

ارائه مدلی برای پیش‌بینی قیمت سهام شرکت ایران خودرو به کمک شبکه‌های عصبی

محمد رضا عباس پور

کارشناس ارشد مهندسی سیستم‌های اقتصادی

abbaspour@ut.ac.ir

محمد رضا امین‌ناصری

استادیار دانشگاه تربیت مدرس

Amin-nas@modares.ac.ir

واژه‌های کلیدی

پیش‌بینی، شبکه عصبی، بازار بورس، پیش‌بینی قیمت سهام، شرکت ایران خودرو

چکیده

بی‌تردید امروزه بیشترین مقدار سرمایه از طریق بازارهای بورس در تمام جهان مبادله می‌شود. در حال حاضر عرضه و تقاضای سالانه ۵۰ میلیون خودرو در جهان صنعت خودروسازی را به یکی از صنایع بزرگ تبدیل کرده است. شرکت ایران خودرو با در اختیار داشتن حدود ۶۵٪ از سهم بازار خودرو کشور چه از نظر تولید و چه از نظر فروش، یکی از شرکت‌های مهم در بازار خودرو ایران و در نتیجه در بازار بورس می‌باشد و لذا تمایل روزافزونی مبنی بر پیش‌بینی قیمت سهام آن مشاهده می‌شود.

از طرف دیگر، امروزه علاقه فزاینده‌ای در استفاده از شبکه‌های عصبی برای پیش‌بینی قیمت سهام در بازار بورس بوجود آمده است. قدرت بالای تشخیص انواع الگوهای موجود در داده‌های بازار و تقریب توابع پیچیده از مشخصات ممتاز شبکه عصبی در کشف فرایند مولد قیمت بازار می‌باشد.

در این مقاله به پیش‌بینی قیمت سهام ایران خودرو (Iran Khodro Stock Exchange Price) IKSEP به کمک شبکه‌های عصبی پرسپترون خواهیم پرداخت. از این رو، پس از بررسی ادبیات موضوع، بوسیله آزمون گردش، امکان پیش‌بینی قیمت سهام شرکت ایران خودرو بررسی گردیده است. به علت نوسانات شدید موجود در داده‌های قیمت سهام شرکت ایران خودرو، روش خاصی برای انتخاب مجموعه تست و آموزش بکار گرفته شده و در نتیجه، قدرت برازش مدل شبکه به مراتب بهبود یافته است. همچنین تأثیر انواع توابع تبدیل برای لایه مخفی و خروجی و انواع ساختار شبکه از لحاظ تعداد گره‌های ورودی و مخفی بر عملکرد شبکه مورد بررسی قرار گرفته و آنها که در بهبود مدل شبکه موثر بوده‌اند، در مدل نهایی لحاظ گردیده‌اند و در نهایت بهترین مدل شبکه برای پیش‌بینی دوره‌های مختلف زمانی ارائه گردیده است.

۱- مقدمه

امروزه بازارهای بورس نه تنها از پارامترهای اقتصاد کلان، بلکه از بسیاری از عوامل دیگر متأثر می‌شوند. تعدد و ناشناخته بودن عوامل مؤثر بر بازار بورس، معمولاً موجب عدم اطمینان در زمینه سرمایه‌گذاری می‌شود. روشن است که خصوصیت عدم اطمینان، امر نامطلوبی است و از طرفی برای سرمایه‌گذارانی که بازار بورس را به عنوان مکان سرمایه‌گذاری انتخاب نموده‌اند، این خصوصیت اجتناب‌ناپذیر است. بنابراین بطور طبیعی تمام تلاش سرمایه‌گذار کاهش عدم اطمینان است و از این جهت پیش‌بینی بازار بورس یکی از ابزارهای کاهش عدم اطمینان می‌باشد.

در ادبیات موضوع، روش‌های گوناگونی برای پیش‌بینی بازار آمده است که می‌توان آنها را در چهار گروه طبقه‌بندی نمود:

- ✓ تحلیل فنی
- ✓ تحلیل بنیادی
- ✓ پیش‌بینی با استفاده از سری‌های زمانی کلاسیک
- ✓ استفاده از سیستم‌های هوشمند

تحلیل‌گران فنی یا نمودارگراها^۱ سعی می‌کنند بر اساس الگوهای موجود در نمودار داده‌های مربوط به بازار، آن را پیش‌بینی کنند. آنها با توجه به برداشت خود از نمودارها، الگوهایی را در جهت تعیین شاخص‌های روزانه، هفتگی و ماهانه بازار تعیین می‌نمایند. تحلیل‌گران بنیادی، با توجه به ارزش واقعی و ذاتی یک سهم اقدام به پیش‌بینی می‌نمایند. در پیش‌بینی با روش سری‌های زمانی کلاسیک، فرض بر این است که مقادیر آینده، سیر خطی مقادیر گذشته را می‌پیمایند. روش‌های هوشمند الگوهای خطی و غیرخطی موجود در داده‌های مربوط به بازار را دنبال می‌کنند تا بدین وسیله فرایند مولد آنها را تقریب بزنند. در این تحقیق تمرکز اصلی بر روش‌های هوشمند و بالخصوص شبکه عصبی می‌باشد.

در دهه اخیر "شبکه‌های عصبی" به عنوان یکی از پر استفاده‌ترین روش‌ها در زمینه طبقه‌بندی، تشخیص الگو و پیش‌بینی سری‌های زمانی بوده است. قدرت بالای تشخیص انواع الگوهای موجود در داده‌های بازار، تقریب توابع پیچیده، پایداری و انعطاف‌پذیری آن در برابر نویزهای داده‌ها، از مشخصات بارز و قدرتمند شبکه عصبی در کشف فرایند مولد قیمت بازار می‌باشد بطوریکه دومین زمینه پرکاربرد استفاده از شبکه‌های عصبی را، پیش‌بینی سری‌های زمانی به خود اختصاص داده است [2,18].

تحقیقات نشان می‌دهد که اکثر سری‌های زمانی در جهان واقعی دارای الگوهای غیرخطی و پیچیده می‌باشند؛ به‌طوری‌که محققان را بر آن داشته است که متدهای پیش‌بینی سری‌های زمانی غیرخطی را ایجاد نمایند. اما این متدها هم با توجه به فرضیات اولیه خود یک رابطه غیرخطی خاص را مورد توجه قرار می‌دهند و این رهیافت باعث عدم کشف الگوهای غیرخطی زیادی می‌شود که در اکثر سری‌های زمانی وجود دارند [2,13,17,18].

رهیافت شبکه‌های عصبی به عنوان روش داده‌محور^۲ و بدون در نظر گرفتن فرضیات موجود در روش‌های مدل‌گرا^۳ چشم‌انداز قدرتمند و نوینی در جهت تقریب توابع پیچیده می‌باشند. با توجه به تحقیقات صورت گرفته و مزایای این روش در مقایسه با روش‌های کلاسیک - که رأی به برتری شگفت‌انگیز شبکه‌های عصبی داده است - ضرورت استفاده از شبکه‌های عصبی در زمینه پیش‌بینی، بیش از پیش معلوم می‌گردد.

استفاده از شبکه‌های عصبی برای پیش‌بینی ایده جدیدی نیست. Hu در سال ۱۹۶۴ در رساله خود برای اولین بار این ایده را برای پیش‌بینی وضعیت هوا بوسیله شبکه‌های خطی تطبیقی ویدرو^۴ مورد استفاده قرار داد. بواسطه نقص الگوریتم آموزشی برای آموزش شبکه‌های چند لایه، این تحقیق کاملاً محدود شده بود. این محدودیت تا سال ۱۹۸۶ که رملهارت الگوریتم پس انتشار خطا^۵ را معرفی نمود، ادامه داشت و پس از آن گستره وسیعی از تحقیقات در این زمینه رشد نمود [18].

¹- Chartists

²- Data-driven

³- Model Based

⁴- Widrow

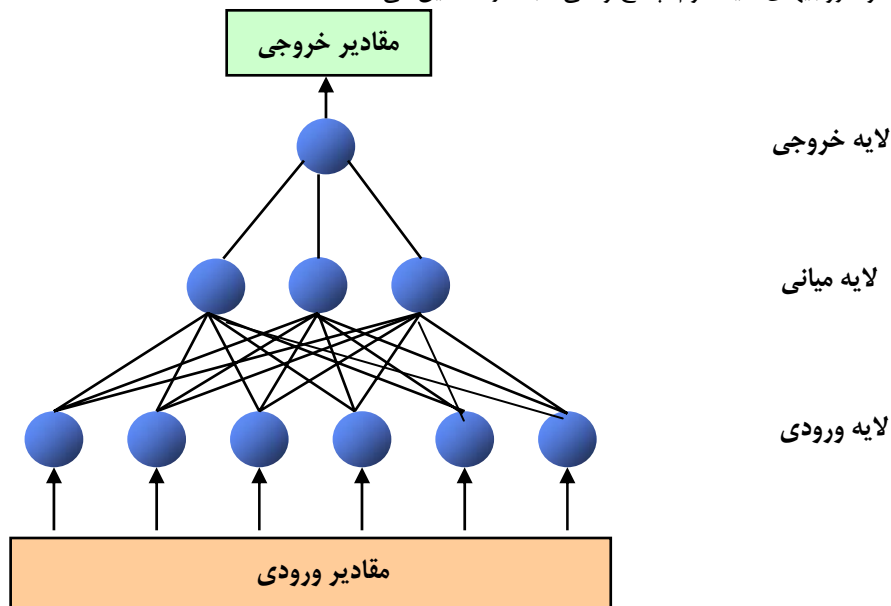
⁵- Backpropagation

خالوزاده در سال ۱۳۷۷، در رسالهٔ دکترای خود به مدل‌سازی و پیش‌بینی قیمت سهام شرکت شهید ایران با شبکه عصبی خاص MLP سه لایه با توابع تبدیل غیرخطی تانژانت هیپربولیک برای لایه مخفی و تابع تبدیل خطی برای لایه خروجی و قانون یادگیری BP استاندارد می‌پردازد. همچنین در این مطالعه قابلیت پیش‌بینی قیمت سهام شرکت بوسيله روش تخمین بعد همبستگی و روش تحلیل R/S بررسی شده است [9].

در سال ۱۹۹۶ کوهزادی در تحقیقی به مقایسه شبکه‌های عصبی و مدل‌های سری زمانی باکس‌جنکینز در پیش‌بینی قیمت ماهانه گندم از سال ۱۹۵۰ تا ۱۹۹۰ پرداخته است [10]. وایت، در تحقیقی پیش‌بینی بهره روزانه سهام شرکت IBM را با شبکه عصبی و مدل AR در نظر گرفته است [15]. در همین سال تحقیقی پیرامون پیش‌بینی شاخص سهام کوالا لامپور با استفاده از شبکه‌های عصبی توسط یو ترتیب داده شده است. در این تحقیق از تحلیل R/S برای مشخص نمودن تصادفی بودن سری زمانی داده‌ها استفاده شده است [16]. وانگ شبکه‌های عصبی مبتنی بر ARIMA (شبکه ترکیبی) را برای پیش‌بینی شاخص قیمت بازار بورس تایوان پیشنهاد می‌نماید [14]. در تحقیقی دیگر، ابراندویچ یک سیستم پیش‌بینی غیرخطی مبتنی بر شبکه عصبی برای پیش‌بینی شاخص سهام S&P طراحی می‌نماید [3]. ژانگ در سال ۱۹۹۸ پیش‌بینی نرخ ارز را با شبکه‌های عصبی و مدل گام زدن تصادفی مورد مطالعه قرار داده است [17]. در سال ۱۹۹۹ دینیز مطالعه‌ای برای پیش‌بینی سری زمانی قیمت یکی از شرکت‌های برزیلی در بازار بورس با شبکه عصبی و مدل باکس‌جنکینز انجام می‌دهد [5]. کاناس در سال ۲۰۰۱ پیش‌بینی بهره بازار را به وسیله مدل رگرسیون خطی و روش شبکه عصبی مورد مقایسه قرار می‌دهد. استینر و ویت کمپر عملکرد چند مدل رگرسیونی و شبکه عصبی را برای پیش‌بینی بهره سهام بازار بورس فرانکفورت مورد بررسی قرار می‌دهند [8]. در سال ۲۰۰۲ تحقیقی به منظور پیش‌بینی مقدار کل تولید صنایع ماشین‌سازی تایوان توسط تزنک انجام شده است. در این تحقیق مدل‌های (سری زمانی فصلی) SARIMA، شبکه عصبی و ترکیب این دو مورد بررسی قرار گرفته است [13]. در ادامه مقاله، پیش‌بینی سری‌های زمانی بوسیله شبکه‌های عصبی و قابلیت پیش‌بینی قیمت سهام در بخش‌های دوم و سوم بررسی می‌شود. در بخش چهارم ضمن بررسی مراحل طراحی مدل، مدل طراحی شده ارائه شده و به ترتیب، پیش‌بینی دو و هفت روز بعد، پیش‌بینی با استفاده از: متغیرهای بنیادی، انواع شبکه عصبی و روش‌های خطی ارائه می‌شود [1].

۲- پیش‌بینی سری‌های زمانی بوسیله شبکه عصبی

شبکه‌های عصبی پرسپترون به‌ویژه پرسپترون چند لایه در زمره کاربردی‌ترین شبکه‌های عصبی می‌باشند. در شکل ۱ یک شبکه پرسپترون سه لایه با معماری ۶-۳-۱ نمایش داده شده است. همانگونه که ملاحظه می‌شود، هر نرون (کوچکترین واحد پردازشگر اطلاعات که اساس شبکه‌های عصبی را تشکیل می‌دهد) در هر لایه به تمام نرون‌های لایه قبل متصل می‌باشد. به چنین شبکه‌هایی شبکه‌های کاملاً مرتبط گویند. شبکه فوق عملاً از به هم پیوستن دو شبکه پرسپترون تک لایه ایجاد شده است. خروجی‌های لایه اول، بردار ورودی لایه دوم را تشکیل می‌دهند و خروجی‌های لایه سوم پاسخ واقعی شبکه را تشکیل می‌دهند.



شکل ۱- یک شبکه عصبی با یک لایه میانی

چندین خصوصیت متمایز و منحصر به فرد شبکه‌های عصبی که برای کار پیش‌بینی جذاب می‌باشند ذیلاً تشریح می‌شوند:
نخست آنکه شبکه‌های عصبی بر خلاف روش‌های مبتنی بر مدل، روش‌هایی خود تطبیق ده و داده‌گرا می‌باشند. در این روشها فرضیات خیلی کمی در مورد مدل‌های مسائل مد نظر قرار می‌گیرد. آنها از مثال‌ها یاد می‌گیرند و روابط بین داده‌ها را حتی اگر این روابط ناشناخته یا سخت برای توصیف باشند بدست می‌آورند. بنابراین برای حل مسائلی که نیاز به دانش پیچیده‌ای دارند اما داده‌های کافی برای آنها وجود دارد، مناسب می‌باشند.

ویژگی دوم شبکه‌های عصبی این است که می‌توانند تعمیم بدهند. شبکه‌های عصبی اغلب می‌توانند به طور صحیح داده‌هایی را که در مرحله آموزش استفاده نشده‌اند، استنباط نمایند.

سوم آنکه شبکه‌های عصبی یک تقریب‌زننده جامع^۱ می‌باشند. در تئوری نشان داده شده است که شبکه عصبی می‌تواند، هر تابع را با هر دقت دلخواه تقریب بزند [2,6,7].

ویژگی بعدی شبکه‌های عصبی این است که غیرخطی هستند. پیش‌بینی سری‌های زمانی از قبیل باکس جنکینز فرض می‌نماید که سری زمانی تحت مطالعه از یک فرایند خطی حاصل می‌شود.

موارد ذیل باید در پیش‌بینی سری‌های زمانی با استفاده از شبکه عصبی در نظر گرفته شود [11,18]:
معماری شبکه: به معنی تعیین تعداد گره‌های ورودی، تعداد لایه‌های مخفی، گره‌های مخفی و تعداد گره‌های خروجی می‌باشد. انتخاب این پارامترها بستگی به مسئله مورد بحث دارد.

لایه‌های مخفی و گره‌های مخفی: گره‌های مخفی در لایه‌های مخفی به شبکه عصبی اجازه می‌دهند خصوصیات داده‌ها را کشف و شناسایی نماید تا بوسیله آن نگاشت‌های غیرخطی پیچیده را بین متغیرهای ورودی و خروجی برقرار نماید. در مورد تعداد گره‌های مخفی شبکه‌های عصبی ملزم به رعایت اصل صرفه‌جویی^۲ می‌باشند که در آن قدرت تعمیم بهتر را از آن شبکه با تعداد گره‌های مخفی کمتر می‌دانند. محققین برای محدود نمودن تعداد گره‌های مخفی برای جلوگیری از مسئله **Overfitting** (یعنی یاد گرفتن دقیق خود داده‌های آموزش، نه رابطه بین آنها که باعث می‌شود شبکه در مرحله آزمایش قدرت تعمیم نداشته باشد) تعداد آنها را حداکثر دو برابر تعداد گره‌های ورودی در نظر گرفته‌اند که در اغلب موارد این انتخاب ابتکاری، نتایج خوبی داده است [2,18].

تعداد گره‌های ورودی: برابر است با تعداد مشاهدات تاخیری که برای کشف کردن الگوی اساسی در سری زمانی استفاده می‌شود. ایده‌آل آن است که تعداد کمی از گره‌های ورودی بتوانند خصوصیات منحصر به فرد موجود در داده‌ها را به شبکه معرفی نمایند. یکی از مسائل مهم و شاید مهم‌ترین مسئله در پیش‌بینی سری‌های زمانی انتخاب تعداد ورودی‌ها می‌باشد. زیرا هر الگوی ورودی شامل اطلاعات مهمی در مورد ساختار خود همبسته پیچیده داده‌ها^۳ می‌باشد.

تعداد گره‌های خروجی: در پیش‌بینی سری‌های زمانی اغلب تعیین تعداد گره‌های خروجی وابسته به افق پیش‌بینی می‌باشد. دو نوع افق پیش‌بینی در مطالعات مورد استفاده قرار گرفته است. نخست افق پیش‌بینی یک روز بعد است و دوم، افق پیش‌بینی چند روز بعد می‌باشد. معمولاً تعداد گره‌های خروجی برای نوع اول یک و برای نوع دوم یک یا چند گره است.

اتصالات گره‌ها: اتصالات بین گره‌ها اساس رفتار شبکه را مشخص می‌نمایند. در اکثر موارد مخصوصاً در مورد پیش‌بینی، از شبکه با اتصالات کامل بین گره‌ها استفاده می‌شود.

تابع تبدیل: تابع تبدیل یا فعال‌ساز یا فشرده‌ساز، ارتباط بین ورودی و خروجی یک گره و یک شبکه را مشخص می‌نماید. این توابع درجه‌ای از غیرخطی بودن را به شبکه تزریق می‌نمایند که برای اکثر کاربردهای شبکه عصبی ارزشمند و مهم می‌باشد. توابع تبدیل به کار گرفته شده توسط محققان در پیش‌بینی اغلب سیگموئید (لجستیک)، تانژانت هیپربولیک و خطی بوده‌اند [2,12,18].

نرمال کردن داده‌ها: نرمال‌سازی داده‌ها باعث می‌شود داده‌های مورد استفاده در دامنه‌ای خاص، فشرده و هماهنگ شوند. نرمال‌سازی مخصوصاً در مواقعی که از توابع سیگموئید یا تانژانت هیپربولیک به عنوان تابع تبدیل شبکه استفاده می‌شود توصیه می‌شود [18]. در

1- Universal Function Approximation

2- Parsimony Principle

3- Complex Autocorrelation

تحقیقات عمدتاً از دو روش نرمال‌سازی خطی و آماری به شرح زیر استفاده می‌شود: (x نمایانگر داده خام، x_{\min} و x_{\max} به ترتیب مینیمم و ماکزیمم و x_n نرمال شده آن می‌باشند)

$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1) \text{ نرمال کردن خطی به دامنه } [0, 1]:$$

$$\text{برای دامنه } [a, b] \text{ نرمال کردن خطی با فرمول } x_n = \frac{(b-a)(x - x_{\min})}{x_{\max} - x_{\min}} + a \text{ انجام می‌شود.}$$

$$(2) \text{ نرمال کردن آماری } x_n = \frac{x - \bar{x}}{\delta} \text{ که } \bar{x} \text{ و } \delta \text{ به ترتیب میانگین و انحراف معیار داده ها می‌باشند.}$$

مجموعه تست و آموزش: برای استفاده از شبکه‌های عصبی مجموعه داده‌ها معمولاً به دو مجموعه تست و آموزش تقسیم می‌شوند. محققان در مسائل پیش‌بینی و تقریب توابع ۲۰ درصد از کل داده‌ها را به عنوان مجموعه تست در نظر می‌گیرند و بقیه را برای آموزش استفاده می‌نمایند. گاهی اوقات از مجموعه سومی به نام مجموعه اعتبار (Valid Set) و تکنیک Cross Validation استفاده می‌شود. بدین صورت که قسمتی از مجموعه داده‌ها به عنوان مجموعه اعتبار در نظر گرفته می‌شود و همانطور که یادگیری شبکه به وسیله مجموعه آموزش دنبال می‌شود قدرت تعمیم شبکه برای مجموعه اعتبار ارزیابی می‌شود. در نقطه‌ای که یادگیری شبکه بهتر می‌شود، ولی قدرت تعمیم شبکه برای مجموعه اعتبار رو به کاهش می‌نهد، یادگیری شبکه باید متوقف شود. در این نقطه در شبکه پدیده Overfitting در حال اتفاق افتادن است. این تکنیک اغلب برای مجموعه داده‌های زیاد مورد استفاده قرار می‌گیرد و در مجموعه داده‌های کم و معمولی همان دو مجموعه تست و آموزش کافی می‌باشد [18].

معیارهای عملکرد: بدلیل محدودیت‌های اطلاعاتی که یک معیار منفرد دارد محققان از چند معیار مختلف جهت ارزیابی عملکرد شبکه استفاده می‌کنند. معیارهای عملکرد مورد استفاده در این تحقیق در جدول ۱ آمده‌اند.

جدول ۱- معیارهای عملکرد مورد استفاده در تحقیق

معیار عملکرد		
نام	مفهوم	فرمول
MAE	میانگین قدرمطلق خطا ^۱	$\frac{\sum e_t }{N}$
MSE	میانگین مجموع مربعات خطا ^۲	$\frac{\sum (e_t)^2}{N}$
MAPE	میانگین قدرمطلق درصد خطا ^۳	$\frac{1}{N} \sum \left \frac{e_t}{y_t} \right * 100$
MdAPE	میانه قدرمطلق درصد خطا ^۴	$Median \left(\left \frac{e_t}{y_t} \right * 100 \right)$
R ²	ضریب تعیین	$1 - \frac{SSE}{SST}$
Trend	درصد تشخیص جهت حرکت سری قیمت	$\text{sgn}[(\hat{y}_t - \hat{y}_{t-1})(y_t - y_{t-1})] \geq 0$

1- Mean Absolute Error

2- Mean Standard Error


3- Mean Absolute Percentage Error

4- Median Absolute Percentage Error

که در آنها $\hat{y}_t = y_t - e_t$ و y_t پیش‌بینی (مقدار سری زمانی در لحظه t) می‌باشد و N تعداد پیش‌بینی یا تعداد الگوهای ورودی به شبکه می‌باشد.

۳- داده‌ها

داده‌هایی که در این مطالعه مورد استفاده قرار گرفته است، مربوط به قیمت سهام شرکت ایران خودرو در بازار بورس اوراق بهادار تهران می‌باشد. در بخش مربوط به متغیرهای موثر بر قیمت سهام شرکت ایران خودرو، متغیرهایی بنیادی از قبیل، نرخ ارز، قیمت نفت و نسبت p/e و متغیر فنی حجم مبادلات سهام در نظر گرفته شده است. تمام اطلاعات مربوط به این متغیرها از کتابخانه بازار بورس اوراق بهادار تهران اخذ شده است. داده‌های مورد مطالعه مربوط به مشاهدات دوره زمانی ۱۳۷۹-۱۳۸۰ می‌باشد و شامل ۳۷۹ مشاهده می‌شود. همچنین نمودار مربوط به سری قیمت سهام ایران خودرو (IKSEP) در طول زمان در شکل ۲ به نمایش درآمده است.



شکل ۲- نمودار سری زمانی IKSEP

همانطور که شکل ۲ نشان می‌دهد سری دارای نوسان ناگهانی (شوک) در پریرود زمانی مربوطه می‌باشد، نقاط این شوکها در جدول ۲ آمده است..

جدول ۲- نقاط شوک سری IKSEP

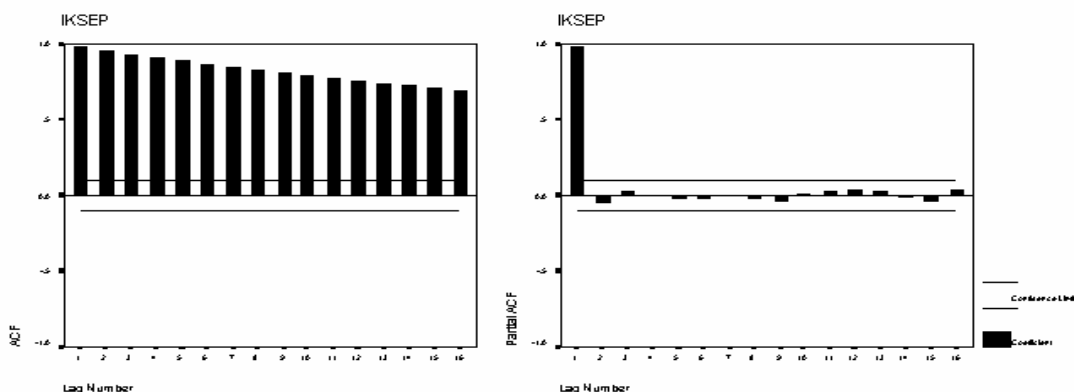
نوسان‌های شدید IKSEP			
شماره	مقدار	تاریخ	نقاط
۱	۱۴۳۷	۷۹/۴/۲۵ و ۷۹/۵/۲۴	۷۶ و ۷۷
۲	۱۲۹۹	۷۹/۱۱/۳۰ و ۷۹/۱۲/۹	۱۸۶ و ۱۸۷
۳	۲۵۸	۸۰/۱۰/۱۰ و ۸۰/۱۱/۱	۳۴۳ و ۳۴۴

همچنین در شکل ۳ منحنی مربوط به توابع خود همبستگی^۱ (ACF) و خود همبستگی جزئی^۲ (PACF) سری IKSEP نشان داده شده است که نشان دهنده همبستگی فوق العاده زیاد میان تاخیرهای سری IKSEP است. همچنین بیان‌کننده ناپیوستگی^۳ خیلی زیاد در سری مربوطه می‌باشد.

1- Auto Correlation Function

2-Partial Auto Correlation Function

3 -Nonstationary



شکل ۳- نمودار ضریب خودهمبستگی و خودهمبستگی جزئی

همانطور که قبلاً عنوان شد برای امکان پیش‌بینی قیمت سهام، باید نشان داده شود میان اطلاعات گذشته قیمت سهام، الگویی وجود دارد که با کشف این الگو، بتوان قیمت سهام شرکت را پیش‌بینی نمود. بدین منظور باید نشان داده شود که سری زمانی قیمت سهام شرکت ایران خودرو تصادفی نیست. در این صورت امکان کشف الگو و پیش‌بینی قیمت سهام وجود دارد.

آزمون‌هایی از قبیل گردش^۱، فراوانی، فریال^۲، گپ^۳ و همبستگی دنباله‌ای^۴، برای بررسی تصادفی بودن یا نبودن یک سری زمانی وجود دارد. روش‌هایی هم مانند تخمین بعد همبستگی^۵، روش محاسبه بزرگترین نمای لیپانوف^۶ و تحلیل R/S^۷ برای آزمون پیش‌بینی‌پذیری سری‌های زمانی بوسیله بررسی ماهیت فرایند مولد قیمت سهام وجود دارد. در این روش‌ها، ساختار سری زمانی مورد بررسی قرار می‌گیرد و سعی در کشف ساختار غیرخطی و آشوبگونه موجود در فرایند مولد قیمت سهام می‌شود.

در این تحقیق، با استفاده از نرم‌افزار SPSS آزمون گردش برای سری IKSEP انجام شده است. مقدار آماره Z برای این آزمون ۱۶/۱۵- می‌باشد که از مقدار ۱/۹۶- خیلی کمتر است و بر این اساس فرض صفر، مبنی بر تصادفی بودن داده‌ها، به شدت رد می‌شود.

۴- طراحی مدل به کمک شبکه عصبی

تقریباً اکثر محققان، شبکه‌های پرسپترون چند لایه (Multilayer Feedforward Perceptron) یا MLP را به‌خاطر کارایی بالای آنها برای پیش‌بینی سری‌های زمانی مورد استفاده قرار داده‌اند. بنابراین در ابتدا از شبکه پیشخور برای مدل‌سازی فرایند مولد سری IKSEP استفاده می‌شود. سپس انواع شبکه‌های دیگر از قبیل Cascade، Elman، GRNN^۸ و RBFN^۹ مورد آزمایش قرار می‌گیرد و بهترین آنها انتخاب می‌شود.

شکل ۴ الگوهای ورودی به شبکه MLP سه لایه (ورودی، مخفی و خروجی) را برای پیش‌بینی یک روز بعد نشان می‌دهد. در پیش‌بینی یک روز بعد در مرحله آموزش، ابتدا مشاهدات سری، در الگوهای p تایی به شبکه ارائه می‌شود. سپس خطای شبکه بر اساس اختلاف بین خروجی شبکه و مشاهده $p+1$ ام محاسبه می‌شود. شبکه MLP سعی می‌کند، مقدار MSE (مجموع مربعات خطا) حاصل از تمام الگوهای ورودی به شبکه را می‌نیمم کند. این عمل با تنظیم پارامترهای وزن و بایاس شبکه صورت می‌گیرد.

1-Runs Test

2-Ferial

3-Gap

4-Serial Correlation


5-Correlation Dimension Estimate

6-Largest Lyapunov Exponent

7-Rescaled Range Analysis

8-General Regresion Neural Networks

9-Radial Based Fuction Network



شکل ۴- ساختار شبکه برای پیش‌بینی یک روز بعد

شبکه بعد از تنظیم این پارامترها در مرحله آموزش، مشاهدات مجموعه آزمایش را تقریب می‌زند. به بیان دیگر، شبکه عصبی الگوهای موجود را که از مجموعه آموزش استخراج نموده است، به مجموعه آزمایش تعمیم می‌دهد. در ادامه مراحل طراحی مدل شبکه عصبی تشریح می‌شود.

۴-۱- نرمال‌سازی داده‌ها

برای بررسی ضرورت نرمال کردن داده‌ها، ابتدا از داده‌های خام برای ورود به شبکه استفاده می‌شود [4,19]. ۸۰٪ داده‌ها به عنوان مجموعه آموزش و ۲۰٪ آن برای تست شبکه استفاده می‌شود. مقدار ضریب تعیین برای مجموعه آزمایش و آموزش تقریباً برابر با صفر است و این نشان می‌دهد که شبکه با معماری‌های مختلف، در کشف روابط بین داده‌ها، در هر دو مجموعه آموزش و آزمایش ناتوان است. بنابراین ابتدا باید داده‌های ورودی و خروجی با روش خطی یا استاندارد (آماري) نرمالیزه شوند. در قدم بعدی شبکه با استفاده از این داده‌ها آموزش دیده و در مقابل داده‌های آزمایش تست می‌شود. در جدول ۳ بهترین عملکرد شبکه با در نظر گرفتن معماری‌های مختلف، در برابر داده‌های نرمال شده به روش خطی و استاندارد ارائه شده است.

جدول ۳- بهترین عملکرد شبکه با داده‌های نرمال شده

بهترین تعداد گره‌ها		معیار عملکرد						روش نرمال‌سازی
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)	
۱	۲	۸۳/۴	۴۶/۵۵	۱/۵۲	۰/۵۸	۰/۶۸	۵۰/۷	خطی
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۵۷	۰/۷	۴۷/۹۵	استاندارد

با توجه به مقادیر شاخص‌های خطا در این جدول به خوبی مشهود است که نرمال‌سازی اثر عمده‌ای در یادگیری شبکه داشته است. از طرف دیگر در مقایسه با روش خطی، نرمال‌سازی استاندارد داده‌ها، کارایی شبکه را بهتر کرده است. بنابراین به‌طور کلی می‌توان گفت فشرده‌سازی کمتر در روش استاندارد نسبت به روش خطی تأثیر مطلوبی بر عملکرد مدل داشته است.

۴-۲- توابع تبدیل

در قسمت‌های گذشته توابع تبدیل که برای شبکه عصبی در نظر گرفته شده بودند عبارت بودند از:

۱- توابع تبدیل سیگموئید یا تانژانت هیپربولیک برای لایه مخفی

۲- تابع تبدیل خطی برای لایه خروجی

با توجه به قسمت‌های قبل توابع تبدیل مورد استفاده برای مسایل پیش‌بینی و تقریب توابع، توابع تانژانت هیپربولیک، سیگموئید و خطی می‌باشند. در مورد سری IKSEP عملکرد تابع تبدیل سیگموئید و تانژانت هیپربولیک بعنوان تابع تبدیل لایه میانی شبکه کاملاً مشابه هم بوده است. بنابراین برای یافتن بهترین توابع تبدیل برای لایه‌های مخفی و خروجی باید ترکیب مختلف دو تابع تانژانت هیپربولیک و خطی برای هر دو لایه در نظر گرفته شود. نتایج استفاده از توابع مختلف برای لایه‌های شبکه در جدول ۴ آمده است.

جدول ۴- بهترین عملکرد شبکه با انواع توابع

بهترین تعداد گره‌ها		معیار عملکرد						تابع
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)	
۲	۲,۳,۴,۵,۶,۷,۸,۹,۱۰,۱۱,۱۲,۱۳,۱۴,۱۵,۱۶,۱۷,۱۸,۱۹,۲۰	۱۱۴/۳	۶۱/۸	۲/۰۱	۱/۱۶	۰/۶	۵۲	خطی برای تمام لایه‌ها
۵	۳	۹۱/۷۸	۵۷/۷	۱/۸۶	۱/۰۱	۰/۶۱	۵۰/۶۷	Tanh برای تمام لایه‌ها
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۵۷	۰/۷	۴۷/۹۵	Tanh برای مخفی - خطی برای خروجی

با توجه به آزمایش‌های انجام شده، مشاهده شده است که همراه با استفاده از تابع تبدیل خطی برای لایه مخفی، تعداد گره‌های مخفی بر عملکرد شبکه بی تأثیر می‌شوند یا به عبارت دیگر، عملاً لایه مخفی از شبکه MLP کنار گذاشته می‌شود و همچنین عملکرد شبکه رو به وخامت می‌نهد. این مسئله ضرورت استفاده از تابع تبدیل غیرخطی (سیگموئید یا تانژانت هیپربولیک) را برای لایه مخفی نشان می‌دهد تا لایه مخفی هم به عنوان یک عنصر مؤثر بر عملکرد شبکه تأثیر گذار باشد. بهمین ترتیب استفاده از تابع تبدیل غیرخطی برای لایه خروجی شبکه، تأثیر نامطلوب بر عملکرد شبکه داشته است. بنابراین بهترین توابع تبدیل برای شبکه، تابع تبدیل غیرخطی (سیگموئید یا تانژانت هیپربولیک) برای لایه مخفی و خطی برای لایه خروجی می‌باشد و تحقیقات با این ترکیب بهینه ادامه می‌یابد.

۴-۳- انتخاب مجموعه آموزش و آزمایش

با توجه به تحقیقات صورت گرفته دو ترکیب برای مجموعه آزمایش و آموزش در نظر گرفته شده است این دو ترکیب عبارتند از:

- ✓ ۲۰-۸۰: ۸۰ درصد مجموعه آموزش - ۲۰ درصد مجموعه آزمایش
- ✓ ۳۰-۷۰: ۷۰ درصد مجموعه آموزش - ۳۰ درصد مجموعه آزمایش

در جدول ۵ نتایج استفاده از این دو ترکیب برای مجموعه داده‌های IKSEP آورده شده است.


جدول ۵- معیارهای عملکرد برای بهترین معماری دو ترکیب فوق

بهترین تعداد گره‌ها		معیار عملکرد						ترکیب
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)	
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۵۷	۰/۷	۴۷/۹۵	۲۰-۸۰
۲	۲	۹۰/۲	۵۵/۳	۱/۸	۰/۹۸	۰/۶۲	۴۸	۳۰-۷۰

۸۰ درصد مجموعه داده‌ها به‌عنوان مجموعه آموزش (۳۰۲ داده) و بقیه داده‌ها برای مجموعه آزمایش استفاده می‌شوند (۷۷ داده). جدول ۶ بهترین نتایج معیارهای عملکرد را به ترتیب در برابر مجموعه آموزش و آموزش نشان می‌دهد. با توجه به جدول، مقدار R² حداکثر برابر با ۰/۷ می‌باشد و این بدین معنی است که ۷۰ درصد از پراکندگی داده‌ها به وسیله تقسیم‌بندی مذکور پوشانده شده است. بنابراین در قدم اول ارزیابی عملکرد شبکه فوق سعی می‌شود تا مقدار R² بهبود داده شود.

جدول ۶- معیارهای عملکرد برای بهترین معماری

بهترین تعداد گره‌ها		معیار عملکرد						مجموعه
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)	
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۵۷	۰/۷	۴۷/۹۵	آزمایش
۲	۲	۱۲۲/۳۴	۵۳/۳	۱/۴۶	۰/۹۳	۰/۹۶	۵۵	آموزش

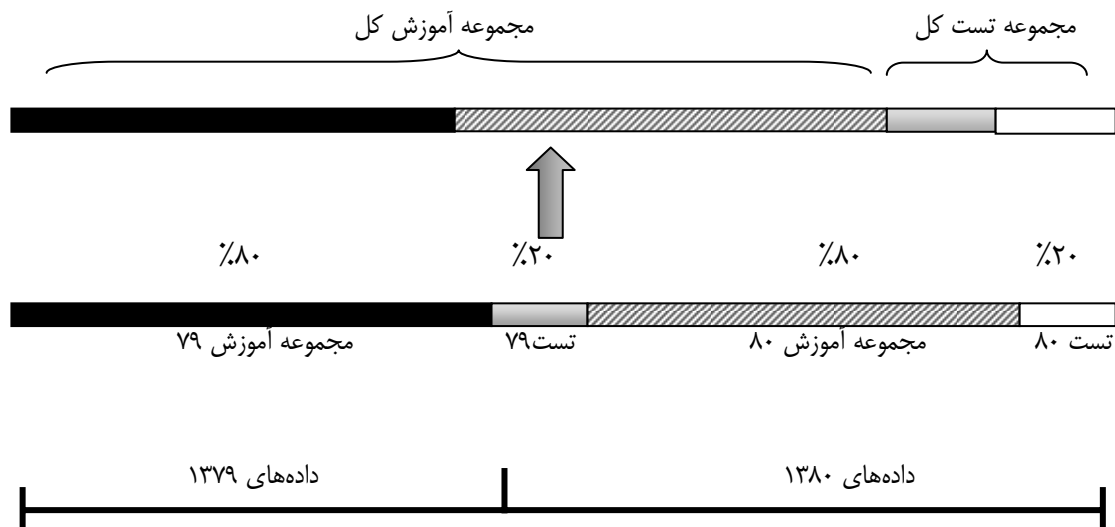


شکل ۵- قدرمطلق خطا در مجموعه آموزش (ب) و آزمایش (الف)

همچنین شکل ۴ مقدار قدرمطلق خطا، یعنی تفاوت بین مقدار واقعی و مقدار پیش‌بینی را برای بهترین مدل ممکن (با ۲ گره ورودی و ۲ گره مخفی) به ترتیب برای مجموعه آموزش و آزمایش نشان می‌دهد. با توجه به این شکل و شوک‌های موجود در مجموعه داده‌ها (که قبلاً ذکر شده‌اند)، روند یادگیری شبکه بخصوص اطراف نقاط شوک دچار اختلال می‌شود و پس از مدتی به حالت عادی برمی‌گردد. این شوک‌های ناگهانی و زیاد، تأثیر نامطلوب در عملکرد شبکه در هر دو مرحله آموزش و آزمایش می‌گذارند. در نتیجه شبکه قادر نخواهد بود پراکندگی داده‌ها را در اطراف نقاط شوک به نحو مطلوبی توضیح دهد و باعث می‌شود مقدار R^2 با وجود تنظیمات مختلف در شبکه، مقدار ۰/۷ باقی بماند.

برای کاستن از تأثیر این شوک‌های ناگهانی و بالطبع توضیح بهتر پراکندگی‌های اطراف نقاط شوک (افزایش مقدار R^2) مجموعه داده‌ها برای سال‌های ۱۳۷۹ و ۱۳۸۰ به صورت جداگانه مورد بررسی قرار می‌گیرد. سپس از هر دو مجموعه، مجموعه‌های آموزش و آزمایش، با رویه ۸۰ درصد مجموعه آموزش، ۲۰ درصد مجموعه آزمایش - انتخاب می‌شود. آنگاه مجموعه آزمایش کل به صورت اجتماع دو مجموعه آموزش و مجموعه آموزش کل به صورت اجتماع دو مجموعه آموزش مورد بررسی قرار گیرد. شکل ۶ این روش تقسیم‌بندی را که روش "ترکیب" نامگذاری می‌کنیم، نشان می‌دهد.

با استفاده از تقسیم‌بندی مذکور، مجموعه آموزش از مناطق مختلف بیشتری از فضای ورودی داده‌ها، انتخاب می‌شود و باعث می‌شود که داده‌های متنوع‌تری از مجموعه داده‌ها برای آموزش شبکه انتخاب شوند و در نتیجه الگوهای بیشتری از داده‌ها توسط شبکه یاد گرفته می‌شود و با یادگیری بیشتر، قدرت توضیح پراکندگی داده‌ها به وسیله شبکه افزایش می‌یابد و دقت پیش‌بینی بهتر می‌شود. مخصوصاً قابلیت تعمیم شبکه‌ای که یادگیری بهتری داشته است در مجموعه آزمایش افزایش می‌یابد.




شکل ۶- روش تقسیم‌بندی "ترکیب"

شبکه MLP سه لایه با استفاده از این داده‌ها با تعداد گره‌های ورودی و مخفی مختلف و روش یادگیری لوبنبرگ مارکوارت آموزش داده می‌شود. شاخص‌های خطا در مقابل مجموعه آزمایش و آموزش برای بهترین معماری در جدول ۷ آمده است.

جدول ۷- معیارهای عملکرد بهترین معماری در تقسیم‌بندی دوم

بهترین تعداد گره‌ها		معیار عملکرد						مجموعه
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)	
۳	۲	۱۶۰/۵۹	۴۷/۳۹	۱/۵۴	۰/۷	۰/۸۹	۵۶/۳۴	آزمایش
۳	۲	۱۰۰/۱۵	۵۱/۲	۱/۳۵	۰/۸۵	۰/۹۷	۵۳/۲۲	آموزش

این جدول نشان می‌دهد که مقدار ضریب تعیین نسبت به مقدار متناظر در تقسیم‌بندی اولیه افزایش قابل ملاحظه‌ای یافته است. همانطور که جدول ۶ نشان می‌دهد با وجود آنکه مقدار R² بهبود خیلی خوبی داشته است، معیارهای خطا نسبت به تقسیم‌بندی اولیه بدتر شده‌اند. با توجه به مقادیر خطا مربوط به مجموعه آزمایش در شکل ۷ برای یک نقطه مقدار خطا خیلی زیاد می‌باشد و همین مقدار خطای خیلی زیاد باعث شده است، با وجود بهبود در مقدار R² در بقیه معیارهای عملکرد بهبودی مشاهده نشود. خطای خیلی زیاد حاصل از نقطه شوک باعث شده است معیارهای عملکرد شبکه دچار اختلال شوند. به گونه‌ای که آنها گویای عملکرد واقعی تقسیم‌بندی جدید نمی‌باشند. با حذف این مقدار خطا، معیارهای عملکرد با مقدار R² که نشان دهنده میزان پراکندگی داده‌ها توسط مدل جدید می‌باشد، همخوانی خواهد داشت. جدول ۸ مقدار این معیارهای عملکرد را در مجموعه آزمایش و آموزش نشان می‌دهد.



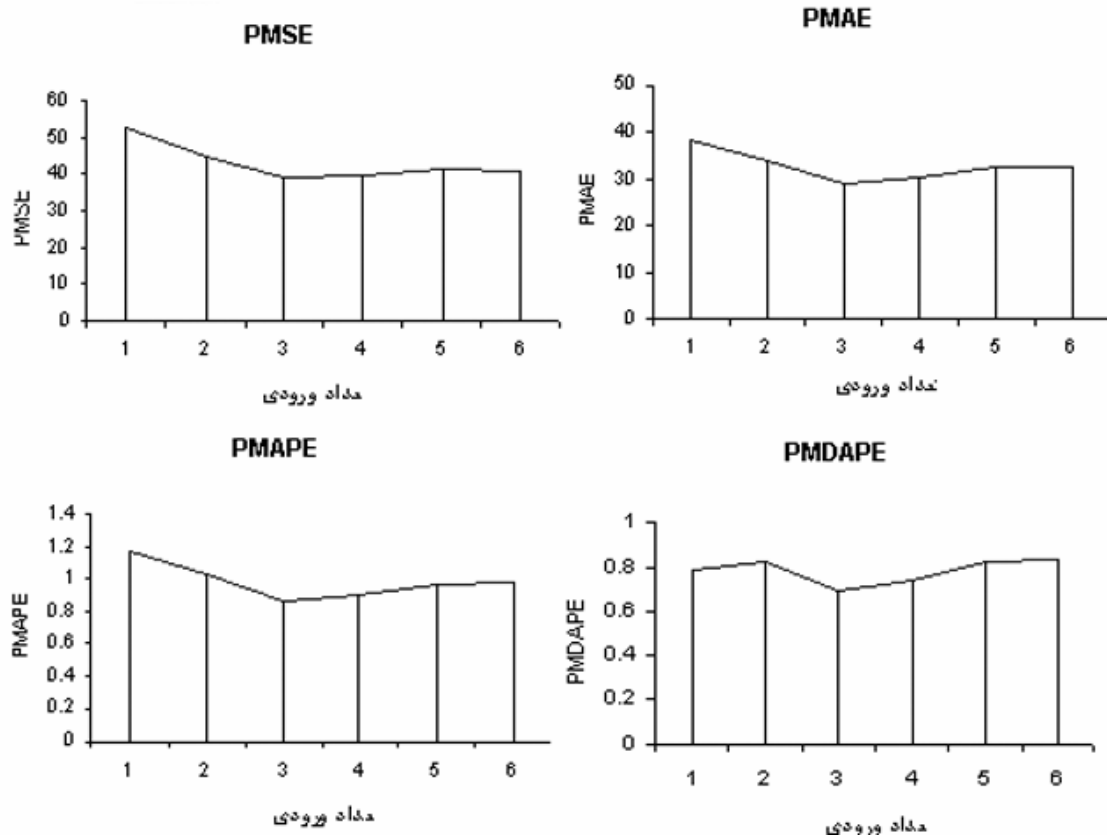
شکل ۷- خطای خالص در تقسیم‌بندی دوم

جدول ۸- مقادیر معیارهای عملکرد اصلاح‌شده


بهترین تعداد گره‌ها		معیار عملکرد						مجموعه
ورودی	مخفی	PMSE	PMAE	PMape	PMDAPE	PR ²	Ptrend(%)	
۳	۲	۶۳/۹۵	۴۵	۱/۲۶	۰/۸۶	۰/۹۹	۵۶/۶۱	آموزش
۳	۲	۳۹/۲	۲۹/۲	۰/۸۷	۰/۶۹	۰/۹۹	۶۰	آزمایش

به منظور ارائه عملکرد شبکه با تقسیم‌بندی جدید، معیارهای MAPE, MSE, MAE, MDape, MAPE, PMSE (Pure MSE), PMDAPE, PMape, PMAE, PR² به عنوان معیارهای جدید عملکرد استفاده می‌شوند. این معیارها با حذف مقادیر خیلی بزرگ خطا محاسبه می‌شوند. بدین ترتیب می‌توان عملکرد واقعی شبکه با تقسیم‌بندی جدید را در پیش‌بینی (پیش‌بینی در مجموعه آزمایش) و شبیه‌سازی (پیش‌بینی در مجموعه آموزش) مورد بررسی قرار داد.

نمودارهای $PMSE$, $PMAE$, $PMSE$, $PMSE$ مربوط به تأثیر تعداد ورودی بر عملکرد شبکه در مجموعه آزمایش در شکل ۸ آمده است. هر چهار معیار با تعداد ورودی سه به حداقل مقدار خود می‌رسند، بنابراین بهترین معماری شبکه با تعداد ورودی سه بدست می‌آید و معماری ۳-۲-۱ در بین معمارهای موجود بهترین جواب را ارائه می‌دهد. شکل ۹ عملکرد شبکه را در شبیه‌سازی و پیش‌بینی برای بهترین معماری (۳-۲-۱) نشان می‌دهد.




شکل ۸- تأثیر تعداد ورودی بر معیارهای عملکرد



شکل ۹- عملکرد شبکه در پیش‌بینی (الف) و شبیه‌سازی (ب)

در قسمت قبل با دانستن اطلاعات سری قیمت IKSEP مربوط به p روز قبل، پیش‌بینی مقدار سری در روز $p+1$ ام انجام گرفت. در عمل باتوجه به زمان‌بری فرایند خرید و فروش سهام، پیش‌بینی چند روز بعد از نظر عملی مفیدتر است. پیش‌بینی دو روز بعد را می‌توان به دو روش انجام داد. اول پیش‌بینی با یک خروجی است. همانند شکل (۸ الف) شبکه براساس p ورودی و خروجی $p+2$ ام سری آموزش داده می‌شود. بهترین معماری با سه ورودی دو مخفی حاصل شده است. مقادیر معیارهای عملکرد در جدول ۹ نشان داده شده است.



شکل ۱۰- الگوی ورودی به شبکه برای پیش‌بینی دو روز بعد

جدول ۹- بهترین معیارهای عملکرد در پیش‌بینی دو روز بعد با دو روش

بهترین تعداد گره‌ها		معیار عملکرد						تعداد گره
ورودی	مخفی	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	خروجی
۳	۲	۶۹/۲	۵۳/۱	۱/۵۸	۱/۲۴	۰/۹۸	۵۲/۲۴	یک
۲	۳	۶۴/۹	۵۰/۶	۱/۵	۱/۲۵	۰/۹۸	۴۹/۲۸	دو

دوم، پیش‌بینی با دو خروجی است. آموزش و تست شبکه بر اساس ساختار موجود در شکل ۸ ب می‌باشد. نتایج نشان می‌دهد که شبکه با دو خروجی برای پیش‌بینی دو گام به جلو موفق‌تر از شبکه با یک خروجی عمل نموده است.

همانند پیش‌بینی دو روز بعد برای پیش‌بینی هفت روز بعد نیز از هر دو ساختار -حالت با یک خروجی و هفت خروجی - استفاده شده است. در این حالت هم پیش‌بینی با هفت خروجی نتایج بهتری ارائه داده است. بهترین نتایج برای پیش‌بینی هفت روز بعد در جدول ۱۰ آمده است.

جدول ۱۰- بهترین معیارهای عملکرد در پیش‌بینی هفت روز بعد با دو روش

بهترین تعداد گره‌ها		معیار عملکرد						تعداد گره
ورودی	مخفی	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	خروجی
۱	۲	۱۳۹/۳	۱۱۰/۷۶	۳/۳	۲/۴۶	۰/۹۵	۴۶/۴	یک
۱	۴	۱۲۰/۴	۹۴/۴	۲/۸	۲/۳	۰/۹۵	۴۶/۴۳	هفت

۵- نتیجه‌گیری

در این تحقیق با توجه به اهمیت پیش‌بینی قیمت سهام ایران خودرو بعنوان بزرگترین واحد خودروسازی کشور و یکی از بزرگترین شرکت‌های عضو بازار بورس تهران، به مدل‌سازی و پیش‌بینی قیمت سهام آن بوسیله شبکه عصبی پرداخته شد. بدین منظور ابتدا وجود الگو بین داده‌های قیمت سهام به کمک آزمون گردش در نظر گرفته شد و پس از اطمینان از تصادفی نبودن رابطه میان داده‌ها، نرمال‌سازی داده‌ها بررسی گردید. نتایج نشان دادند که نرمال‌سازی داده‌ها و بویژه نرمال‌سازی استاندارد تاثیر قابل توجهی در بهبود عملکرد شبکه خواهد داشت.

در ادامه انواع توابع تبدیل رایج برای لایه‌های مختلف شبکه مورد بررسی قرار گرفتند. نتایج حاصله نشان دهنده ضرورت بکارگیری تابع تبدیل غیرخطی (تانژانت هیپربولیک یا سیگموئید) برای لایه مخفی و تابع خطی برای لایه خروجی بوده است.

سپس دو روش رایج تقسیم بندی داده ها به مجموعه آموزش و آزمایش مورد بررسی قرار گرفتند. به منظور بهبود عملکرد شبکه در توضیح نقاط شوک داده ها، روش تقسیم بندی جدیدی برای مجموعه‌های آموزش و آزمایش در نظر گرفته شد. با استفاده از تقسیم‌بندی مذکور، مجموعه آموزش از مناطق مختلف بیشتری از فضای ورودی داده‌ها، انتخاب می‌شود و باعث می‌شود که داده‌های متنوع‌تری از مجموعه داده‌ها برای آموزش شبکه انتخاب شوند و در نتیجه الگوهای بیشتری از داده‌ها توسط شبکه یاد گرفته می‌شود و با یادگیری بیشتر، قدرت توضیح پراکندگی داده‌ها و در نتیجه دقت پیش‌بینی به وسیله شبکه افزایش می‌یابد [1].

منابع و مراجع

[1] عباس‌پور، محمدرضا، پیش‌بینی قیمت سهام شرکت ایران خودرو با شبکه عصبی، پایان‌نامه کارشناسی ارشد مهندسی صنایع-سیستم‌های اقتصادی، دانشگاه تربیت مدرس، مهر ۱۳۸۱.

[2] Boyd, M. and Kaastra, I., Designing a Neural Network for Forecasting Financial and Economic Time Series, Vol.10, 1996.

[3] Chenoweth, T. and Obradovic, Z., A Multi-Component Nonlinear Prediction System for the S&P 500 Index, Neurocomputing, Vol. 10, P.275-290, 1996.

[4] Chua, Ching-Wu, Zhang, P., A comparative study of linear and nonlinear models for aggregate retail sales forecasting, Int. J. Production Economics, unpublished paper, 2003.

[5] Diniz, H., Architecture Design of Artificial Neural Networks Based on Box & Jenkins Models for Time Series Prediction, IEEE, 1999.

[6] Haykin, S., Neural Networks: A Comprehensive Foundation, Prentice-Hall, 1999.

[7] Jang, J.R., Sun, C. and Mizutani, E., Neuro-Fuzzy and Soft Computing, Prentice-Hall, 1997.

[8] Kanas, A. and Yannopoulos, A., Comparing Linear and Nonlinear Forecasts for Stock Returns, Vol.10, 2001.

[9] Khaloozadeh, H and Sedigh, AK., Long Term Prediction of Tehran Price Index (TEPIX) using Neural Networks, ieeexplore.ieee.org, 2001.

[10] Kohzadi, N., Boyd, M., Kermanshahi, B. and Kaastra, I., A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices, Neurocomputing, Vol.15, 1996.

[11] Shaikh, A. and Zahid, I., Using neural networks for forecasting volatility of S&P 500 Index futures prices, Journal of Business Research, Vol.57, P.1116– 1125, 2004.

[12] The Mathworks Web Site. <http://www.mathworks.com>

[13] Tseng, F., Yu, H. and Tzeng, G., Combining Neural Network Model with Seasonal Time Series ARIMA Model, Technological Forecasting & Social Change, Vol.69, 2002.

[14] Wang, G. and Leu, J., Stock Market Trend Prediction Using ARIMA Based Neural Networks, IEEE, 1996.

[15] White H., Economic Prediction Using Neural Networks: The case of IBM Daily Stock Returns, <http://www.citeseer.nj.nec.com/context>, 1993.

[16] Yao, J. and Poh, H., Forecasting The KLSE Index Using Neural Networks, Department of Information System and Computer Science, National University of Singapore, 1996.

[17] Zhang, G. and HU, M.Y., Neural Network Forecasting of the British pound/US Dollar Exchange Rate, Omega, Vol. 26, No.4., 1998, P.495-509.



- [18] Zhang, G. and Pattuwo E.B., Forecasting with Artificial Neural Networks: the State of the Art, International Journal of forecasting, Vol.14, P.35-62, 1998.
- [19] Zhang, G. and Qi, M., Neural network forecasting for seasonal and trend time series, European Journal of Operational Research, Vol.160, P.501–514, 2005.