

به کارگیری مدل ترکیبی شبکه‌های عصبی مصنوعی با رگرسیون فازی با هدف پیش‌بینی قیمت طلا

مهدی خاشعی^{۱*} و مهدی بیجاری^۲

^۱ دانشجوی دکتری تخصصی مهندسی صنایع، دانشگاه صنعتی اصفهان

^۲ دانشیار دانشکده مهندسی صنایع، دانشگاه صنعتی اصفهان

(تاریخ دریافت ۸۵/۴/۱۰، تاریخ دریافت روایت اصلاح شده ۸۸/۱۰/۱۵، تاریخ تصویب ۸۹/۱/۱۸)

چکیده

یکی از مشکلات مهم در پیش‌بینی با شبکه‌های عصبی مصنوعی، فراهم کردن داده‌های لازم برای پیش‌بینی است؛ چرا که شبکه‌های عصبی برای حصول نتایج دقیق نیاز به داده‌های زیادی دارند. اما باید توجه داشت که جمع‌آوری داده‌های مورد نیاز شبکه، نخست، بسیار هزینه‌بر است و دوم، مدت زمان طولانی را طلب می‌کند. بنابراین با توجه به تغییرات سریع در محیط‌های واقعی و به ویژه سیستم‌های اقتصادی و مالی، پیش‌بینی در این گونه محیط‌ها نیازمند روش‌هایی است که با تعداد داده‌های قابل حصول کم نیز کارآمد و کارا باشند. روش‌های پیش‌بینی فازی، به دلیل استفاده از اعداد فازی به جای اعداد قطعی، نسبت به سایر روش‌های مشابه به داده‌های کمتری نیاز داشته، اما عملکرد آنها همیشه رضایت‌بخش نیست. در این مقاله برای بر طرف کردن محدودیت تعداد داده‌های مورد نیاز شبکه و حصول نتایج دقیق‌تر برای پیش‌بینی قیمت طلا، مدل ترکیبی شبکه‌های عصبی مصنوعی با رگرسیون فازی پیشنهاد شده است. نتایج تجربی بیانگر کارآمدی این روش در پیش‌بینی قیمت طلا است.

واژه‌های کلیدی: شبکه‌های عصبی مصنوعی (ANNs)، رگرسیون فازی، مدل‌های ترکیبی، پیش‌بینی سری‌های زمانی

مقدمه

نشده است، اما در حالت کلی تعداد داده‌های مورد نیاز شبکه به ساختار شبکه، الگوریتم آموزش، پیچیدگی مسئله مورد نظر و اختلال‌های موجود در داده‌ها وابسته است. نام و اسکیر [۲] تأثیرات اندازه‌های متفاوت داده‌های مورد نیاز شبکه را آزمایش کرده و دریافتند که افزایش تعداد داده‌ها، عملکرد شبکه عصبی مصنوعی را در مسائل پیش‌بینی بهتر خواهد کرد و به دست آوردن سطح معینی از دقت، نیاز به داده‌های آموزش با مقدار معین دارد.

با تعداد داده‌های کافی، شبکه‌های عصبی می‌توانند ساختارهای پیچیده موجود در داده‌ها را مدل کنند. بنابراین، برای نمونه‌های بزرگ شبکه‌های عصبی سودمندتر از سایر مدل‌های آماری خطی خواهند بود. البته این نکته هم قابل توجه است که شبکه‌های عصبی مصنوعی نیاز به تعداد داده‌های بیشتری نسبت به مدل‌های خطی برای رسیدن به عملکرد مناسب را ندارند. "کانگ" دریافت که شبکه‌های عصبی مصنوعی پیش‌بینی‌های کاملاً خوبی با داده‌های کمتر از ۵۰ خواهند داشت، در صورتی که مدل‌های باکس-جکینز برای

به تازگی شبکه‌های عصبی مصنوعی به طور گسترده‌ای مورد مطالعه قرار گرفته و محققان بسیاری این گونه از شبکه‌ها را برای پیش‌بینی سری‌های زمانی مورد استفاده قرار داده‌اند. زانگ در مقاله‌ای این گونه از مدل‌ها را به طور کامل مرور کرده است [۱]. مزیت اصلی شبکه‌های عصبی مصنوعی، قابلیت مدل‌سازی غیرخطی و انعطاف‌پذیرشان است. در این گونه از شبکه‌ها دیگر نیازی به تشخیص شکل خاص مدل نبوده و مدل بر اساس اطلاعات موجود در داده‌ها شکل می‌گیرد. این رویکرد مبتنی بر داده برای بسیاری از مجموعه داده‌های تجربی بخصوص زمانی که هیچ اطلاعات تئوریک برای پیشنهاد یک فرآیند تولید داده مناسب در دسترس نباشد، بسیار کارآمد و کارا هستند. با وجود همه مزیت‌هایی که برای شبکه‌های عصبی مصنوعی در نظر گرفته می‌شود، این گونه از شبکه‌ها معایبی نیز دارند که از جمله مهم‌ترین آنها می‌توان به نیاز به داده‌های زیاد برای حصول نتایج دقیق اشاره کرد.

هر چند قانون تعریف شده‌ای برای تعیین تعداد داده‌های مورد نیاز شبکه، برای مسائل مختلف تبیین

معنی‌دار بین داده‌ها)، همچنان در این گونه از مدل‌ها وجود دارد.

در این مقاله برای پیش‌بینی‌های بهتر، حصول نتایج دقیق‌تر و همچنین نیاز به تعداد داده‌های کمتر، از مفاهیم روش رگرسیون فازی استفاده شده است تا بتوان از مزایای موجود در این روش برای پیش‌بینی‌های بهتر استفاده کرده و محدودیت نیاز به داده‌های زیاد در شبکه‌های عصبی مصنوعی را نیز تا حد امکان رفع کرد.

سایر قسمت‌های این مقاله بدین ترتیب است: در بخش دوم، روش شبکه‌های عصبی مصنوعی در مدل‌سازی سری‌های زمانی شرح داده شده است. مدل رگرسیون فازی در بخش سوم توضیح داده شده است. در بخش چهارم مدل ترکیبی شبکه‌های عصبی مصنوعی با رگرسیون فازی تشریح شده است. استفاده از مدل ترکیبی در پیش‌بینی قیمت طلا و مقایسه‌ی عملکرد آن با مدل شبکه‌های عصبی مصنوعی، رگرسیون فازی و شبکه‌های عصبی- فازی در بخش پنجم آورده شده است، در نهایت نیز نتایج حاصله مورد تجزیه و تحلیل قرار گرفته‌اند.

شبکه‌های عصبی مصنوعی در مدل‌سازی سری‌های زمانی

شبکه‌های عصبی مصنوعی از جمله روش‌هایی هستند که قادر به تخمین موارد غیرخطی متعدد در داده‌ها بوده و یک چارچوب محاسبه‌ای انعطاف‌پذیر برای دامنه وسیعی از مسائل غیرخطی هستند. یکی از مزیت‌های بارز این گونه از مدل‌ها نسبت به مدل‌های غیرخطی دیگر، این است که شبکه‌های عصبی مصنوعی یک تقریب‌زننده جهانی هستند که می‌توانند هر نوع تابعی را با دقت دلخواه تقریب بزنند [۱۶].

این گونه از شبکه‌ها به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدل‌سازی نیاز ندارند و به طور کلی یک مدل مبتنی بر داده هستند. شبکه‌های عصبی پیشرو با یک لایه مخفی یکی از پرکاربردترین مدل‌های شبکه‌های عصبی برای پیش‌بینی سری‌های زمانی هستند [۱۷].

این گونه مدل‌ها از سه لایه پردازش ساده اطلاعات متصل به هم تشکیل شده‌اند. رابطه بین خروجی (y_t) و ورودی‌ها ($y_{t-1}, \dots, y_{t-p}$) در این گونه از شبکه‌ها به این ترتیب است:

پیش‌بینی‌های موفق، دست کم احتیاج به ۵۰ داده، دارند [۳].

روش‌های پیش‌بینی فازی همچون رگرسیون فازی به دلیل استفاده از اعداد فازی به جای اعداد قطعی نیاز به داده‌های کمتری نسبت به سایر مدل‌های پیش‌بینی دارند، اما عملکرد این گونه از روش‌ها در حالت کلی، به ویژه در محیط‌هایی با تغییرات سریع، داده‌های پرت و یا تغییرات معنی‌دار بین داده‌ها، چندان رضایت‌بخش نیست. تاناکا [۴-۵] برای جلوگیری از خطای مدل‌سازی، رگرسیون فازی را که یک مدل پیش‌بینی فاصله‌ای است پیشنهاد داده است، اما این مدل نیز معایبی دارد که از جمله مهم‌ترین آنها می‌توان به وسیع‌شدن بیش از حد فاصله پیش‌بینی که به دلیل وجود برخی از مقادیر پرت ایجاد می‌شود، اشاره کرد. سری‌های زمانی فازی توسط سانگ و چیزوم [۶-۷] بر اساس معادلات فازی و منطق تقریبی مدلسازی و مطرح شدند. چن [۸] نیز یک روش سری زمانی بر اساس سری‌های زمانی و مفاهیم سانگ و چیزوم، پیشنهاد داده است.

استفاده از مدل‌های ترکیبی یا ترکیب مدل‌های مختلف، یک راه معمول در بهبود دقت پیش‌بینی‌ها است. شبکه‌های عصبی- فازی، کلاس خاصی از مدل‌های ترکیبی هستند که از ترکیب شبکه‌های عصبی مصنوعی و سیستم‌های منطق فازی تشکیل می‌شوند [۹-۱۰]. در این گونه از روش‌ها از الگوریتم‌های یادگیری شبکه‌های عصبی برای تعیین عوامل سیستم منطق فازی استفاده می‌شود. شبکه‌های عصبی- فازی همچون *ANFIS* [۱۱] از زمان معرفی تا به امروز، در بسیاری از مسائل پیش‌بینی در زمینه‌های مختلف علوم مورد استفاده قرار گرفته‌اند و نتایج مطلوبی نیز ارائه کرده‌اند [۱۲].

هانگ و لی با استفاده از شبکه‌های عصبی- فازی قیمت الکتریسیته مصرفی را پیش‌بینی کرده‌اند [۱۳]. آبراهام و نس تقاضای مصرف الکتریسیته را با استفاده از مدل‌های عصبی- فازی مدل‌سازی کرده‌اند [۱۴]. لی و وانگ نیز با به کارگیری سیستم‌های عصبی- فازی چند متغیره مسئله مدیریت ریسک در بازارهای مالی را بررسی کرده‌اند [۱۵]. با وجود اینکه شبکه‌های عصبی- فازی، نتایج دقیق‌تری نسبت به سایر مدل‌های فازی ارائه می‌کنند، اما معایبی همچون به کارگیری در شرایط خاص (محیط‌هایی با تغییرات سریع، داده‌های پرت و یا تغییرات

موجود در مشاهده‌ها به عنوان بردار ورودی شبکه است که شاید مهم‌ترین عامل در طراحی مدل‌های شبکه‌های عصبی باشد؛ چرا که این عامل در تعیین ساختار خودهمبسته غیرخطی سری‌های زمانی نقش اساسی دارد [۱۹].

هیچ تئوری خاصی برای انتخاب p وجود ندارد. از این رو تجربه و آزمایش‌ها، مشخص‌کننده مقدار مناسب p و همچنین q خواهد بود. وقتی یک ساختار شبکه‌ای p و q مشخص شد، شبکه آماده آموزش و تخمین عوامل است. همانند مدل‌سازی خودرگرسیون میانگین متحرک انباشته (ARIMA) عوامل طوری تخمین زده می‌شوند که معیار دقت مانند میانگین مربع‌های خطاها (MSE) حداقل شود. فرآیند این آموزش توسط الگوریتم‌های بهینه‌سازی غیرخطی همچون پس‌انتشار خطا انجام می‌گیرد.

مدل برآورد شده اغلب توسط یک نمونه جداگانه که در فرآیند آموزش مورد استفاده قرار نگرفته است (داده‌های آزمون) ارزیابی می‌شود و این با فرآیند مدل‌سازی مدل خودرگرسیون میانگین متحرک انباشته که از یک نمونه برای شناسایی، تخمین و ارزیابی مدل استفاده می‌کند متفاوت است. دلیل این موضوع نیز آن است که شکل کلی مدل (خطی) برای مدل‌سازی اریما از قبل مشخص است [۲۰]، در صورتی که در مدل‌سازی شبکه‌های عصبی این طور نبوده و در مدل‌سازی با شبکه‌های عصبی مصنوعی مدل غیرخطی همانند مرتبه مدل باید تخمین زده شود و ممکن است شبکه دچار برازش بیش از حد شود.

مدل رگرسیون فازی

مدل‌های کلاسیک از مفهوم عبارت خطا استفاده می‌کنند. به عبارت دیگر، تخمین‌های این گونه از مدل‌ها مقادیر دقیقی بوده و شامل جمله خطا نمی‌شوند. این همان مفهوم پایه‌ای رگرسیون فازی است که توسط تاناکا و همکارانش [۴] پیشنهاد شده است. مفهوم اساسی تئوری فازی و رگرسیون فازی این است که جمله خطا از باقیمانده‌های بین مقادیر تخمین زده شده و مقادیر اصلی یا مشاهده‌ها تولید نمی‌شود، بلکه در نبود قطعیت عوامل مدل و امکان توزیع در ارتباط با مشاهده‌های حقیقی به کارگرفته می‌شوند. یک مدل رگرسیون خطی فازی در حالت کلی به این ترتیب است:

$$y_t = b_0 + \sum_{j=1}^q w_j \cdot g(b_{0j} + \sum_{i=1}^p w_{i,j} \cdot y_{t-i}) + \varepsilon_t \quad (1)$$

به طوری که $w_{i,j}, w_j$ عوامل مدل بوده که اغلب وزن‌های اتصالی نامیده می‌شوند، p تعداد گره‌های ورودی و q تعداد گره‌های مخفی هستند. توابع سیگموئیدی (رابطه ۲) و خطی از جمله توابعی هستند که اغلب به عنوان توابع فعال‌سازی برای لایه‌های مخفی و خروجی مورد استفاده قرار می‌گیرند.

$$\text{Sig}(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

از این رو مدل شبکه‌های عصبی مصنوعی رابطه (۱) در حقیقت به عنوان یک نگاشت غیرخطی از مشاهده‌های گذشته به مقدار آینده خواهند بود، به عبارت دیگر:

$$y_t = f(y_{t-1}, \dots, y_{t-p}, w) + \varepsilon_t \quad (3)$$

به طوری که w بردار همه عوامل و f تابعی است که توسط ساختار شبکه عصبی و وزن‌های اتصالی تعیین می‌شود.

بنابراین شبکه‌ی عصبی معادل یک مدل خودرگرسیون غیرخطی است. رابطه‌ی (۳) همچنین بیانگر این موضوع است که یک نرون (خروجی) در لایه خروجی برای پیش‌بینی یک مرحله‌ای مورد استفاده قرار می‌گیرد. مدل ساده بیان شده توسط رابطه‌ی (۳) قدرت تقریب بسیار زیادی دارد؛ چرا که به شرط آنکه تعداد گره‌های مخفی (q) به اندازه کافی بزرگ باشند، قادر است هر تابع دلخواه را تقریب بزند. در عمل اغلب ساختار شبکه عصبی ساده که تعداد نرون کمتری در لایه مخفی دارد، در پیش‌بینی‌های خارج از نمونه (داده‌های آزمون) بهتر عمل می‌کند و این به دلیل دوری جستن از مسئله برازش بیش از حد است که اغلب در فرآیند مدل‌سازی شبکه‌های عصبی رخ می‌دهد [۱۸].

یک مدل بیش از حد برازش شده، برای داده‌هایی که برای ساخت مدل استفاده شده باشند، برازش خوبی نشان می‌دهد، اما توانایی تعمیم آن، برای داده‌های خارج از نمونه، بسیار ضعیف خواهد بود. انتخاب تعداد نرون‌های لایه مخفی، وابسته به داده‌ها بوده و هیچ قانون سیستماتیکی برای تعیین این عامل در طراحی شبکه‌های عصبی وجود ندارد. علاوه بر این، مرحله مهم دیگر مدل‌سازی شبکه‌های عصبی، انتخاب تعداد وقفه‌های

$y_1, y_2, \dots, y_k$ بیشتر از مقدار انتخابی سطح h باشد. انتخاب مقدار سطح h بر گسترش‌های عوامل فازی مدل مؤثر است.

$$\mu_{\tilde{y}}(y_t) \geq h \quad \text{for } t = 1, 2, \dots, k \quad (9)$$

شاخص t به تعداد داده‌های غیرفازی به کار گرفته شده در ساخت مدل بر می‌گردد. مسئله‌ی پیدا کردن عوامل رگرسیون فازی توسط تاناکا به شکل یک برنامه‌ریزی خطی فرموله شده است [۵]:

$$\begin{aligned} \text{Min} \quad & S = \sum_{t=1}^k c' |X_t| \\ & X_t' \alpha + (1-h)c' |X_t| \geq y_t \quad t = 1, 2, \dots, k \\ \text{sub.to} \quad & X_t' \alpha - (1-h)c' |X_t| \leq y_t \quad t = 1, 2, \dots, k \\ & c \geq 0 \end{aligned} \quad (10)$$

به طوری که $\alpha' = (\alpha_1, \alpha_2, \dots, \alpha_n)$ و $c' = (c_1, c_2, \dots, c_n)$ بردار متغیرهای مجهول و S کل ابهامی است که پیش از این تعریف شده است.

فرموله کردن مدل ترکیبی

شبکه‌های عصبی مصنوعی، مدل‌های پیش‌بینی دقیقی برای دامنه وسیعی از مسائل هستند، اما دارای محدودیت تعداد زیاد داده‌های گذشته برای حصول نتایج دقیق هستند. در صورتی که امروزه به دلیل نبود قطعیت محیط و توسعه سریع تکنولوژی‌های نوین، اغلب باید موقعیت‌های آینده را با استفاده از داده‌های کم و در بازه‌های زمانی کوتاه‌مدت پیش‌بینی کرد. بنابراین در دنیای امروز به روش‌های پیش‌بینی نیاز است که به داده‌های کمتری نیاز داشته و در این گونه از شرایط نیز کارآمد و کارا باشند. مدل رگرسیون فازی یک مدل پیش‌بینی بازه‌ای مناسب در شرایط داده‌های قابل حصول کم است، اما همیشه عملکرد مناسبی ندارند. هدف این مقاله بهره‌گیری از مزیت‌های رگرسیون فازی برای پیش‌بینی سری‌های زمانی و بر طرف کردن محدودیت نیاز به داده‌های زیاد در روش شبکه‌های عصبی مصنوعی برای پیش‌بینی است. عوامل شبکه‌های عصبی (وزن‌ها و بایاس‌ها) مقادیری قطعی هستند ($w_{ij}, w_{0,j}$ و $b_{0,j}$) و در صورتی که در روش پیشنهادی به جای به کارگیری این مقادیر قطعی، عوامل مربوط به لایه نهایی به صورت

$$\tilde{Y} = \tilde{\beta}_0 + \tilde{\beta}_1 x_1 + \dots + \tilde{\beta}_n x_n = \sum_{i=1}^n \tilde{\beta}_i x_i = X' \tilde{\beta} \quad (4)$$

به طوری که X بردار متغیرهای مستقل، علامت پریم "۱" عملگر ترانهاده، n تعداد متغیرها و $\tilde{\beta}_i$ مجموعه‌های فازی بیانگر i امین عامل مدل هستند. این اعداد فازی (عوامل $\tilde{\beta}_i$) به شکل اعداد فازی نوع-ال دایوس و پریس [۲۱] $(\alpha_i, c_i)_L$ با توزیع احتمال به شکل زیر هستند:

$$\mu_{\tilde{\beta}_i}(\beta_i) = L\{(\alpha_i - \beta_i / c)\} \quad (5)$$

به طوری که L یک تابع است. عوامل فازی نیز به شکل اعداد فازی مثلثی به کار گرفته شده‌اند.

$$\mu_{\tilde{\beta}_i}(\beta_i) = \begin{cases} 1 - \frac{|\alpha_i - \beta_i|}{c_i} & \alpha_i - c_i \leq \beta_i \leq \alpha_i + c_i, \\ 0 & \text{otherwise,} \end{cases} \quad (6)$$

به طوری که $\mu_{\tilde{\beta}_i}(\beta_i)$ تابع عضویت مجموعه فازی بیانگر عوامل β_i است. α_i نیز مرکز عدد فازی و c_i گسترش حول مرکز هستند. حال با توجه به اصل گسترش، تابع عضویت عدد فازی $\tilde{y}_t = X_t' \tilde{\beta}$ را می‌توان بدین ترتیب تعریف کرد:

$$\mu_{\tilde{y}}(y_t) = \begin{cases} 1 - \frac{|y_t - X_t' \alpha|}{c' |X_t|} & \text{for } X_t \neq 0, \\ 1 & \text{for } X_t = 0, \quad y_t = 0, \\ 0 & \text{for } X_t = 0, \quad y_t \neq 0, \end{cases} \quad (7)$$

به طوری که α و c به ترتیب بردار مقادیر مربوط به عوامل و گسترش‌های آنها حول مرکز هستند. به طور کلی مدل از حداقل کردن کل ابهام‌ها (که برابر با مجموع گسترش‌های تکی و مربوط به هر یک از عوامل فازی مدل است) استفاده می‌کند.

$$\text{Minimize} \quad S = \sum_{t=1}^k c' |X_t| \quad (8)$$

این روش همچنین به طور همزمان شرایطی را که مقدار عضویت به ازای هر مشاهده y_t بزرگ‌تر از یک حد آستانه تعیین شده در سطح h است ($h \in [0, 1]$) را نیز در نظر می‌گیرد. این معیار، بیانگر این حقیقت است که خروجی فازی مدل باید برای همه نقاط داده‌ای

$$\begin{aligned} \text{Min } S &= \sum_{j=0}^q \sum_{t=1}^k c_j |w_j| |u_{t,j}| \\ \sum_{j=0}^q \alpha_j u_{t,j} + (1-h) \left(\sum_{j=0}^q c_j |u_{t,j}| \right) &\geq y_t \\ S.T \quad \sum_{j=0}^q \alpha_j u_{t,j} - (1-h) \left(\sum_{j=0}^q c_j |u_{t,j}| \right) &\leq y_t \\ c_j &\geq 0 \quad \text{for } j=0,1,\dots,q \quad t=1,2,\dots,k \end{aligned} \quad (17)$$

مراحل روش ترکیبی به طور خلاصه به این شرح است:

مرحله اول: آموزش یک مدل شبکه عصبی با استفاده از اطلاعات موجود در مشاهده‌ها که به صورت غیرفازی هستند. نتیجه مرحله اول، جواب بهینه عوامل $w^* = (w_0^*, w_1^*, \dots, w_q^*)$ است که به عنوان یکی از مجموعه داده‌های ورودی در مرحله دوم مورد استفاده قرار می‌گیرند.

مرحله دوم: تعیین حداقل ابهام با استفاده از معادله‌ی (17) و وزن‌های حاصله از مرحله‌ی اول $w^* = (w_0^*, w_1^*, \dots, w_q^*)$. تعداد محدودیت‌ها برابر با تعداد مشاهده‌ها است و مدل ترکیبی بدین ترتیب خواهد بود:

$$\tilde{y}_t = \langle \alpha_0, c_0 \rangle u_{0,t} + \langle \alpha_1, c_1 \rangle u_{1,t} + \dots + \langle \alpha_q, c_q \rangle u_{q,t} \quad (18)$$

که α_i, c_i به ترتیب مراکز و گسترش‌های اعداد فازی هستند.

مرحله سوم: با توجه به نظرات ایشیوچی داده‌های حد بالا و پایین مدل وقتی که دامنه مدل ترکیبی وسیع شود، حذف خواهند شد. برای ساختن مدلی شامل همه شرایط ممکن، اگر مجموعه داده‌ها شامل تفاوت‌های مشخص یا موارد خارج از محدوده باشند، c_j ها بسیار گسترده خواهند شد. طبق نظرات ایشیوچی [22] داده‌های اطراف مرزهای بالا و پایین مدل حذف می‌شود، سپس مدل بار دیگر فرمول‌بندی می‌شود.

به کارگیری مدل ترکیبی برای پیش‌بینی قیمت طلا

از مدل حاصله، در این قسمت برای پیش‌بینی دامنه تغییرات قیمت طلا استفاده شده است. اطلاعات

اعداد فازی مثلثی در نظر گرفته شده‌اند $(\tilde{w}_j, \tilde{b}_0)$. علاوه بر این، در این مقاله متدولوژی ارائه شده توسط ایشیوچی و تاناکا [22] برای شرایطی که دامنه پیش‌بینی وسیع می‌شود، به کار گرفته شده است. یک مدل ترکیبی با توابع و عوامل فازی در حالت کلی به این ترتیب است.

$$\tilde{y}_t = \tilde{b}_0 + \sum_{j=1}^q \tilde{w}_j \cdot g(b_{0,j} + \sum_{i=1}^p w_{i,j} \cdot y_{t-i}) \quad (11)$$

که y_t مشاهده‌ها و $\tilde{w}_j, \tilde{b}_0$ اعداد فازی هستند. حال معادله (11) با جایگذاری

$u_{t,j} = g(b_{0,j} + \sum_{i=1}^p w_{i,j} \cdot y_{t-i})$ به شکل زیر تبدیل می‌شود:

$$\tilde{y}_t = \tilde{b}_0 + \sum_{j=1}^q \tilde{w}_j \cdot u_{t,j} = \sum_{j=0}^q \tilde{w}_j \cdot u_{t,j} \quad (12)$$

عوامل فازی در این معادله به شکل اعداد فازی مثلثی مطابق زیر در نظر گرفته شده‌اند:

$$\mu_{\tilde{\beta}_i}(\beta_i) = \begin{cases} 1 - \frac{|\alpha_i - \beta_i|}{c_i} & \alpha_i - c_i \leq \beta_i \leq \alpha_i + c_i \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

تابع عضویت مجموعه فازی است $\mu_{\tilde{\beta}_i}(\beta_i)$ ؛ به طوری که مشخص می‌شود. حال با استفاده از عوامل β_i که با عوامل به صورت اعداد فازی مثلثی و همچنین اصل β_i فازی مطابق ذیل خواهد بود [5]. y_t گسترش، تابع عضویت

$$\mu_{\tilde{y}}(y_t) = \begin{cases} 1 - \frac{|y_t - \sum_{j=0}^q \alpha_j \cdot u_{t,j}|}{\sum_{j=0}^q c_j |u_{t,j}|} & \text{for } u_{t,j} \neq 0 \\ 0 & \text{otherwise} \end{cases} \quad (14)$$


حال با در نظر گرفتن سطح آستانه‌ی h برای میزان توابع عضویت همه‌ی مشاهده‌ها مطابق رابطه‌ی (15)

$$\mu_{\tilde{y}}(y_t) \geq h \quad \text{for } t=1,2,\dots,k \quad (15)$$

و مقدار تابع هدف S مطابق رابطه‌ی زیر:

$$S = \sum_{j=0}^q \sum_{t=1}^k c_j |w_j| |u_{t,j}| \quad (16)$$

به قسمی که w_j وزن‌های ارتباطی بین نرون خروجی و نرون j ام لایه میانی هستند، خواهیم داشت.



شکل ۳: مقادیر واقعی و برآورد شده توسط شبکه عصبی.

مرحله دوم (تعیین حداقل ابهام): با قراردادن وزن‌های


اول

مرحله

$$(w_0^*, w_1^*, w_2^*, w_3^*) = (-11.712, -5.280, 0.5096, 17.275)$$

عوامل فازی مدل با استفاده از معادله (۱۷) به دست آمده‌اند ($h=0$). نتایج حاصله در شکل (۴) آورده شده است.

$$\tilde{y}_t = \langle -19.852, 0.000 \rangle u_{1,t} + \langle 0.6175, 0.000 \rangle u_{2,t} + \langle 20.133, 0.1649 \rangle u_{3,t} \quad (19)$$




شکل ۴: مقادیر واقعی و حد بالا و پایین آنها.

همان طور که در شکل (۴) مشاهده می‌شود، مقادیر واقعی در فواصل فازی قرار گرفته‌اند، اما طول فواصل فازی وسیع شده و مدل ترکیبی فواصل مناسبی را به دست نمی‌دهد.

مرحله سوم: از نتایج به دست آمده مشخص می‌شود که مشاهده مربوط به بیست و پنجم آذرماه (شماره ۱۹) در مرز پایینی قرار گرفته است، بنابراین محدودیت خطی که توسط این مشاهده تولید شده است را حذف کرده و سپس مرحله دوم بار دیگر تکرار می‌شود ($h=0$). نتایج حاصله در شکل (۴) آورده شده است.

$$\tilde{y}_t = \langle -20.666, 0.000 \rangle u_{1,t} + \langle 0.5158, 0.000 \rangle u_{2,t} + \langle 23.020, 0.1366 \rangle u_{3,t} \quad (20)$$

استفاده شده در این تحقیق شامل ۴۰ داده روزانه قیمت طلا (یک مثقال طلای ۱۸ عیار) از شنبه پنجم آذرماه تا چهارشنبه بیست و هشتم دی‌ماه سال ۱۳۸۴ است که در شکل (۱) نمایش داده شده است. لازم به ذکر است داده‌ها مربوط به روزهای شنبه تا چهارشنبه هر هفته بوده و برای روزهای دیگر قیمتی اعلام نشده است.




شکل ۱: داده روزانه قیمت طلا از ۵ آذرماه الی ۲۸ دی‌ماه ۱۳۸۴ (ریال).

پیش‌بینی

با به کارگیری مدل ترکیبی ابتدا ۳۵ مشاهده (پنج هفته اول) برای آموزش شبکه و سپس ۵ مشاهده (هفته آخر) برای آزمایش عملکرد مدل مورد استفاده قرار گرفته‌اند.

مرحله اول: با توجه به اصول طراحی شبکه‌های عصبی مصنوعی [۲۳] و به کارگیری نرم‌افزار *MATLAB7* شبکه ایدال، شبکه $N^{(2-3-1)}$ بوده است. مدل حاصله در شکل (۲) نشان داده شده است: وزن‌ها و بایاس‌های شبکه ذکر شده در جدول (۱) آورده شده است.



شکل ۲: ساختار شبکه عصبی چندلایه پیش‌خور.

همچنین مقادیر واقعی و برازش شده توسط شبکه را می‌توانید در شکل (۳) مشاهده کنید. معیارهای عملکردی این شبکه نیز در جدول (۲) آورده شده است.

جدول ۱: مقادیر مربوط به وزن ها و بایاس های شبکه نهایی پیش بینی قیمت.

Input Weights			Hidden Weights	Biases	
$W_{i,1}^1$	$W_{i,2}^1$	$W_{i,3}^1$		$W_{0,i}$	W_0
۱/۳۱۱۳	۳۱/۹۸۹	-۶/۲۲۳۳	-۵/۲۷۹۸	۲۰/۹۷۸۸	-۱۱/۷۱۱۵
-۶/۷۵۸۵	-۲۱/۴۳۲۵	۱۰/۳۹۶۱	۰/۵۰۹۶۴	-۴/۷۶۶۳	
			۱۷/۲۷۵۲	۴/۳۰۶۲	


جدول ۲: معیارهای عملکرد شبکه عصبی در پیش بینی قیمت.

آموزش		تست					
MSE	MAE	MSE	SSE	RMSE	ME	MAPE	MAE
$1/8 \times 10^{-7}$	۳۴۰۷	$8/6 \times 10^{-7}$	$4/3 \times 10^{-4}$	۴۲۹۱	۸۴۱۶	۱/۵۲۰	۸۴۱۶

جدول ۳: حدود بالا و پایین و مقادیر اصلی داده های آزمایش.

حد بالای مقادیر		حد پایین مقادیر		مقادیر واقعی	تاریخ
قبل از حذف	بعد از حذف	قبل از حذف	بعد از حذف		
۵۵۸۱۰۰	۵۵۴۸۰۰	۵۳۹۱۰۰	۵۳۹۱۰۰	۵۴۳۶۰۰	شنبه ۲۴-دی
۵۵۸۱۰۰	۵۵۴۹۰۰	۵۳۹۱۰۰	۵۳۹۲۰۰	۵۵۳۲۰۰	یکشنبه ۲۵-دی
۵۵۷۹۰۰	۵۵۴۴۰۰	۵۳۹۰۰۰	۵۳۸۷۰۰	۵۵۴۴۰۰	دوشنبه ۲۶-دی
۵۵۹۲۰۰	۵۵۵۹۰۰	۵۴۰۲۰۰	۵۴۰۱۰۰	۵۵۳۲۰۰	سه شنبه ۲۷-دی
۵۵۸۹۰۰	۵۵۵۷۰۰	۵۳۹۹۰۰	۵۴۰۰۰۰	۵۵۳۲۰۰	چهارشنبه ۲۸-دی


ترکیبی نسبت به روش رگرسیون فازی شده است. قابل ذکر است که بازه به دست آمده از رگرسیون فازی بدون استفاده از شبکه های عصبی، بازه ای به طول ۲۸۰۰ تومان بوده است، در صورتی که طول بازه پیش بینی شده توسط روش ترکیبی ۱۶۰۰ تومان است و این خود بیانگر بیش از ۷۵ درصد بهبود در دقت نتایج است. مدل سری زمانی فازی در شکل (۶) آورده شده است. مقایسه بین میانگین مربع های خطای مدل پیشنهادی ($MSE = 8/6 \times 10^{-7}$) و شبکه های عصبی - فازی ($MSE = 9/9 \times 10^{-7}$) نیز بیانگر بیش از ۱۳ درصد بهبود در دقت نتایج و برتری مدل پیشنهادی بر مدل های عصبی - فازی در پیش بینی نقطه ای است و این در حالی است که مدل پیشنهادی در اساس برای پیش بینی بازه ای طراحی شده است.



شکل ۵: مقادیر واقعی و حد بالا و پایین آنها.

در انتها نیز با استفاده از مدل ترکیبی بازبینی شده، مقادیر آینده متغیر وابسته پیش بینی شده اند. نتایج مقادیر پیش بینی شده در جدول (۳) آورده شده است. این نکته قابل ذکر است که داده های مربوط به حد بالا و پایین مقادیر در جدول تا دو رقم گرد شده اند. همان طور که مشاهده می شود، نتایج حاصله و فواصل فازی نسبت به مدل قبلی مطلوب تر است.

از مقایسه طول بازه پیش بینی شده توسط روش ترکیبی با میانگین قدرمطلق خطای شبکه چندلایه پیش خور، با فرض توزیع یکنواخت مقادیر واقعی در اطراف تابع برآورد شده و فضای پیش بینی، نتایج حاصله بیانگر برتری اکید روش ترکیبی بر شبکه های عصبی مصنوعی است. همچنین پیش پردازش انجام شده بر داده های خام اولیه توسط شبکه های عصبی باعث بهبود نتایج روش



شکل ۶: مدل سری زمانی فازی.

نتیجه گیری

تغییرات تکنولوژیکی و جهانی شدن تجارت و بازارهای مالی باعث شده است تا توانایی در پیش بینی دقیق تر و سریع تر الگوهای موجود در حفظ توان رقابتی اهمیت بیشتری پیدا کند. اما تغییرات سریع این گونه از محیط های ناشناخته و به ویژه بازارهای مالی، پیش بینی کنندگان را از نظر تأمین داده های لازم برای حصول نتایج مطلوب دچار مشکل کرده است. در این مقاله بر اساس اصول و مفاهیم پایه ای شبکه های عصبی مصنوعی (ANNs) و رگرسیون فازی، مدلی از ترکیب دو روش مزبور برای پیش بینی سری های زمانی پیشنهاد شده است. مدل پیشنهادی با فازی در نظر گرفتن عوامل لایه میانی شبکه چندلایه پیشخور (FFNN)، داده های مورد نیاز برای حصول نتایج مطلوب را کاهش داده است. نتایج به دست آمده بیانگر آن است که مدل ترکیبی نه تنها توانایی

انجام یک پیش بینی مناسب را داشته، بلکه برای تصمیم گیرندگان بهترین و بدترین حالت ممکن را نیز فراهم می کند. مدل پیشنهادی همچنین در شرایط برابر، عملکرد بهتری نسبت به شبکه های چندلایه پیشخور و رگرسیون فازی داشته است. بنابراین مدل پیشنهادی را می توان به عنوان یک گزینه مناسب در پیش بینی سری های زمانی، به ویژه در محیط های مالی و در شرایط داده های قابل حصول کم در نظر گرفت. در حالت کلی مزایای روش ترکیبی که با به کارگیری شبکه های عصبی و منطق فازی در این روش حاصل شده است را می توان در موارد زیر خلاصه کرد:

- ۱- بر طرف کردن مسئله کمبود داده ها
- ۲- ارائه بهترین و بدترین حالات ممکن
- ۳- حصول نتایج دقیق تر

مراجع

- 1- Zhang, G., Patuwo, B. E. and Hu, M Y. (1998), "Forecasting with artificial neural networks: The state of the art." *International Journal of Forecasting* 14, PP. 35- 62.
- 2- Nam, K. and Schaefer, T. (1995), "Forecasting international airline passenger traffic using neural networks." *Logistics and Transportation* 31 (3), PP. 239-251.
- 3- Kang, S. (1991), *An Investigation of the Use of Feedforward Neural Networks for Forecasting*, Ph.D. Thesis, Kent State University.
- 4- Tanaka, H. (1987), "Fuzzy data analysis by possibility linear models.", *Fuzzy Sets and Systems*, 24(3), PP. 363- 375.
- 5- Tanaka, H. and Ishibuchi, H. (1992), *Possibility regression analysis based on linear programming*, in: J. Kacprzyk, M. Fedrizzi (Eds.), *Fuzzy Regression Analysis*, Omnitech Press, Warsaw and Physica-Verlag, Heidelberg, PP. 47 -60.
- 6- Song, Q. and Chissom, B.S. (1993), "Forecasting enrollments with fuzzy time series - part I," *Fuzzy Sets and Systems* 54(1), PP. 1- 9.
- 7- Song, Q. and Chissom, B.S. (1994), "Forecasting enrollments with fuzzy time series - part II", *Fuzzy Sets and Systems*, 62(1), PP. 1- 8.
- 8- Chen, S.M. (1996), "Forecasting enrollments based on fuzzy time series." *Fuzzy Sets and Systems*, 81(3), PP. 311-319.
- 9- Padmakumari, K., Mohandas, K. and Thiruvengadam, S. (1999), "Long term distribution demand forecasting using neuro fuzzy computations." *Electrical Power and Energy Systems* 21, PP. 315-322.
- 10- Nauck, D. and Kruse, R. (1999), "Neuro-fuzzy systems for function approximation." *Fuzzy Sets and Systems* 101, PP. 261-271.

- 11- JSR, J. (1993), ANFIS: Adaptive-network-based fuzzy inference system, *IEEE Trans Systems, Man, Cyb.* 23, PP. 665–85.
- 12- Wang, W. and Chen, Z. (2007), “A neuro-fuzzy based forecasting approach for rush order control applications.” *Expert Systems with Applications* xxx, PP. xxx–xxx.
- 13- Hong, Y. and Lee, C. (2005), “A neuro-fuzzy price forecasting approach in deregulated electricity markets.” *Electric Power Systems Research* 73, PP. 151–157.
- 14- Abraham, A. and Nath, B. (2001), “A neuro-fuzzy approach for modeling electricity demand in Victoria.” *Applied Soft Computing* 1, PP. 127–138.
- 15- Lee, V. and Wong, H. (2007), “A multivariate neuro-fuzzy system for foreign currency risk management decision making.” *Neurocomputing* 70, PP. 942–951.
- 16- Smith, K., Gupta, N. and Jatinder, D. (2000) "Neural networks in business: techniques and applications for the operations researcher." *Computers & Operations Research* 27, PP.1045-1076.
- 17- Hwang, H B. and Ang, H. T. (2001), "A simple neural network for ARMA (p; q) time series." *Omega* 29, PP. 319 – 333.
- 18- Demuth, H. and Beale, B. (2004) *Neural Network Toolbox User Guide*, The Mathworks Inc, Natick.
- 19- Thawornwong, S. and Enke, D. (2000), "The adaptive selection of financial and economic variables for use with artificial neural networks." *Neurocomputing* 31, PP. 1-13.
- 20- Nasr, G., Badr, E.A. and Joun, C. (2003) "Back propagation neural networks for modeling gasoline consumption." *Energy Conversion and Management* 44, PP. 893 –905.
- 21- Dubois, D. and Prade, H. (1980), "Theory and Applications.” *Fuzzy Sets and Systems*, Academic Press, New York.
- 22- Ishibuchi, H. and Tanaka, H. (1988) "Interval regression analysis based on mixed 0-1 integer programming problem." *J. Japan Soc. Ind. Eng* 40, (5), PP. 312 - 319.
- 23- Khashei, M. (2005), *Forecasting and analysis of Esfahan Steel Company productions price in Tehran Metals Exchange using Artificial Neural Networks*, Master of Science Thesis, Isfahan University of Technology.