

فصلنامه پژوهشنامه بازرگانی، شماره ۴۰، پاییز ۱۳۸۵، ۵۲ -

مدل سازی پیش بینی قیمت سهام با رویکرد شبکه های عصبی فازی

دکتر عادل آذر* امیر افسر**

شبکه های عصبی فازی / منطق فازی / شبکه های عصبی مصنوعی /
قیمت سهام / پیش بینی

چکیده

پیش بینی قیمت سهام در بورس اوراق بهادار از اهمیت خاصی برخوردار است، زیرا نشان دهنده وضعیت کلی مطلوب یا نامطلوب سرمایه گذاری برای سهامداران و سرمایه گذاران است. در میان روش های پیش بینی، شبکه های عصبی مصنوعی و منطق فازی در بسیاری از زمینه های کاربردی استفاده شده اند و هر کدام آن ها دارای محاسن و معایبی هستند. این مقاله به دنبال ترکیب تئوری استدلال فازی با روش شبکه های عصبی جهت بهبود دقت و سرعت همگرایی مدل پیش بینی است. بنابراین، یک مدل ترکیبی شبکه های عصبی و تئوری استدلال فازی بر اساس مدل استدلال تاکاگی سوگنو در نظر گرفته شده است.

در این تحقیق، مدل شبکه های عصبی فازی پیش بینی قیمت سهام طراحی شده و از لحاظ شش معیار ارزیابی عملکرد با روش ARIMA مقایسه شده

* دانشیار دانشگاه تربیت مدرس.

** عضو هیأت علمی دانشگاه قم.

است، نتایج تحقیق بیانگر این حقیقت است که شبکه‌های عصبی فازی در تمامی شش معیار ارزیابی عملکرد بر روش ARIMA برتری داشته است و دارای ویژگی‌های منحصر بفرد همگرایی سریع، دقت بالا، و توانایی تقریب تابع قوی هستند و برای پیش‌بینی شاخص قیمت سهام مناسب می‌باشند.

طبقه‌بندی JEL: G24, G15, C45, C32.

مقدمه

امروزه در موضوعات اقتصادی - بازرگانی، پیش‌بینی به عنوان یکی از مهمترین شاخه‌های علمی مطرح شده است و روز به روز توسعه و پیشرفت می‌نماید. مدیران بخش‌های مختلف اقتصادی و بازرگانی، به دلیل وجود انبوه متغیرهای تأثیرگذار، ترجیح می‌دهند مکانیزمی را در اختیار داشته باشند که بتواند آن‌ها را در امور تصمیم‌گیری‌شان یاری و مشاوره دهد؛ به همین دلیل، سعی در روی آوردن به روش‌هایی در پیش‌بینی دارند که به واسطه آن‌ها تخمین‌هایشان به واقعیت نزدیک و خطایشان بسیار کم باشد. توجه به روش‌های نوین پیش‌بینی (از قبیل روش‌های شبکه‌های عصبی مصنوعی و الگوریتم‌های فازی) سبب شده است تا چالش‌های دیگری در علم پیش‌بینی ایجاد شود. در مطالعات مختلف انجام شده موضوعات اقتصادی، مالی و بازرگانی، این روش‌ها جواب‌های متعددی داده‌اند. در بعضی مطالعات که با استفاده از داده‌های سری زمانی یک یا چند متغیره صورت گرفته است، روش‌های پیش‌بینی شبکه عصبی جواب بهتری داده و با داده‌ها برازش بهتر پیدا نموده‌اند، اما در بعضی مدل‌های دیگر، روش کلاسیک مانند اقتصادسنجی و یا روش‌های هموارسازی نمائی، جواب‌های بهتر داده‌اند.^۱

در سال‌های اخیر، شبکه‌های عصبی مصنوعی به طور متداول به عنوان ابزار تقریبی غیرخطی استفاده شده‌اند و دارای محاسن زیادی در پیش‌بینی، طبقه‌بندی، خوشه‌بندی و تکنیک‌های بهینه‌سازی هستند. با این همه، شبکه‌های عصبی مصنوعی مبتنی بر الگوریتم پس‌انتشار خطا دارای برخی ضعف‌ها مانند گیر کردن شبکه در نقطه مینیمم محلی هستند و سرعت همگرایی محاسبات اغلب پایین است که بر روایی و دقت مدل پیش‌بینی تأثیر می‌گذارد. بنابراین، محققین ترغیب شدند تا تئوری استدلال فازی را با شبکه‌های عصبی مصنوعی جهت بهبود سرعت همگرایی و دقت مدل پیش‌بینی ترکیب نمایند. بنابراین، شبکه عصبی فازی بر مبنای مدل استدلال تاکاگی - سوگنو^۲ بهبود یافته را پیشنهاد نمودند.

1. آذر و رجب زاده (۱۳۸۲).

2. Takagi-Sugeno.

۱. شبکه‌های عصبی فازی

در طی دهه اخیر شاهد حضور موفق شبکه‌های عصبی مصنوعی^۱ بوده‌ایم. ایده آموزش برای حل مسائل شناسایی الگوهای پیچیده با استفاده از دیدگاه عامل‌های داده هوشمند برای محققان دانشگاهی بسیار چالش برانگیز شده است. شبکه‌های عصبی ابزار محاسباتی ساده‌ای برای آزمون داده‌ها و ایجاد مدل از ساختار داده‌ها است. داده‌هایی که برای ایجاد مدل‌ها استفاده می‌شوند، به داده‌های آموزشی مشهور هستند. هر گاه شبکه عصبی از داده‌های آموزشی برای یادگیری الگوهای موجود در داده‌ها استفاده کند، می‌تواند آن‌ها را برای دستیابی به خروجی‌ها و نتایج مختلف بکار بگیرد.

انواع مختلفی از شبکه‌های عصبی مصنوعی با توجه به اهداف تحقیق می‌توانند مورد استفاده قرار گیرند که یکی از معروف‌ترین آن‌ها، شبکه عصبی چند لایه پیش‌خور^۲ (MFNN) می‌باشد. شبکه عصبی چند لایه پیش‌خور، مثالی از شبکه عصبی آموزش داده شده با استفاده از ناظر است. بر طبق مطالعات اخیر^۳، بیش از پنجاه درصد مطالعات کاربردی بازرگانی شبکه عصبی گزارش شده، از شبکه‌های عصبی چند لایه پیش‌خور (MFNNها) با قوانین الگوریتم یادگیری پس انتشار استفاده کرده‌اند. این نوع شبکه عصبی بدلیل کاربردهای گسترده در بسیاری از ابعاد مسائل مربوط به مدیریت، مانند پیش‌بینی اصولی، طبقه‌بندی و مدل‌سازی، بسیار محبوب است. MFNN برای حل مسائلی که شامل یادگیری ارتباط بین یک مجموعه ورودی‌ها و خروجی‌های مشخص هستند، مناسب می‌باشد. که در حقیقت یک تکنیک آموزش با ناظر برای یادگیری ارتباط‌های بین داده‌ها با استفاده از مجموعه داده‌های آموزش است.

شبکه‌های عصبی از ورودی‌ها، ضرایب سیناپسی، مجموعه‌ای از نرون‌ها و خروجی‌ها تشکیل می‌شود. فرض کنید بردار ورودی‌های $[x_1, x_2, \dots, x_n]^T$ به نرون‌ها وارد شوند و ضرایب سیناپسی آن‌ها به ترتیب برابر $W_{1j}, W_{2j}, \dots, W_{nj}$ باشد. این ضرایب گرچه در بیشتر اوقات به صورت ضرایب ثابت اسکالر در نظر گرفته شده‌اند، اما می‌توان آن‌ها را به

1. Artificial Neural Networks.
2. Multilayered Feedforward Neural Network.
3. Wong et al. (2000).

عنوان تابعی از ورودی مربوطه در نظر گرفت. در این حالت ضرایب سیناپسی به صورت $W_{1j}(X_1), \dots, W_{nj}(X_n)$ نشان داده می‌شود. هم چنین در حالت کلی می‌توان ورودی‌های نرون Z را به صورت بردار $[d_{1j}, \dots, d_{nj}]$ در نظر گرفت، بطوری که $d_{ij} = W_{ij}(x_i)$ باشد. اگر سطح فعالیت نرون (برآیند ورودی‌های نرون) از یک مقدار آستانه ای T بیشتر باشد، خروجی نرون فعال خواهد شد. نحوه محاسبه برآیند ورودی‌ها در شبکه‌های عصبی فازی از اهمیت ویژه‌ای برخوردار است و با توجه به نحوه محاسبه آن‌ها، با انواع مختلفی از شبکه‌های عصبی فازی مواجه خواهیم شد. اگر تعداد ورودی‌های نرون برابر n باشد، برآیند ورودی‌ها به طور کلی بصورت زیر نمایش داده می‌شود:

$$I_j = \sum_{i=1}^n d_{ij}$$

و بالاخره خروجی نرون Z با استفاده از تابع تبدیل ϕ_j محاسبه خواهد شد. خروجی نرون عصبی Z_j (به طور کلی به صورت زیر است):

$$Y_j = \phi_j[I_j, T_j]$$

الگوریتم یادگیری پس انتشار خطا^۱ بدین صورت است که برای یک الگوی ورودی داده شده، شبکه یک خروجی Z_k (یا مجموعه ای از خروجی‌ها) را ایجاد می‌کند و این واکنش را با واکنش مطلوب هر عصب d_k مقایسه می‌کند. این مقدار برای مسایل پیش‌بینی، مقداری پیوسته می‌باشد. وزن‌های شبکه سپس برای صحیح شدن یا کاهش خطا اصلاح می‌شوند و الگوی بعدی نمایان می‌شود. اصلاح وزن‌ها به طور پیوسته در این روال تا زمانی که کل خطاها از سطح تولرانس از پیش تعیین شده کمتر شود، ادامه می‌یابد.^۲ دلیل اینکه تأثیر این به روز رسانی ورودی‌ها به صورت تدریجی مجذور میانگین خطا (MSE) را به حداقل می‌رساند، این است که تمامی الگوهای ورودی، متکی بر این حقیقت هستند که الگوریتم یادگیری پس انتشار خطا، گرادیان نزولی در تابع خطا دارد. به طور کلی، شبکه‌های عصبی مصنوعی برای مقصودی که ما از آن استفاده می‌کنیم،

1. Backpropagation.

2. Wrebos (1974); Le Cun (1985); Parker (1985).

توانایی بالایی در توسعه یک مدل در زمانی منطقی را ندارد. از سوی دیگر، مدل‌سازی فازی برای کاربرد ادغام تصمیمات از متغیرهای متفاوت، نیازمند یک رویکرد جهت یادگیری از تجربیات (داده‌های جمع آوری شده) است. شبکه‌ای عصبی مصنوعی و مدل فازی در بسیاری از زمینه‌های کاربردی استفاده شده‌اند و هر کدام آن‌ها دارای محاسن و معایبی هستند. بنابراین، ترکیب موفقیت‌آمیز این دو دیدگاه، مدل‌سازی شبکه‌های عصبی مصنوعی و فازی، موضوع مطالعات آتی قرار گرفته است.

در میان روش‌های مدل‌سازی نوین، سیستم‌های فازی جایگاه ویژه‌ای را کسب نموده‌اند. این امر را می‌توان معلول توانایی پیاده‌سازی دانش بشری با استفاده از مفهوم برچسب‌های زبانی و قواعد فازی، غیرخطی بودن و قابلیت تطبیق‌پذیری این نوع سیستم‌ها دانست. به طور خلاصه یک سیستم فازی یک سیستم مبتنی بر قواعد منطقی اگر - آنگاه است. نقطه شروع ساخت یک سیستم فازی به دست آوردن مجموعه‌ای از قواعد اگر - آنگاه فازی از دانش فرد خبره یا دانش حوزه مورد نظر است. به دست آوردن این قواعد مهمترین و سخت‌ترین مرحله کار است. چراکه نیازمند دانش بالای فرد متخصص و پیاده‌سازی صحیح آن است. داشتن روشی که در کنار دانش بشری بتوان از اطلاعات عددی موجود برای ساخت قواعد استفاده کرد نیز می‌تواند در این مرحله بسیار مفید باشد. به این صورت موفق به پیاده‌سازی یک سیستم فازی به گونه‌ای شده‌ایم که قابلیت یادگیری داشته باشد. بنابراین قادر خواهیم بود که خطای مقادیر خروجی را با استفاده از روش کمترین مجموع مربعات خطا به دست آوریم. با ترکیب این روش و روش پس انتشار خطا به یک روش آموزش ترکیبی دست پیدا نموده‌ایم که به این صورت عمل می‌کند؛ در هر دور آموزش، هنگام حرکت رو به جلو خروجی‌های گره‌ها به صورت عادی تا لایه آخر محاسبه می‌شوند و سپس پارامترهای نتیجه توسط روش کمترین مجموع مربعات خطا محاسبه می‌شوند. در ادامه پس از محاسبه خطا در بازگشت رو به عقب نسبت خطا بر روی پارامترهای شرط پخش شده و با استفاده از روش شیب نزولی خطا مقدار آن‌ها تصحیح می‌شود.

ساختار نرون فازی همانند نرون فضای قطعی است با این تفاوت که همه یا بعضی از

اجزاء و پارامترهای آن در قالب منطق فازی بیان می‌شوند. برای تبدیل یک نرون معمولی به نرون فازی راه‌های مختلفی وجود دارد که استفاده از هر کدام از آن‌ها ما را به انواع مختلفی از نرون‌های فازی می‌رساند. در یک نرون فازی بردار ورودی مختلفی از فضای $x = [x_1, x_2, \dots, x_n]^T \in \mathbb{R}^n$ در فضای $[0,1]^n$ تعریف می‌شود. این بردار از علائم فازی که تابع عضویت آن‌ها در محدوده $[0,1]$ تعریف می‌گردد تشکیل شده است. ورودی‌ها پس از اعمال تغییرات توسط ضرایب، به صورت ورودی خالص وارد نرون می‌گردند. تغییر ورودی‌ها در اثر ضرایب به انواع مختلفی ممکن است. این تغییر می‌تواند به صورت ضرب معمولی و نیز می‌تواند به شکل ماکزیمم ورودی و ضریب مربوطه باشد. برآیند ورودی‌های نرون را می‌توان با استفاده از عملگرهای \wedge Min و \vee Max محاسبه کرد. به عنوان مثال:

$$I_j = \wedge_{i=1}^n d_{ij} = \wedge_{i=1}^n x_i w_{ij}$$

مفهوم نرون فازی را می‌توان چنین تصور کرد که هر نرون فازی نمایشی است از یک متغیر زبانی مانند متوسط^۱، کم^۲ و غیره. بنابراین خروجی نرون I_j بیانگر یک تابع عضویت است یعنی درجه تعلق بردار ورودی $[x_1, x_2, \dots, x_n]^T$ را به یک مقوله زبانی نشان می‌دهد.

۲. ادبیات تحقیق

تحقیقات زیادی در زمینه پیش‌بینی قیمت سهام، شاخص قیمت سهام، بازده سرمایه‌گذاری و ریسک سهام به وسیله شبکه‌های عصبی مصنوعی تا کنون انجام گرفته است که می‌توان به تحقیق‌های Wang و دیگران در پیش‌بینی روند بازار سهام، Wittkemper و Steiner در پیش‌بینی ریسک سیستماتیک سهام، Bharati و Desai در پیش‌بینی بازده سهام‌های بزرگ، Qi در پیش‌بینی بازده سهام، Leung و دیگران در پیش‌بینی بازده سهام، Dhar و Chou در پیش‌بینی درآمد و بازده اشاره نمود. در زمینه

1. Medium.

2. Low.

ترکیب منطق فازی و شبکه‌های عصبی فازی نیز تحقیقات زیادی انجام شده است. Kuo و Cohen یک ANN پیش‌خور با سیستم استدلال فازی به وسیله مدل‌سازی فازی تاکاگی ارائه داده‌اند. Hayashi و Buckley یافته‌های جدید در الگوریتم یادگیری و کاربردهای آن برای FNN را مورد بررسی قرار داده‌اند. FNN تأکید شده در موارد فوق، فقط برای داده‌های عددی مناسب هستند. اما معمولاً دانش خبرگان از نوع فازی است. بنابراین برخی محققان تلاش‌هایی برای حل این مشکل انجام داده‌اند. Ishibuchi و دیگران، روش‌های یادگیری شبکه‌های عصبی دیگری را ارائه داده‌اند که نه فقط برای داده‌های عددی بکار روند، بلکه اغلب دانش خبره بوسیله قوانین اگر - آنگاه فازی ارائه شود. Lee و Lin یک FNN ارائه داده‌اند که قادر است هم ورودی‌ها و هم خروجی‌های فازی را اداره کند. Kuo و دیگران نیز یک سیستم پشتیبان تصمیم‌هوشمند بر مبنای شبکه‌های عصبی فازی برای پیش‌بینی و معامله سهام ارائه داده‌اند.

۳. بررسی تجربی پیش‌بینی قیمت سهام

برای مدل‌سازی پیش‌بینی قیمت سهام در این تحقیق از دو روش شبکه‌های عصبی فازی و ARIMA استفاده شده است. داده‌های روزانه قیمت سهام بورس اوراق بهادار در بازه زمانی پنج ساله مهرماه ۱۳۷۸ تا مهرماه ۱۳۸۳ به صورت سری زمانی انتخاب شده است. در طراحی شبکه‌های عصبی فازی، با توجه به تعداد زیاد داده‌ها، نیمی از داده‌ها به عنوان داده‌های آموزشی، ۲۵٪ به عنوان داده‌های آزمایشی و باقیمانده به عنوان داده‌های اعتبارسنجی انتخاب شده‌اند.

قبل از پردازش داده‌ها بوسیله شبکه‌های عصبی فازی، داده‌ها باید نرمال‌سازی شوند تا توان پیش‌بینی بالاتر رود. بنابراین تبدیلی بر روی داده‌های ورودی به شبکه انجام می‌شود که داده‌ها در فاصله $[L, H]$ قرار گیرند. این کار با استفاده از رابطه زیر انجام می‌شود:

$$X_{\text{scaled}} = mX_i + b$$

که در این رابطه:

$$m = \frac{H - L}{X_{\text{max}} - X_{\text{min}}}, \quad b = \frac{X_{\text{max}} \cdot L - X_{\text{min}} \cdot H}{X_{\text{max}} - X_{\text{min}}}$$

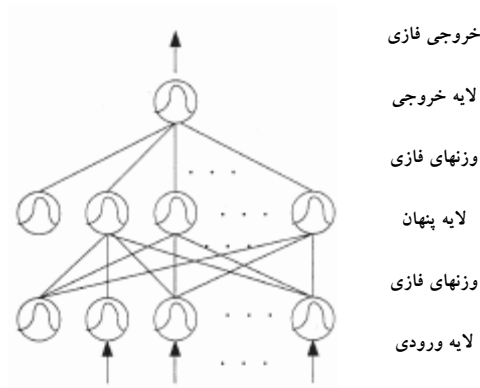
در این رابطه، H و L حد بالا و پایین فاصله نرمال‌سازی هستند و معمولاً برابر 1 و -1 در نظر گرفته می‌شوند، X_{\max} ، X_{\min} نیز به ترتیب مقادیر کمینه و بیشینه X_i ها هستند. در این صورت رابطه ذکر شده به شکل ساده‌تر زیر که اغلب مورد استفاده قرار می‌گیرد، تبدیل می‌شود:

$$X_n = \frac{2(X - X_{\min})}{X_{\max} - X_{\min}} - 1$$

انتخاب فاصله $[L, H]$ بسته به نوع مسئله مورد نظر و تابع تبدیل انتخاب شده، متفاوت است. فاصله‌هایی که بیشتر از بقیه مورد استفاده قرار می‌گیرند، $[1, 0]$ و $[0, 1]$ هستند، که برای توابع تبدیل هیپربولیک و لگستیک بکار می‌روند^۱. در این تحقیق داده‌ها در فاصله $[1, -1]$ نرمال‌سازی شده‌اند.

۳-۱. طراحی مدل شبکه‌های عصبی فازی

ساختارهای مختلفی برای پیاده‌سازی یک سیستم فازی توسط شبکه‌های عصبی پیشنهاد شده‌اند که یکی از پر قدرت‌ترین این ساختارها، ساختار موسوم به شبکه عصبی انطباقی بر مبنای سیستم استدلال فازی^۲ (ANFIS) است که توسط Jang ابداع گردیده است^۳. معماری سیستم استدلال عصبی فازی در شکل (۱) نشان داده شده است.



شکل ۱- معماری شبکه عصبی فازی

1. Wilson et al., (2002).
2. Adaptive-Network-based Fuzzy Inference Systems.
3. Jang (1991, 1993).

در طراحی مدل شبکه‌های عصبی فازی، از شبکه عصبی چند لایه پیش‌خور (MFNN) با الگوریتم یادگیری پس انتشار خطا و سیستم استنتاج فازی ساگنو^۱ با تابع ورودی "تفاوت دو تابع سیگموئید" و تابع خروجی خطی و برای غیرفازی نمودن از تابع میانگین متحرک استفاده گردید. برای طراحی سیستم بهینه شبکه‌های عصبی فازی، از طریق تغییر مداوم تعداد لایه‌ها و تعداد نرون‌های لایه پنهان، توپولوژی مناسب شبکه عصبی مورد بررسی قرار گرفت و از طریق تغییر مداوم توابع عضویت مختلف و تعداد توابع عضویت، سیستم مناسب پایگاه استنتاج فازی طراحی شد. تعداد توابع عضویت استفاده شده در این تحقیق، ۱۰۰ تابع می‌باشد. تابع عضویت یک مجموعه فازی یک نگاشت از اعضای مجموعه A در بازه [۰، ۱] است به گونه‌ای که:


$$A: X \rightarrow [0,1]$$

در حالت کلی هر تابعی که چنین نگاشتی را پیاده کند می‌تواند به عنوان تابع عضویت یک مجموعه فازی مورد استفاده واقع شود. همانطور که اشاره شد، برای تابع ورودی در این تحقیق از تابع تفاوت دو تابع سیگموئید استفاده گردیده است. این تابع در شکل (۲) نشان داده شده است. یک تابع عضویت سیگموئید به صورت زیر تعریف می‌گردد؛

$$f(x; a, c) = \frac{1}{1 + e^{-a(x-c)}}$$


تابع عضویت تفاوت دو تابع سیگموئید به چهار عامل بستگی دارد که عبارتند از: a_1 ، c_1 ، a_2 و c_2 .

$$f_1(x; a_1, c_1) - f_2(x; a_2, c_2)$$




شکل ۲- تابع عضویت تفاوت دو تابع سیگموئید ($a_1=5, c_1=2, a_2=5, c_2=7$)

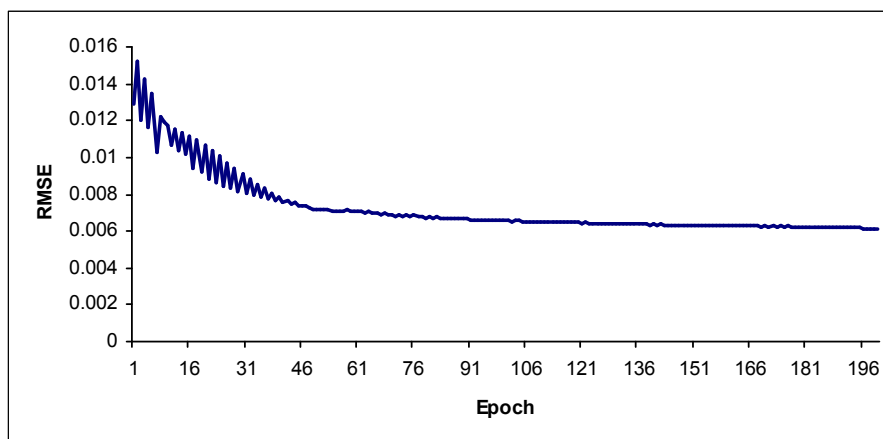
به این صورت موفق به پیاده‌سازی یک سیستم فازی به گونه‌ای شده‌ایم که قابلیت یادگیری داشته باشد. بنابراین قادر خواهیم بود تا خطای مقادیر خروجی را با استفاده از روش جذر میانگین مجذور خطا (RMSE) به دست آوریم. با ترکیب این روش و روش پس انتشار خطا به یک روش آموزش ترکیبی دست پیدا نموده‌ایم که به این صورت عمل می‌کند؛ در هر دور آموزش، هنگام حرکت رو به جلو خروجی‌های گره‌ها به صورت عادی تا لایه آخر محاسبه می‌شوند و سپس پارامترهای نتیجه توسط روش جذر میانگین مجذور خطا محاسبه می‌شوند. در ادامه پس از محاسبه خطا در بازگشت رو به عقب نسبت خطا بر روی پارامترهای شرط پخش شده و با استفاده از روش شیب نزولی خطا مقدار آن‌ها تصحیح می‌شود. نمودار میزان بهبود مقدار RMSE در تکرارهای مختلف آموزش شبکه‌های عصبی فازی برای پیش‌بینی شرکت‌های مورد بررسی در شکل‌های (۳) تا (۶) نشان داده شده است. همان‌طور که مشاهده می‌شود، با افزایش تعداد تکرارها، میزان بهبود در مقدار RMSE کاهش یافته و تقریباً در تکرارهای پایانی هیچ‌گونه بهبودی حاصل نمی‌گردد. دوباره تأکید می‌شود که مقادیر خطا براساس داده‌های نرمال شده در فاصله $[-1, 1]$ می‌باشد و مقدار خطای واقعی باید پس از تبدیل این داده‌ها به داده‌های واقعی محاسبه گردد.



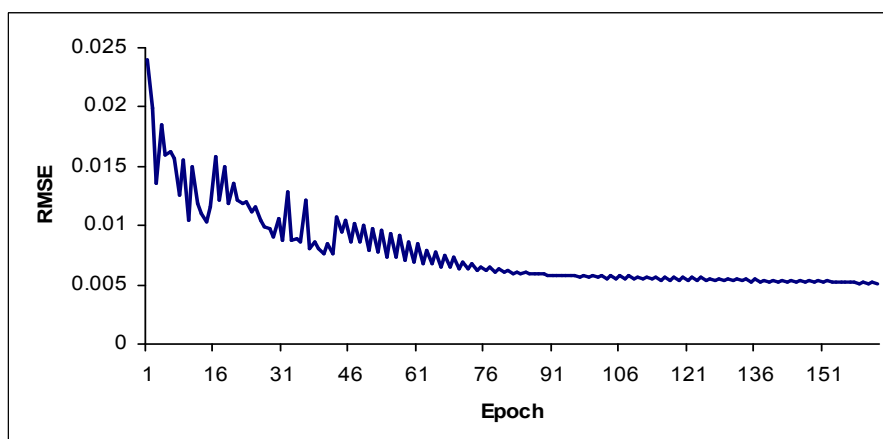
شکل ۳- مقدار RMSE در تکرارهای آموزش شبکه‌های عصبی فازی شرکت پتروشیمی آبادان



شکل ۴- مقدار RMSE در تکرارهای آموزش شبکه‌های عصبی فازی شرکت ایران خودرو



شکل ۵ - مقدار RMSE در تکرارهای آموزش شبکه‌های عصبی فازی شرکت توسعه صنایع بهشهر



شکل ۶ - مقدار RMSE در تکرارهای آموزش شبکه‌های عصبی فازی شرکت سرمایه‌گذاری غدیر

مقادیر شش معیار ارزیابی عملکرد مدل شبکه‌های عصبی فازی برای هر چهار شرکت نیز در جدول (۱) نشان داده شده است.

۲-۳. طراحی مدل ARIMA

یکی از معتبرترین فنون پیش‌بینی آماری، مدل ARIMA^۱ می‌باشد. این روش عبارت است از برآوردن یک الگوی میانگین متحرک تلفیق شده با خودرگرسیو^۲ به مجموعه داده‌ها و بدست آوردن الگوی ریاضی شرطی است. یک مدل ARIMA سه جزء دارد: (۱) خودرگرسیو، (۲) میانگین یکپارچه و (۳) میانگین متحرک. ساختمان مدل بنیادی ARIMA مشتمل بر چهار مرحله است، این مراحل عبارتند از: (۱) توجیه و شناسایی مدل، (۲) تخمین پارامتر (۳) تشخیص و دریافت مدل (۴) تأیید، پیش‌بینی و منطقی بودن.

مدل $ARIMA(p,d,q)$ عمومی و کلی می‌باشد. در این مدل p مرتبه خودرگرسیو مدل و q مرتبه میانگین متحرک مدل و d مرتبه تفاضلی مدل (جهت ایستا کردن مدل) می‌باشد. آنچه که این مدل را کاملتر از مدل‌های دیگر می‌نماید، تبدیل مناسب جهت پایا بودن مدل است.

$$\psi_p = (B)Z_t = \delta + \theta_q(B)a_t$$

که در آن

$$Z_t = (1 - \beta)^d y_t$$

و یا

$$Z_t = \nabla^d y_t$$

که y_t داده‌های سری زمانی داده شده می‌باشد. در ترکیبات مدل ARIMA به ندرت مقادیر q و d و p از ۲ بیشتر می‌شود و عملاً همین دامنه کوچک بسیاری از حالت‌های عملی موجود در پیش‌بینی را می‌پوشاند. در مدل ARIMA طراحی شده در این تحقیق، مرتبه خودرگرسیو (p)، برابر ۱، مرتبه میانگین متحرک مدل (q) برابر ۱ و مرتبه تفاضلی مدل (d) برابر ۱ می‌باشد ($ARIMA(1,1,1)$). مقادیر شش معیار ارزیابی عملکرد روش ARIMA برای هر چهار شرکت نیز در جدول (۱) نشان داده شده است.

1. Autoregressive-Integrated Moving Average.

2. Auto Regressive.

۳-۳. ارزیابی عملکرد پیش‌بینی

برای مسائل پیش‌بینی، از برخی معیارهای عملکرد برای نشان دادن چگونگی یادگیری ارتباط‌های داده‌ها در شبکه عصبی فازی استفاده می‌شود. در این تحقیق از ۶ معیار استفاده می‌شود که سه مورد اول از خانواده محاسبات میانگین خطای استاندارد هستند: مربع میانگین خطای استاندارد (MSE)، مربع مجذور میانگین خطا (RMSE)، و مربع میانگین خطای استاندارد نرمال شده (NMSE). دو مورد بعدی R^2 و NMSE هستند که R^2 ضریب تعیین است و در ارتباط با NMSE است و $NMSE=1-R^2$. مقدار R^2 بین صفر تا یک است و مقدار یک نشان‌دهنده تطابق کامل داده‌ها است، در حالی که مقدار صفر نشان‌دهنده عملکردی است که می‌توان از استفاده میانگین مقدار خروجی واقعی d به عنوان مبنای پیش‌بینی‌ها انتظار داشت. دو معیار بعدی در مورد خطای مطلق هستند: میانگین قدر مطلق خطا (MAE) و میانگین قدر مطلق درصد خطا (MAPE). از آنجا که هر یک از معیارهای ارزیابی عملکرد، جنبه خاصی را مورد ارزیابی قرار می‌دهد، برای ارزیابی عملکرد روش‌های شبکه‌های عصبی فازی و ARIMA از هر شش معیار فوق استفاده شده است. نتایج معیارهای ارزیابی عملکرد برای هر دو روش در جدول (۱) آورده شده است.

جدول ۱- معیارهای ارزیابی عملکرد برای روش‌های مختلف

روش	نام شرکت	RMSE	MSE	NMSE	MAPE	MAE	R^2
شبکه‌های عصبی فازی	پتروشیمی آبادان	۳۴/۱۹۶۷	۱۱۷۰	۰/۰۰۶۸۸	۰/۰۰۰۸۱۲	۱۹/۷۸۷۵	۰/۹۹۹۹۹
	ایران خودرو	۲۴/۲۴۸۸	۵۸۸/۰۰۳۵	۰/۰۰۰۹۹۸	۰/۰۰۰۱۳۲	۱۳/۶۱۸۳	۰/۹۹۹۹۹
	توسعه صنایع بهشهر	۲۱/۵۲۰۹	۴۶۳/۱۴۸۱	۰/۰۰۰۹۱۲	۰/۰۰۰۱۷۴	۱۱/۹۶۲۴	۰/۹۹۹۹۹
	سرمایه‌گذاری غدیر	۱۵/۷	۲۴۵/۲۹۸۸	۰/۰۰۰۷۳	۰/۰۰۰۹۲۶	۱۰/۹۲۸۳	۰/۹۹۹۹۹
ARIMA	پتروشیمی آبادان	۲۲۸/۱۶۹۴	۵۲۰۶۱	۰/۰۰۳۱	۰/۰۰۶۹	۱۴۶/۷۳۵۷	۰/۹۹۶۹
	ایران خودرو	۲۰۶/۸۹۴۲	۴۲۸۰۵	۰/۰۰۷۱	۰/۰۰۱۶۷	۸۹/۹۲۸	۰/۹۹۲۹
	توسعه صنایع بهشهر	۱۲۱/۸۳۵۱	۱۴۸۴۴	۰/۰۰۲۶	۰/۰۰۲۶۵	۷۴/۱۹۲۹	۰/۹۹۷۴
	سرمایه‌گذاری غدیر	۱۶۸/۴۶۱۵	۲۸۳۷۹	۰/۰۰۸۵	۰/۰۰۵۶	۷۵/۵۸۰۵	۰/۹۹۱۵

همانطور که در جدول (۱) مشاهده می‌شود، روش شبکه‌های عصبی فازی در هر چهار شرکت از لحاظ تمامی معیارهای ارزیابی عملکرد بر روش ARIMA برتری دارد. میزان بهبود خطای پیش‌بینی توسط معیارهای مختلف، متفاوت بوده است، برای مثال معیار RMSE نسبت به معیار MAE در استفاده از دو روش شبکه‌های عصبی فازی و ARIMA بهبود بیشتری نشان می‌دهد. این بدان دلیل است که معیارهای مختلف از روش‌های مختلفی برای محاسبه میزان خطا استفاده می‌کنند.

جمع‌بندی و ملاحظات

تحلیل سری‌های زمانی و پیش‌بینی، یک حوزه فعال پژوهش در طی چند دهه اخیر است. صحت پیش‌بینی سری‌های زمانی در بسیاری از فرایندهای تصمیم‌گیری اصولی و حیاتی است و به همین دلیل، پژوهش برای بهبود اثربخشی مدل‌های پیش‌بینی هرگز متوقف نشده است. با تلاش‌های Box و Jenkins، مدل ARIMA یکی از محبوبترین روش‌ها در حوزه پیش‌بینی شده است. در طی دهه اخیر، شبکه‌های عصبی فازی برای حل مسایل شناسایی الگوهای پیچیده با استفاده از دیدگاه عامل‌های داده هوشمند برای محققان دانشگاهی بسیار چالش برانگیز شده و در حوزه‌های مختلفی مورد استفاده قرار گرفته است. در این تحقیق مدل پیش‌بینی قیمت سهام با استفاده از شبکه‌های عصبی فازی و روش ARIMA طراحی شده و از لحاظ معیارهای عملکرد (MAE، NMSE، RMSE، MSE)، MAPE و R^2) با هم مقایسه شده‌اند. نتایج تحقیق نشان‌گر آن است که شبکه‌های عصبی فازی برای چهار شرکت مورد بررسی از لحاظ تمامی معیارهای عملکرد بر روش ARIMA برتری دارد. برای مثال، از نظر معیار RMSE میزان خطای شبکه‌های عصبی فازی به صورت چشمگیری نسبت به روش ARIMA کمتر است. این موضوع بدین دلیل است که داده‌های پیش‌بینی قیمت سهام ماهیت غیرخطی دارند. چنانچه داده‌های مورد استفاده به این میزان غیرخطی نبودند، میزان بهبود خطای روش شبکه‌های عصبی فازی بدین حد نمی‌شد و حتی ممکن بود روش خطی ARIMA پاسخ بهتری ارائه دهد. نتایج تجربی این تحقیق و تحقیقات مشابه نشان داده‌اند که ترکیب شبکه‌های عصبی مصنوعی و منطق فازی و ایجاد

شبکه‌های عصبی فازی موفقیت‌آمیز بوده و باعث کاهش قابل توجه در خطای پیش‌بینی شده است که خصیصه‌های قابل توجهی در همگرایی سریع، دقت بالا و توانایی تقریب تابع قوی دارد. علاوه بر این، از آنجا که سیستم شبکه‌های عصبی فازی نیازمند داده‌های صریح و قطعی نبوده و نمونه بزرگی از داده‌ها را نیاز ندارد، می‌تواند پیش‌بینی خوبی از شاخص قیمت سهام ارائه دهد و اطمینان می‌دهد که این روش نسبت به روش‌های کلاسیک پیش‌بینی مناسب‌تر است.

منابع

آذر، عادل و علی رجب زاده (۱۳۸۲)؛ "ارزیابی روش های پیش بینی ترکیبی: با رویکردهای شبکه های عصبی-کلاسیک در حوزه اقتصاد"، مجله تحقیقات اقتصادی، شماره ۶۳، صص. ۸۷-۱۱۴.

Buckley, J. J., Hayashi, Y. (1994); "Fuzzy neural networks: a survey", *Fuzzy Sets and Systems*, 66, pp. 1-13.

Desai, V. S. and Bharati, R. (1998); "A comparison of linear regression and neural network methods for predicting excess returns on large stocks", *Annals of Operations Research*, 78, pp. 127-163.

Dhar, V. and Chou, D. (2001); "A comparison of nonlinear methods for predicting earnings surprises and returns", *IEEE Transactions on Neural Networks*, 12(4), pp. 907-921.

Ishibuchi, H., Kwon, K., Tanaka, H. (1995); "A learning algorithm of fuzzy neural networks with triangular fuzzy weights", *Fuzzy Sets and Systems*, 71, pp. 277-293.

Ishibuchi, H., Okada, H., Fujioka, R., Tanaka, H. (1993); "Neural networks that learn from fuzzy if-then rules", *IEEE Trans. Fuzzy Systems*, FS-1, pp. 85-97.

Jang, J. R. and Sun, C. (1995); "Nero Fuzzy Modelling and Control", *Proc. of the IEEE*, pp. 378-405.

Jang, J. R. (1991); "Fuzzy Modeling Using Generalized Neural Networks and Kalman Filter Algorithm", *Proc. of the Ninth National Conf. on Artificial Intelligence (AAAI-91)*, pp. 762-767.

_____ (1993); "ANFIS: Adaptive-Neural-based Fuzzy Inference Systems", *IEEE Transactions on Systems, Man, and Cybernetics*, 23 (3), pp. 665-685.

Kuo, R. J., Chen, C. H. and Hwang, Y. C. (2001); "An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network", *Fuzzy Sets and Systems*, 118 (1), pp. 21-45.

- _____ (2001); "An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network", *Fuzzy Sets and Systems*, 118, pp. 21-45.
- Kuo, R.J., Lee, L.C., Lee, C.F. (1998); "Intelligent stock decision support system through artificial neural networks and fuzzy Delphi", *Comput. Intell. Finance*, 6, pp. 24-34.
- Le Cun, Y. (1985); "Une procedure d'apprentissage pour reseau a seuil assymetrique", *Cognitive*, 85, pp. 599-604.
- Lee, C.C. (1990); "Fuzzy logic in control systems: fuzzy logic controller", *IEEE Trans. Systems Man Cybernet*, Part I, 20 (2), pp. 404 - 418.
- Leung, M.T., Daouk, H., and Chen, A.-S. (2001); "Forecasting stock indices: A comparison of classification and level estimation models", *International Journal of Forecasting*, 16, pp. 173-190.
- Parker, D.B. (1985); "Learning logic: Casting the cortex of the human brain in silicon", Technical Report TR-47. Cambridge, MA. *Center for Computational Research in Economics and Management*, MIT.
- Qi, M. (1999); "Nonlinear predictability of stock returns using financial and economic variables", *Journal of Business & Economic Statistics*, 17(4), pp. 419-429.
- _____ (2001); "Predicting US recessions with leading indicators via neural network models", *International Journal of Forecasting*, 17(3), pp. 383-401.
- Wang, J.-H. and Leu, J.-Y. (1996); "Stock market trend prediction using ARIMA-based neural networks", *IEEE International Conference on Neural Networks*, pp. 2160-2165.
- Werbos, P.J. (1974); *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*, Cambridge, MA: Harvard University, Ph.D. dissertation.
- Wilson, I.D., Paris, S.D., Ware, J.A., D.H. (2002); "Residential property price time series forecasting with neural networks", *Knowledge-based Systems*, 15, pp. 335-341.

-
- Wittkemper, H. and Steiner, M. (1996); "Using neural networks to forecast the systematic risk of stocks", *European Journal of Operational research*, 90(3), pp. 577-588.
- Wong, B.K., Jiang, L. and Lam, J. (2000); "A bibliography of neural network business application research: 1994-1998", *Computers and Operations Research*, 27(11), pp. 1045-1076.