

رگرسیون خطی فازی با استفاده از برنامه‌ریزی آرمانی

حسن حسنپور^۱، حمیدرضا ملکی^۲، محمدعلی یعقوبی^۳

hassanhassanpur@yahoo.com, maleki@sutech.ac.ir, yaghoobi@mail.uk.ac.ir

چکیده

با وجود این که زمان زیادی از پیدایش رگرسیون فازی نمی‌گذرد، این مبحث توسعه بسیار زیادی یافته است. در این مقاله سعی شده است برخی از روش‌های رگرسیون خطی فازی به اختصار مرور شود. سپس شیوه‌ای جدید برای محاسبه ضرایب مدل رگرسیون خطی فازی مبتنی بر رگرسیون کمترین قدر مطلق خطا و با استفاده از یک فاصله وزن‌دار بین اعداد فازی مثلثی ارائه شده است. در روش ارائه شده برای محاسبه ضرایب رگرسیون از برنامه‌ریزی آرمانی استفاده می‌شود. نتایج بدست آمده برتری این روش را نسبت به برخی از روش‌های موجود از نظر خطای برازش و حساسیت نسبت به داده‌های پرت نشان می‌دهد.

واژه‌های کلیدی: رگرسیون خطی فازی، برنامه‌ریزی آرمانی، برنامه‌ریزی خطی، فاصله وزن‌دار، عدد فازی.

۱ مقدمه

سر و کار نداریم. بسیاری اوقات از واژه‌هایی که یک مفهوم مقدار کاملاً مشخصی را در ذهن تداعی می‌کنند استفاده نمی‌کنیم. برای مثال، از عباراتی مانند «تقریباً»، «کم و بیش»، «کوتاه»، «خیلی خوب»، و «نسبتاً خوب» استفاده می‌کنیم یا از کمیت‌های نادقیقی مانند «حدوداً ۲» به جای عدد ۲، و «اعداد خیلی بزرگ» صحبت به میان می‌آوریم. در چنین مواردی، با داده‌های مبهم یا اصطلاحاً فازی سروکار داریم. در مبحث رگرسیون نیز اگر بخشی یا تمام مشاهدات به جای اعداد حقیقی، اعداد فازی باشند، باید از رگرسیون فازی استفاده کرد. اگر ورودی‌ها اعداد حقیقی و پاسخ‌ها اعداد فازی باشند، هدف رگرسیون خطی فازی برازش مدلی به صورت زیر بر داده‌ها است

$$\tilde{Y} = \tilde{A}_0 + \tilde{A}_1 x_1 + \dots + \tilde{A}_p x_p \quad (2)$$

که در آن ضرایب رگرسیون $\tilde{A}_p, \dots, \tilde{A}_1, \tilde{A}_0$ اعداد فازی

تحلیل رگرسیون، ابزاری آماری برای یافتن رابطه‌ای بین دو یا چند متغیر بر مبنای تعدادی مشاهده است. از این رابطه برای پیش‌بینی مقدار متغیر وابسته (خروجی یا پاسخ) به ازای مقادیر معینی از متغیر(های) مستقل (ورودی) استفاده می‌شود. مجموعه‌ای شامل n داده به صورت $(x_{i1}, x_{i2}, \dots, x_{ip}, y_i)$ به ازای $i = 1, 2, \dots, n$ را در نظر بگیرید که در آن x_{ij} مقدار متغیر مستقل x_j و y_i مقدار متغیر وابسته y در مشاهده i است. هدف رگرسیون خطی، برازش مدلی خطی به صورت

$$Y = a_0 + a_1 x_1 + \dots + a_p x_p = \sum_{j=0}^p a_j x_j, \quad (1)$$

که در آن $x_0 = 1$ ، بر داده‌های فوق است به گونه‌ای که پاسخ‌های برآورد شده از مدل یعنی $y_i = \sum_{j=0}^p a_j x_{ij}$ کمترین فاصله ممکن را تا پاسخ‌های داده شده y_i داشته باشند. در بسیاری از مسایل دنیای واقعی با داده‌های دقیق

^۱بخش ریاضی، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان

^۲دانشکده علوم پایه، دانشگاه صنعتی شیراز

^۳بخش آمار، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان

$$r\tilde{A}_1 = \begin{cases} (ra_1, r\alpha_1, r\beta_1) & r \geq 0, \\ (ra_1, |r|\beta_1, |r|\alpha_1) & r < 0. \end{cases} \quad (7)$$

در بخش بعد برخی از روش‌های موجود برای برآورد ضرایب مدل رگرسیون خطی به اختصار مرور شده و به بعضی از اشکالات آنها اشاره شده است. در نهایت شیوه‌ای جدید برای محاسبه ضرایب رگرسیون ارائه شده و خواص آن مورد بررسی قرار گرفته است.

۲ معرفی بر برخی از روش‌های رگرسیون خطی فازی

دو دیدگاه کلی برای مواجهه با مساله رگرسیون خطی فازی وجود دارد: دیدگاه کمترین مربعات و دیدگاه برنامه‌ریزی ریاضی. استفاده از روش کمترین مربعات در رگرسیون خطی فازی اولین بار توسط کلمینس^۴ [۲] در سال ۱۹۸۷ ارائه شد و توسط دیگران توسعه یافت (برای مثال به [۱، ۲، ۴، ۱۰، ۱۱، ۱۲] مراجعه نمایید). استفاده از برنامه‌ریزی خطی در رگرسیون خطی فازی اولین بار توسط تاناكا^۵ و همکاران [۲۰] در سال ۱۹۸۲ ارائه شد. آنها یک مدل برنامه‌ریزی خطی برای محاسبه ضرایب مدل رگرسیون (۲) با این فرض که خروجی و ضرایب مدل اعداد فازی مثلثی متقارن باشند ارائه کردند که تابع هدف آن کمینه کردن مجموع پهنه‌های ضرایب بود و محدودیت‌های آن باعث می‌شد که به ازای مقدار مشخصی از h ، $-h$ —برش پاسخ‌های برآورد شده از مدل شامل $-h$ —برش پاسخ‌های داده شده‌ی متناظر شان باشند. از جمله نواقص این مدل این است که جواب به مقیاس متغیرهای ورودی x وابسته است [۷]، بسیاری از پهنه‌های ضرایب مدل صفر به دست می‌آیند [۷]، و دیگر این که مدل نسبت به داده‌های پرت بسیار حساس است [۱۵].

می‌باشند و از نماد \oplus برای جمع اعداد فازی استفاده شده است. در صورتی که هم ورودی‌ها و هم پاسخ‌ها اعداد فازی باشند، هدف رگرسیون خطی فازی برازش مدلی به یکی از صورت‌های زیر بر داده‌ها است

$$\tilde{Y} = a_0 \oplus a_1 \tilde{x}_1 \oplus \dots \oplus a_p \tilde{x}_p, \quad (3)$$

$$\tilde{Y} = \tilde{A}_0 \oplus a_1 \tilde{x}_1 \oplus \dots \oplus a_p \tilde{x}_p, \quad (4)$$

$$\tilde{Y} = \tilde{A}_0 \oplus \tilde{A}_1 \tilde{x}_1 \oplus \dots \oplus \tilde{A}_p \tilde{x}_p. \quad (5)$$

در مدل (۳)، ضرایب رگرسیون همگی غیرفازی‌اند، در مدل (۴)، \tilde{A}_0 فازی ولی سایر ضرایب غیرفازی‌اند و در مدل (۵)، تمام ضرایب رگرسیون اعداد فازی‌اند. مقالات بسیار زیادی پیرامون رگرسیون خطی فازی توسط افراد مختلف نوشته شده است که در اکثر آنها خروجی‌ها و ضرایب رگرسیون اعداد فازی مثلثی متقارن و ورودی‌ها اعداد حقیقی فرض شده‌اند. در بخش بعد به برخی از آنها به اختصار اشاره خواهد شد. یک عدد فازی مثلثی مانند \tilde{A} ، با یک سه‌تایی مرتب $\tilde{A} = (a, \alpha, \beta)$ نمایش داده می‌شود که در آن عدد حقیقی a مرکز و اعداد مثبت α و β به ترتیب پهنه‌های چپ و راست آن نام دارند.تابع عضویت \tilde{A} عبارت است از

$$\mu_{\tilde{A}}(x) = \begin{cases} \frac{x-(a-\alpha)}{\alpha} & a-\alpha \leq x \leq a \\ \frac{(a+\beta)-x}{\beta} & a \leq x \leq a+\beta \\ 0 & \text{سایر جاهای} \end{cases}$$

بازه‌های $[a - (1-h)\alpha, a + (1-h)\beta]$ که $1 \leq h \leq 0$ و $[a - \alpha, a + \beta]$ به ترتیب $-h$ —برش و تکیه‌گاه \tilde{A} نام دارند. اگر $\alpha = \beta$ یک عدد فازی مثلثی متقارن نام دارد و با $\tilde{A} = (a, \alpha)$ نمایش داده می‌شود. با استفاده از اصل گسترش اعداد فازی [۲۱]، برای دو عدد فازی $\tilde{A}_1 = (a_1, \alpha_1, \beta_1)$ و $\tilde{A}_2 = (a_2, \alpha_2, \beta_2)$ و عدد حقیقی r داریم

$$\tilde{A}_1 \oplus \tilde{A}_2 = (a_1 + a_2, \alpha_1 + \alpha_2, \beta_1 + \beta_2), \quad (6)$$

و آن این که هر دو روش برای محاسبه ضرایب رگرسیون از مجموع پهناهای ضرایب رگرسیون به عنوان درجه ابهام مدل رگرسیون استفاده می‌کنند. در نتیجه هرچه پهناهی ضرایب به دست آمده بیشتر باشد ابهام خروجی‌های برآورد شده توسط مدل بیشتر خواهد بود. به عبارت دیگر، خروجی‌های برآورد شده کارایی کمتری خواهند داشت. کیم و بیشو برای رفع این نقصه روش دیگری ارائه نمودند که در آن برای محاسبه نقاط ابتدا، مراکز و نقاط انتهایی ضرایب فازی مثلثی، سه مدل کمترین مربعات معمولی حل می‌شود. در [۶] نشان داده شده است که روش کیم و بیشو در بسیاری از موارد پهناهای منفی برای ضرایب رگرسیون به دست می‌دهد، و این نقصه با اعمال شرایط اضافی بر مدل‌های کمترین مربعات کیم و بیشو برطرف شده است [۶].

ساکاوا و یانو^۸ [۱۷] به کمک سه شاخص دبوا و پراد^۹ [۵] برای تساوی اعداد فازی، سه مدل برنامه‌ریزی خطی مختلف برای محاسبه ضرایب هریک از مدل‌های (۲) و (۵) ارائه کردند. علاوه بر این، سه مدل برنامه‌ریزی خطی دو هدفی نیز توسط این نویسندها به کمک سه شاخص مذکور ارائه شده است. حجتی^{۱۰} و همکاران [۷] دو مدل برنامه‌ریزی خطی با استفاده از برنامه‌ریزی آرمانی برای محاسبه ضرایب مدل‌های (۲) و (۵) ارائه کردند. این دو مدل نیز همانند اکثر مدل‌های ارائه شده مراکز اعداد مثلثی را در محاسبه ضرایب رگرسیون به حساب نمی‌آورند.

دو مدل برنامه‌ریزی خطی نیز توسط پیترز^{۱۱} [۱۴] و ازلکان و داکستین^{۱۲} [۱۳] برای محاسبه ضرایب مدل (۲) ارائه شده

تاناکا [۳] مدل قبلی را به این صورت اصلاح کرد که به جای مجموع پهناهای ضرایب، مجموع پهناهای پاسخ‌های برآورد شده را در نظر گرفت و دو مدل برنامه‌ریزی خطی ارائه کرد. یکی از این دو مدل مجموع مذکور را تحت همان شرایط مدل تاناکا و همکارانش کمینه می‌سازد. مدل دوم مجموع مذکور را با این محدودیت‌ها که به ازای مقدار مشخصی از h —برش پاسخ‌های داده شده‌ی متناظر شان باشند، بیشینه می‌کند. مدل کمینه‌سازی ارائه شده همواره جواب شدنی دارد ولی مدل بیشینه‌سازی ارائه شده گاهی اوقات جواب شدنی ندارد [۳]. علاوه بر این، هر دو مدل نسبت به داده‌های پرت بسیار حساس می‌باشند.

ایراد دیگری که ساویک و پدریچ^۶ [۱۸] بر مدل تاناکا و همکاران گرفتند این بود که مدل مذکور مراکز داده‌ها را در محاسبه ضرایب رگرسیون به حساب نمی‌آورد. لازم به ذکر است که اکثر روش‌های موجود این ضعف را دارند. حال آنکه این مراکز به دلیل داشتن بیشترین درجه عضویت، بیشترین اهمیت را دارند. ساویک و پدریچ برای برطرف کردن این نقصه یک روش دو مرحله‌ای برای محاسبه ضرایب رگرسیون ارائه کردند. در مرحله اول، مراکز ضرایب به روش کمترین مربعات محاسبه می‌شوند و در مرحله دوم، برای محاسبه پهناهای ضرایب، یک مدل برنامه‌ریزی خطی مشابه مدل تاناکا و همکاران با استفاده از مراکز به دست آمده در مرحله اول تشکیل و حل می‌شود.

کیم و بیشو^۷ [۱۱] نقصه دیگری از مدل تاناکا و همکارانش و همچنین روش دو مرحله‌ای ساویک و پدریسز را مطرح کرده‌اند

Savic and Pedrycz^۱

Kim and Bishu^۲

Sakawa and Yano^۳

Dubois and Prade^۴

Hojati^۵

Peters^۶

Özelkan and Duckstein^۷

- اکثر روش‌ها مراکز داده‌ها را در محاسبه ضرایب رگرسیون به حساب نمی‌آورند.

در این مقاله برای رفع اشکالات فوق، روشی مبتنی بر رگرسیون کمترین قدر مطلق خطا و با استفاده از یک تابع فاصله جدید روی اعداد فازی مثلثی ارائه شده است. روش را برای محاسبه ضرایب مدل (۲) با خروجی و ضرایب فازی مثلثی شرح می‌دهیم. این روش برای محاسبه ضرایب مدل‌های (۲)، (۳) و (۴) با خروجی و ضرایب فازی ذوزنقه‌ای و همچنین برای محاسبه ضرایب مدل (۵) با داده‌های مثلثی قابل کاربرد است.

همانگونه که قبل اشاره شد، هدف رگرسیون معمولی برازش یک مدل بر تعدادی داده است به‌گونه‌ای که پاسخ‌های برآورد شده از مدل کمترین فاصله ممکن را با پاسخ‌های داده شده داشته باشند. برای این منظور در رگرسیون معمولی تابعی از تفاصلات بین پاسخ‌های برآورده شده و پاسخ‌های داده شده را کمینه می‌کنند. به طور مشابه، در رگرسیون فازی هدف برازش یک مدل فازی بر مجموعه‌ای از داده‌های فازی است به‌گونه‌ای که پاسخ‌های فازی برآورده شده از مدل تا حد ممکن به پاسخ‌های فازی داده شده نزدیک باشند. به‌وضوح طبیعی است که انتظار داشته باشیم که نقاط با بیشترین درجه عضویت در پاسخ‌های برآورده شده به نقاط با درجات عضویت دیگر در پاسخ‌های برآورده شده به نقاط متناظر در پاسخ‌های داده شده نزدیک باشند. بنابراین سعی می‌کیم توابع عضویت پاسخ‌های داده شده و برآورده شده را تا حد ممکن به هم نزدیک کنیم. چون در این مقاله پاسخ‌های مشاهده شده اعداد فازی مثلثی فرض شده‌اند، سعی برآن است که این کار با نزدیک کردن

است. قیود هر دو مدل شامل اعداد ثابتی است که قبل از حل مدل‌ها باید تعیین و در مدل‌ها گنجانده شوند. اما روشی عملی برای انتخاب مناسب این ثابت‌ها ارائه نشده است. این امر استفاده از این روش‌ها را مشکل می‌کند.

چن^{۱۳} [۲] برای کاهش تاثیر داده‌های پرت، تعدادی محدودیت به محدودیت‌های مدل تاناکا و همکاران اضافه کرده است. لازم به ذکر است که همان اشکال ذکر شده در بند قبل در مدل چن نیز وجود دارد. زیرا محدودیت‌های اضافه شده شامل ثابتی است که قبل از حل مدل باید تعیین و در مدل گنجانده شود.

یک روش حذفی نیز برای تعیین داده‌های پرت توسط هونگ و یانگ^{۱۴} [۸] ارائه شده است. در این روش برای تعیین داده‌های پرت میزان تغییر در تابع هدف مدل در ازای حذف هریک از داده‌ها مورد بررسی قرار می‌گیرد.

ایشیبوچی و نی^{۱۵} [۹] برخی از محدودیت‌های استفاده از مدل رگرسیون با ضرایب فازی مثلثی متقارن را ذکر کرده‌اند. به‌دلیل آن برای مدل رگرسیون خطی فازی (۲) با ورودی‌های حقیقی و خروجی و ضرایب فازی مثلثی، ضرایب مثلثی متقارن را به اعداد مثلثی و ذوزنقه‌ای نامتقارن تعیین می‌دانند.

۳ محاسبه ضرایب رگرسیون با استفاده از برنامه‌ریزی آرمانی

برخی از اشکالات روش‌های مرور شده در بخش ۲ عبارت‌اند از

- اغلب روش‌ها روی داده‌های متقارن متمرکز شده‌اند.
- برخی از روش‌ها نسبت به داده‌های پرت بسیار حساس می‌باشند.

خطا می‌باشد. ویژگی استفاده از تعریف ۱ این است که با انتخاب متغیرهای انحرافی مناسب [۱۶]، مدل غیرخطی (۹) به راحتی به مدل برنامه‌ریزی آرمانی وزن‌دار زیر تبدیل می‌شود

$GP1(w_1, w_2)$:

$$\begin{aligned} & \text{minimize}_{\substack{i=1 \\ i \in \circ}} \sum_{i=1}^n (w_1(n_{ic} + p_{ic}) + \\ & w_2(n_{il} + p_{il} + n_{ir} + p_{ir})) \end{aligned} \quad (10)$$

s.t.

$$\sum_{j=0}^p a_j x_{ij} + n_{ic} - p_{ic} = y_i, \quad i = 1, \dots, n \quad (11)$$

$$\sum_{j=0}^p \alpha_j x_{ij} + n_{il} - p_{il} = \alpha_{y_i}, \quad i = 1, \dots, n \quad (12)$$

$$\sum_{j=0}^p \beta_j x_{ij} + n_{ir} - p_{ir} = \beta_{y_i}, \quad i = 1, \dots, n \quad (13)$$

$$n_{ik} \cdot p_{ik} = 0, \quad i = 1, \dots, n, \quad k = l, c, r \quad (14)$$

$$n_{ik}, p_{ik} \geq 0, \quad i = 1, \dots, n, \quad k = l, c, r \quad (15)$$

$$a_j \in \mathbb{R}, \alpha_j, \beta_j \geq 0, \quad j = 0, 1, \dots, p. \quad (16)$$

در این مدل، n_{ic} و p_{ic} به ترتیب انحرافات منفی و مثبت بین مراکز پاسخ‌های برآورده شده و پاسخ‌های داده شده می‌باشند. به همین ترتیب n_{il} و p_{il} به ترتیب انحرافات منفی و مثبت بین پهنه‌های چپ پاسخ‌های برآورده شده و پاسخ‌های داده شده، و در نهایت n_{ir} و p_{ir} به ترتیب انحرافات منفی و مثبت بین پهنه‌های راست پاسخ‌های برآورده شده و پاسخ‌های داده شده می‌باشند. در واقع اگر $\sum_{j=0}^p a_j x_{ij} < y_i$ ، داریم $n_{ic} > 0$ و $p_{ic} = 0$ و چنانچه $y_i > \sum_{j=0}^p a_j x_{ij}$ داریم $n_{ic} = 0$ و $p_{ic} > 0$. سایر متغیرهای انحرافی نیز ویژگی مشابهی دارند.

اکنون توجه خود را به بررسی خواص مدل فوق معطوف می‌کنیم. اگر پاسخ‌های داده شده متقاضان باشند به ازای هر i داریم $\alpha_{y_i} = \beta_{y_i}$. برای برآورده پاسخ‌های متقاضان کافی است

مراکز و پهنه‌های پاسخ‌های برآورده شده به مقادیر متناظر در پاسخ‌های داده شده انجام شود. از این رو فاصله وزن دار دو عدد فازی مثلثی را به صورت زیر تعریف می‌کنیم.

تعریف ۱ فرض کنید (Y, α_Y, β_Y) و $\tilde{y} = (y, \alpha_y, \beta_y)$ دو عدد فازی مثلثی باشند و $w_1, w_2 \geq 0$ که حداقل یکی از آنها غیر صفر است. فاصله وزن دار \tilde{y} و \tilde{Y} را به صورت زیر تعریف می‌کنیم

$$d^w(\tilde{y}, \tilde{Y}) = w_1 |y - Y| + w_2 (|\alpha_y - \alpha_Y| + |\beta_y - \beta_Y|).$$

به سادگی می‌توان نشان داد که d^w یک تابع فاصله روی $T(\mathbb{R}) \times T(\mathbb{R})$ است که $T(\mathbb{R}) \times T(\mathbb{R})$ مجموعه اعداد فازی مثلثی و \mathbb{R} مجموعه اعداد حقیقی است. همچنین در انتهای این بخش به چگونگی انتخاب وزن‌های w_1 و w_2 اشاره خواهد شد.

تعداد n داده به صورت $(x_{i1}, x_{i2}, \dots, x_{ip}, \tilde{y}_i)$ ، به ازای $i = 1, 2, \dots, n$ ، که در آن ورودی‌های x_{ij} اعدادی حقیقی و پاسخ‌های \tilde{y}_i اعداد فازی مثلثی به صورت $(y_i, \alpha_{y_i}, \beta_{y_i})$ می‌باشند مفروض است. مدل (۲) که در آن به ازای $j = 0, 1, \dots, p$ $\tilde{Y}_j = (a_j, \alpha_j, \beta_j)$ را در نظر بگیرید. بدون آن که از کلیت موضوع کاسته شود می‌توان فرض کرد که به ازای هر i و j ، $x_{ij} > 0$. در این صورت با توجه به روابط (۶) و (۷)، i -امین پاسخ برآورده شده عبارت است از

$$\tilde{Y}_i = (\sum_{j=0}^p a_j x_{ij}, \sum_{j=0}^p \alpha_j x_{ij}, \sum_{j=0}^p \beta_j x_{ij}). \quad (8)$$

اکنون برای محاسبه ضرایب مدل با توجه به توضیحات قبل مدل برنامه‌ریزی غیرخطی زیر را ارائه می‌کنیم

$$\begin{aligned} & \text{minimize}_{\substack{j=0 \\ j \in \circ}} d^w(\tilde{y}_i, \tilde{Y}_i) \\ & \text{s.t.} \quad a_j \in \mathbb{R}, \alpha_j, \beta_j \geq 0, \quad j = 0, 1, \dots, p. \end{aligned} \quad (9)$$

که \tilde{Y}_i در رابطه (۸) و d^w در تعریف ۱ آمده است. با توجه به تعریف d^w ، مدل فوق مبتبنی بر رگرسیون کمترین قدر مطلق

$$\begin{aligned} s.t. \quad & \sum_{j=0}^p a_j x_{ij} + n_{ic} - p_{ic} = y_i, i = 1, \dots, n \\ & a_j \in \mathbb{R} \quad j = 0, \dots, p \\ & n_{ic}, p_{ic} \geq 0 \quad i = 1, \dots, n \end{aligned}$$

 $(LP3)$:

$$\begin{aligned} \text{minimize} \quad & \sum_{i=1}^n (n_{il} + p_{il}) \\ s.t. \quad & \sum_{j=0}^p \alpha_j x_{ij} + n_{il} - p_{il} = \alpha_{y_i}, i = 1, \dots, n \\ & \alpha_j, n_{il}, p_{il} \geq 0, j = 0, \dots, p, i = 1, \dots, n \end{aligned}$$

 $(LP4)$:

$$\begin{aligned} \text{minimize} \quad & \sum_{i=1}^n (n_{ir} + p_{ir}) \\ s.t. \quad & \sum_{j=0}^p \beta_j x_{ij} + n_{ir} - p_{ir} = \beta_{y_i}, i = 1, \dots, n \\ & \beta_j, n_{ir}, p_{ir} \geq 0, j = 0, \dots, p, i = 1, \dots, n \end{aligned}$$

۴ نتایج عددی

در این بخش دو معیار برای ارزیابی مدل‌های رگرسیون ارائه می‌شود، و سپس با حل مثال‌هایی روش ارائه شده با برخی از روش‌های قبل مقایسه می‌شود. کیم و بیشو [۱۱] برای ارزیابی کارایی مدل رگرسیون خطی فازی با داده‌های مثلثی، از مساحت ناحیه غیر مشترک زیرنمودار توابع عضویت دو عدد فازی مثلثی (ناحیه سایه‌دار در شکل ۱) به عنوان فاصله آن دو استفاده کردند.

$$E_i = \int_{S_{\tilde{y}_i} \cup S_{\tilde{Y}_i}} |\mu_{\tilde{y}_i}(x) - \mu_{\tilde{Y}_i}(x)| dx \quad (17)$$

که در آن $S_{\tilde{y}_i}$ و $S_{\tilde{Y}_i}$ به ترتیب تکیه‌گاه‌های اعداد فازی مثلثی \tilde{y}_i و \tilde{Y}_i می‌باشند. ما نیز E_i را به عنوان خطای i -امین پاسخ برآورده شده می‌پذیریم. بهوضوح هرچه E_i کوچکتر باشد توابع عضویت پاسخ‌های برآورده شده و پاسخ‌های داده شده به هم نزدیکترند.

ضرایب مدل رگرسیون را متقارن درنظر بگیریم. یعنی به ازای هر j قرار دهیم $\beta_j = \alpha_j$. در این صورت قیود (۱۲) و (۱۳) معادل خواهند شد و می‌توان یکی از آنها را حذف کرد، که در این صورت تعداد n قید از قیود مدل کاسته می‌شود. علاوه بر این، با توجه به ویژگی روش سیمپلکس [۱۶]، قیود غیرخطی (۱۴) را می‌توان حذف کرد و مدل را به یک مدل برنامه‌ریزی خطی تبدیل نمود که آن را $LP1(w_1, w_2)$ می‌نامیم. وجود وزن‌های w_1 و w_2 باعث می‌شود که بتوان با تخصیص مقادیر مختلف به آنها بسته به اهمیت نسبی مراکز و پهنه‌های پاسخ‌ها، جواب‌های مختلفی به دست آورد. به این ترتیب که هرچه اهمیت مراکز پاسخ‌ها نسبت به پهنه‌های آنها بیشتر باشد، به w_1 مقدار بیشتری (در مقایسه با w_2) اختصاص می‌دهیم. برای مثال، اگر اهمیت مراکز دو برابر پهنه‌ها تشخیص داده شود می‌توان قرارداد $w_1 = 2$ و $w_2 = 1$ به علاوه، با روش سعی و خطا ممکن است مقادیر وزن‌های مناسب‌تر و نتایج مطلوب‌تری به دست آید. فرض کنید مراکز و پهنه‌های پاسخ‌ها از اهمیت یکسانی برخوردار باشند. قرار می‌دهیم $w_1 = w_2 = 1$ و مدل به دست آمده را برای سادگی $GP1$ و مدل برنامه‌ریزی خطی حاصل از آن را $LP1$ می‌نامیم. ویژگی مهم این دو مدل این است که چون قیود (۱۱)، (۱۲) و (۱۳) مستقل از هم می‌باشند، هریک از این دو مدل را می‌توان به سه مدل مجزاً تجزیه کرد که تعداد قیود هریک به مراتب از تعداد قیود مسایل اصلی کمتر است. این ویژگی به خصوص زمانی که تعداد مشاهدات زیاد باشد از اهمیت ویژه‌ای برخوردار است زیرا تعداد قیود به میزان قابل توجهی کاهش می‌یابد. مدل‌های برنامه‌ریزی خطی حاصل از تجزیه $LP1$ عبارت‌اند از

 $(LP2)$:

$$\text{minimize} \quad \sum_{i=1}^n (n_{ic} + p_{ic})$$

ساکاوا و یانو [۱۷] (SY)، مدل کیم و بیشو [۱۱] (KB)، مدل حجتی و همکاران [۷] (HBS)، مدل عربپور و تاتا [۱] (AT)، و مدل ارائه شده در این مقاله ($GP1$) در جدول ۲ آمده است. مقایسه مقادیر دو سطر آخر جدول ۲ نشان می‌دهد که هم TE و هم λ در این مثال از تمامی روش‌های مورد $GP1$ در این مثال از TE در آن کمتر از TE در $GP1$ مقایسه (به استثنای HBS که TE در آن کمتر از TE در $GP1$ و λ در آن مساوی λ در $GP1$ است) بهتر می‌باشد. مدل‌های رگرسیون به دست آمده از روش‌های مذکور به قرار زیراند

$$\tilde{Y}_T = (2/7000, 0) \oplus (0/1750, 1/9250)x$$

$$\tilde{Y}_{T-min} = (3/8500, 2/8500) \oplus (2/1000, 0)x$$

$$\tilde{Y}_{T-max} = (4/6232, 0) \oplus (1/7750, 0/2082)x$$

$$\tilde{Y}_{SY} = (4/6232, 0) \oplus (1/5662, 0)x$$

$$\tilde{Y}_{KB} = (4/9500, 1/8400) \oplus (1/2100, 0/1600)x$$

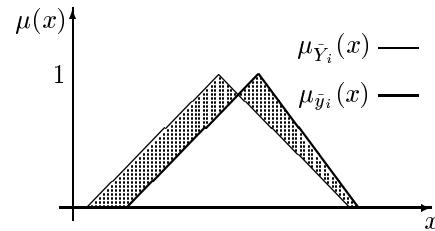
$$\tilde{Y}_{HBS} = (6/2500, 1/6500) \oplus (1/2500, 0/1500)x$$

$$\tilde{Y}_{AT} = (4/9500, 1/8400) \oplus (1/2100, 0/1600)x$$

$$\tilde{Y}_{GP1} = (6/2500, 1/8000) \oplus (1/2500, 0/2000)x$$

مثال ۲ در این مثال، برای مقایسه دقیق تر روش ارائه شده با روش‌های مذکور در مثال ۱، یک مطالعه شبیه‌سازی به صورت زیر انجام شده است.

تعداد پنج مجموعه از داده‌ها هر یک شامل $n = 20$ مقدار یک متغیر حقیقی و متغیر وابسته فازی مثلثی تولید شده است. مقدار متغیر مستقل x از توزیع یکنواخت روی بازه $(0, u)$ به ازای ۵ مقدار $10, 20, 30, 40$ و 50 برای μ استخراج شده‌اند. همچنین برای تولید ۲۰ مقدار متغیر وابسته y ، هر بار سه عدد y_1, y_2 و y_3 از توزیع یکنواخت روی بازه $(0, u)$ به ازای مقادیر فوق برای μ استخراج شده و برای تشکیل یک عدد فازی مثلثی، به ترتیب صعودی مرتب شده‌اند. خطای کل TE و λ به ازای انتخاب‌های مختلف μ و نیز میانگین آنها، در جداول مذکور برتری $GP1$ بر سایر روش‌ها را هم از نظر TE و λ به ترتیب در جداول ۳ و ۴ آمده‌اند. مقایسه \overline{TE} و $\overline{\lambda}$ در جداول مذکور برتری $GP1$ بر سایر روش‌ها را هم از نظر TE و λ از نظر λ نشان می‌دهد.



شکل ۱. فاصله بین دوتابع عضویت

مراکز اعداد فازی مثلثی به دلیل داشتن بیشترین درجه عضویت از اهمیت ویژه‌ای برخوردارند. برای ارزیابی مدل رگرسیون از نظر میزان نزدیکی مراکز پاسخ‌های برآورده شده و داده شده، پارامتر جدیدی را معرفی می‌کنیم که عبارت است از مجموع فواصل مراکز پاسخ‌های برآورده شده و داده شده

$$\lambda = \sum_{i=1}^n |y_i - \sum_{j=0}^p a_j x_{ij}| \quad (18)$$

واضح است که مقدار کوچکتر λ نشان دهنده برازش بهتر مراکز پاسخ‌های برآورده شده بر مراکز پاسخ‌های داده شده است. در ادامه سه مثال عددی ارائه می‌کنیم و نتایج حاصل از چند روش را با هم مقایسه می‌کنیم.

مثال ۱ داده‌های جدول شماره ۱ شامل پنج مقدار یک متغیر مستقل و مقادیر متغیر وابسته نظری‌شان را که اعداد فازی مثلثی متقارن می‌باشند در نظر بگیرید. این مثال توسط تاناکا و همکاران [۲۰] ارائه شده است.

جدول ۱. داده‌های مثال ۱

\tilde{y}_i	x_{i1}	i
$(8, 1/8)$	۱	۱
$(7/4, 2/2)$	۲	۲
$(9/5, 2/6)$	۳	۳
$(13/5, 2/6)$	۴	۴
$(13, 2/4)$	۵	۵

مقادیر خطای E_i ، خطای کل، $TE = \sum_{i=1}^n E_i$ ، و λ برای مدل تاناکا و همکارانش [۲۰] (T)، مدل کمینه‌سازی تاناکا [۳] ($T - min$)، مدل بیشینه‌سازی تاناکا [۳] ($T - max$)، مدل

مثال ۴ اکنون داده‌های مثال ۱ را در نظر بگیرید که در آن λ را با داده پرت ($20, 1/8$) عوض کردیم. مجددًاً مقادیر TE, E_i , و λ برای مدل‌های مذکور در مثال ۱ محاسبه شده و در جدول ۶ ارائه شده است. همچنین اختلاف مقادیر دو سطر آخر جداول ۲ و ۶ در جدول ۷ آمده است.

این جدول نشان می‌دهد که از نظر TE , کمترین حساسیت نسبت به داده پرت را مدل $GP1$ دارد، و از نظر λ , حساسیت مدل‌های HBS و $GP1$ نسبت به داده پرت از سایر مدل‌های مورد مقایسه کمتر است. ضمناً مدل $T - max$ پس از اضافه شدن داده پرت جواب ندارد، که بیانگر بیشترین حساسیت نسبت به داده پرت است.

مثال ۳ در مثال قبل پنج نمونه و هر یک شامل $n = 20$ داده روی بازه‌های $(u, 0)$ به ازای $50, 20, \dots, 10$ در نظر گرفته شد. در این مثال نیز یک مطالعه شبیه‌سازی، مانند مثال قبل انجام شده است، با این تفاوت که تعداد 100 نمونه، و هر یک شامل $n = 20$ داده تولید شده است. مقادیر متغیرهای مستقل و وابسته در نمونه‌ی $k - 1$ از توزیع یکنواخت روی بازه‌ی $(k, 0)$ به ازای $100, 2, \dots, 1$ استخراج شده‌اند. برای رعایت اختصار، فقط مقادیر TE و $\bar{\lambda}$ در جدول ۵ ارائه شده است. مجددًاً مقایسه این مقادیر برتری $GP1$ بر سایر روش‌ها هم از نظر TE و هم از نظر λ نشان می‌دهد.

جدول ۲. خطای روش‌های مختلف در مثال ۱

E_i								i
$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	
۰/۲۰۰	۲/۲۰۷	۰/۰۰۰	۲/۲۰۷	۱/۸۰۰	۱/۹۲۲	۳/۲۵۶	۰/۲۴۶	۱
۳/۸۵۴	۳/۰۵۰	۳/۷۴۳	۳/۰۵۰	۲/۲۰۰	۲/۳۵۱	۲/۸۵۰	۲/۸۵۰	۲
۱/۸۰۰	۱/۰۹۲	۱/۷۸۷	۱/۰۹۲	۲/۷۰۰	۲/۰۱۶	۱/۵۲۲	۳/۴۹۳	۳
۲/۹۱۱	۲/۸۴۴	۲/۸۷۹	۲/۸۴۴	۲/۷۰۰	۲/۶۲۴	۲/۲۵۸	۷/۶۷۵	۴
۰/۴۰۰	۰/۹۵۰	۰/۰۰۰	۰/۹۵۰	۲/۴۰۰	۱/۴۷۴	۲/۴۱۵	۸/۳۰۷	۵
۹/۱۶۵	۱۰/۱۴۴	۸/۳۹۹	۱۰/۱۴۴	۱۱/۶۰۰	۱۰/۳۸۷	۱۲/۴۰۲	۲۲/۵۷۰	TE
۵/۶۰۰	۷/۱۰۰	۵/۶۰۰	۷/۱۰۰	۷/۴۶۶	۷/۱۰۸	۷/۹۵۰	۱۲/۵۷۵	λ

جدول ۳. مقادیر TE در مثال ۲

(TE) خطای کل								u
$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	
۲۵/۶۹۴	۳۶/۲۸۴	۴۰/۵۵۰	۳۶/۲۸۴	۵۴/۲۹۶	۴۴/۱۴۷	۶۵/۳۰۳	۱۱۲/۲۶۱	۱۰
۸۲/۷۵۷	۹۰/۵۱۵	۸۶/۵۸۴	۹۰/۵۱۵	۱۰۳/۵۲۳	۱۰۷/۴۵۵	۱۳۶/۸۹۱	۱۲۷۹/۷۲۹	۲۰
۲۰۷/۱۵۱	۲۱۳/۰۰۶	۱۵۹/۵۲۰	۲۱۳/۰۰۶	۱۴۶/۶۸۸	۱۵۲/۹۲۳	۲۲۶/۲۲۰	۳۵۲/۲۴۱	۳۰
۱۹۳/۱۴۹	۲۱۸/۹۰۶	۲۳۰/۶۷۵	۲۱۸/۹۰۶	۲۴۹/۷۰۰	۱۶۰/۰۵۰	۲۲۸/۶۱۹	۵۳۷/۹۹۳	۴۰
۲۱۴/۶۳۷	۲۱۶/۲۰۳	۲۳۱/۱۸۸	۲۱۶/۲۰۳	۲۷۹/۰۱۹	۲۷۶/۱۰۷	۳۵۷/۵۴۸	۵۴۲۴/۰۸۵	۵۰
۱۴۶/۸۷۸	۱۵۵/۰۰۲	۱۴۹/۷۰۳	۱۵۵/۰۰۳	۱۶۶/۶۴۷	۱۴۸/۲۳۵	۲۲۲/۹۱۶	۱۵۶۱/۴۸۲	TE

جدول ۴. مقادیر λ در مثال ۲

λ								u
$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	
۲۹/۰۲۵	۲۹/۲۲۸	۴۷/۴۵۶	۲۹/۲۲۸	۳۶/۵۱۵	۳۶/۱۰۷	۸۰/۷۰۳	۱۴۶/۵۲۶	۱۰
۷۲/۹۵۷	۷۹/۸۱۲	۸۵/۷۴۱	۷۹/۸۱۲	۸۳/۵۲۹	۷۷/۵۸۱	۱۶۷/۲۸۹	۲۴۴۱/۶۷۸	۲۰
۸۵/۵۹۷	۸۸/۱۲۸	۲۰۲/۵۲۵	۸۸/۱۲۸	۱۰۳/۴۲۴	۹۸/۸۹۳	۲۹۴/۰۳۹	۴۶۸/۲۵۵	۳۰
۲۰۰/۵۲۵	۲۰۳/۲۲۹	۲۴۵/۸۲۲	۲۰۳/۲۲۹	۲۲۱/۳۲۱	۲۵۳/۲۶۹	۴۱۱/۱۴۵	۷۳۰/۰۴۰	۴۰
۱۴۹/۴۶۲	۱۵۱/۷۱۳	۲۲۵/۱۱۱	۱۵۱/۷۱۳	۲۳۷/۸۸۴	۱۶۲/۱۴۸	۴۶۱/۶۸۸	۹۷۳۰/۵۵۵	۵۰
۱۰۷/۷۱۲	۱۱۰/۴۲۶	۱۶۲/۵۲۳	۱۱۰/۴۲۶	۱۳۶/۵۲۷	۱۲۵/۶۰۰	۲۸۲/۹۳۷	۲۷۰۳/۴۱۱	λ

جدول ۵. مقادیر \overline{TE} و $\bar{\lambda}$ در مثال ۳

$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	روش
۲۳۴/۵۲۵	۲۶۰/۰۵۱	۲۵۱/۱۰۱	۲۶۰/۰۵۱	۲۶۴/۶۵۸	۲۵۰/۹۵۷	۳۷۲/۵۵۸	۲۵۸۴/۹۹۰	TE
۱۷۳/۷۴۲	۱۷۸/۸۴۶	۲۷۶/۹۶۷	۱۷۸/۸۴۶	۲۲۷/۱۲۳	۲۲۹/۳۵۹	۴۷۷/۴۷۹	۲۰۸۹/۵۲۴	λ

جدول ۶. خطای روش‌های مختلف در مثال ۴

$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	E_i	i
۲/۸۰۰	۲/۸۰۰	۴/۲۰۰	۲/۸۰۰	۵/۶۵۰	—	۸/۴۷۸	۲/۵۶۶	۱	
۴/۴۰۰	۴/۳۶۰	۴/۶۰۰	۴/۳۶۰	۶/۰۵۰	—	۸/۳۰۲	۸/۳۰۲	۲	
۴/۹۵۰	۴/۱۰۵	۴/۸۲۸	۴/۱۰۵	۱/۹۶۱	—	۵/۵۱۰	۹/۷۱۹	۳	
۰/۰۰۰	۲/۸۴۴	۰/۳۹۲	۲/۸۴۴	۶/۰۵۳	—	۷/۲۴۰	۱۶/۶۶۰	۴	
۰/۴۰۰	۳/۰۸۴	۰/۰۰۰	۳/۰۸۴	۶/۲۵۰	—	۸/۱۸۵	۲۱/۳۷۱	۵	
۱۳/۵۵۰	۱۸/۲۴۳	۱۴/۰۳۰	۱۸/۲۴۳	۲۵/۹۶۴	—	۳۷/۷۱۴	۵۹/۶۱۷	TE	
۱۷/۶۰۰	۱۹/۵۰۰	۱۷/۶۰۰	۱۹/۵۰۰	۲۲/۸۵۰	—	۲۳/۲۰۰	۴۱/۰۰۰	λ	

جدول ۷. میزان تغییر در TE و λ در روش‌های مختلف پس از اضافه شدن داده برت در مثال ۴

$GP1$	AT	HBS	KB	SY	$T - max$	$T - min$	T	روش
۴/۳۸۵	۸/۰۹۹	۵/۶۳۱	۸/۰۹۹	۱۴/۳۶۴	—	۲۵/۳۱۲	۳۷/۰۴۷	TE
۱۲/۰۰۰	۱۳/۴۰۰	۱۲/۰۰۰	۱۳/۴۰۰	۱۷/۲۸۴	—	۱۶/۲۵۰	۲۸/۴۲۵	تغییر در λ

۵ نتیجه

ویرگی مهم مدل برنامه‌ریزی خطی ارائه شده تجزیه‌پذیر بودن آن است، که باعث می‌شود تعداد قیود مدل به میزان قابل توجهی کاهش یابد. نتایج عددی نشان می‌دهد که روش ارائه شده از نظر نزدیکی توابع عضویت پاسخ‌های برآورد شده و داده شده و به خصوص از نظر نزدیکی مراکز آنها بر بسیاری از روش‌های قبلی مورد مقایسه برتری دارد (توجه داریم که مراکز پاسخ‌های فازی مثلثی به دلیل داشتن بیشترین درجه عضویت، اهمیت ویژه‌ای دارند). ضمناً روش ارائه شده برای داده‌های ذوزنقه‌ای و مثلثی متقارن و نامتقارن قابل استفاده است.

در این مقاله، روش جدیدی برای محاسبه ضرایب مدل رگرسیون خطی فازی با ورودی‌های غیرفازی و خروجی فازی ارائه شد. در روش ارائه شده، ابتدا با استفاده از یکتابع فاصله وزن دار جدید روی اعداد فازی مثلثی، یک مدل بهینه‌سازی غیرخطی برای محاسبه ضرایب رگرسیون ارائه گردید که به سادگی به یک مدل برنامه‌ریزی آرمانی و درنهایت به یک مدل برنامه‌ریزی خطی تبدیل می‌شود. مزیت این تبدیل این است که روش سیمپلکس جواب دقیق مدل برنامه‌ریزی خطی را به دست می‌دهد، حال آن که الگوریتم‌های موجود برای حل مدل‌های غیرخطی اغلب جواب تقریبی به دست می‌دهند.

مراجع

- [1] Arabpour A. R. and Tata, M., Estimating the parameters of a fuzzy linear regression model, *Iranian Journal of Fuzzy Systems*, To appear.

- [2] Celmins, A. (1987), Least squares model fitting to fuzzy vector data, *Fuzzy Sets and Systems*, 22, 245-269.
- [3] Chen, Y.S. (2001), Outliers detection and confidence interval modification in fuzzy regression, *Fuzzy Sets and Systems*, 119, 259-272.
- [4] Diamond, P. (1988), Fuzzy Least squares, *Inform. Sci.*, 46, 141-157.
- [5] Dubois, D. and Prade, H. (1983), Ranking fuzzy numbers in setting of possibility theory, *Inform. Sci.*, 30, 183-224.
- [6] Hassanpur, H. and Maleki, H.R. (2007), A simple method for evaluation of fuzzy linear regression models by ordinary least-squares method, *Extended Abstracts of the 38th Annual IMC, 3-6 Sept 2007, University of Zanjan, Zanjan, Iran.*
- [7] Hojati, M., Bector, C.R. and Smimou, K. (2005), A simple method for computation of fuzzy linear regression, *EJOR*, 166, 172-184.
- [8] Hung, W.L. and Yang, M.S. (2006), An omission approach for detecting outliers in fuzzy regression models, *Fuzzy Sets and Systems*, 157, 3109-3122.
- [9] Ishibuchi, H. and Nii, M. (2001), Fuzzy regression using asymmetric fuzzy coefficients and fuzzified neural networks, *Fuzzy Sets and Systems*, 119, 273-290.
- [10] Kao, C. and Chyu, C.L. (2003), Least-squares estimates in fuzzy regression analysis, *EJOR*, 148, 426-435.
- [11] Kim, B. and Bishu, R.R. (1998), Evaluation of fuzzy linear regression models by comparing membership functions, *Fuzzy Sets and Systems*, 100, 343-352.
- [12] Modarres, M., Nasrabadi, E., and Nasrabadi, M.M. (2005), Fuzzy linear regression models with least square errors, *Applied Mathematics and Computation*, 163, 977-989.
- [13] Özelkan, E.C. and Duckstein, L. (2000), Multi-objective fuzzy regression: a general framework, *Computers & Operations Research*, 27, 635-652.
- [14] Peters, G. (1994), Fuzzy linear regression with fuzzy intervals, *Fuzzy Sets and Systems*, 63, 45-55.

- [15] Redden, D. T. and Woodall, W.H. (1994), Properties of certain fuzzy linear regression models, *Fuzzy Sets and Systems*, 64, 361-375.
- [16] Sakawa, M. (1993). *Fuzzy Sets and Interactive Multiobjective Optimization*, Plenum Press, New York.
- [17] Sakawa, M. and Yano, H. (1992), Multiobjective fuzzy linear regression analysis for fuzzy input-output data, *Fuzzy Sets and Systems*, 47, 173-181.
- [18] Savic D.A. and Pedrycz, W. (1991), Evaluation of fuzzy linear regression models, *Fuzzy Sets and Systems*, 39, 51-63.
- [19] Tanaka, H. (1987), Fuzzy data analysis by possibilistic linear models, *Fuzzy Sets and Systems*, 24, 363-375.
- [20] Tanaka, H., Uejima, S., and Asai, K. (1982), Linear regression analysis with fuzzy model, *IEEE Transactions on Systems, Man, and Cybernetics*, 12, 903-907.
- [21] Zadeh, L.A. (1978), Fuzzy sets as a basis for a theory of possibility, *Fuzzy Sets and Systems*, 1, 3-28.