

# رویکردی نوین در مدل‌سازی شبکه عصبی مصنوعی بر اساس منطق رگرسیون فازی و کاربرد آن در پیش‌بینی (مورد کاوی: پیش‌بینی قیمت گاز مایع ژاپن)

سیدعلی ترابی<sup>۱</sup>، شیما پاشاپورعلی نظری<sup>۲\*</sup> و نجمه نشاط<sup>۳</sup>

<sup>۱</sup> دانشیار دانشکده مهندسی صنایع - پردیس دانشکده‌های فنی - دانشگاه تهران

<sup>۲</sup> فارغ التحصیل کارشناسی ارشد مهندسی صنایع - پردیس دانشکده‌های فنی - دانشگاه تهران

<sup>۳</sup> دانشجوی دکترای مهندسی صنایع - دانشگاه تربیت مدرس

(تاریخ دریافت ۹۱/۲/۱۶، تاریخ دریافت روایت اصلاح‌شده ۹۱/۴/۱۷، تاریخ تصویب ۹۲/۱/۲۴)

## چکیده

در این مقاله، یک رویکرد جدید مدل‌سازی برای مدل‌های شبکه عصبی مصنوعی بر مبنای مفاهیم شبکه‌های عصبی و رگرسیون فازی ارائه شده است. به این منظور، مدل شبکه عصبی مصنوعی در قالب یک مدل رگرسیون غیرخطی فازی فرموله شده است، به نحوی که این مدل، مزایای هر دو مدل رگرسیون فازی و شبکه عصبی مصنوعی را دارد. بنابراین، این مدل به دلیل انعطاف‌پذیری بالا، قابلیت استفاده در شرایط نبود قطعیت، مبهم یا پیچیده را دارد. علاوه بر این، مطالعه موردی پیش‌بینی قیمت گاز مایع در بازار ژاپن (بزرگ‌ترین واردکننده گاز طبیعی جهان) برای نشان دادن نحوه استفاده از این رویکرد ارائه شده است. نتایج به دست آمده نشان می‌دهد که قدرت پیش‌بینی مدل ارائه شده قابل قبول است. علاوه بر این، در شرایط غیرقطعی و پیچیده می‌تواند بر خلاف مدل‌های شبکه عصبی، اطلاعات شفافی از روابط موجود بین متغیرهای ورودی و پاسخ مدل به تصمیم‌گیرنده ارائه دهد.

**واژه‌های کلیدی:** شبکه‌های عصبی مصنوعی، رگرسیون فازی، مدل‌سازی قیمت گاز طبیعی

## مقدمه

را برای حل مسائل در شرایط نبود قطعیت، ادغام کرده‌اند. در این رویکرد، رگرسیون برداری، پشتیبان مزیت بهینه-سازی عمومی را در طراحی شبکه عصبی فازی فراهم می‌کند. نتایج به دست آمده نشان‌دهنده این مسئله است که روش شبکه عصبی فازی- رگرسیون برداری پشتیبان<sup>۳</sup>، می‌تواند به صورت اتوماتیک، قوانین فازی را تولید کند و با کاهش قابل ملاحظه توابع اصلی فازی در تقریب، عملکرد خوبی ارائه دهد.

به طور مشابه، چیافنگ جوانگ و همکاران [۲]، چیافنگ جوانگ و چنگ دا [۳] یک مدل بازگشتی جدید ارائه کردند که به عنوان مدل بازگشتی محلی شبکه عصبی فازی با رگرسیون برداری پشتیبان شناخته شده است. در این مقاله، نویسندگان، یادگیری عصبی را برای آموزش پارامترهای شبکه به کار بردند. هدف این رویکرد، مینیمم کردن خطای یادگیری توسط الگوریتم رگرسیون برداری پشتیبان است. مقایسه نتایج حاصل از شبیه‌سازی مدل ارائه‌شده با مدل‌های شبکه عصبی فازی بازگشتی،

در دنیای امروز، ارائه مدل‌های کمی برای اهداف پیش‌بینی در بازارها که منجر به سرمایه‌گذاری‌ها و تصمیمات بهبودیافته می‌شود، مسئله‌ای اساسی است. شبکه‌های عصبی مصنوعی به عنوان یک رویکرد شناخته شده، به طور وسیعی در مسائل پیش‌بینی مورد استفاده قرار می‌گیرد.

در ادبیات مربوطه، تلاش‌های زیادی در زمینه مدل‌سازی داده‌های رگرسیون فازی با به کار بردن رویکرد شبکه عصبی مصنوعی انجام شده است. به این منظور، شبکه‌های عصبی فازی<sup>۱</sup> توسعه یافته و اغلب با تکنیک‌های دیگر ادغام شده است تا جایگزین مناسبی برای رویکردهای رگرسیون فازی ارائه کند. با این وجود، نبود مزایای مدل‌های رگرسیونی در این رویکردها محسوس است. از جمله می‌توان به کار چین تنگ و همکاران [۱] اشاره کرد که توانایی و دقت بالای رگرسیون برداری پشتیبان<sup>۲</sup> و قدرت استدلال‌گری کارای شبکه عصبی فازی

مدل‌های شبکه عصبی) و قابلیت کشف روابط موجود بین متغیرهای ورودی و پاسخ یک مدل را همانند مدل‌های کلاسیک دارد. همچنین مزایای هر دو مدل شبکه‌های عصبی و رگرسیون فازی را نیز دارد، به نحوی که کاستی‌های ذکر شده آنها را بر طرف کند. ویژگی‌های منحصر به فردی که این مدل دارد، از ترکیب شبکه عصبی مصنوعی با رگرسیون فازی ناشی می‌شود. بنابراین، به دلیل انعطاف‌پذیری بالایی که دارد، در شرایط نبود قطعیت، مبهم و پیچیده قابل استفاده است.

آنچه که در ادامه مقاله می‌آید به این شرح سازماندهی شده است: بخش دوم، رویکرد مدل‌سازی پیشنهادی را معرفی می‌کند و بخش سوم، اختصاص به مطالعه موردی دارد. نتیجه‌گیری و ملاحظات پایانی در بخش چهارم ارائه شده‌اند. در ادامه این بخش، تکنیک‌هایی که در مدل پیشنهادی گنجانده شده‌اند، توضیح داده شده‌اند. بخش ۱،۱ مدل‌های رگرسیون فازی و بخش ۱،۲ مدل‌های شبکه عصبی را معرفی می‌کنند.

## مدل‌های رگرسیون فازی

فرض کنید  $x_{mn}$  و  $y_m$  به ترتیب  $m$ امین متغیر غیر وابسته و متغیر وابسته در یک مدل رگرسیون فازی باشد. در مورد مشاهده  $m$ ام،  $\beta_i$  پارامتر مربوط به  $m$ امین متغیر غیروابسته و  $\varepsilon_m$  جمله خطای مربوط به  $m$ امین مشاهده است و مدل رگرسیون کلاسیک به صورت زیر قابل بیان است:

$$y_m = \beta_0 + \beta_1 x_{m1} + \dots + \beta_n x_{mn} + \varepsilon_m, m = 1, 2, \dots, k \quad (1)$$

پارامتر رگرسیون  $\beta_i$  اغلب از طریق داده‌های نمونه، قابل محاسبه است. اگر  $\beta_i$  به صورت غیرقطعی تخمین زده شود، در رگرسیون فازی به شکل زیر نشان داده می‌شود:

$$\tilde{Y} = \tilde{\beta}_0 + \tilde{\beta}_1 X_1 + \dots + \tilde{\beta}_n X_n = \sum_{i=0}^n \tilde{\beta}_i X_i = X' \tilde{\beta} \quad (2)$$

به طوری که  $\tilde{Y}$  خروجی فازی،  $X' = [X_1, X_2, \dots, X_n]^T$  بردار ورودی حقیقی و  $\tilde{\beta} = \{\tilde{\beta}_0, \tilde{\beta}_1, \dots, \tilde{\beta}_n\}$  مجموعه‌ای از اعداد فازی است که مایل به پیدا کردن آنها بر اساس تعدادی از معیارهای مناسب برازش هستیم و  $\tilde{\beta}_i$  ها اعداد فازی مثلی به این ترتیب هستند:

حاکمی از بهبود عملکرد در صورت استفاده از این مدل است.

به علاوه توسعه شبکه‌های عصبی مصنوعی ساده به شبکه‌های عصبی مصنوعی غیرمتقارن<sup>۴</sup> (مصلح و همکاران [۴]) و شبکه‌های عصبی رگرسیونی عمومی بر مبنای فازی<sup>۵</sup> برای کنترل سرعت مکش موتور (نوغونداری و رشیدی [۵]) را در میان کارهای انجام‌شده می‌توان یافت. به تازگی، مدلی ترکیبی از شبکه‌های عصبی مصنوعی و رگرسیون فازی برای پیش‌بینی سری‌های زمانی توسط خاشعی و همکاران [۶] ارائه شده است. مولفینیک مدل شبکه عصبی مصنوعی را به صورت مدل سری‌های زمانی فرمول‌بندی کردند، به نحوی که در شرایط وجود داده‌های ناقص و نیز زمانی که داده‌های تاریخی در دسترس نباشند، قابل استفاده است.

در یک جمع‌بندی کلی، می‌توان گفت شبکه‌های عصبی، مثال‌هایی از رویکردهای رگرسیون انعطاف‌پذیر هستند، اما تفاوت‌های اساسی با تکنیک‌های کلاسیک (پارامتریک) دارند که از جمله می‌توان به این موارد اشاره کرد: (۱) هیچ فرض اولیه‌ای در رابطه با شکل مدل در روند ساخت مدل مورد نیاز نیست. جواب‌هایی که برای مدل‌سازی روابط غیرخطی پیچیده فراهم می‌کنند، بهتر از مدل‌های پارامتریک هستند (۳) توانایی زیادی در برخورد با مسائلی که شامل روابط غیرخطی بین متغیرها هستند، از خود نشان می‌دهند. با این وجود، شبکه‌های عصبی، توانایی حل مسائلی که در شرایط نبود قطعیت تعریف می‌شوند را ندارند و به عنوان تکنیک‌های جعبه سیاه شناخته می‌شوند. شرایط نبود قطعیت اغلب در خلال توسعه سریع تکنولوژی‌های جدید، داده‌های غیردقیق و ناکافی و نیز نبود اطمینان از کفایت متغیرهای مستقل تعریف‌شده به وجود می‌آیند. بنابراین همواره لازم است که وضعیت بعدی در شرایط نبود قطعیت و مبهم پیش‌بینی شود. مدل‌های رگرسیون فازی، مدل‌های مناسبی در این-گونه موارد هستند. با این وجود، توانایی نگاشت توابع با رفتار غیرخطی را ندارند.

با توجه به آنچه ذکر شد، در این مقاله مراحل بازنویسی روابط بین متغیرهای ورودی و خروجی یک مدل شبکه عصبی، در قالب یک رگرسیون غیرخطی فازی، تشریح می‌شود. این مدل، توانایی حل مسائل در شرایط نبود قطعیت و نگاشت توابع غیرخطی (همانند یک

که در آن  $w_{i,q}$  ( $i = 1, 2, \dots, n; q = 1, 2, 3, \dots, Q$ ) و  $w_q$  ( $q = 0, 1, 2, \dots, Q$ ) پارامترهای مدل هستند که اغلب وزن های رابطه نامیده می شوند،  $n$  تعداد گره های ورودی،  $X_{mq} = g(w_{0,q} + \sum_{i=1}^n w_{i,q} \cdot x_{mi})$ ،  $Q$  تعداد گره های مخفی و  $f$  و  $g$  توابع انتقال هستند که اغلب به صورت تابع لجستیک مورد استفاده قرار می گیرند. می توان مشاهده کرد که طبق فرمول نویسی رابطه (۶) شبکه عصبی را می توان معادل با یک رگرسیون چندگانه غیرخطی دانست. در عمل، شبکه ای با یک لایه مخفی که شامل تعداد کمی گره های مخفی است، بدون در نظر گرفتن نوع نمونه، به خوبی توانایی پیش بینی را دارد. البته باید دقت داشت که ممکن است این موضوع به دلیل برازش بیش از حد برای یک نمونه خاص باشد، در حالی که قابلیت تعمیم برای داده های خارج از نمونه را ندارد. (خاشعی و همکاران [۶]).

برای بهبود عملکرد شبکه های عصبی مصنوعی، اغلب از تعدادی رویکردهای داده کاوی در روند یادگیری شبکه استفاده می شود. از جمله این رویکردها، روش های داده کاوی پویا، چندگانه، هرس، هرس جامع و همچنین شبکه های شامل توابع شعاعی<sup>۶</sup> است. (هیسکین [۸]).

### فرمول بندی پیشنهادی

در این بخش، مراحل فرمول بندی مدل شبکه عصبی مصنوعی به صورت مدل رگرسیون غیرخطی فازی که قادر به حل مسائلی در شرایط نبود قطعیت و غیرخطی است را شرح می دهیم. این مدل، هم مزایای شبکه های عصبی مصنوعی و هم مزایای رگرسیون فازی را دارد. با این ویژگی که کمبودهای ذکر شده در این دو رویکرد را کاهش می دهد.

مراحل این روش در زیر خلاصه شده اند:

مرحله ۱:

پارامترهای معین  $w_{i,q}$  ( $i = 0, \dots, n; q = 1, \dots, Q$ ) را با پارامترهای فازی به فرم اعداد فازی مثلثی  $\tilde{w}_q$  ( $q = 0, \dots, Q$ ) و  $\tilde{w}_{i,q}$  ( $i = 0, \dots, n; q = 1, \dots, Q$ ) مطابق معادله (۲) جایگزین کنید:

$$\mu_{\tilde{\beta}_i} = \begin{cases} 1 - \frac{|\alpha_i - \beta_i|}{c_i} & \text{if } \alpha_i - c_i \leq \beta_i \leq \alpha_i + c_i \\ 0 & \text{Otherwise} \end{cases} \quad (3)$$

که  $\mu_{\tilde{\beta}_i}$  تابع عضویت  $\tilde{\beta}_i$ ،  $\alpha_i$  مرکز آن و  $c_i$  نشان دهنده پراکندگی عدد فازی حول مرکز است. بر اساس اصل توسعه فازی، تابع عضویت اعداد فازی با استفاده از پارامتر فازی  $\tilde{\beta}_i$  به صورت زیر قابل بیان است (خاشعی و همکاران [۶]):

$$\mu_{\tilde{\beta}_i} = \begin{cases} 1 - \frac{|Y_m - X_m \cdot \alpha|}{c' |X_m|} & \text{for } X_m \neq 0 \\ 1 & \text{for } X_m = 0, Y_m = 0 \\ 0 & \text{for } X_m = 0, Y_m \neq 0 \end{cases} \quad (4)$$

مسئله پیدا کردن  $\tilde{\beta}_i$  به صورت مسئله برنامه ریزی خطی توسط تاناکا و ایشی بوچی [۷] به این ترتیب ارائه شده است:

$$\begin{aligned} \text{Minimize } S &= \sum_{m=1}^k c' |X_m| \\ \text{Subject to } &\begin{cases} X'_m \cdot \alpha + (1-h)c' |X_m| \geq Y_m \\ X'_m \cdot \alpha - (1-h)c' |X_m| \leq Y_m \\ c \geq 0 \end{cases} \end{aligned} \quad (5)$$

که در آن تابع هدف، مینیمم کردن پراکندگی کلی  $S$  است که به صورت مجموع پراکندگی های پارامترهای فازی مدل تعریف می شود.  $k$  تعداد مشاهدات و  $h$  مرز تابع عضویت  $\tilde{Y}$  است.

### مدل های شبکه عصبی

مدل های شبکه عصبی، مجموعه ای از مدل های غیرخطی انعطاف پذیر هستند که قادر به کشف الگوهای موجود در داده ها هستند. در واقع این سیستم ها، در خلال پردازش داده های تجربی، اطلاعات و یا قوانین پنهان در داده ها را به ساختار شبکه منتقل می کنند. این مدل ها می توانند آینده یک رویداد را با استفاده از داده های تاریخی آن، پیش بینی کنند.

رابطه بین خروجی  $y_m$  و ورودی های  $x_{m1}, x_{m2}, \dots, x_{mn}$  به صورت فرمول ریاضی زیر قابل ارائه است:

$$\begin{aligned} y_m &= f \left( w_0 + \sum_{q=1}^Q w_q \cdot g(w_{0,q}) + \sum_{i=1}^n w_{i,q} \cdot x_{mi} \right) + \varepsilon_m \\ &= f \left( w_0 + \sum_{q=1}^Q w_q \cdot X_{mq} \right) = f \left( \sum_{q=0}^Q w_q \cdot X_{mq} \right) \end{aligned} \quad (6)$$

$$= \begin{cases} \frac{X_{mq} - \sum_{i=0}^n a_{iq} \cdot x_i}{\sum_{i=0}^n b_{iq} \cdot x_i - \sum_{i=0}^n a_{iq} \cdot x_i} & \text{if } \sum_{i=0}^n a_{iq} \cdot x_i \leq X_{mq} \leq \sum_{i=0}^n b_{iq} \cdot x_i \\ \frac{X_{mq} - \sum_{i=0}^n c_{iq} \cdot x_i}{\sum_{i=0}^n b_{iq} \cdot x_i - \sum_{i=0}^n c_{iq} \cdot x_i} & \text{if } \sum_{i=0}^n b_{iq} \cdot x_i \leq X_{mq} \leq \sum_{i=0}^n c_{iq} \cdot x_i \\ 0 & \text{Otherwise} \end{cases} \quad (11)$$

$$\mu_{y_m} = \begin{cases} 1 - \frac{|y_m - \sum_{q=0}^Q e_q \cdot X_{mq}|}{\sum_{q=0}^Q c_q \cdot |X_{mq}|} & \text{for } X_{mq} \neq 0 \\ 0 & \text{Otherwise} \end{cases} \quad (12)$$

مرحله ۵:

سرانجام، برای تشکیل مسئله برنامه‌ریزی خطی، از معیار مینیمم‌سازی پراکندگی کل (مجموع پراکندگی‌های هر یک از پارامترهای فازی) مطابق رابطه (۵) استفاده کنید و با حل مسئله، مقادیر بهینه متغیرهای تصمیم  $(e_q, d_q)$  را به دست آورید:

$$\text{Minimize } S = \sum_{m=1}^k \sum_{q=0}^Q (e_q - d_q) \cdot |X_{mq}| \quad (13)$$

$$\sum_{q=0}^Q e_q \cdot X_{mq} + (1-h) \left( \sum_{q=0}^Q (e_q - d_q) \cdot |X_{mq}| \right) \geq y_m, \quad m = 1, 2, \dots, k$$

$$\sum_{q=0}^Q e_q \cdot X_{mq} - (1-h) \left( \sum_{q=0}^Q (e_q - d_q) \cdot |X_{mq}| \right) \leq y_m, \quad q = 1, 2, \dots, Q$$

## مطالعه موردی

این روزها، گاز طبیعی به عنوان سوختی تمیز که مانع از افزایش تولید گازهای گلخانه‌ای می‌شود، در میان سوخت‌های فسیلی دیگر جهان (بخصوص در کشورهای عضو پیمان کیوتو) جایگاه خاصی به دست آورده است. رشد سریع تقاضا برای گاز سبب شده است که بازار گاز از بازار خریداران به بازار فروشندگان تبدیل شود. همین موضوع قیمت گاز را بسیار پراهمیت کرده است. بنابراین، مطالعه و پیش‌بینی قیمت‌های فروش گاز بر اساس داده‌های واقعی و اطلاعات بازار و نیز با استفاده از رویکردهای مدل‌سازی و پیش‌بینی کارا، اجتناب‌ناپذیر است.

در موضوع ادبیات، مطالعه‌های زیادی روی پیش‌بینی قیمت گاز انجام شده است. اغلب مطالعه‌های اخیر نشان داده‌اند که رویکرد شبکه‌های عصبی مصنوعی در مقایسه با رویکردهای اقتصادسنجی و رگرسیون خطی، به دلیل ماهیت غیرخطی و پیچیده قیمت گاز، کارا تر است. دوریس و رویتز [۱۰] برتری مدل شبکه عصبی مصنوعی خود رگرسیونی در مقایسه با یک مدل اقتصادی که شامل

$$\tilde{y}_m = f \left( \tilde{w}_0 + \sum_{q=1}^Q \tilde{w}_q \cdot g(\tilde{w}_{0,q} + \sum_{i=1}^n \tilde{w}_{i,q} \cdot x_{mi}) \right) + \varepsilon_m \quad (7)$$

$$= f \left( \tilde{w}_0 + \sum_{q=1}^Q \tilde{w}_q \cdot \tilde{X}_{mq} \right) = f \left( \sum_{q=0}^Q \tilde{w}_q \cdot \tilde{X}_{mq} \right)$$

مرحله ۲:

تابع عضویت پارامترهای فازی  $(a_{iq}, b_{iq}, c_{iq})$  و  $\tilde{w}_{i,q} = (d_q, e_q, f_q)$  به فرم اعداد فازی مثلثی که به ترتیب در رابطه‌های (۸) و (۹) نشان داده شده است را تعیین کنید:

$$\mu_{\tilde{w}_{i,q}} = \begin{cases} \frac{(w_{iq} - a_{iq})}{(b_{iq} - a_{iq})} & \text{if } a_{iq} \leq w_{iq} \leq b_{iq} \\ \frac{(w_{iq} - c_{iq})}{(b_{iq} - c_{iq})} & \text{if } b_{iq} \leq w_{iq} \leq c_{iq} \\ 0 & \text{Otherwise} \end{cases} \quad (8)$$

$$\mu_{\tilde{w}_q} = \begin{cases} \frac{(w_q - a_q)}{(b_q - a_q)} & \text{if } a_q \leq w_q \leq b_q \\ \frac{(w_q - c_q)}{(b_q - c_q)} & \text{if } b_q \leq w_q \leq c_q \\ 0 & \text{Otherwise} \end{cases} \quad (9)$$

مرحله ۳:

تابع عضویت  $\tilde{X}_{mq}$  بر اساس  $(i = 0, 1, 2, \dots, n)$  و  $\mu_{\tilde{w}_q}$  ( $q = 0, 1, 2, \dots, Q$ ) استفاده از اصل توسعه فازی (ما و خراسانی [۹]) همانند رابطه (۵) را به دست آورید:

$$\mu_{\tilde{X}_{mq}} = \begin{cases} \frac{X_{mq} - \sum_{i=0}^n a_{iq} \cdot x_i}{\sum_{i=0}^n b_{iq} \cdot x_i - \sum_{i=0}^n a_{iq} \cdot x_i} & \text{if } \sum_{i=0}^n a_{iq} \cdot x_i \leq X_{mq} \leq \sum_{i=0}^n b_{iq} \cdot x_i \\ \frac{X_{mq} - \sum_{i=0}^n c_{iq} \cdot x_i}{\sum_{i=0}^n b_{iq} \cdot x_i - \sum_{i=0}^n c_{iq} \cdot x_i} & \text{if } \sum_{i=0}^n b_{iq} \cdot x_i \leq X_{mq} \leq \sum_{i=0}^n c_{iq} \cdot x_i \\ 0 & \text{Otherwise} \end{cases} \quad (10)$$

باید توجه کرد که برای سادگی توابع انتقال  $(f)$  و  $(g)$ ، توابع ساتلین و وزن‌های مربوط بین ورودی‌ها و لایه پنهانی، اعداد قطعی در نظر گرفته می‌شوند.

مرحله ۴:

همانند مرحله ۳، تابع عضویت  $\tilde{y}_m$  در رابطه (۱۱) داده شده است. با در نظر گرفتن رابطه (۴) آن را تصحیح و به فرم رابطه (۱۲) بازنویسی کنید:

برای تخمین وزن‌های مربوط به مدل شبکه عصبی مصنوعی، پنج رویکرد داده‌کاوی پویا<sup>۱۱</sup>، چندگانه<sup>۱۲</sup>، هرس<sup>۱۳</sup>، هرس کامل<sup>۱۴</sup> و شبکه‌های شامل توابع شعاعی<sup>۱۵</sup> استفاده شده است. برای به دست آوردن بهترین ساختار شبکه، از جعبه ابزار Neuro Solution نرم‌افزار مطلب استفاده می‌شود. شبکه‌های مختلف شامل یک تا سه لایه پنهانی، تعداد مختلف از نرون‌ها در لایه‌های پنهانی و توابع فعال‌سازی مختلف، امتحان شدند. سرانجام شبکه‌ای با کم‌ترین خطای میانگین مربعات<sup>۱۶</sup>، برای هر رویکرد، به عنوان شبکه بهینه انتخاب شده است.

باید ذکر کرد شرایط لازم برای خاتمه مرحله یادگیری، دستیابی به مقدار  $1e-005$  برای کم‌ترین خطای میانگین مربعات، ۲۰۰ برای ماکزیمم تعداد هر دوره و  $1e-010$  برای مینیمم مقدار شیب خطا برای هر دوره است. نتایج شاخص‌های خطای درصد میانگین مطلق<sup>۱۷</sup>، ریشه میانگین مربعات خطا<sup>۱۸</sup>، کسر مطلق از واریانس<sup>۱۹</sup> برای پنج شبکه در جدول (۲) آمده است که خطای درصد میانگین مطلق، میانگین نسبت خطا به مقادیر واقعی را نشان می‌دهد و به این شکل است:

$$MAPE (\%) = \frac{1}{m} \sum_{i=1}^m \left| 100 \frac{(y_i - \hat{y}_i)}{y_i} \right| \quad (14)$$

که  $\hat{y}_i$  مقدار پیش‌بینی شده توسط مدل شبکه عصبی مصنوعی،  $y_i$  مقدار واقعی و  $m$  تعداد داده‌ها است. ریشه میانگین مربعات خطا به صورت زیر محاسبه می‌شود:

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (15)$$

در آخر،  $R^2$  یک معیار آماری که می‌تواند برای تحلیل چندگانه استفاده شود، به شکل زیر قابل محاسبه است:

$$R^2 = 1 - \frac{\sum_{i=1}^m (y_i - \hat{y}_i)^2}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (16)$$

متغیر تأخیر زمانی کوتاه‌مدت (روزانه) در پیش‌بینی قیمت گاز است را نشان می‌دهند.


گابریل وونک پارادو و همکاران [۱۱] دو مدل اقتصادی برای پیش‌بینی قیمت گاز طبیعی را با یکدیگر مقایسه کردند. مدل اول بر اساس داده‌های جمع‌آوری شده از «آژانس بین‌المللی انرژی»<sup>۷</sup> و مدل دوم بر پایه اطلاعات نفت خام جمع‌آوری شده ایالات متحده ساخته شده است. نویسندگان تصریح کردند که هیچ یک از این دو مدل، کارایی قابل توجهی ندارند و ضریب هم‌بستگی‌شان از ۲۰٪ تجاوز نمی‌کند. به تازگی، در مقاله‌های منتشر شده توسط نابنی و انگوین [۱۲] از مدل شبکه عصبی مصنوعی، مدل خودرگرسیون GARCH<sup>۸</sup>، مدل سری‌های زمانی و مدل رگرسیون چندگانه برای پیش‌بینی قیمت ماهانه گاز در بازار ایرلند استفاده شده است. کارکرد این مدل‌ها در چهار حالت ارزیابی شده است. این چهار حالت عبارتند از ثابت، انطباقی (تنظیم پارامترهای مدل با استفاده از EKF: فیلترکالمن توسعه یافته) اصلی، چند جزئی (استفاده از تکنیک RHWT)<sup>۹</sup>. نتایج این مطالعه نشان‌دهنده برتری مدل شبکه عصبی نسبت به مدل خودرگرسیون GARCH در همه حالات است.

در این مقاله، تابع قیمت LNG<sup>۱۰</sup> بازار ژاپن (به عنوان بزرگ‌ترین وارد کننده LNG جهان و یکی از سه بازار بزرگ جهان) برای آزمون رویکرد پیشنهادی، انتخاب شده است. غیرخطی و پیچیده بودن تابع قیمت LNG و اطمینان نداشتن از کفایت داده‌ها و متغیرهای مؤثر شناسایی شده، پیش‌بینی قیمت LNG را تبدیل به گزینه مناسبی برای بررسی کرده است.

طبق ادبیات مربوطه (فیون [۱۳]، دوپیس-دنيس [۱۴]، الهگارت و همکاران [۱۵]، ویلار و جوتز [۱۶]، طباطبایی [۱۷])، ۱۵ متغیر مستقیم و غیرمستقیم (کمکی)، مؤثر بر پیش‌بینی قیمت LNG تشخیص داده شده‌اند که در جدول (۱) آمده است (همراه با اطلاعات آماری آنها). داده‌های مربوطه از سال ۱۹۹۸ تا فوریه ۲۰۱۰ به طور ماهانه از کنسرسیوم بین‌المللی انرژی جمع‌آوری شده است. داده‌های مربوط به سال‌های ۱۹۹۸ تا ۲۰۰۷ برای یادگیری و بقیه برای آزمایش کردن انتخاب شده‌اند. باید توجه کرد که داده‌های پرت، نادیده گرفته شده‌اند.

جدول ۱: اطلاعات آماری متغیرهای مؤثر در قیمت LNG در بازار ژاپن (سالکی، زهرا، "استفاده از داده کاوی برای پیش بینی قیمت گاز طبیعی" پایان نامه کارشناسی ارشد - دانشگاه تربیت مدرس، دانشکده فنی مهندسی، شهریور ۱۳۸۸)

متغیرهای مؤثر	واحد	مقدار میانگین	انحراف میانگین	فاصله		نرخ رشد میانگین
				مینیمم	ماکزیمم	
قیمت گاز طبیعی در بازار HentyHub	MMBtu/\$	۴,۳۳	۲,۸۱	۱,۴۱	۱۳,۷۱	۰,۱۳
قیمت گاز طبیعی در بازار BritishICE	MMBtu/\$	۴,۹۵	۲,۸۰	۱,۶۶	۱۴,۳۳	۰,۱۰
قیمت نفت WTI	MMBtu/\$	۶,۶۵	۴,۴۶	۱,۹۰	۲۳,۱۶	۰,۱۱
قیمت نفت برنت انگلیس	MMBtu/\$	۶,۴۵	۴,۴۶	۱,۷۰	۲۲,۹۶	۰,۱۲
قیمت میانگین نفت خام وارداتی ژاپن	MMBtu/\$	۶,۶۵	۴,۶۵	۱,۹۴	۲۲,۷۸	۰,۱۶
میانگین قیمت نفت عمان و دبی	MMBtu/\$	۶,۴۴	۴,۵۶	۱,۷۳	۲۲,۵۷	۰,۱۶
قیمت گاز نفت مایع (LPG)	MMBtu/\$	۶,۹۶	۳,۹۰	۲,۱۷	۱۹,۱۸	۰,۰۹
قیمت نفت کوره (۰,۱)	MMBtu/\$	۴,۶۳	۳,۰۲	۱,۴۸	۱۷,۳۷	۰,۱۱
قیمت نفت کوره (۰,۳,۵)	MMBtu/\$	۴,۰۹	۲,۸۰	۱,۳۲	۱۵,۷۹	۰,۱۰
قیمت گازولین (۰,۲)	MMBtu/\$	۷,۹۰	۵,۵۸	۲,۱۶	۲۸,۱۸	۰,۱۳
قیمت نفت کوره ۱۸۰	MMBtu/\$	۳,۹۱	۲,۷۱	۱,۰۹	۱۴,۸۹	۰,۱۲
مصرف گاز بین المللی	TCM	۰,۲۱	۰,۰۲	۰,۱۸	۰,۲۵	۰,۰۲
تولید گاز بین المللی	BCM	۰,۲۱۳	۰,۰۲۳	۰,۱۸	۰,۲۵	۰,۰۲۵
مصرف نفت بین المللی	MMbl/d	۶,۵۴۳	۰,۴۵۴	۵,۷۹	۷,۳۲	۰,۰۱۷
تولید نفت بین المللی	MMBbl/d	۶,۳۵۹	۰,۴۰۲	۵,۶۸	۷,۰۱	۰,۰۱۵



شکل ۱: ساختار شبکه مدل هرس کامل

نفت برنت انگلیس و قیمت نفت خام وارداتی ژاپن دارای ضریب همبستگی ۰,۶۷,۸ هستند، قیمت نفت برنت انگلیس حذف و متغیر سال مربوطه به مجموعه متغیرهای ورودی اضافه می شود.

همان گونه که ذکر شد، وزن ها و انحرافات ورودی، برای سادگی، اعداد قطعی فرض می شوند. برای به دست آوردن مرکز و پهنای فاصله برای وزن های پنهان ( $c_q$  و  $e_q$ ) با فرض  $d_1 = 0,5$  روش پیشنهادی به صورت مسئله برنامه-ریزی خطی در زیر آمده است.

قدر مطلق کسر واریانس بین صفر و یک تغییر می-کند. مقدار  $R^2$  به طور ایده آل برابر یک است. در حالی که در مدل های نامناسب مقدار آن نزدیک یک است.

اگر هدف، انتخاب بهترین مدل شبکه عصبی مصنوعی با تأکید همزمان بر دو اصل دقت و هزینه باشد، شبکه هرس جامع با چهار متغیر ورودی انتخاب می شود. این چهار متغیر ورودی عبارتند از: قیمت نفت برنت انگلیس، میانگین قیمت نفت عمان و دبی، قیمت گازوئیل (۰,۲) و میانگین قیمت نفت خام وارداتی ژاپن. از آنجایی که قیمت

جدول ۲: نتایج عددی شاخص های عملکرد RMSE، R2 و MAPE برای مدل های شبکه عصبی مصنوعی

شاخص شبکه	R <sup>2</sup>	RMSE	MAPE
پویا	۰,۹۶۴۱	۰,۰۱۶	۱,۸۱۲
چندگانه	۰,۹۷۴۳	۰,۰۱۲	۱,۲۴۱
هرس	۰,۹۷۲۲	۰,۰۱۲	۱,۲۸۷
هرس کامل	۰,۹۶۷۵	۰,۰۱۶	۱,۸۲۱
شبکه های شامل توابع شعاعی	۰,۹۶۲۵	۰,۰۱۵	۱,۸۰۳

جدول ۳: وزن ها و انحرافات مدل هرس کامل

وزن های ورودی				وزن های پنهان	انحرافات	
W <sub>i,1</sub>	W <sub>i,2</sub>	W <sub>i,3</sub>	W <sub>i,4</sub>	W <sub>q</sub>	W <sub>0,j</sub>	W <sub>0</sub>
-۲,۵۶۷۸	۱۰,۳۹۶۱	-۲,۰۱۱۲	۱۶,۰۰۲۳	-۲,۶۷۹۰	-۱۳,۲۷۵۶	-۱,۶۲۲۱
۱,۳۱۱۳	۱۷,۲۸۳۴	۸,۵۳۳۱	-۰,۲۳۴۴	۰,۰۴۰۲	۳,۰۱۱۱	
۴,۶۷۰۱	-۱,۸۷۶۶	-۱۱,۹۰۱۲	۱۴,۷۵۵۸	۱۴,۶۷۲۳	-۸,۳۷۸۳	
۰,۲۳۴۹	۲۰,۹۱۲۳	-۲,۷۶۶۳	۵,۰۳۷۷۷	۵,۲۳۱۰	-۵,۲۳۱۱	

جدول ۴: مرکز و پهنای وزن های پنهان

C <sub>q</sub>	e <sub>q</sub>	
۰,۴۷۸	-۱,۶۲۲۱	W <sub>0</sub>
۰,۸۸۲	-۲,۶۷۹۰	W <sub>1</sub>
۰,۰۱۶	۰,۰۴۰۲	W <sub>2</sub>
۲,۵۸۳	۱۴,۶۷۲۳	W <sub>3</sub>
۱,۷۷۱	۵,۲۳۱۰	W <sub>4</sub>

عملکرد مدل های پیشنهادی با استفاده از ۳۰ داده در جدول (۵) آمده است.

$$y_m = f(0.478 + \sum_{q=1}^4 c_q + X_{mq})$$

$$= \text{Saltin}(\sum_{q=0}^4 c_q + X_{mq}) = \sum_{q=0}^4 c_q + X_{mq}$$

باید دقت کرد که در نظر گرفتن مرکز وزن های پنهان (C<sub>q</sub>) منجر به، به دست آوردن y<sub>m</sub> های قطعی می شود. همان گونه که دیده می شود، مدل پیشنهادی، عملکرد قابل قبولی دارد و نزدیک به مدل هرس جامع است. به هر حال، با استفاده از تحلیل حساسیت می توان ساختار شبکه را بهبود بخشید. از مزیت های قابل توجه این مدل می توان گفت که این مدل قادر است با مسائل پیچیده و در شرایط اطمینان نداشتن، به صورت مدل جعبه سفید عمل کند.

$$\text{Minimize } S = \sum_{m=1}^{70} \sum_{q=0}^4 c_q \cdot |X_{mq}| \quad (17)$$

$$\sum_{q=0}^4 e_q \cdot X_{mq} + (1 - 0.5) \left( \sum_{q=0}^4 c_q \cdot |X_{mq}| \right) \geq y_m, \quad m = 1, 2, \dots, 70$$

$$\sum_{q=0}^4 e_q \cdot X_{mq} - (1 - 0.5) \left( \sum_{q=0}^4 c_q \cdot |X_{mq}| \right) \leq y_m, \quad q = 1, 2, \dots, 4$$

که m تعداد داده های آموزش دیده و q تعداد نرون ها در لایه پنهانی شبکه های هرس کامل است. مرکز و پهنای وزن های پنهان (C<sub>q</sub> و e<sub>q</sub>) با استفاده از نرم افزار GAMS محاسبه و در جدول (۴) آمده است.

برای ارزیابی عملکرد مدل پیشنهادی، مرکز وزن های پنهان (C<sub>q</sub>) به عنوان وزن ها (W<sub>q</sub>) برای محاسبه y<sub>m</sub> (مطابق رابطه (۱۸)) با داده هایی که برای آزمایش کردن کنار گذاشته شده اند، در نظر گرفته می شوند. نتایج ارزیابی

جدول ۵: نتایج عملکرد شاخص‌های  $R^2$ ، RMSE، MAPE برای مدل پیشنهادی

مدل شبکه	$R^2$
$R^2$	۰٫۹۴۰۱
RMSE	۲٫۰۱۱
MAPE	۰٫۰۱۹

جدول ۶: ویژگی‌های رویکرد مدل‌سازی پیشنهادی در مقایسه با سایر رویکردهای ذکر شده در مرور ادبیات

ویژگی	توانایی در داشتن خروجیهای چندگانه	حل مسائل پیچیده و غیرخطی	حل مسائل با داده‌های نامطمئن، غیرقطعی و محدود	مدل‌سازی هوشمند	قابلیت اطمینان و توانایی پیش‌بینی بالا	به صورت جعبه سفید بودن	حل مسائل در شرایط مبهم	تعیین متغیر های تأثیرگذار	توانایی در برخورد با داده- های پرت و متناقض
رویکرد پیشنهادی	✓	✓	✓	✓	✓	✓	✓	✓	✓
Reiter و Doris (۱۹۹۹)		✓		✓	✓			✓	
Gabrielle Wong- Parado et al. (۲۰۰۵)								✓	
Nabney Nguyen و (۲۰۰۸؛ ۲۰۱۰)	✓	✓		✓	✓			✓	

## نتایج و ملاحظات نهایی

رگرسیون فازی فرمول‌بندی کردیم. این رویکرد مدل‌سازی جدید، به دلیل انعطاف‌پذیری بالا، قابل استفاده در شرایط نبود قطعیت، مبهم و پیچیده را دارد. به اضافه، تابع قیمت گاز مایع در بازار ژاپن (بزرگ‌ترین واردکننده گاز طبیعی جهان) بر اساس رویکرد مدل‌سازی پیشنهادی، به عنوان مطالعه موردی، فرمول‌بندی شده است. بر مبنای نتایج شاخص‌های عملکرد، مدل پیشنهادی معتبر است و همچنین می‌تواند در شرایط غیرقطعی و پیچیده، اطلاعات شفاف‌تری از روابط موجود بین متغیرهای ورودی و پاسخ مدل به تصمیم‌گیرنده ارائه دهد.

مطابق جدول (۶)، برتری رویکرد پیشنهادی در مقایسه با رویکردهای ذکر شده در مرور ادبیات، با در نظر گرفتن ویژگی‌های مهم آن، قابل بررسی است.

در دنیای امروزی، مدل‌های محاسباتی برای مسائل پیش‌بینی در بازار که منجر به بهبود تصمیم‌گیری‌ها و سرمایه‌گذاری‌ها می‌شود، ضروری است. به تازگی، شبکه‌های عصبی مصنوعی به طور گسترده در زمینه مسائل پیش‌بینی مورد استفاده قرار گرفته‌اند. اگر چه، شبکه‌های عصبی مصنوعی قادر به حل مسائل تعریف شده در شرایط نبود قطعیت نیستند و در این شرایط به عنوان تکنیک‌های جعبه سیاه شناخته می‌شوند. این روزها، اغلب با مسائلی روبه‌رو هستیم که هدف آنها، پیش‌بینی در شرایط نبود قطعیت و مبهم است. مدل‌های رگرسیون فازی در این موارد، مدل‌های مناسبی هستند. با این وجود، این مدل‌ها توانایی نگاشت توابع با رفتار غیرخطی را ندارند. از این رو، مدل شبکه عصبی مصنوعی را بار دیگر به صورت مدل



## مراجع

- 1- Chin-Teng L. et al. (2005). "Fuzzy neural network design using support vector regression for function approximation with outliers." *International Conference on Man and Cybernetics, IEEE*, Vol. 3., No. 3, PP. 2763- 2768.
- 2- Chia-Feng J., Ren-Bo H. and Wei-Yuan Ch. (2010). "An Interval Type-2 Fuzzy-Neural Network With Support-Vector Regression for Noisy Regression Problems." *IEEE Transactionson Fuzzy System*, Vol. 18, No. 4, PP. 686-699.
- 3- Chia-Feng J. and Cheng-Da H. (2010). "A Locally Recurrent Fuzzy Neural Network With Support Vector Regression for Dynamic-System Modeling. Fuzzy Systems." *IEEE Transactionson Fuzzy System*, Vol. 18, No. 2, PP. 261-273.
- 4- Mosleh, M., Otadi, M. and Abbasbandy, S. (2010). "Evaluation of fuzzy regression models by fuzzy neural network." *Journal of Computational and Applied Mathematics*, Vol. 234, No.3, PP.825-834..
- 5- Noghondari, M.R. and Rashidi, M. (2004). "General regression neural network based fuzzy approach for sensorless speed control of induction motor drives." *39<sup>th</sup> International Engineering Conference*, UPEC, PP.353- 357.
- 6- Khashei, M., Reza Hejazi, S. and Bijari, M. (2008). "A new hybrid artificial neural networks and fuzzy regression model for time series forecasting." *Fuzzy Sets and Systems*, Vol. 159, No.7, PP.769-786.
- 7- Tanaka, H. and Ishibuchi, H. (1992). Possibility regression analysis based on linear programming, Warsaw and Physica-Verlag, Heidelberg: Omnitech Press.
- 8- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Prentice Hall, ISBN 0-13-273350-1.
- 9- Ma, L. and Khorasani, K. (2003). "A new strategy for adaptively constructing multilayer feed-forward neural networks." (51), p.361–385.
- 10- Doris F. R. Prediction of Short-term Natural Gas Prices Using Econometric and Neural Network Models, SPE Hydrocarbon Economics and Evaluation Symposium, Dallas, Texas, 21-23 March 1999..
- 11- Gabrielle Wong-parodi, Larry Dale and Alex Iekov. "Comparing price forecast accuracy of natural gas models and futures markets". *Journal of Energy policy*, Vol. 34, No. 18, PP.4115-4122
- 13- Nguyen, Hang T and Nabney, Ian T. (2008). "Combining the wavelet transform and forecasting". *Proceedings of the seventh international conference on machine learning and applications*. PP. 311-317.
- 14- Favennec, J.P. (2002). "Oil and Gas prices decoupling?" paper presented at The IEA Regulatory Forum, Lawrence Berkeley National Laboratory.
- 15- L'Hégaret, G., Siliverstovs, B., Neumann, A. and Hirschhausen, C.V. (2005). "International Market Integration for Natural Gas? A Co integration Analysis of Prices in Europe, North America and Japan." *Energy Economics* Vol. 27, No. 4, PP.603-615.
- 16- Villar, J.A. and Joutz, F.L., (2006). "The Relationship between Crude Oil and Natural Gas Prices." EIA, Office of Oil and Gas. Available from <http://www.eia.doe.gov/oiaf/analysispaper/henryhub/index.html>
- 17 - Tabatabaei, S. Ali R. and Paytakhti Oskouei, S.J. (Jun.2005). "Mechanisms of Oil Recovery by Non-Hydrocarbon Gas Injection." Presented at 13th Oil, Gas & Petrochemical Congress: 4th International Conference on Improved Oil Recovery, Tehran, 24-26.

## واژه‌های انگلیسی به ترتیب استفاده در متن

- 1- Fuzzy Neural Networks (FNN)
- 2- Support Vector Regression (SVR)
- 3- Support Vector Regression Fuzzy Neural Network (SVRFNN)
- 4- Fuzzy Radial Basis Function Networks (FRBFN)
- 5- Fuzzy based General Regression Neural Network (FGRNN)
- 6- Networks with Radial Basis Function (RBFN)
- 7- Energy International Agency (EIA)
- 8- Generalised Autoregressive Conditional Heteroschedasti
- 9- Redandant Haar Wavelet Transform
- 10- Liquid Natural Gas
- 11- Dynamic
- 12- Multiple
- 13- Prune
- 14- Exhaustive prune
- 15- Networks with Radial Basis Function
- 16- Mean Square Errors (MSE)
- 17- Mean Absolute Percentage Error(MAPE)
- 18- Root Mean Square Error(RMSE)
- 19- Absolute Fraction of Variance ( $R^2$ )