

استفاده از روش بوت استرپ^۱ در رگرسیون کمترین مربعات فازی

علیرضا عربپور^۲، فرزانه مرادی^۳

چکیده:

به منظور پیدا کردن رابطه خطی مناسب بین یک متغیر وابسته و چند متغیر مستقل در یک محیط فازی مدل‌های رگرسیون خطی فازی به کار برده می‌شوند. در این مقاله ابتدا پارامترهای مدل رگرسیون خطی فازی را با روش کمترین مربعات برآورد کرده ایم سپس بوت استرپ را به عنوان یک روش باز نمونه‌گیری برای بهبود برآوردهای مدل رگرسیون خطی فازی به کار برده‌ایم و در نهایت با چند مثال عددی کارایی این روش را با سایر سایر روش‌های رگرسیون کمترین مربعات فازی مورد مقایسه قرار داده‌ایم.

واژه‌های کلیدی: رگرسیون فازی، کمترین مربعات، باز نمونه‌گیری، بوت استرپ.

۱ مقدمه

مجموعه‌های فازی اولین بار توسط زاده^۴ [۲۴] معرفی شد. پس از آن اولین بار تاناکا^۵ و همکاران [۱۸] رگرسیون فازی را مورد بحث و بررسی قرار دادند. در این روش داده‌ها اعداد فازی مثلثی هستند و با مینیمم کردن یک شاخص فازی ضرایب رگرسیونی را تخمین زدند، این روش در سال‌های بعد توسط تاناکا و همکارانش بهبود یافت، در واقع اساس کار تاناکا روش‌های برنامه‌ریزی ریاضی بود. یاگر^۶ [۲۲] با رهیافتی متفاوت ساده‌ترین حالت رگرسیون فازی را مورد بحث قرار داد، وی با مشاهدات فازی مقدار متغیر وابسته را پیش‌بینی نمود.

چانگ و لی^۷ [۷] به برخی از ضعف‌های مدل پیشنهادی تاناکا اشاره کردند، به خصوص آنها نشان دادند که تحلیل رگرسیون فازی تاناکا همیشه برآوردهای مجاز نمی‌دهد. پیترز^۸ [۱۷] مدل رگرسیون خطی فازی دیگری بر مبنای روش تاناکا و با استفاده از روش برنامه‌ریزی خطی فازی معرفی کرد. کیم و بیشو^۹ [۱۴] مینیمم کردن اختلاف بین توابع عضویت اعداد فازی مشاهده شده و تخمین زده شده را ملاک کار قرار دادند.

در همان حین که بیشتر مدل‌های رگرسیون فازی با استفاده از برنامه‌ریزی ریاضی تحلیل می‌شدند جاجوگا^{۱۰}

^۱ Bootstrap

^۲ بخش آمار، دانشگاه شهید باهنر کرمان

^۳ دانشجوی کارشناسی ارشد آمار ریاضی، بخش آمار، دانشگاه شهید باهنر کرمان

^۴ Zadeh

^۵ Tanaka

^۶ Yager

^۷ Chang and Lee

^۸ Peterz

^۹ Kim and Bishu

^{۱۰} Jajuga

ناپارامتری فازی با ورودی غیرفازی و خروجی فازی $L - R$ بر مبنای تکنیک هموارسازی خطی موضعی پیشنهاد دادند. در سال های اخیر برازش مدل رگرسیون فازی به سمت روش های عددی پیش رفته است. عبدالله و باکلی^{۱۸} [۲] روش مونت کارلو را در رگرسیون فازی به کار بردند.

از دیگر روش های عددی می توان باز نمونه گیری را نام برد. یکی از روش های باز نمونه گیری، بوت استرپ است. نمونه گیری بوت استرپ توسط افرون^{۱۹} [۱۰] ارائه شد و مدت ها روی آن کار شد. لیانگ^{۲۰} و همکاران [۱۵] بوت استرپ را در مدل رگرسیون خطی جزئی به کار بردند. پس از آن ولیلا^{۲۱} [۲۰] از بوت استرپ برای تخمین توزیع مجانبی برآوردگر کمترین مربعات در مدل رگرسیون معمولی استفاده کرد. پاپارودیتیس^{۲۲} و همکاران [۱۶] آزمون فرض بوت استرپ را در مدل های رگرسیون معمولی به کار بردند.

در ادامه به طور خلاصه رگرسیون کلاسیک و پس از آن رگرسیون فازی را در بخش ۲ ارائه داده و روش های متفاوت جهت برآورد پارامترهای مدل رگرسیون فازی را مورد بحث قرار می دهیم. در بخش ۳ به معرفی روش بوت استرپ و کاربرد آن در رگرسیون پرداختیم و پس از

[۱۲] ضرایب رگرسیون خطی را با استفاده از یک نسخه تعمیم یافته از روش کمترین مربعات محاسبه کرد. سلمینس^{۱۱} [۴ و ۵] روشی برای برازش دادن یک مدل فازی چند متغیره با مینیم کردن یک تابع هدف کمترین مربعات پیشنهاد کرد و یک روش کمترین مربعات برای مدل های رگرسیون فازی ارائه داد. دایاموند^{۱۲} [۹] یک متر بر مجموعه اعداد فازی معرفی کرد و از این متر برای تعریف معیار کمترین مربعات فازی استفاده کرد. چانگ و لی [۶] یک روش رگرسیون فازی بر مبنای روش کمترین مربعات برای تخمین مقدار مراکز و پهنای های اعداد فازی $L - R$ پیشنهاد کردند. یانگ و لین^{۱۳} [۲۳] یک روش کمترین مربعات برای مدل هایی با ورودی و خروجی فازی پیشنهاد دادند. کائو و چیو^{۱۴} [۱۳] یک روش کمترین مربعات با استفاده از تابع عضویت مجموع مربعات خطا ارائه دادند. کاپی^{۱۵} و همکاران [۸] یک روش کمترین مربعات برای تخمین یک مدل رگرسیون خطی با پاسخ فازی $L - R$ پیشنهاد دادند. عربپور و تاتا^{۱۶} [۳] با تعمیم و استفاده از فاصله ای که توسط دایاموند برای اعداد فازی تعریف شده است، پارامترهای مدل رگرسیون خطی فازی را برای داده های مثلثی و دوزنقه ای به دست آوردند.

وانگ^{۱۷} و همکاران [۲۱] روشی برای رگرسیون

Celmins^{۱۱}Diamond^{۱۲}Yang and Lin^{۱۳}Kao and Chio^{۱۴}Coppi^{۱۵}Arabpour and Tata^{۱۶}Wang^{۱۷}Abdallah and Buckley^{۱۸}Efron^{۱۹}Liang^{۲۰}Velilla^{۲۱}Paparoditis^{۲۲}

رگرسیون خطی فازی نامیده می‌شود. در واقع رگرسیون فازی تعمیمی از رگرسیون معمولی است.

به طور کلی سه روش برای تحلیل مدل‌های رگرسیون خطی فازی ارائه شده است: ۱- روش‌های کمترین مربعات فازی ۲- روش‌های برنامه‌ریزی ریاضی و ۳- روش‌های عددی، که در ادامه به طور مختصر به معرفی این سه روش می‌پردازیم.

۱.۲ روش‌های کمترین مربعات فازی

در این روش از مینیمم کردن مجموع مربعات خطا به عنوان یک معیار برازش استفاده می‌شود. روش‌های کمترین مربعات فازی بر اساس کمترین درجه اختلاف بین مقادیر مشاهده شده و مقادیر تخمین زده شده استوار هستند.

در این بخش به اولین و یکی از آخرین مدل‌ها بر اساس روش‌های کمترین مربعات فازی اشاره می‌کنیم.

۱.۱.۲ مدل سلیمینس

این روش در سال ۱۹۸۷ ارائه شد و بر مبنای یک اندازه سازگار بین داده‌ها و مدل برازش داده شده است. اگر فرض کنیم A و B دو عدد فازی مثلثی باشند این اندازه به صورت زیر تعریف می‌شود:

$$\gamma(A, B) = \max_x \min[\mu_A(x), \mu_B(x)]$$

که $\mu_A(x)$ تابع عضویت A و $\mu_B(x)$ تابع عضویت B است. مقدار γ بین صفر و یک است، مقدار صفر را وقتی می‌گیرد که پهنای دو عدد فازی هیچ همپوشانی نداشته

آن استفاده از روش بوت‌استرپ در رگرسیون فازی را شرح داده‌ایم. در پایان نیز برای مقایسه کارایی این روش با سایر روش‌های رگرسیون خطی فازی به روش کمترین مربعات چند مثال عددی در بخش ۴ ارائه خواهیم داد.

۲ تحلیل رگرسیون کلاسیک و فازی

وظیفه کلی تحلیل رگرسیون به صورت شناسایی رابطه بین متغیرهای مستقل $\underline{x} = (x_1, x_2, \dots, x_k)$ و متغیر وابسته y تعریف شده است، که k تعداد متغیرهای مستقل در مدل می‌باشد. مدل رگرسیون در این مورد به صورت زیر بیان می‌شود:

$$\underline{y} = f(\underline{x}) + \underline{\varepsilon}$$

که $f(\underline{x})$ یک بردار از توابع $(f_1(\underline{x}), f_2(\underline{x}), \dots, f_n(\underline{x}))^T$ و $\underline{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^T$ یک بردار از خطای تصادفی تخمین تابعی و n تعداد تکرارها است. مدل کلی فوق اغلب با فرض یک رابطه خطی بین متغیرهای مستقل و وابسته ساده‌تر می‌شود. متغیر وابسته چندگانه y به طور جداگانه n مدل رگرسیون مستقل ارائه می‌دهد. در ساده‌ترین حالت برای یک متغیر وابسته ساده مدل رگرسیون به فرم زیر داده می‌شوند:

$$y = b_0 + b_1 x + \varepsilon$$

که مدل رگرسیون خطی ساده نامیده می‌شود و مدل:

$$y = b_0 + b_1 x_1 + \dots + b_k x_k + \varepsilon$$

مدل رگرسیون خطی چندگانه نامیده می‌شود. هنگامی که پارامترهای مدل رگرسیون خطی به جای توزیع احتمالی با توابع عضویت فازی بیان شوند مدل‌های فوق مدل

اعداد فازی مثلثی به اعداد فازی دوزنقه‌ای تعمیم داده‌اند که برای سه مدل رگرسیون خطی فازی با مشاهدات فازی مثلثی به شرح زیر می‌باشد:

۱- مدل رگرسیون خطی فازی ساده که در آن متغیر مستقل اعداد فازی مثلثی و پارامترها اعداد غیرفازی می‌باشند، به فرم زیر است:

$$\tilde{y}_i = b_0 + b_1 \tilde{x}_i + \tilde{\varepsilon}_i \quad (1)$$

که مشاهدات به صورت اعداد فازی مثلثی زیر می‌باشند:

$$\tilde{y}_i = (y_{il}, y_i, y_{ir}) \quad , \quad \tilde{x}_i = (x_{il}, x_i, x_{ir})$$

در این روش برای مدل فوق پارامترها به صورت زیر برآورد می‌شوند:

$$\begin{aligned} S(b_0, b_1) &= \sum_{i=1}^n d^2(\tilde{y}_i, b_0 + b_1 \tilde{x}_i) \\ &= \sum_{i=1}^n [(y_i - b_0 - b_1 x_i)^2 + (y_{il} - b_0 - b_1 x_{il})^2 \\ &\quad + (y_{ir} - b_0 - b_1 x_{ir})^2] \end{aligned}$$

با مشتق‌گیری نسبت به پارامترها داریم:

$$\begin{aligned} \hat{b}_1 &= \frac{\sum_{i=1}^n (x_{il} y_{il} + x_i y_i + x_{ir} y_{ir}) - 3n \bar{x} \bar{y}}{\sum_{i=1}^n (x_{il}^2 + x_i^2 + x_{ir}^2) - 3n \bar{x}^2} \\ \hat{b}_0 &= \bar{y} - \hat{b}_1 \bar{x} \end{aligned}$$

که در آن:

$$\bar{y} = \frac{\sum_{i=1}^n (y_{il} + y_i + y_{ir})}{3n}, \quad \bar{x} = \frac{\sum_{i=1}^n (x_{il} + x_i + x_{ir})}{3n}$$

۲- مدلی که پارامترها اعداد فازی مثلثی و متغیرهای مستقل اعداد غیرفازی هستند:

$$\tilde{y}_i = \tilde{b}_0 + \tilde{b}_1 x_i + \tilde{\varepsilon}_i \quad (2)$$

باشند و زمانی برابر یک است که مراکز دو کمیت فازی بر هم منطبق شوند.

اندازه مذکور در واقع اندازه سازگاری بین هر مقدار مشاهده شده و مقدار برآورد شده است. در این روش هدف، پیدا کردن مدلی است که سازگاری کلی بین داده‌ها و مدل برازش شده ماکسیمم شود که معادل با مینیمم سازی تابع زیر است:

$$W = \sum_{i=1}^n (1 - \gamma_i)^2$$

به طوری که:

$$\hat{y} = \tilde{b}_0 + \tilde{b}_1 \pm \sqrt{c_0^2 + 2c_0 x + c_1^2 x^2}$$

بخش اول معادله فوق $(m_0 + m_1 x)$ خط مرکزی مدل رگرسیون فازی را نشان می‌دهد که ضرایب آن با استفاده از رگرسیون کمترین مربعات موزون به دست می‌آیند و از معکوس مربع ابهام هر داده به عنوان وزن آن داده استفاده می‌شود. قسمت دوم معادله $(\pm \sqrt{c_0^2 + 2c_0 x + c_1^2 x^2})$ حدود فازی بالا و پایین مدل رگرسیون را مشخص می‌کند که c_0 و c_1 نیم‌پهنای فازی ضرایب $\tilde{b}_0$ و $\tilde{b}_1$ هستند. بر طبق تعریف سلمینس مقدار c_0 هماهنگی فازی بین ضرایب است. هماهنگی بین دو پارامتر فازی مفهوم مشابهی با کواریانس احتمالی بین دو پارامتر معمولی دارد.

۲.۱.۲ مدل عربپور و تاتا

عربپور و تاتا [۳] با استفاده از متر تعریف شده، توسط دایاموند برای برآورد پارامترهای مدل رگرسیون خطی فازی یک روش کمترین مربعات پیشنهاد دادند و آن را از

برای چنین مدلی خواهیم داشت:

$$\begin{aligned} \hat{b}_{\backslash l} &= \frac{\sum_{i=1}^n x_{il} y_{il} - n \bar{x}_l \bar{y}_l}{\sum_{i=1}^n x_{il}^2 - n \bar{x}_l^2}, \hat{b}_{o_l} = \bar{y}_l - \hat{b}_{\backslash l} \bar{x}_l \\ \hat{b}_{\backslash} &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}, \hat{b}_o = \bar{y} - \hat{b}_{\backslash} \bar{x} \end{aligned}$$

$$S(b_o, b_{\backslash}) = \sum_{i=1}^n d^2(\tilde{y}_i, \tilde{b}_o + \tilde{b}_{\backslash} x_i)$$

$$= \sum_{i=1}^n [(y_i - b_o - b_{\backslash} x_i)^2 + (y_{il} - b_{o_l} - b_{\backslash l} x_{il})^2 + (y_{ir} - b_{o_r} - b_{\backslash r} x_{ir})^2]$$

که پارامترها مانند مدل قبل تعریف می‌شوند و:

$$\begin{aligned} \bar{y}_l &= \frac{\sum_{i=1}^n y_{il}}{n} & \bar{y} &= \frac{\sum_{i=1}^n y_i}{n} & \bar{y}_r &= \frac{\sum_{i=1}^n y_{ir}}{n} \\ \bar{x}_l &= \frac{\sum_{i=1}^n x_{il}}{n} & \bar{x} &= \frac{\sum_{i=1}^n x_i}{n} & \bar{x}_r &= \frac{\sum_{i=1}^n x_{ir}}{n} \end{aligned}$$

که با مشتق‌گیری نسبت به پارامترها به دست می‌آوریم:

$$\begin{aligned} \hat{b}_{\backslash r} &= \frac{\sum_{i=1}^n x_i y_{ir} - n \bar{x} \bar{y}_r}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}, \hat{b}_{o_r} = \bar{y}_r - \hat{b}_{\backslash r} \bar{x} \quad (۳) \\ \hat{b}_{\backslash l} &= \frac{\sum_{i=1}^n x_i y_{il} - n \bar{x} \bar{y}_l}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}, \hat{b}_{o_l} = \bar{y}_l - \hat{b}_{\backslash l} \bar{x} \\ \hat{b}_{\backslash} &= \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}, \hat{b}_o = \bar{y} - \hat{b}_{\backslash} \bar{x} \end{aligned}$$

که در آن:

$$\hat{b}_{\backslash} = (\hat{b}_{\backslash l}, \hat{b}_{\backslash}, \hat{b}_{\backslash r}), \quad \hat{b}_o = (\hat{b}_{o_l}, \hat{b}_o, \hat{b}_{o_r})$$

و

$$\bar{y}_l = \frac{\sum_{i=1}^n y_{il}}{n}, \quad \bar{y} = \frac{\sum_{i=1}^n y_i}{n}, \quad \bar{y}_r = \frac{\sum_{i=1}^n y_{ir}}{n}$$

۳- مدلی که هم پارامترها و هم متغیرهای مستقل اعداد فازی مثلثی هستند، داریم:

$$\tilde{y}_i = \tilde{b}_o + \tilde{b}_{\backslash} \tilde{x}_i + \tilde{\varepsilon}_i \quad (۴)$$

و برای این مدل خواهیم داشت:

$$\begin{aligned} S(b_o, b_{\backslash}) &= \sum_{i=1}^n d^2(\tilde{y}_i, \tilde{b}_o + \tilde{b}_{\backslash} \tilde{x}_i) \\ &= \sum_{i=1}^n [(y_i - b_o - b_{\backslash} x_i)^2 + (y_{il} - b_{o_l} - b_{\backslash l} x_{il})^2 + (y_{ir} - b_{o_r} - b_{\backslash r} x_{ir})^2] \end{aligned}$$

در این حالت نیز با مشتق‌گیری، برآورد پارامترها به صورت زیر به دست می‌آید:

$$\hat{b}_{\backslash r} = \frac{\sum_{i=1}^n x_{ir} y_{ir} - n \bar{x}_r \bar{y}_r}{\sum_{i=1}^n x_{ir}^2 - n \bar{x}_r^2}, \hat{b}_{o_r} = \bar{y}_r - \hat{b}_{\backslash r} \bar{x}_r \quad (۵)$$

۲.۲ روش‌های برنامه‌ریزی ریاضی

در این روش‌ها از مینیمم کردن ابهام مدل به عنوان معیار برازش استفاده می‌شود. مزیت روش‌های برنامه‌ریزی ریاضی سادگی آنها در برنامه‌ریزی و محاسبات است و عیب عمده این روش‌ها این است که مفهوم کمترین مربعات در نظر گرفته نشده است و در نتیجه پهنای مقادیر تخمین زده شده بسیار عریض است و همچنین با اضافه شدن یک مشاهده به داده‌ها تعداد قیدهای مساله دویا چند برابر می‌شود.

در این بخش به اولین و یکی از آخرین مدل‌ها براساس روش‌های برنامه‌ریزی ریاضی اشاره می‌کنیم.

۱.۲.۲ مدل تاناکا و واتادا

تاناکا و واتادا [۱۹] مدل رگرسیون خطی فازی با خروجی فازی، ورودی غیرفازی و پارامترهای فازی را در نظر گرفتند:

$$\tilde{y}_i = \tilde{b}_o + \tilde{b}_{\backslash} x_{i1} + \dots + \tilde{b}_k x_{ik} + \varepsilon_i, \quad i = 1, 2, \dots, n$$

که مقدار h توسط تصمیم گیرنده مشخص می شود.

۲.۲.۲ مدل حجتی و همکاران

حجتی و همکاران [۱۱] روشی برای تخمین ضرایب رگرسیون ارائه دادند به طوری که مجموع انحراف نقاط بالایی h -برش های مقادیر پیش بینی شده و مقادیر مشاهده شده و انحراف نقاط پایینی این h -برش ها مینیمم شود. در این مدل فرض شده است که مقادیر مشاهده شده و ضرایب رگرسیون اعداد فازی مثلثی متقارن هستند. این مدل به صورت مساله برنامه ریزی زیر ارائه شده است:

$$\min \sum_{i=1}^n (d_{iU}^+ + d_{iU}^- + d_{iL}^+ + d_{iL}^-)$$

به گونه ای که

$$\begin{aligned} \sum_{j=0}^k (a_j + (1-h)\alpha_j)x_{ij} + d_{iU}^+ - d_{iU}^- \\ = y_i + (1-h)e_i, \quad i = 1, \dots, n \\ \sum_{j=0}^k (a_j - (1-h)\alpha_j)x_{ij} - d_{iL}^+ - d_{iL}^- \\ = y_i - (1-h)e_i, \quad i = 1, \dots, n \end{aligned}$$

$$d_{iU}^+, d_{iU}^-, d_{iL}^+, d_{iL}^- \geq 0, \quad i = 1, \dots, n$$

$$\alpha_j \geq 0, a_j \in \mathbb{R}, j = 0, \dots, k, 0 \leq h \leq 1$$

قابل ذکر است که $|d_{iU}^+ - d_{iU}^-|$ فاصله بین نقطه بالایی h -برش مقدار پیش بینی شده و نقطه بالایی h -برش مقدار مشاهده شده است و $|d_{iL}^+ - d_{iL}^-|$ فاصله بین نقطه پایینی h -برش مقدار پیش بینی شده و نقطه پایینی h -برش مقدار مشاهده شده است. تابع هدف در حقیقت مینیمم سازی مجموع این دو فاصله است.

که در آن پارامترها و مقدار متغیر مستقل در مشاهده i -ام اعداد فازی مثلثی متقارن هستند که به ترتیب با $\tilde{b}_j = (a_j, \alpha_j)$, $j = 0, \dots, k$ و $\tilde{y}_i = (y_i, e_i)$, $i = 1, \dots, n$ نشان داده می شوند. مدل فوق را به صورت زیر می توان بازنویسی کرد:

$$\tilde{y}_i = (\underline{a} \underline{x}_i, \underline{\alpha} |\underline{x}_i|)$$

که در آن:

$$\underline{a} = (a_0, a_1, \dots, a_k)^T, \quad \underline{\alpha} = (\alpha_0, \alpha_1, \dots, \alpha_k)^T$$

$$\underline{x}_i = (1, x_{i1}, \dots, x_{ik})^T, \quad i = 1, \dots, n$$

تاناکا و واتادا [۱۹] پارامترهای فازی را به قسمی تعیین کردند که ابهام مدل که به صورت زیر تعریف می شود:

$$J(\underline{\alpha}) = \sum_{i=1}^n \underline{\alpha} |\underline{x}_i|$$

مینیمم شود، به طوری که به ازای هر مقدار معین h ، h -برش مقادیر تخمین زده شده h -برش مقادیر مشاهده شده را بپوشاند، یعنی $[\tilde{y}_i]^h \subseteq [\hat{y}_i]^h$ که در آن:

$$[\tilde{y}_i]^h = [y_i - l^{-1}(h)e_i, y_i + l^{-1}(h)e_i]$$

و

$$[\hat{y}_i]^h = [\underline{a} \underline{x}_i - l^{-1}(h)\underline{\alpha} |\underline{x}_i|, \underline{a} \underline{x}_i + l^{-1}(h)\underline{\alpha} |\underline{x}_i|]$$

تحلیل بالا منجر به مساله برنامه ریزی خطی زیر می شود:

$$\min J(\alpha) = \sum_{i=1}^n \underline{\alpha} |\underline{x}_i|$$

به گونه ای که

$$\underline{a} \underline{x}_i - l^{-1}(h)\underline{\alpha} |\underline{x}_i| \leq y_i - l^{-1}(h)e_i, \quad i = 1, \dots, n$$

$$-\underline{a} \underline{x}_i - l^{-1}(h)\underline{\alpha} |\underline{x}_i| \leq -y_i - l^{-1}(h)e_i, \quad i = 1, \dots, n$$

$$\alpha_j \geq 0, a_j \in \mathbb{R}, j = 0, 1, \dots, k, 0 \leq h \leq 1$$

۳.۲ روش‌های عددی

از جمله روش‌های عددی که در رگرسیون فازی مورد استفاده گرفته است، می‌توان از روش مونت کارلو نام برد. عبدالله و باکلی [۲] روش مونت کارلو را در رگرسیون خطی فازی به کار بردند. روش کار آن‌ها به این صورت است که ابتدا دو خطا روی مقادیر مشاهده شده و برآورد شده تعریف کردند سپس دنباله تصادفی از بردارهای غیرفازی برای ضرایب مدل تولید کردند و آن برداری را به عنوان راه حل مساله رگرسیون فازی ارائه دادند که خطاهای نامبرده را مینیمم کند.

۳ مدل رگرسیون فازی به روش بوت‌استرپ

واژه بوت‌استرپ از ماجرای «بارن مانچوسن»^{۲۳} نوشته رادف اریک راسپه^{۲۴} در اواخر قرن ۱۸ گرفته شده است که وقتی خودش را در ته دریاچه بدون هیچ کمک و وسیله‌ای می‌بیند با استفاده از بند پوتینش خود را بالا می‌کشد [۱]. در اینجا نیز موقعی که کمترین اطلاعات را داریم یعنی نه توزیع جامعه معلوم است نه اینکه داده‌ها به اندازه کافی هستند، سعی می‌کنیم با استفاده از نمونه کوچکی که در دست داریم استنباط خوب و معتبر ارائه دهیم. در این روش، آنالیز روی داده‌های واقعی است؛ نمونه‌های کوچک ولی معتبر و موثق قسمت مهم یک تحقیق است و در عمل برپایه شبیه‌سازی است، اما در برخی مثال‌ها نیازی به شبیه‌سازی نیست. در واقع

شبیه‌سازی از توزیع جامعه می‌باشد ولی اگر توزیع جامعه نامعلوم باشد به تعداد دلخواه نمونه از نمونه اصلی برداشته و میانگین آن‌ها را در نظر می‌گیریم، پس نیازی به توزیع جامعه نیست.

در رگرسیون به دو صورت می‌توانیم از بوت‌استرپ استفاده کنیم یکی اینکه از مشاهدات نمونه بوت‌استرپ بگیریم و دیگر اینکه از باقیمانده‌های مدل نمونه بوت‌استرپ انتخاب کنیم.

۱- بوت‌استرپ از مشاهدات: در این روش از نمونه‌ای که در دست داریم، نمونه باجایگذاری برمی‌داریم سپس به این نمونه‌ها مدل برازش می‌دهیم، سپس میانگین برآوردهای این مدل‌ها را به عنوان برآورد اصلی انتخاب می‌کنیم.

۲- بوت‌استرپ از باقیمانده‌ها: در این روش با نمونه‌ای که در دست داریم $((x_i, y_i), i = 1, 2, \dots, n)$ مدل را برازش می‌دهیم و باقیمانده‌های مدل را از رابطه $\varepsilon_i = y_i - \hat{b}_0 - \hat{b}_1 x_i, i = 1, \dots, n$ به دست می‌آوریم، سپس از این باقیمانده‌ها نمونه باجایگذاری برمی‌داریم به طوری که احتمال انتخاب هر $\varepsilon_i, i = 1, \dots, n$ در هر انتخاب $\frac{1}{n}$ می‌باشد. فرض کنید این نمونه بوت‌استرپ $(\varepsilon_1^*, \varepsilon_2^*, \dots, \varepsilon_n^*)$ باشد. با اضافه کردن این باقیمانده‌های جدید، مقادیر پاسخ جدید را از رابطه $y_i^* = \hat{b}_0 + \hat{b}_1 x_i + \varepsilon_i^*, i = 1, \dots, n$ به دست می‌آوریم. این مقادیر پاسخ جدید و متغیرهای مستقل، نمونه جدید $((x_i, y_i^*), i = 1, 2, \dots, n)$ را تشکیل می‌دهد و با این داده‌های جدید مدل برازش می‌دهیم. برآوردهای حاصل

^{۲۳} Baron Manchosen
^{۲۴} Radolf Erick Raspe

مثال ۴-۱ کیم-بیشو [۱۴]، کائو-چیو [۱۳] و حجتی و همکاران [۱۱] از داده‌های جدول ۱ برای نشان دادن مدل‌های خود در مساله رگرسیون فازی با ورودی غیرفازی و خروجی فازی استفاده کردند. در این مثال ۵ جفت داده به صورتی که در جدول ۱ آمده است وجود دارد. در واقع این مدل از رابطه (۲) پیروی می‌کند که با استفاده از معادلات رابطه (۳) برآورد اولیه پارامترها به دست می‌آید. مدل رگرسیون خطی فازی که توسط کائو-چیو [۱۳] برازش شده به صورت زیر است:

$$\tilde{y}_{KC} = (1/94, 4/95, 6/75) + 1/71x$$

عربیور-تاتا [۳] با به کار بردن روش کمترین مربعات، مدل رگرسیون فازی را برای این داده‌ها به صورت زیر ارائه داده‌اند:

$$\tilde{y}_{AT} = (3/11, 4/95, 6/79) + (1/55, 1/71, 1/87)x$$

پس از اجرای روش بوت استرپ روی مدل بالا و استفاده از روش عربیور-تاتا جهت برآورد پارامترها، خواهیم داشت:

$$\tilde{y}_{Boot} = (3/069, 4/875, 6/729) + (1/554, 1/706, 1/877)x$$

همان‌طور که در جدول ۲ مشاهده می‌کنید، مجموع خطاهای محاسبه شده برای این داده‌ها در مدل رگرسیون فازی با به کارگیری روش بوت استرپ مقدار ۱۳۹/۰ است که از خطای مدل‌های دیگر به طور قابل توجهی کمتر است.

را $\hat{b}_0^*$ و $\hat{b}_1^*$ می‌نامیم. این عمل را چندین بار تکرار می‌کنیم سپس میانگین برآوردها را به عنوان برآورد بوت استرپ ارائه می‌دهیم.

این روش بهتر از روش اول است زیرا حتی اگر باقیمانده‌ها نرمال نباشند می‌توان استنباط دقیق‌تری در مورد پارامترهای مدل انجام داد.

در این مقاله پس از انجام هر دو روش برای انتخاب نمونه بوت استرپ، به دلیل اینکه نمونه بوت استرپ از باقیمانده‌ها خطای کمتری داشت از روش دوم استفاده شد.

ابتدا پارامترهای مدل رگرسیون فازی را در هر یک از سه مدل با روابط (۱)، (۲) و (۴) با استفاده از روش عربیور-تاتا [۳] برآورد کرده‌ایم سپس در هر یک از این سه مدل روش بوت استرپ را به کار برده‌ایم به این صورت که در هر مدل B بار از باقیمانده‌های مدل نمونه‌گیری با جایگذاری انجام داده‌ایم و به روشی که توضیح داده شد پاسخ جدید تولید کردیم و با این داده‌های جدید به همان روش کمترین مربعات، مدل برازش دادیم و در هر مرحله برآورد پارامترها $(\hat{b}_i^*, \hat{b}_{1i}^*)$ ، $i = 1, \dots, B$ را به دست آوردیم. در پایان B مرحله، میانگین این برآوردها را به عنوان برآورد پارامترهای مدل اصلی در نظر گرفته‌ایم.

۴ مثال‌ها

در این بخش با بیان چند مثال عددی نشان خواهیم داد در مدلی که مشاهدات اعداد مثلثی فازی هستند با اجرای بوت استرپ به شیوه‌ای که گفته شد برآوردهای بهتر با خطای کمتری به دست می‌آید.

با رابطه (۲) پیروی می‌کنند. مدل رگرسیون ارائه شده توسط کائو-چیو [۱۳] برای این داده‌ها به صورت زیر است:

$$\tilde{y}_{KC} = -4/89487 + 1/19542x \\ + (-2/99, 0, 1/80)$$

مدل به دست آمده از روش عربپور-تاتا [۳] به فرم زیر است:

$$\tilde{y}_{AT} = (-5/249, -4/895, -4/541) \\ + (1/138, 1/195, 1/252)x$$

مدل برازش شده پس از به کارگیری بوت‌استرپ و استفاده از روش عربپور-تاتا [۳] به فرم زیر است:

$$\tilde{y}_{Boot} = (-5/195, -4/894, -4/554) \\ + (1/136, 1/193, 1/245)x$$

همان‌طور که در جدول ۴ مشاهده می‌کنید مجموع خطاهای محاسبه شده برای این داده‌ها با اجرای بوت‌استرپ مقدار ۱۰/۰۹۵۵ است که از مجموع خطاهای مدل‌های دیگر کمتر است.

جدول ۳. داده‌های مثال ۲-۴.

$\tilde{y}_i$	x_i
$(-2/1, -1/6, -1/1)$	۱
$(-2/3, -1/8, -1/3)$	۳
$(-1/5, -1, -0/5)$	۴
$(0/7, 1/2, 1/7)$	۵/۶
$(1/2, 2/2, 3/2)$	۷/۸
$(5/8, 6/8, 7/8)$	۱۰/۲
$(9, 10, 11)$	۱۱
$(9, 10, 11)$	۱۱/۵
$(9, 10, 11)$	۱۲/۷

جدول ۱. داده‌های مثال ۱.

$\tilde{y}_i$	x_i
$(6/2, 8/0, 9/8)$	۱
$(4/2, 6/4, 8/6)$	۲
$(6/9, 9/5, 12/1)$	۳
$(10/9, 13/5, 16/1)$	۴
$(10/6, 13/0, 15/4)$	۵

جدول ۲. خطای برآورد شده برای داده‌های جدول ۱.

Boot	AT	KC	Obs.
۲/۲۷۸۱	۵/۴۶۶۸	۱۰/۰۹۳۷	۱
۲/۹۹۱۰	۱۱/۶۴۵۹	۷/۶۹۱۴	۲
۰/۹۸۸۴	۱/۱۶۶۰	۰/۴۱۳۷	۳
۲/۹۰۸۰	۸/۸۰۱۱	۱۳/۷۱۶۸	۴
۰/۸۴۸۴	۰/۸۶۵۲	۰/۲۷۲۱	۵
۱۰/۰۱۳۹	۲۷/۹۴۵۰	۳۲/۱۸۹۵	جمع

نکته ۱

روش بوت‌استرپ را روی برش صفر خط رگرسیون فازی به کار می‌بریم و آنگاه میانگین ضرایب بدست آمده را به عنوان برآورد اصلی در نظر می‌گیریم، به عبارتی بهترین برازش را در برش صفر خط رگرسیون به دست می‌آوریم یا در بدترین وضعیت ممکنه بهترین برازش را انجام می‌دهیم، به همین دلیل است که مدل بدست آمده در چنین حالتی دارای کمترین خطا می‌باشد.

نکته ۲

با توجه به اینکه مدل AT خطای کمتری نسبت به مدل های قبلی دارد [۳] بنابراین با اجرای روش بوت‌استرپ روی این مدل، مجموع خطاها از روش‌های قبلی نیز کمتر می‌شود.

مثال ۲-۴ برای مقایسه مدل ارائه شده با مدل کائو-چیو [۱۳] و مدل عربپور-تاتا [۳] از داده‌های جدول ۳ استفاده کردیم که شامل ۹ مشاهده با ورودی غیرفازی و خروجی فازی است. این داده‌ها نیز از مدلی

$$+(0/5184, 0/5207, 0/5232)\tilde{x}$$

خطاهای این مدل را به دست آوردیم و با مدل یانگ-لین [۲۳] و عربپور-تاتا [۳] مقایسه کردیم. داده‌ها و نتایج در جدول ۶ آمده است.

جدول ۵. داده‌های مثال ۳-۴.

$\tilde{y}_i$	$\tilde{x}_i$
(۳/۵، ۴، ۴/۵)	(۱/۵، ۲، ۲/۵)
(۵، ۵/۵، ۶)	(۳، ۳/۵، ۴)
(۶/۵، ۷/۵، ۸/۵)	(۴/۵، ۵/۵، ۶/۵)
(۶، ۶/۵، ۷)	(۶/۵، ۷، ۷/۵)
(۸، ۸/۵، ۹)	(۸، ۸/۵، ۹)
(۷، ۸، ۹)	(۹/۵، ۱۰/۵، ۱۱/۵)
(۱۰، ۱۰/۵، ۱۱)	(۱۰/۵، ۱۱، ۱۱/۵)
(۹، ۹/۵، ۱۰)	(۱۲، ۱۲/۵، ۱۳)

جدول ۶. خطای برآورد شده برای داده‌های جدول ۵.

Boot	AT	YL	Obs.
0/84328	0/85856	0/82247	۱
0/22715	0/21580	0/27822	۲
1/50390	1/51221	1/53468	۳
0/91310	0/94164	0/95111	۴
0/76982	0/77724	0/77397	۵
1/44985	1/47983	1/51546	۶
0/99826	1/06797	1/10235	۷
0/80802	0/83765	0/88847	۸
7/51338	7/69090	7/86673	جمع

در این مدل نیز مجموع خطاهای برازش شده با به کارگیری بوت استرپ مقدار ۷/۵۱۳۳۸ است، که از مجموع خطاهای دو مدل دیگر کمتر است.

۵ نتیجه‌گیری

برای برآورد پارامترها در مدل رگرسیون خطی فازی روش‌های متعددی ارائه شده است. از این روش‌ها می‌توان روش کمترین مربعات را نام برد که با مینیمم کردن مربعات خطا (تفاضل بین مقادیر مشاهده شده و برآورد شده) مدل مناسبی برازش می‌دهد. در این مقاله برای بهبود برآوردهای به دست آمده از روش

جدول ۴. خطای برآورد شده برای داده‌های جدول ۳.

Boot	AT	KC	Obs.
0/8749	0/9113	2/8875	۱
0/7400	0/7473	1/9324	۲
1/0156	1/0471	1/9943	۳
0/8719	0/8928	1/9458	۴
1/7434	1/7993	2/6143	۵
0/8258	0/8685	1/4666	۶
1/9067	1/9537	3/0077	۷
1/6440	1/6401	2/4298	۸
0/4732	0/5342	1/4254	۹
10/0955	10/3944	19/7039	جمع

مثال ۳-۴ در این مثال برای نشان دادن تاثیر بوت استرپ روی برآوردهای مدل رگرسیون، این روش را روی داده‌هایی که توسط یانگ و لین مورد استفاده قرار گرفت به کار می‌بریم. در این مثال پارامترها و ورودی مدل اعداد فازی مثلثی هستند یعنی مدل به صورت رابطه (۴) است و برآوردهای اولیه از معادلات رابطه (۵) به دست می‌آیند. مدل رگرسیون ارائه شده برای این داده‌ها توسط یانگ-لین [۲۳] به صورت زیر است:

$$\tilde{y}_{YL} = (3/2052, 3/4967, 3/7882)$$

$$+(0/5251, 0/5293, 0/5335)\tilde{x}$$

برای ارزیابی مدل پیشنهادی، آن را با مدل رگرسیون فازی عربپور-تاتا [۳] که به صورت زیر است، مقایسه می‌کنیم:

$$\tilde{y}_{AT} = (3/2758, 3/5724, 3/8386)$$

$$+(0/5188, 0/5193, 0/5235)\tilde{x}$$

مدل برازش داده شده به روش بوت استرپ و استفاده از روش عربپور-تاتا [۳] جهت برآورد پارامترها به این صورت است:

$$\tilde{y}_{Boot} = (3/2887, 3/5628, 3/8169)$$

کمترین مربعات در مدل رگرسیون خطی فازی از روش بوت استرپ استفاده شده است. با اجرای این روش روی چند مثال عددی تاثیر بوت استرپ روی کاهش خطاهای مدل به وضوح مشاهده شد. اجرای این روش با استفاده از کامپیوتر به آسانی امکان پذیر است و می توان مدل مناسب داده ها را پیدا کرد.

مراجع

- [۱] دوست طلب، ص. (۱۳۸۵)، شبیه سازی و باز نمونه گیری، نشریه دانشجویی آمار، ندا، سال چهارم، شماره اول، ۲۱-۳۳.
- [2] Abdalla, A. and Buckley, J.J. (2008). Monte Carlo methods in fuzzy linear regression II, *Soft Comput*, 12, 463-468.
- [3] Arabpour, A. R. and Tata, M. (2008). Estimating the parameters of a fuzzy linear regression model, *Iranian Journal of Fuzzy Systems*, 5, 2, 1-19.
- [4] Celmins, A. (1987). Least squares model fitting to fuzzy vector data, *Fuzzy Sets and Systems*, 22, 245-269.
- [5] Celmins, A. (1987). Multidimensional least-squares fitting of fuzzy models, *Mathematical Modelling*, 9, 669-690.
- [6] Chang, P.T. and Lee, E.S. (1996). A generalied fuzzy weighted least squares regression, *Fuzzy Sets and Systems*, 82, 289-298.
- [7] Chang, P.T. and Lee, E.S. (1994). Fuzzy linear regression with spreads unrestricted in sign, *Computers and Mathematics with Applications*, 28, 61-70.
- [8] Coppi, R., D'Urso P., Giordani P. and Santoro, A. (2006). Least squares estimation of a linear regression model with L-R fuzzy response, *Computational Statistics and Data Analysis*, 51, 267-286.
- [9] Diamond, P. (1988). Fuzzy least squares, *Infomation Sciences*, 46, 141-157.

- [10] Efron, B. (1979). Bootstrap methods: another look at the Jackknife, *Analysis Statistics*, 101-118.
- [11] Hojati, M., Bector, C.R. and Smimou, K. (2005). A simple method for computation of fuzzy linear regression, *European Journal of Operational Research*, 166, 172-184.
- [12] Jajuga, K. (1986). Linear fuzzy regression, *Fuzzy Sets and Systems*, 20, 343-353.
- [13] Kao, C. and Chyu, C. (2002). A fuzzy linear regression model with better explanatory power, *Fuzzy Sets and Systems*, 126, 401-409.
- [14] Kim, B. and Bishu, R.R. (1998). Evaluation of fuzzy linear regression models by comparing membership functions, *Fuzzy Sets and Systems*, 100, 343-353.
- [15] Liang, H., Hardle, W. and Sommerfeld, V. (2000). Bootstrap approximation in a partially linear regression model, *Journal of Statistical Planning and Inference*, 91, 413-426.
- [16] Paparoditis, E. and Politis, D.N. (2005). Bootstrap hypothesis testing in regression models, *Statistics and Probability Letters*, 74, 356-365.
- [17] Peters, G. (1994), Fuzzy linear regression with fuzzy intervals, *Fuzzy Sets and Systems*, 63, 45-55.
- [18] Tanaka, H., Uejima, S. and Asai, K. (1982). Linear regression analysis with fuzzy model, *IEEE Transactions on Systems Man Cybernet*, 12(6), 903-907.
- [19] Tanaka, H. and Watada, J. (1988). Possibilistic systems and their application to the linear regression model, *Fuzzy Sets and Systems*, 27, 275-289.
- [20] Velilla, S. (2001). On the bootstrap in misspecified regression models, *Computational Statistics and Data Analysis*, 36, 227-242.
- [21] Wang, N., Zhang, W.X. and Mei, C.L. (2007). Fuzzy nonparametric regression based on local linear smoothing technique, *Information Sciences*, 177, 3882-3900.

-
- [22] Yager, R.R. (1982). Fuzzy prediction based on regression models, *Information Sciences*, 26, 45-63.
- [23] Yang, M. and Lin, T. (2001). Fuzzy least-squares linear regresion analysis for fuzzy input-output data, *Fuzzy Sets and Systems*, 126, 389-399.
- [24] Zadeh, L.A. (1965). Fuzzy sets, *Information Control*, 8, 338-353.