cybernet. B* 27(1): 1-13.
- [18] Zimmermann H.J. (1996), *Fuzzy Set Theory and Its Applications*, Kluwer, Dordrecht, 3rd ed.