

برآورد پارامترهای فازی از طریق وزن‌های فازی و برنامه‌ریزی خطی

صدیقه دانش^{*}، رحمان فرنوش^{۱**} و طاهره رزاق نیا^{***}

^{*}گروه آمار، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی

^{**}گروه ریاضی و آمار، دانشگاه علم و صنعت

^{***}گروه ریاضی و آمار، واحد رودهن، دانشگاه آزاد اسلامی

تاریخ دریافت: ۱۳۹۴/۷/۱۸ تاریخ پذیرش: ۱۳۹۵/۵/۱۹

چکیده: تحلیل رگرسیون فازی یکی از پرکاربردترین تکنیک‌های آماری می‌باشد که رابطه بین متغیرها را نشان می‌دهد. در این بررسی رگرسیون فازی با ورودی غیر فازی و خروجی فازی در نظر گرفته می‌شود. برای پیش‌بینی مدل رگرسیون فازی، یک الگوریتم هیبریدی بر پایه برنامه-ریزی خطی و وزن‌های فازی، در مواردی که تعداد داده‌ها کم بوده و یا با رگرسیون ناپارامتری فازی سروکار داشته و شکل تابعی آن مشخص نمی‌باشد، طراحی می‌شود. در این برنامه‌ریزی خطی، تابع هدف، پهنه‌ای خروجی‌ها را کمینه می‌کند. با استفاده از مثال‌های عددی، عملکرد این روش با روش‌های دیگر مانند برنامه‌ریزی خطی و برنامه‌ریزی مربعی مقایسه می‌شود. در این مقاله، با استفاده از مثال‌های نشان داده می‌شود که روش هیبریدی در مقایسه با روش‌های دیگر دقت پیش‌بینی بیشتری دارد.

واژه‌های کلیدی: رگرسیون فازی؛ برنامه‌ریزی خطی؛ برنامه‌ریزی مربعی؛ شبکه عصبی فازی تطبیقی.

ردیف‌بندی ریاضی (۲۰۱۰): ۹۲B۲۰ و ۶۲J۸۶

۱- مقدمه

نظریه مجموعه فازی، اولین بار توسط پروفسور عسگر زاده [۱] در سال ۱۹۶۲ و رگرسیون خطی فازی اولین بار در سال ۱۹۸۲ توسط تاناکا و همکاران [۲] مطرح شد. آن‌ها مدل‌های رگرسیون خطی با پارامترهای فازی، ورودی غیر فازی و خروجی فازی را به صورت مسائل برنامه‌ریزی خطی

فرموله کردند. هدف آن‌ها مینیمم کردن ابهام مدل رگرسیون خطی فازی بود، به طوری که تکیه‌گاه مقادیر تخمین زده شده، تکیه‌گاه مقادیر مشاهده شده را در یک سطح معین بپوشاند. در سال ۱۹۸۸، دیاموند [۳] روش کمترین مربعات فازی را برای مدل‌های رگرسیون خطی فازی پیشنهاد کرد. به طور کلی چندین تکنیک رگرسیون فازی بر پایه روش کمترین مربعات فازی [۴-۸] و مسائل برنامه‌ریزی مانند برنامه‌ریزی خطی و برنامه‌ریزی مربعی [۹-۱۳] معرفی شده‌اند. در مهروموم‌های اخیر روش‌هایی بر پایه شبکه عصبی مصنوعی برای حل مسائل با رفتارهای پیچیده و برآورد پارامترهای رگرسیونی بکار گرفته شده است. تنانکا، ایشی بچی و کوان [۱۴، ۱۵] تحلیل رگرسیون فازی با استفاده از شبکه‌های عصبی فازی معرفی کردند که در الگوریتم پیشنهادی خود از شبکه عصبی پسرو، وزن‌های فازی مثلثی و برنامه‌ریزی خطی استفاده کردند. در سال ۱۹۹۳، جنگ [۱۶] شبکه عصبی تطبیقی بر پایه سیستم استنباط فازی پیشنهاد کرد. چنگ و لی [۱۷]، یک شبکه عصبی فازی معرفی کرده و دالکلیک و آپیدان [۱۸، ۱۹] از روش پیشنهادی توسط چنگ و لی استفاده کرده و یک الگوریتم بر پایه خوشه‌بندی برای پیش‌بینی رگرسیون فازی پیشنهاد دادند. همچنین دانش و همکاران [۲۰] یک الگوریتم بر پایه شبکه عصبی فازی تطبیقی و حداقل مربعات فازی برای پیش‌بینی رگرسیون فازی پیشنهاد کردند.

در این مقاله، یک الگوریتم هیبریدی به منظور پیش‌بینی مدل رگرسیونی فازی و کاهش خطای پایه وزن‌های فازی و برنامه‌ریزی خطی پیشنهاد می‌شود. در این الگوریتم، روش شبیب کاهشی برای محاسبه پارامترهای اولیه (وزن‌های فازی) و برنامه‌ریزی خطی برای محاسبه پارامترهای نتیجه استفاده می‌شوند که تکیه‌گاه مقادیر تخمین زده شده، تکیه‌گاه مقادیر مشاهده شده را در یک سطح معین می‌پوشاند. همچنین، روش پیشنهادی با دو روش برنامه‌ریزی خطی و برنامه‌ریزی مربعی به منظور بررسی عملکرد روش مقایسه می‌شود.

این مقاله شامل ۳ بخش می‌باشد. در ادامه این بخش به تعاریف اولیه درباره فازی و شبکه عصبی فازی تطبیقی پرداخته شده و در بخش دوم با استفاده از فنون شبکه عصبی فازی تطبیقی، یک الگوریتم هیبریدی بر پایه وزن‌های فازی و برنامه‌ریزی خطی معرفی می‌گردد. در بخش سوم دو مثال برای نشان دادن روش پیشنهادی و مقایسه آن با دو روش برنامه‌ریزی خطی و برنامه‌ریزی مربعی بیان می‌شود.

۱-۱- مفاهیم و تعاریف مقدماتی

تعریف ۱: اگر M مجموعه‌ای ناتهی باشد، آنگاه مجموعه فازی X از M با مجموعه دوتایی زیر مشخص می‌گردد:

$$X = \{(x, \mu_X(z)) | x \in X\}. \quad (1)$$

تعريف ۱: مجموعه فازی $X \in X$ برای هر x میزان عضویت $\mu_X(z) : X \rightarrow [0, 1]$ را در مجموعه فازی X نشان می‌دهد.

تعريف ۲: مجموعه در سطح h ($-h$ -برش): برای هر $h \leq 1$, X^h که با $[X]^h$ نشان داده می‌شود به صورت زیر تعریف می‌شود:

$$[X]^h = X_h = \{z \in Z | \mu_X(z) \geq h\}, \quad (2)$$

ضمناً مجموعه

$$[X]^h = X_h = \{z \in Z | \mu_X(z) > h\}, \quad (3)$$

را مجموعه قوی در سطح h (برش قوی) مینامیم.

تعريف ۳: عدد فازی مثلثی: فرض کنید (l_X, a_X, r_X) یک عدد فازی مثلثی باشد که l_X, a_X و r_X به ترتیب مرکز کرانه‌های چپ، و راست عدد فازی مثلثی می‌باشند و تابع عضویت $\mu_X(z) : X \rightarrow [0, 1]$ به صورت زیر تعریف می‌شود:

$$\mu_X(z) = \begin{cases} L\left(\frac{a_X - z}{a_X - l_X}\right), & l_X < z < a_X, \\ R\left(\frac{z - a_X}{r_X - a_X}\right), & a_X < z < r_X, \\ 0, & \text{otherwise.} \end{cases} \quad (4)$$

همچنین عدد فازی مثلثی را می‌توان با نماد TR بدین صورت نمایش داد:

$$T(R) = \{Y_j : Y_j = (a_j, \alpha_j, \beta_j)\}, \quad (5)$$

که a_j مرکز، α_j و β_j پهنه‌ای چپ و راست عدد فازی مثلثی Y_j می‌باشد و عدد فازی مثلثی متقارن که در آن پهنه‌ای چپ و راست باهم برابر هستند، به صورت زیر نمایش داده شود:

$$T(R) = \{Y_j : Y_j = (a_j, \alpha_j)\}. \quad (6)$$

تعريف ۴: رگرسیون فازی: مدل رگرسیون فازی به صورت زیر را در نظر بگیرید [۱۱]:

$$\begin{aligned} Y &= f(x) + \varepsilon = (a(x) - \alpha(x), a(x), a(x) + \beta(x))_{LR} + \varepsilon \\ &= (l(x), a(x), r(x))_{LR} + \varepsilon, \end{aligned} \quad (7)$$

در این مدل، $x = (x_1, x_2, \dots, x_p)$ یک بردار متغیرهای مستقل p -بعدی از ورودی‌ها که متعلق به فضای $D \subseteq R^p$ است، Y متغیر پاسخ و دارای ساختار فازی است. همچنین ϵ جمله خطأ است که یک متغیر تصادفی با میانگین صفر در نظر گرفته می‌شود. $\{+\}$ یک عملگر است که تعریف آن وابسته به اعداد فازی است.

در بحث بالا، رابطه بین متغیر ورودی و خروجی معلوم فرض شده و با معادله خطی (۷) نمایش داده می‌شود. در بسیاری موقعیت‌های عملی این رابطه نامعلوم می‌باشد. بنابراین رگرسیون ناپارامتریک که شکل تابعی آن مشخص نمی‌باشد، لازم به نظر می‌رسد.

تعریف ۵: فاصله دیاموند: فرض کنید $A = (l_a, a_a, r_a)$ و $B = (l_B, a_B, r_B)$ دو عدد فازی مثلثی باشند. فاصله بین دو عدد فازی A و B به صورت زیر بیان می‌شود [۳]:

$$d^*(A, B) = (l_B - l_A)^+ + (a_B - a_A)^+ + (r_B - r_A)^+. \quad (8)$$

فاصله تعریف شده، نزدیکی بین دوتابع عضویت دو عدد فازی مثلثی را اندازه می‌گیرد.

نتیجه ۱: توابع عضویت دو عدد فازی A و B را مساوی گویند اگر داشته باشیم:

$$d^*(A, B) = 0. \quad (9)$$

تعریف ۶: برنامه‌ریزی خطی: مدل رگرسیون فازی زیر را در نظر بگیرید:

$$Y_j = p_0 + p_1 x_{j1} + p_2 x_{j2} + \dots + p_p x_{jp} = P X_j, \quad j = 1, \dots, n, \quad (10)$$

n تعداد نقاط مشاهده شده، $x_j = (x_{j1}, x_{j2}, \dots, x_{jp})$ یک بردار p -بعدی از متغیرهای مستقل در j امین مشاهده، $P = (p_0, p_1, \dots, p_p)$ یک بردار p -بعدی از پارامترهای نامعلوم و Y_j j امین مقدار مشاهده شده متغیرهای وابسته می‌باشد. P را می‌توان به صورت بردار $P = \{\alpha_0, \alpha_1, \dots, \alpha_p\}$ نمایش داد که، $b = (b_0, b_1, \dots, b_p)$ به ترتیب مقادیر مرکز و پهنهای مقدار p_i به ازای $i = 0, \dots, p$ می‌باشند. همچنین b_i و α_i به ترتیب مقادیر مرکز و پهنهای مقدار p_i به ازای $i = 0, \dots, p$ می‌باشند. بنابر روش پیشنهادی تواناکا [۳]، پارامترهای رگرسیون فازی با استفاده از روش برنامه‌ریزی خطی، به صورت تابع هدف زیر به دست می‌آیند:

$$\min L = \sum_{j=1}^n \sum_{i=0}^p \alpha_i |x_{ji}|, \quad (11)$$

بهطوری که باید دو قید زیر برقرار باشند:

$$\sum_{i=0}^p b_i |x_{ji}| - (1-h) \sum_{i=0}^p \alpha_i |x_{ji}| \leq a_j - (1-h)\beta_j, \quad (12)$$

$$\sum_{i=0}^p b_i |x_{ji}| + (1-h) \sum_{i=0}^p \alpha_i |x_{ji}| \geq a_j + (1-h)\beta_j, \quad j = 1, \dots, n, \quad (13)$$

که در آن باید $\alpha_i \geq 0$ باشند. در این مدل، قیود سبب می‌شوند $-h$ - برش مقادیر تخمین زده شده، $-h$ - برش مقادیر مشاهده شده را بپوشاند، بهطوری که $1 < h \leq 0$ است.

تعریف ۷: برنامه‌ریزی مربعی: فرض کنید $(Y_j = (l_{y_j}, a_{y_j}, r_{y_j}), j$ امین مقدار مشاهده شده و $(\hat{Y}_j = (\hat{l}_{y_j}, \hat{a}_{y_j}, \hat{r}_{y_j}), j$ امین مقدار برآورده شده باشد. در این مقاله،تابع هدف پیشنهادی توسط دانوس [۱۲] بکار گرفته می‌شود که به صورت زیر تعریف می‌شود:

$$\sum_{j=1}^n k_1 (l_{y_j} - \hat{l}_{y_j})^2 + \left[k_2 (a_{y_j} - \hat{a}_{y_j})^2 + (r_{y_j} - \hat{r}_{y_j})^2 \right]. \quad (14)$$

اگر $k_1 > k_2$ یعنی اینکه برای مراکز و اگر $k_2 < k_1$ یعنی اینکه برای پهنانها ارزش بیشتری قائل می‌شویم. فرض کنید $(Y_j = (a_{y_j}, \beta_{y_j}), j$ عدد فازی مثلثی متقاضی باشند. بنابراین، روابط زیر برقرار هستند:

$$l_{y_j} = a_{y_j} - \beta_{y_j}, \quad r_{y_j} = a_{y_j} + \beta_{y_j}, \quad \hat{l}_{y_j} = \hat{a}_{y_j} - \hat{\beta}_{y_j}, \quad \hat{r}_{y_j} = \hat{a}_{y_j} + \hat{\beta}_{y_j}. \quad (15)$$

با در نظر گرفتن $k_1 = k_2$ و با جایگذاری روابط (۱۵) در رابطه (۱۴)، رابطه زیر به دست می‌آید:

$$\begin{aligned} \sum_{j=1}^n & \left\{ \left[(a_{y_j} - \beta_{y_j}) - (\hat{a}_{y_j} - \hat{\beta}_{y_j}) \right]^2 + (a_{y_j} - \hat{a}_{y_j})^2 \right. \\ & \left. + \left[(a_{y_j} + \beta_{y_j}) - (\hat{a}_{y_j} + \hat{\beta}_{y_j}) \right]^2 \right\} = \sum_{j=1}^n \left[2(a_{y_j} - \hat{a}_{y_j})^2 + 2(\beta_{y_j} - \hat{\beta}_{y_j})^2 \right]. \end{aligned} \quad (16)$$

رابطه (۱۶) به عنوان تابع هدف بکار گرفته می‌شود. بنابراین در این برنامه‌ریزی مربعی، تابع هدف زیر را مینیمم می‌کنیم:

$$\sum_{j=1}^n \left[2(a_{y_j} - \hat{a}_{y_j})^2 + 2(\beta_{y_j} - \hat{\beta}_{y_j})^2 \right],$$

بهطوری که دو قید ذکر شده در (۱۲) و (۱۳) باید برقرار باشند.

تعريف ۸: سیستم استنتاج عصبی فازی تطبیقی: سیستم استنتاج عصبی فازی تطبیقی، شبکه‌ای تطبیق‌پذیر و قابل آموزش است که به لحاظ عملکرد کاملاً شبیه سیستم استنتاج فازی می‌باشد. این سیستم از قابلیت‌های شبکه عصبی و استنتاج فازی بهصورت یکجا استفاده می‌کند و ضعف‌های هر یک توسط دیگری پوشش داده می‌شود. به دلیل اینکه این سیستم آموزش‌پذیر است، جزء شبکه عصبی و به جهت اینکه برای کاهش خطا از داده‌های مسئله استفاده می‌شود، به آن شبکه عصبی تطبیقی می‌گویند. از مزیت‌های این روش این است که نیاز به محاسبات پیچیده ندارد و برای سیستم‌های پیچیده و غیردقیق بهخوبی جواب می‌دهد. این شبکه، یک شبکه چند لایه‌ای است که در آن هر یک از گره‌ها عملیات خاصی روی سیگنال‌های ورودی خود انجام می‌دهند. سیستم استنتاج عصبی فازی تطبیقی مبتنی بر قواعد منطقی "شرط و نتیجه" می‌باشد که بهصورت شکل (۱) نشان داده می‌شود. در این شکل برای سادگی، سیستم با یک ورودی، سه تابع عضویت و یک خروجی در نظر گرفته شده است. در این سیستم مجموعه سه قانون بهصورت زیر تعریف می‌شود (برای اطلاعات بیشتر مراجع [۲۱، ۲۶] را ببینید):

$$\text{قاعده ۱: اگر } x \in A_1, \text{ باشد آنگاه } f_1 = p_1^1 + p_1^2 x.$$

$$\text{قاعده ۲: اگر } x \in A_2, \text{ باشد آنگاه } f_2 = p_2^1 + p_2^2 x.$$

$$\text{قاعده ۳: اگر } x \in A_3, \text{ باشد آنگاه } f_3 = p_3^1 + p_3^2 x.$$

مجموعه‌های فازی و f_k خروجی نتیجه قانون k ام می‌باشد که $k = 1, 2, 3$ است. مطابق شکل (۱)، ساختار مدل انفیس از پنج لایه تشکیل گردیده است که عبارتند از:

لایه اول؛ گره‌های ورودی (با مریع نشان داده که داخل آن پارامترهایی است که باید برآورد شوند). در این لایه، عمل فازی کردن صورت گرفته و درجه عضویت گره‌های ورودی بهصورت بازه‌های مختلف فازی با استفاده از تابع عضویت آن‌ها مشخص می‌شود. در این لایه برای فازی کردن ورودی می‌توان از تابع عضویت مختلف مانند مثلثی، ذوزنقه‌ای، نرمال و ... استفاده کرد و تابع عضویتی که کمترین خطا در خروجی را ایجاد کند، بهعنوان تابع عضویت انتخابی برای ورودی‌ها در نظر گرفته می‌شود. خروجی هر لایه را با نماد $o_{\square k}$ نمایش می‌دهیم (k ، امین گره هر لایه \square می‌باشد). که در آن خروجی لایه اول بهصورت زیر بیان می‌شود:

$$o_{\square k} = \mu_{A_k}(x), k = 1, 2, 3. \quad (17)$$

در این مقاله، به دلیل اینکه تابع عضویت نرمال کمترین خطا را در خروجی ایجاد کرده، از این تابع عضویت استفاده کردہ‌ایم که بهصورت زیر تعریف می‌شود:

$$\mu_{A_k}(x) = \exp\left[-\left(\frac{x - \tau_k}{2\sigma_k}\right)^2\right], k = 1, 2, 3, \quad (18)$$

که τ_k و σ_k پارامترهای تابع عضویت مجموعه فازی A_k هستند و پارامترهای هر کدام از گره‌ها تعیین‌کننده شکل تابع عضویت مجموعه فازی آن گره می‌باشد.

لایه دوم؛ گره‌های قاعده: هر گره در این لایه درجه فعالیت یک قانون را محاسبه می‌کند که در این لایه پارامتر مجھول وجود ندارد. بنابراین گره‌های این لایه، گره ثابت می‌باشند و با دایره نشان داده شده‌اند. در این لایه با توجه به مقدار ورودی، وزن هر قانون یا میزان اهمیت آن مشخص می‌شود.

$$o_{\tau,k} = w_k = \mu_{A_k}(x), k = 1, 2, 3. \quad (19)$$

لایه سوم؛ گره‌های متوسط: در این لایه k امین گره، نسبت درجه فعالیت قانون k ام را به درجه فعالیت کلیه قوانین به صورت زیر نرمال‌سازی می‌کند که گره‌های این لایه نیز گره‌های ثابت می‌باشند.

$$o_{\tau,k} = \bar{w}_k = \frac{w_k}{w_1 + w_2 + w_3}, k = 1, 2, 3. \quad (20)$$

درجه فعالیت نرمال شده قانون k ام است.

لایه چهارم؛ گره‌های نتیجه: در این لایه، خروجی هر گره برابر است با:

$$o_{\tau,k} = \bar{w}_k f_k = \bar{w}_k (p_{\circ}^k + p_{\circ}^k x), k = 1, 2, 3. \quad (21)$$

وزن‌های نرمال شده لایه سوم (\bar{w}_k) در رابطه خطی $p_{\circ}^k + p_{\circ}^k x$ ضرب می‌شوند. در این لایه ضرایب p_{\circ}^k و p_{\circ}^k پارامترهای مجھول بوده که با روش حداقل مربعات به دست آورده می‌شوند. به دلیل اینکه در این لایه پارامتر مجھول وجود دارد، در شکل (۲۱) با مربع نشان داده شده‌اند. (در این لایه تعداد گره‌ها برابر تعداد خروجی‌ها است).

لایه پنجم؛ گره‌های خروجی: در این لایه، پارامترهای اولیه که از لایه اول به دست آورده و پارامترهای نتیجه که از لایه چهارم به دست آورده شده‌اند را در رابطه (۲۱) قرار داده و خروجی‌های به دست آمده از سه گره را باهم جمع می‌کنیم، یا به عبارتی مقدار خروجی نهایی را به صورت زیر به دست می‌آوریم:

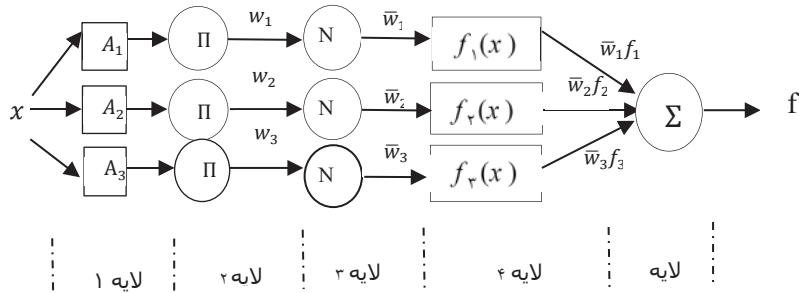
$$o_{\Delta,k} = \sum_{k=1}^n \bar{w}_k f_k = \bar{w}_1 f_1 + \bar{w}_2 f_2 + \bar{w}_3 f_3. \quad (22)$$

با جایگزین کردن (۲۱) در رابطه (۲۲) خروجی نهایی برابر است با:

$$\begin{aligned} o_{\Delta,k} &= Y = \bar{w}_1 (p_0 + p_1 x) + \bar{w}_2 (p_0 + p_2 x) + \bar{w}_3 (p_0 + p_3 x) \\ &= \sum_{k=1}^3 \sum_{i=0}^1 p_i^k \bar{w}_k x. \end{aligned} \quad (23)$$

رابطه (۲۳) می‌تواند به صورت رابطه خطی زیر نوشته شود:

$$Y = p_0 + p_1 x. \quad (24)$$



شکل (۱): ساختار سیستم استنتاج عصبی فازی تطبیقی.

بهطورکلی در روش انفیس ورودی و خروجی غیر فازی می‌باشند. در این مقاله نشان می‌دهیم که پارامترهای $(i = 0, 1)$ p_i می‌توانند اعداد فازی باشند که در این صورت خروجی الگوریتم هیبریدی (انفیس) فازی خواهد بود. همچنین نشان می‌دهیم مقادیر پارامترهای اولیه و ثانویه را می‌توانیم با استفاده از دو گام زیر به دست آوریم: گام اول، ورودی‌ها و مرکز خروجی‌ها را بدون در نظر گرفتن پهنانها با روش انفیس آموزش داده، پارامترهای اولیه را به دست می‌آوریم. گام دوم، مجموعه پارامترهای اولیه به دست آمده ثابت فرض شده و مجموعه پارامترهای ثانویه (نتیجه) با استفاده از برنامه‌ریزی خطی محاسبه می‌شوند. در ادامه روش پیشنهادی توضیح داده می‌شود.

۲- رگرسیون فازی و روش استنباط فازی عصبی تطبیقی

فرض کنید پارامترهای نتیجه y_j ، p_i^k و \hat{Y}_j در معادله (۲۴) اعداد فازی مثلثی بوده و به صورت زیر نمایش داده می‌شوند.

$$p_i^k = (b_i^k, \alpha_i^k), i = 0, \dots, p, k = 1, \dots, m, \quad (25)$$

تعداد جفت داده‌های مشاهده شده می‌باشد. با استفاده از تعاریف بالا، عملگرهای فازی و جایگزین کردن p_i^k در معادله (۲۴)، خروجی \hat{Y}_j برای یک ورودی x به صورت زیر محاسبه می‌شود:

$$\begin{aligned} \hat{Y}_j &= (b_0^j, \alpha_0^j) \bar{w}_0 + (b_1^j, \alpha_1^j) \bar{w}_1 x + (b_\circ^j, \alpha_\circ^j) \bar{w}_\circ + (b_1^r, \alpha_1^r) \bar{w}_r x + (b_\circ^r, \alpha_\circ^r) \bar{w}_\circ \\ &\quad + (b_r^r, \alpha_r^r) \bar{w}_r x = \sum_{k=1}^r \sum_{i=0}^m b_i^k \bar{w}_k x_i + \sum_{k=1}^r \sum_{i=0}^m \alpha_i^k \bar{w}_k x_i, \end{aligned} \quad (26)$$

که \bar{w}_k معلوم می‌باشد.

مدل رگرسیون فازی (۱۰) را در نظر بگیرید. فرض کنید $x_j = (x_{j1}, x_{j2}, \dots, x_{jp})$ یک بردار p -بعدی از متغیرهای مستقل در j امین مشاهده، $P = (p_0, p_1, \dots, p_p)$ یک بردار p -بعدی از پارامترهای نامعلوم فازی و y_j امین مقدار مشاهده شده متغیرهای وابسته باشد. P را می‌توان به صورت بردار $P = \{b, \alpha\}$ داد به طوری که، $b = (b_0^k, b_1^k, \dots, b_p^k)$ و $\alpha = (\alpha_0^k, \alpha_1^k, \dots, \alpha_p^k)$ مقادیر مرکز و پهنهای مقدار p_i برای $i = 0, \dots, p$ می‌باشد. با استفاده از تعاریف بالا، عملگرهای فازی و جایگزین کردن p_i^k در معادله (۱۹)، خروجی \hat{Y}_j برابر است با:

$$\hat{Y}_j = \sum_{k=1}^r \sum_{i=0}^m b_i^k \bar{w}_k x_{ji} + \sum_{k=1}^r \sum_{i=0}^m \alpha_i^k \bar{w}_k x_{ji}. \quad (27)$$

بنابراین، روابط زیر برقرارند:

$$\hat{\alpha}_{y_j} = \sum_{k=1}^r \sum_{i=0}^m b_i^k \bar{w}_k x_{ji}, \quad \hat{\beta}_{y_j} = \sum_{k=1}^r \sum_{i=0}^m \alpha_i^k \bar{w}_k x_{ji}. \quad (28)$$

در الگوریتم هیبرید پیشنهادی، روش پیش انتشار و پس انتشار باهم ترکیب شده و پارامترهای اولیه به دست می‌آیند و پارامترهای ثانویه با روش برنامه‌ریزی خطی به دست آورده می‌شوند. در این مقاله، با استفاده از روش بکار گرفته شده، در جعبه‌ابزار (انفیس) نرم‌افزار متلب و روش جنگ

[۱۶]، \bar{w}_k (وزن‌های فازی) فقط برای مراکز خروجی بهینه می‌شوند بنابراین، تأثیر پهنا نادیده گرفته شده و تأثیر آن‌ها در بخش برآورد پارامترهای ثانویه در نظر گرفته می‌شود. که در ادامه به بحث در مورد آن می‌پردازیم. بهمنظور بهینه کردن پارامترهای اولیه، مقدار خطای لایه آخر به صورت زیر تعریف می‌شود:

$$e = \sum_{j=1}^n e_j^r = \sum_{j=1}^n (a_{y_j} - \hat{a}_{y_j})^r, \quad (29)$$

بنابراین مقدار خطای پس انتشار برای هر لایه با استفاده از فرمول زیر به دست آورده می‌شود [۱۶، ۱۷]:

$$e_{l,k} = \sum_{r=1}^{M_{l+1}} e_{l+1,r} \frac{\partial A_{l+1,r}}{\partial o_{l,k}}, \quad (30)$$

مقدار خطای پس انتشار $e_{l,k}$ این گره لایه l می‌باشد. $A_{l+1,r}$ این گره r تابع گره $o_{l,k}$ این لایه می‌باشد، M_{l+1} تعداد کل گره‌ها در $(l+1)$ این لایه می‌باشد.

بنابراین بردار گرادیانت به صورت اندازه خطای مشتقات نسبت به هر پارامتر تعریف می‌شود. مشتق اندازه خطای e نسبت به پارامتر δ برابر است با:

$$\frac{\partial e}{\partial \delta} = \frac{1}{n} \sum_{j=1}^n \frac{\partial e_j^r}{\partial \delta} = \sum_{j=1}^n e_{l,k} \frac{\partial o_{l,k}}{\partial \delta}. \quad (31)$$

بنابراین، فرمول بهینه کردن وزن‌های فازی به صورت زیر تعریف می‌شود:

$$\Delta \delta = -g \frac{\partial e}{\partial \delta}, \quad (32)$$

به طوری که g نرخ یادگیری می‌باشد به صورت زیر محاسبه می‌شود:

$$g = \frac{rk}{\sum_{\delta} \left(\frac{\partial e}{\partial \delta} \right)^r}, \quad (33)$$

r اندازه گام‌ها می‌باشد. برای جزئیات بیشتر [۱۶] را ببینید.

در الگوریتم پیشنهادی، پارامترهای ثانویه، با حل کردن مدل برنامه‌ریزی خطی زیر به دست می‌آیند:

$$\min \sum_{j=1}^n \sum_{k=1}^m \sum_{i=0}^p b_i^k \bar{w}_{kj} x_{ji}, \quad (34)$$

به طوری که دو قید زیر برقرار باشند:

$$\sum_{k=1}^m \sum_{i=0}^p b_i^k \bar{w}_{kj} x_{ji} - (1-h) \sum_{k=1}^m \sum_{i=0}^p \alpha_i^k \bar{w}_{kj} x_{ji} \leq a_{y_j} - (1-h) \beta_{y_j}, \quad (35)$$

$$\sum_{k=1}^m \sum_{i=0}^p b_i^k \bar{w}_{kj} x_{ji} + (1-h) \sum_{k=1}^m \sum_{i=0}^p \alpha_i^k \bar{w}_{kj} x_{ji} \geq a_{y_j} + (1-h) \beta_{y_j}, \quad (36)$$

$$\alpha_i^k \bar{w}_{kj} \geq 0, \quad i = 0, \dots, p, \quad k = 1, \dots, m, \quad j = 1, \dots, n.$$

به دلیل اینکه فقط مرکز خروجی‌ها برای به دست آوردن پارامترهای اولیه استفاده می‌شوند، بنابراین می‌توان از جعبه‌ابزار نرم‌افزار متلب برای به دست آوردن پارامترهای اولیه استفاده کرد. ولی به دست آوردن پارامترهای ثانویه نیازمند برنامه‌نویسی می‌باشد که در این مقاله، پیاده‌سازی الگوریتم پیشنهادی شامل به دست آوردن پارامترهای اولیه و ثانویه، با برنامه‌نویسی در محیط متلب صورت پذیرفته است.

۲-۱- ارزیابی مدل انفیس

فرض کنید $(Y_j = (\hat{l}_j, \hat{a}_j, \hat{r}_j))$ مقدار مشاهده شده و $(\hat{Y}_j = (\hat{l}_j, \hat{a}_j, \hat{r}_j))$ مقدار برآورد شده و a_k, l_k و r_k به ترتیب پهنانی چپ، مرکز، پهنانی راست مقدار مشاهده شده باشد. همچنین با توجه به فرمول (۱۶) داریم:

$$\begin{aligned} ERROR &= \frac{1}{n} \sum_{j=1}^n (Y_j - \hat{Y}_j)^T \\ &= \frac{1}{n} \sum_{j=1}^n \left[2 \left(a_{y_j} - \sum_{k=1}^m \sum_{i=0}^p b_i^k \bar{w}_{jk} x_{ji} \right)^T + 2 \left(\beta_{y_j} - \sum_{k=1}^m \sum_{i=0}^p \alpha_i^k \bar{w}_{jk} x_{ji} \right)^T \right] \end{aligned} \quad (37)$$

رابطه (۳۷) را به عنوان یک کمیت برای اندازه‌گیری خطاب، به منظور ارزیابی مدل مورداستفاده قرار می‌دهیم. مقادیر بزرگ این کمیت نشان‌دهنده فقدان برازش و مقدار خیلی کوچک آن بیشتر برازش مقادیر خروجی را نشان می‌دهد. همچنین برای ارزیابی مدل از روش کیم و بیشو [۲۲] استفاده می‌شود که به صورت زیر تعریف می‌شود.

$$E_k = \int_{S(Y_k) \cup S(\hat{Y}_k)} |Y_k - \hat{Y}_k| dy, \quad (38)$$

به طوری که (Y_k) و (\hat{Y}_k) به ترتیب تکیه گاه مقادیر مشاهده شده و مقادیر برآورد شده می باشند هر چه مقدار E_k به صفر نزدیکتر باشد مقدار برآش بهتر می باشد.

۲- الگوریتم یادگیری مدل هیبریدی

برای برآورد پارامترهای مدل، الگوریتم یادگیری زیر را استفاده می کنیم.

- ۱- مقدار h وارد کنید.
- ۲- مقادیر پارامترهای اولیه بهینه را به دست آورید.
- الف- زوج (x_j, a_j) را به روش انفیس آموزش دهید.
- ب- زمانی که مقدار میانگین خطای e رابطه (30) کمتر از مقدار از قبل تعیین شده یا به یک مقدار ثابت رسید آموزش پایان پذیرد در غیر این صورت به مرحله الف رفته و وزن های فازی بهینه شود.
- ۳- مقادیر پارامترهای اولیه به دست آمده را در رابطه (27) قرار دهید.
- ۴- پارامترهای ثانویه را با حل کردن برنامه ریزی خطی (34) به دست آورید.
- ۵- مرکز و پهنهای خروجی ها را با توجه به روابط (28) تعیین کنید.
- ۶- برای ارزیابی روش پیشنهادی مقادیر خطای j و E_j و $ERROR$ محاسبه را کنید.

۳- مثال های عددی

برای نشان دادن روش پیشنهادی مثال های زیر تجزیه و تحلیل می شوند.

مثال ۱: جدول ۱ مقادیر مشاهده شده $(x_j, a_j, \beta_j), j = 1, \dots, 5$ که از $[23]$ گرفته شده اند را نشان می دهد. x_j یک متغیر مستقل و (a_{y_j}, β_{y_j}) یک متغیر فازی مثلثی وابسته با مرکز a_{y_j} و پهنهای β_{y_j} می باشد. ساختار مدل پیشنهادی برای یک ورودی و یک خروجی با برنامه نویسی در نرم افزار متلب طراحی می شود. توابع عضویت مختلف را امتحان کرده و به دلیل اینکه تابع عضویت نرمال کمترین خطای در برآورد را ایجاد می کند، برای ایجاد وزن های فازی انتخاب می شود. مقادیر (x_j, a_j, β_j) را با روش انفیس آموزش داده و زمانی که خطای به یک مقدار ثابت رسید (شکل ۳ را مشاهده کنید) پارامترهای اولیه به دست آمده را در رابطه (26) قرار می دهیم و پارامترهای ثانویه را با استفاده از روش برنامه ریزی خطی محاسبه نموده و سپس با قرار دادن پارامترهای اولیه و ثانویه به دست آمده در روابط (28) مرکز و پهنهای خروجی ها را محاسبه می کنیم. جدول ۱، مقادیر پارامترهای اولیه و ثانویه به دست آمده را نشان می دهد.

همچنین دو روش برنامه‌ریزی خطی و مربعی برای برآشاندن مدل رگرسیونی بکار گرفته می‌شوند. برای ارزیابی روش‌ها، مقادیر خطای E_j و $ERROR$ محاسبه می‌گردند. در برآورد دارد.

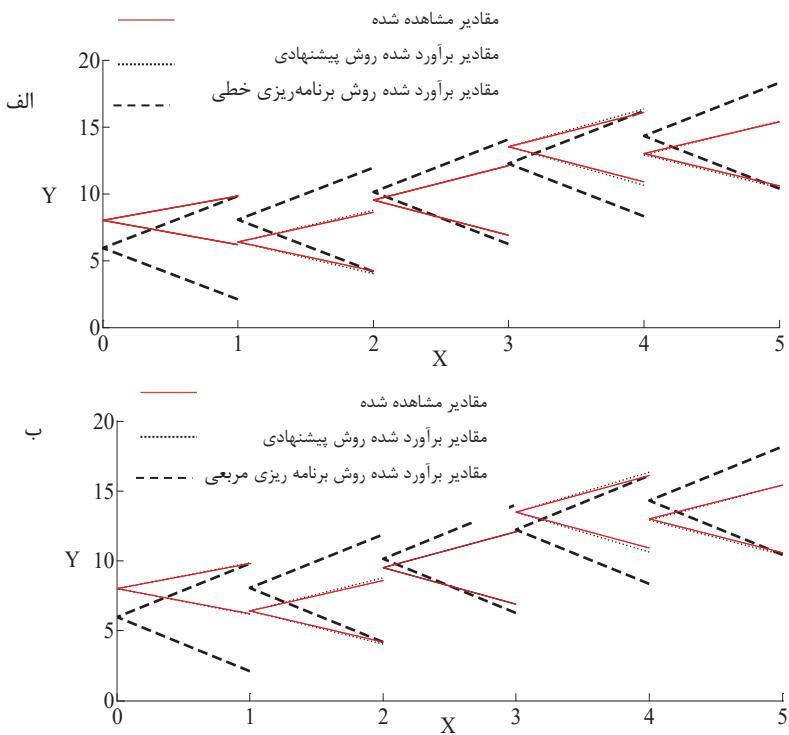
جدول (۱): مقادیر پارامترهای اولیه و ثانویه به دست آمده در روش پیشنهادی برای مثال ۱.

شماره گره	پارامترهای اولیه	پارامترهای ثانویه	پارامترهای اولیه	پارامترهای ثانویه
k	(τ_k, σ_k)	(b_1^k, α_1^k)	$(b_{\circ}^k, \alpha_{\circ}^k)$	(b_1^k, α_1^k)
۱	$(0/8006, 0/5167)$	$(4/6526, 0/9917)$	$(3/0.5741/8376)$	
۲	$(3/0.824, 0/7944)$	$(-2/5611, 1/7770)$	$(4/0.201, 0/2744)$	
۳	$(5/2558, 0/3846)$	$(3/8357, 1/0650)$	$(1/7545, 0/2774)$	

جدول (۲): نتایج رگرسیونی به دست آمده با استفاده از روش پیشنهادی و روش‌های برنامه‌ریزی خطی و مربعی برای مثال ۱.

روش برنامه-ریزی مربعی	روش برنامه-ریزی خطی	روش پیشنهادی	(a_j, β_j)	x_j
$(5/9587, 3/8413)$	$(5/9582, 3/8620)$	$(7/1, 997/8368)$	$(8/0, 1/8)$	۱
$(8/0500, 3/8500)$	$(8/0539, 3/8838)$	$(6/4020, 2/3759)$	$(6/4, 2/2)$	۲
$(10/1413, 3/8587)$	$(10/1496, 3/9055)$	$(9/4999, 2/6003)$	$(9/5, 2/6)$	۳
$(12/2327, 3/8673)$	$(12/22453, 3/9273)$	$(13/4946, 2/8681)$	$(13/5, 2/6)$	۴
$(14/3240, 3/8760)$	$(14/3410, 3/9490)$	$(12/9210, 2/4962)$	$(13/0, 2/4)$	۵
$11/2994$	$11/6004$	$0/0491$	$ERROR$	

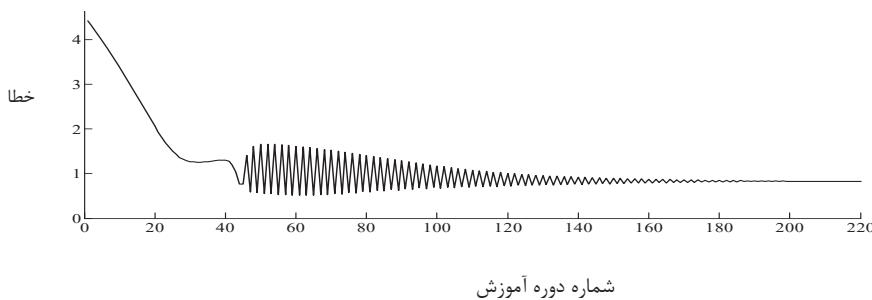
جدول ۲ و ۳ و شکل ۲، نتایج رگرسیونی به دست آمده از روش‌های مختلف را نشان می‌دهند. همانطور که در جدول ۲ و شکل ۲ دیده می‌شود، تفاوت قابل ملاحظه‌ای بین مقادیر برآورد شده و مقادیر مشاهده شده با روش پیشنهادی وجود ندارد. همچنین از نتایج به دست آمده در جدول ۲ و ۳ دیده می‌شود مقادیر خطای E_j و $ERROR$ روش پیشنهادی کم می‌باشد که نشان می‌دهد روش پیشنهادی تمایل به ایجاد مقادیر برآورد شده نزدیک به مقادیر مشاهده شده دارد. همچنین دقت قابل ملاحظه‌ای در برآورد دارد.



شکل (۲): نتایج رگرسیونی به دست آمده برای مثال یک با استفاده از روش‌های مختلف (الف) برنامه‌ریزی خطی و روش پیشنهادی (ب) برنامه‌ریزی مربعی و روش پیشنهادی.

جدول (۳): مقادیر خطای E_j برای مثال ۱.

x_j	روش پیشنهادی	روش برنامه‌ریزی خطی	روش برنامه‌ریزی مربعی	روش برنامه‌ریزی
۱	۰/۰۳۶۸	۳/۳۴۷۵	۳/۳۴۴۰	۲/۸۵۰۰
۲	۰/۱۷۵۶	۲/۸۵۸۷	۲/۸۵۰۰	۱/۵۲۱۸
۳	۰/۰۰۰۳	۱/۵۶۳۹	۱/۵۲۱۸	۲/۲۸۶۲
۴	۰/۲۶۸۲	۲/۲۷۲۲	۲/۲۸۶۲	۲/۳۸۴۳
۵	۰/۱۵۹۸	۲/۴۲۶۷	۲/۳۸۴۳	۱۲/۳۸۶۳
Total error E_j	۰/۶۴۰۸	۱۲/۴۶۹۰	۱۲/۳۸۶۳	



شکل (۳): رفتار همگرایی روش پیشنهادی برای مثال ۱.

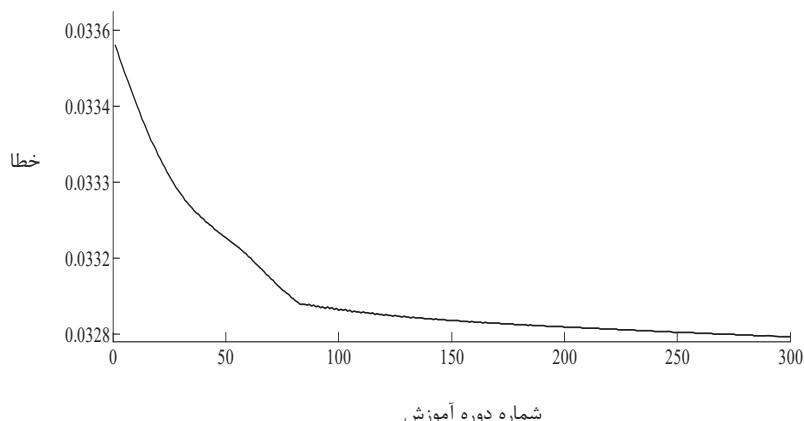
مثال ۲ (ناپارامتری): مجموعه داده شده در جدول ۵ از [۹] گرفته شده است. x_j یک متغیر مستقل و $(Y_j = (a_{y_j}, \beta_{y_j}))$ ، یک متغیر فازی مثلثی وابسته با مرکز a_{y_j} و پهنهای β_{y_j} می‌باشد. تابع عضویت نرمال برای ایجاد وزن‌های فازی انتخاب می‌شود. روش‌های مختلف برای برازش مدل رگرسیونی بکار گرفته می‌شوند. برای ارزیابی روش‌ها، مقادیر خطای E_j و $ERROR$ محاسبه می‌گردد. جدول ۴ مقادیر پارامترهای اولیه و متعاقب به دست آمده را نشان می‌دهد. جدول ۵ و ۶، نتایج رگرسیونی به دست آمده برای روش‌های مختلف را نشان می‌دهند. همانطور که در جدول ۵ دیده می‌شود تفاوت قابل ملاحظه‌ای بین مقادیر برآورد شده و مقادیر مشاهده شده با روش پیشنهادی وجود ندارد. همچنین از نتایج به دست آمده در جدول ۵ و ۶ مشاهده می‌شود همانند مثال قبل مقادیر E_j و $ERROR$ روش پیشنهادی کم می‌باشد بنابراین، روش پیشنهادی دقیق‌تری در پیش‌بینی در مقایسه با دو روش دیگر دارد. همچنین شکل ۴ رفتار همگرایی روش پیشنهادی را نشان می‌دهد.

جدول (۴): مقادیر پارامترهای اولیه و متعاقب به دست آمده در روش پیشنهادی برای مثال ۲

شماره گره	پارامترهای اولیه	پارامترهای ثانویه	پارامترهای ثانویه	پارامترهای اولیه
۱	(τ_k, σ_k)	$(b_{\circ}^k, \alpha_{\circ}^k)$	$(b_{\circ}^k, \alpha_{\circ}^k)$	(b_1^k, α_1^k)
۲	$(-0.5389, 1/8920)$	$(-0/0966, 0/0169)$	$(0/8100, 0/0057)$	$(3/9541, 0/0389)$
۳	$(2/6096, 1/2880)$	$(5/1757, 0/0479)$	$(-20/1908, 0/0811)$	$(1/5003, 0/0338)$

جدول (۵): نتایج رگرسیونی بدست آمده با استفاده از روش پیشنهادی و روش‌های برنامه‌ریزی خطی و مربعی برای مثال ۲.

$f(x_j) = (\hat{a}_j, \hat{\beta}_j)$	$Y_j = (a_j, \beta_j)$	x_j
روش برنامه‌ریزی خطی	روش پیشنهادی	روش برنامه‌ریزی مربعی
(۰/۲۱۰۰, ۰/۱۰۰۰)	(۰/۲۲۸۵, ۰/۱۱۸۹)	(۰/۲۷۹۴, ۰/۰۴۶۷)
(۰/۲۳۲۱, ۰/۱۱۲۱)	(۰/۲۷۳۳, ۰/۱۴۲۰)	(۰/۲۴۰۴, ۰/۰۶۰۱)
(۰/۲۵۴۱, ۰/۱۲۴۱)	(۰/۲۹۵۷, ۰/۱۵۳۶)	(۰/۲۲۷۰, ۰/۰۷۴۱)
(۰/۲۷۶۲, ۰/۱۳۶۲)	(۰/۳۱۸۱, ۰/۱۶۵۲)	(۰/۲۳۳۱, ۰/۰۸۸۳)
(۰/۲۹۸۲, ۰/۱۴۸۲)	(۰/۳۴۰۵, ۰/۱۷۶۷)	(۰/۲۵۱۳, ۰/۱۰۲۳)
(۰/۳۲۰۳, ۰/۱۶۰۳)	(۰/۳۶۲۹, ۰/۱۸۸۳)	(۰/۲۷۴۸, ۰/۱۱۵۸)
(۰/۳۴۲۴, ۰/۱۷۲۴)	(۰/۴۳۰۲, ۰/۲۲۲۹)	(۰/۲۹۸۸, ۰/۱۲۸۷)
(۰/۳۶۴۴, ۰/۱۸۴۴)	(۰/۴۵۲۶, ۰/۲۳۴۵)	(۰/۳۲۰۸, ۰/۱۴۱۱)
(۰/۳۸۶۵, ۰/۱۹۶۵)	(۰/۴۷۵۰, ۰/۲۴۶۱)	(۰/۳۳۹۹, ۰/۱۵۲۹)
(۰/۴۰۸۵, ۰/۲۰۸۵)	(۰/۴۹۷۴, ۰/۲۵۷۶)	(۰/۳۵۷۱, ۰/۱۶۴۳)
(۰/۴۳۰۶, ۰/۲۲۰۶)	(۰/۵۱۹۸, ۰/۲۶۹۲)	(۰/۳۷۳۸, ۰/۱۷۵۲)
(۰/۴۵۲۶, ۰/۲۲۲۶)	(۰/۵۴۲۲, ۰/۲۸۰۷)	(۰/۳۹۲۱, ۰/۱۸۵۷)
(۰/۴۷۴۷, ۰/۲۴۴۷)	(۰/۵۶۴۶, ۰/۲۹۲۳)	(۰/۴۱۴۱, ۰/۱۹۵۹)
(۰/۴۹۶۸, ۰/۲۵۶۸)	(۰/۵۸۷۰, ۰/۳۰۳۸)	(۰/۴۴۲۱, ۰/۲۰۵۸)
(۰/۵۱۸۸, ۰/۲۶۸۸)	(۰/۶۰۹۴, ۰/۳۱۵۴)	(۰/۴۷۷۸, ۰/۲۱۵۵)
(۰/۵۴۰۹, ۰/۲۸۰۹)	(۰/۷۰۶۱, ۰/۱۰۷۴)	(۰/۵۲۳۱, ۰/۲۲۵۰)
(۰/۵۶۲۹, ۰/۲۹۲۹)	(۰/۷۵۰۹, ۰/۱۳۰۵)	(۰/۵۷۹۴, ۰/۲۳۴۳)
(۰/۵۸۵۰, ۰/۳۰۵۰)	(۰/۷۸۵۶, ۰/۱۹۹۸)	(۰/۶۴۷۸, ۰/۲۴۳۵)
(۰/۶۰۷۱, ۰/۳۱۷۱)	(۰/۷۴۷۷, ۰/۲۱۱۴)	(۰/۶۵۰, ۰/۲۴۰)
		ERROR
۰/۰۵۳۶	۰/۰۵۴۷	۰/۰۲۲۵



شکل (۴): رفتار همگرایی روش پیشنهادی برای مثال ۲

مراجع

- [1].Zadeh, L.A. (1965). Fuzzy sets, *Information and Control*, **8**, 338-353.
- [2].Tanaka, H. Uejima, S. Asia, K. (1982). Linear regression analysis with fuzzy model, *IEEE Transactions on Systems, Man and Cybernetics*, **12**, 903-907.
- [3]. Diamond, P. (1988). Fuzzy least squares, *Information Sciences*, **46**, 141-157.
- [4].Farnoosh, R. Ghasemian, J. and Solaymani fard, O. (2012). A modification on ridge estimation for fuzzy nonparametric regression, *Iranian Journal of Fuzzy System*, **9**, 75-88.
- [5].Hong, D.H. Song, J.-K. Young, H. (2001). Fuzzy least-squares linear regression analysis using shape preserving operations, *Information Sciences*, **138**, 185-193.
- [6].Razzaghnia, T. Danesh S. and Maleki, A. (2011). Hybrid fuzzy regression with trapezoidal fuzzy data, Proc. SPIE 8349, 834921.
- [7].Razzaghnia, T. Danesh, S. (2015). Nonparametric Regression with Trapezoidal Fuzzy Data, *International Journal on Recent and Innovation Trends in Computing and Communication (IJRITCC)*, 3826 – 3831.

-
- [8].Wang, N. Zhang, W. X. Mei, C. L. (2007). Fuzzy nonparametric regression based on local linear smoothing technique, *Information Sciences*, **177**, 3882-3900.
 - [9].Tanaka, H. Ishibushi, H. (1991). Identification of possibilistic linear systems by quadratic membership functions of fuzzy parameters, *Fuzzy Sets and Systems*, **41**, 145-160.
 - [10].Tanaka, H. Lee, H. (1998). Interval regression analysis by quadratic programming approach, *IEEE Transactions on Fuzzy Systems*, **6**, 473-481.
 - [11].Cheng, C.-B. Lee, E. S. (1999). Nonparametric fuzzy regression k-NN and kernel smoothing techniques, *Computers and Mathematics with Applications*, **38**, 239-251.
 - [12].Donoso, S. Marin, N. and Amparo, V. (2006). M. Quadratic programming models for fuzzy regression, International Conference on Mathematical and Statistical Modeling in Honor of Enrique Castillo.
 - [13].Razzaghnia, T. Pasha, E. (2009). A new mathematical programming approach in fuzzy linear regression models, *J. Sci. A. U*, **18**, 50-59.
 - [14].Ishibuchi, H. Kwon, K. Tanaka, H. (1995). A learning algorithm of fuzzy neural networks with triangular fuzzy weights, *Fuzzy Sets and Systems*, **71**, 277-293.
 - [15].Ishibuchi, H. Tanaka, H. (1992). Fuzzy regression analysis using neural networks, *Fuzzy Sets and Systems*, **50**, 257-265.
 - [16].Jang. J.S.R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Trans Syst Man Cyber*, **23**, 665-685.
 - [17].Cheng, C.-B. Lee, E. S. (1999). Applying Fuzzy Adoptive Network to Fuzzy Regression Analysis, *Computers and Mathematics with Applications*, **38**, 123-140.
 - [18].Dalkilic, T. E. Apaydin, T. (2009). A fuzzy adaptive network approach to parameter estimation in cases where independent variables come from an exponential distribution, *Journal of Computational and Applied Mathematics*, **233**, 36-45.
 - [19].Dalkilic, T. E. Apaydin, T. (2014). Parameter Estimation by ANFIS in Cases Where Outputs are Non-Symmetric Fuzzy Numbers, *International Journal of Applied Science and Technology*, 92-103.

-
- [20].Danesh, S. Farnoosh, R. Razzaghnia, T. (2016). Fuzzy nonparametric regression based on adaptive neuro fuzzy inference system, *Neurocomputing*, **173**, 1450-1460.
 - [21].Jang, J.S.R. (1992). Self-learning fuzzy controllers based on temporal back-propagation, *IEEE Transactions on Neural Network*, **3**, 714-723.
 - [22].Kim, B. and Bishu, R. R. (1998). Evaluation of fuzzy linear regression models by comparing membership functions, *Fuzzy Sets and Systems*, **100**, 343-351.
 - [23].Tanaka, H., Hayashi, I., Watada, J. (1989). Possibilistic linear regression analysis for fuzzy data. *European Journal of Operational Research*, **40**, 389-396.

Fuzzy Parameter Estimation via Fuzzy Weights and Linear Programming

Sedigheh Danesh *, Rahman Farnoosh **, Tahereh Razzaghnia ***

*Department of Statistics, Science and Research Branch, Islamic Azad University, Tehran, Iran

**School of Mathematics, Iran University of Science and Technology, Tehran, Iran

***Department of Statistics, Roudehen Branch, Islamic Azad University, Roudehen, Iran

Abstract

Fuzzy regression represents the relation between variables. Fuzzy regression analysis is one of the most widely used statistical techniques. In this study, fuzzy regression is considered with the crisp input and the fuzzy output. A hybrid algorithm based on fuzzy weights and linear programming is designed for the fuzzy nonparametric regression model prediction that function form is assumed unknown and in cases low data. In proposed method, the objective function minimizes the spread of outputs. Finally, the performance of the suggested method is compared with linear programming (LP) and quadratic programming (QP) methods using the numerical examples. The results demonstrate that the proposed method has more accurate than the LP and QP methods. Also, it is verified in cases of low data.

Keywords: Fuzzy regression; Linear programming; Quadratic programming; Adaptive neuro fuzzy inference system

Mathematics Subject Classification (2010): 92B20, 62J86
