

پیش‌بینی قیمت سهام شرکت ایران خودرو به کمک شبکه‌های عصبی

محمد رضا عباس‌پورⁱ، محمد رضا امین‌ناصریⁱⁱ

چکیده

بی‌تر دید 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 است و از این‌رو، تمايل روزافزونی نسبت به پیش‌بینی قیمت سهام آن مشاهده می‌شود.

در این تحقیق به پیش‌بینی قیمت سهام ایران خودرو به کمک شبکه‌های عصبی خواهیم پرداخت. از این‌رو، ابتدا بوسیله آزمون گردش، امکان پیش‌بینی قیمت سهام شرکت ایران خودرو بررسی شده است. سپس از شبکه‌های عصبی RBFN، GRNN، Cascade، Elman و MLP برای پیش‌بینی یک، دو و هفت روز بعد قیمت سهام استفاده شده است. به علت نوسانات شدید موجود در داده‌های قیمت سهام شرکت ایران خودرو، روش خاصی برای انتخاب مجموعه نتست و آموزش به کار گرفته شده و در نتیجه، قدرت برآش مدل شبکه به مراتب بهبود یافته است. همچنین تأثیر انواع توابع تبدیل برای لایه مخفی و خروجی، انواع الگوریتم‌های یادگیری، انواع ساختار شبکه از لحاظ تعداد گره‌های ورودی و مخفی و چهارمتغیر بنیادی و فنی؛ نرخ ارز، قیمت نفت، حاصل تقسیم قیمت بر عایدی هر سهم و حجم مبادلات سهام بر عملکرد شبکه، مورد بررسی قرار گرفته است و آنها که در بهبود مدل شبکه موثر بوده‌اند، در مدل نهایی لحاظ و در نهایت بهترین مدل شبکه برای پیش‌بینی حالات مختلف ارائه شده‌است. در خاتمه به مدل سازی خطی قیمت سهام شرکت، با دو روش هموارسازی نمایی و باکس جنکینز پرداخته شده‌است. نتایج به دست آمده نشان داده است که پیش‌بینی به وسیله شبکه عصبی به مراتب بهتر از روش‌های خطی عمل می‌کند.

کلمات کلیدی

پیش‌بینی، شبکه عصبی، بازار بورس، پیش‌بینی قیمت سهام، شرکت ایران خودرو، هموارسازی نمایی، روش باکس جنکینز.

ⁱ - کارشناس ارشد مهندسی سیستم‌های اقتصادی: m.r.abbaspour@gmail.com
ⁱⁱ - استادیار دانشگاه تربیت مدرس: amin-nas@modares.ac.ir

IRAN KHODRO CO. Stock Price Prediction with Neural Networks

M.R.Amin-Naseri; M.R. Abbaspour

ABSTRACT

Iran Khodro company is a leading auto maker in Iran which holds about 65% of the market share and hence the share holders show great interests in predicting its stock exchange price. On the other hand due to the chaotic behavior of share price in Teharn Stock Exchange the classical models such as ARIMA and ARCH would not be efficient models to represent the dynamics governing the share price.

However, neural network (NN) models are proposed to predict Iran Khodro Stock Exchange Price(IKSEP). Several neural network models such as MLP, ELMAN, CASCADE, GRNN and RBFN were examined. Because of serious volatility in IKSEP, special method was proposed for testing and training the data which considerably improved the results. Extensive tests have been carried out to choose the most suitable feature such as, the type of transfer function, the number of hidden and output layers, the training algorithm, and the technical and fundamental variables. Some fundamental variables such as oil price, P/E and volume of stock exchange were introduced in the model and showed to be considerably effective in the accuracy of forecast. The best results obtained from NN models were compared to those obtained by using exponential smoothing and Box-Jenkins models. The results showed the NN forecasts were superior to those of the time series model.

KEYWORDS

Forecasting, Neural Networks, Stock Market, Prediction of Stock Price, IRAN KHODRO CO., Exponential Smoothing, Box-Jenkins.

پیش‌بینی کنند. آنها با توجه به برداشت خود از نمودارها،
الگوهای را به منظور تعیین شاخص‌های روزانه، هفتگی و

ماهانه بازار تعیین می‌کنند. تحلیل‌گران بنیادی، با توجه به
ارزش واقعی و ذاتی یک سهم اقدام به پیش‌بینی می‌کنند. 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 بدين وسیله فرایند
مولد آنها را تقریب بزنند. در این تحقیق مرکز اصلی بر
روش‌های هوشمند و به ویژه شبکه عصبی است.

در دهه اخیر "شبکه‌های عصبی" یکی از پراستفاده‌ترین
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 است؛ پیش‌بینی سری‌های زمانی دومین زمینه
پرکاربرد استفاده از شبکه‌های عصبی را، به خود اختصاص
داده است [۱۸].

تحقیقات نشان می‌دهد که اکثر سری‌های زمانی در جهان
واقعی دارای الگوهای غیرخطی و پیچیده هستند؛ به طوری که

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 ویژگی عدم
اطمینان، امر نامطلوبی است و از طرفی برای سرمایه‌گذارانی که
بازار بورس را به عنوان مکان سرمایه‌گذاری انتخاب کرده‌اند،
این خصوصیت اجتناب‌ناپذیر است. بتایران به طور طبیعی تمام
تلاش سرمایه‌گذار کاهش عدم اطمینان است و از این جهت
پیش‌بینی بازار بورس یکی از ایزارهای کاهش عدم اطمینان به
شمار می‌رود.

در ادبیات موضوع، روش‌های گوناگونی برای پیش‌بینی
بازار آمده است که می‌توان آنها را در چهار گروه طبقه‌بندی
کرد [۱]:

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

تحلیل‌گران فنی یا نمودارگرها سعی می‌کنند بر اساس
الگوهای موجود در نمودار داده‌های مربوط به بازار، آن را

در تحقیق دیگری، ابراندوج یک سیستم پیش‌بینی غیرخطی مبتنی بر شبکه عصبی برای پیش‌بینی شاخص سهام S&P طراحی می‌کند [۵]. ژانگ در سال ۱۹۹۸ پیش‌بینی نرخ ارز را با شبکه‌های عصبی و مدل گام زدن تصادفی مطالعه کرد [۱۷]. در سال ۱۹۹۹ دینیز مطالعه‌ای برای پیش‌بینی سری زمانی قیمت یکی از شرکت‌های بزرگی در بازار بورس با شبکه عصبی و مدل باکس جنکینز انجام داده است [۶]. کاناس در سال ۲۰۰۱ پیش‌بینی بهره بازار را با مدل رگرسیون خطی و روش شبکه عصبی مقایسه می‌کند. استینر و ویت کمپر عملکرد چند مدل رگرسیونی و شبکه عصبی را برای پیش‌بینی بهره سهام بازار بورس فرانکفورت بررسی می‌کنند [۹]. در سال ۲۰۰۲ تحقیقی به منظور پیش‌بینی مقدار کل تولید صنایع ماشین‌سازی تایوان توسط تزنگ به انجام رسیده است. در این تحقیق مدل‌های (سری زمانی فصلی) SARIMA، شبکه عصبی و ترکیب این دو بررسی شده است [۱۳].

در ادامه مقاله، در بخش‌های دوم و سوم پیش‌بینی سری‌های زمانی بوسیله شبکه‌های عصبی و قابلیت پیش‌بینی قیمت سهام بررسی می‌شود. در بخش چهارم ضمن بررسی مراحل طراحی مدل، مدل طراحی شده و به ترتیب، پیش‌بینی دو و هفت روز بعد، پیش‌بینی با استفاده از: متغیرهای بنیادی، انواع شبکه عصبی و روش‌های خطی ارائه می‌شود [۲].

۲- پیش‌بینی سری‌های زمانی با شبکه عصبی

شبکه‌های عصبی پرسپترون به ویژه پرسپترون چند لایه در زمرة کاربردی‌ترین شبکه‌های عصبی قرار دارند. در شکل (۱) یک شبکه پرسپترون سه لایه با معماری ۶-۲-۱ 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 است. به چنین شبکه‌هایی، شبکه‌های کاملاً مرتبط می‌گویند. شبکه فوق عملاً از بهم پیوستن دو شبکه پرسپترون تک لایه ایجاد شده است. خروجی‌های لایه اول، بردار ورودی لایه دوم را و خروجی‌های لایه سوم پاسخ واقعی شبکه را تشکیل می‌دهند. چندین خصوصیت متمایز و منحصر به فرد شبکه‌های عصبی که برای کار پیش‌بینی جالب توجه و مناسب هستند، ذیلاً تشریح می‌شوند:

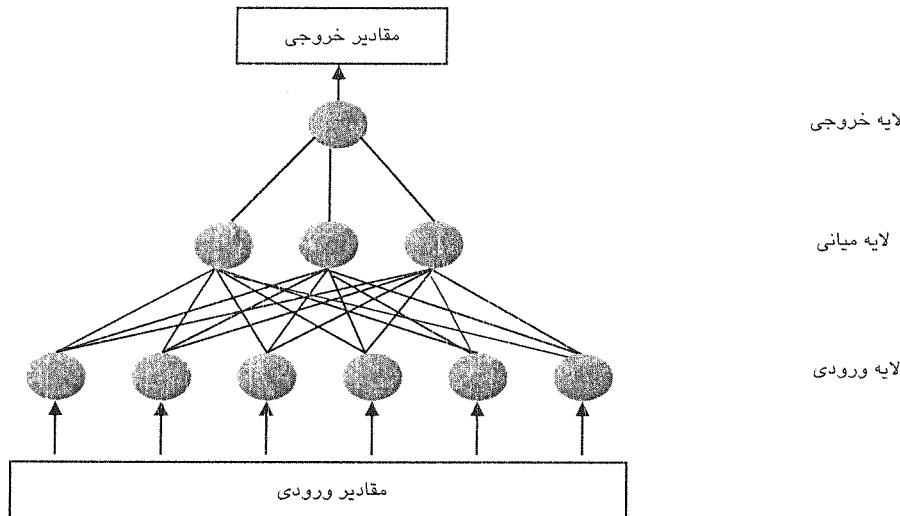
تحقیقان را بر آن داشته است که روش‌های پیش‌بینی سری‌های زمانی غیرخطی را ایجاد نمایند. اما این روش‌ها هم با توجه به فرضیات اولیه خود یک رابطه غیرخطی خاص را مورد توجه قرار می‌دهند و این رهیافت باعث عدم کشف الگوهای غیرخطی زیادی می‌شود که در اکثر سری‌های زمانی وجود دارند [۴],[۱۷],[۱۸].

رهیافت شبکه‌های عصبی به عنوان روش داده محور^۱ بدون در نظر گرفتن فرضیات موجود در روش‌های مدل‌گرا^۲ چشم انداز قدرتمند و نوینی در جهت تقریب توابع پیچیده است. 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 می‌شود.

استفاده از شبکه‌های عصبی برای پیش‌بینی ایده‌جیدی نیست. H۱۱ در سال ۱۹۶۴ در رساله خود برای اولین بار این ایده را برای پیش‌بینی وضعیت هوا با شبکه‌های خطی تطبیقی ویدرو^۳ مورد استفاده قرار داد. به واسطه نقص الگوریتم آموزشی برای آموزش شبکه‌های چند لایه، این تحقیق کاملاً محدود شده بود. این محدودیت تا سال ۱۹۸۶ که رملهارت الگوریتم پس انتشار خطأ را معرفی کرد، ادامه داشت و پس از آن گستره وسیعی از تحقیقات در این زمینه پیدا شد [۱۸].

حالوزاده در سال ۱۳۷۷، در رساله دکتری خود به مدل‌سازی و پیش‌بینی قیمت سهام شرکت شهد 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 با روش تخمین بعد همبستگی و روش تحلیل R/S بررسی شده است [۱۰].

در سال ۱۹۹۶ کوهزادی در تحقیقی به مقایسه شبکه‌های عصبی و مدل‌های سری زمانی باکس جنکینز در پیش‌بینی قیمت ماهانه گدم از سال ۱۹۹۰ تا ۱۹۹۰ پرداخته است [۱۱]. واپس در تحقیقی پیش‌بینی بهره روزانه سهام شرکت IBM را با شبکه عصبی و مدل AR در نظر گرفته است [۱۵]. در همین سال تحقیقی درباره پیش‌بینی شاخص سهام کوالالامپور با استفاده از شبکه‌های عصبی توسط یاو ترتیب داده شده است. در این تحقیق از تحلیل R/S برای تشخیص تصادفی بودن سری زمانی داده‌ها استفاده شده است [۱۶]. وانگ شبکه‌های عصبی مبتنی بر ARIMA (شبکه ترکیبی) را برای پیش‌بینی شاخص قیمت بازار بورس تایوان پیشنهاد کرده است [۱۴].



شکل(۱): یک شبکه عصبی با یک لایه میانی

داده‌ها را کشف و شناسایی کند تا با آن نگاشته‌های غیرخطی پیچیده را بین متغیرهای ورودی و خروجی برقرار کند. در مورد تعداد گره‌های مخفی شبکه‌های عصبی، طراحان ملزم به رعایت اصل صرفه‌جویی^۱ هستند که بر این اساس در آن قدرت تعیین بهتر از آن شبکه‌های با تعداد گره‌های مخفی کمتر خواهد بود. محققین برای محدود کردن تعداد گره‌های مخفی و جلوگیری از مسئله Overfitting، تعداد آنها را حداقل دو برابر تعداد گره‌های ورودی در نظر گرفته‌اند که در اغلب موارد این

انتخاب ابتکاری، نتایج خوبی داده است [۴],[۲].

تعداد گره‌های ورودی: برابر است با تعداد مشاهدات تاریخی که برای کشف 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 مسائل در پیش‌بینی سری‌های زمانی، انتخاب تعداد ورودی‌هاست. زیرا هر الگوی ورودی شامل اطلاعات مهمی در مورد ساختار خود همبسته پیچیده داده‌ها^۲ است.

تعداد گره‌های خروجی: در پیش‌بینی سری‌های زمانی اغلب تعیین تعداد گره‌های خروجی وابسته به افق پیش‌بینی است. دو نوع افق پیش‌بینی در مطالعات مورد استفاده بوده است. نخست افق پیش‌بینی یک روز بعد و دوم، افق پیش‌بینی چند روز بعد است. 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 می‌کند. در اکثر موارد، به ویژه در مسائل پیش‌بینی، از شبکه با اتصالات کامل بین گره‌ها استفاده می‌شود.

نخست آن که شبکه‌های عصبی بر خلاف روش‌های مبتنی بر مدل، روش‌هایی خود تطبیق‌ده و داده‌گرا هستند. 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 برای توصیف کردن سخت باشند- به دست می‌آورند. بنابراین برای حل مسائلی که نیاز به دانش پیچیده‌ای دارند اما داده‌های کافی برای آنها وجود دارد، مناسب هستند.

ویژگی دوم شبکه‌های عصبی این است که قابل تعیین هستند. شبکه‌های عصبی اغلب می‌توانند به طور صحیح داده‌هایی را که در مرحله آموزش استفاده نشده‌اند، استنباط کنند.

سوم آن که شبکه‌های عصبی تقریب‌زننده جامع^۳ هستند. به صورت تئوری نشان داده شده است که شبکه عصبی می‌تواند، هر تابع را با هر دقت دلخواه تقریب بزند [۷],[۴].

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

موارد زیر باید در پیش‌بینی سری‌های زمانی با استفاده از شبکه عصبی در نظر گرفته شود:

معماری شبکه: به معنی تعیین تعداد گره‌های ورودی، تعداد لایه‌های مخفی، گره‌های مخفی و تعداد گره‌های خروجی است. 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

معیارهای عملکرد: به دلیل محدودیت‌های اطلاعاتی که یک معیار منفرد دارد اغلب 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

فرمول	نام معیار
$\frac{\sum e_i }{N}$	MAE ^۸
$\frac{\sum (e_i)^2}{N}$	MSE ^۹
$\frac{1}{N} \sum \left \frac{e_i}{y_i} \right * 100$	MAPE ^{۱۰}
$Median \left(\left \frac{e_i}{y_i} \right * 100 \right)$	MDAPE ^{۱۱}
$1 - \frac{SSE}{SST}$	R ^۲
$\text{sgn}[(\hat{y}_t - \hat{y}_{t-1})(y_t - y_{t-1})] \geq 0$	Trend ^{۱۲}
t^y مقدار پیش‌بینی؛ y^t مقدار سری زمانی در لحظه t	
$e_i = \hat{y}_i - y_i$ تعداد الگوهای ورودی به شبکه	

۳-داده‌ها

داده‌های این مطالعه قیمت سهام شرکت ایران خودرو (Iran Khodro Stock Exchange Price) در بازار بورس IKSEP اوراق بهادار تهران است که از این پس به اختصار با نشان داده می‌شود. در بخش مربوط به متغیرهای موثر بر قیمت سهام شرکت ایران خودرو، متغیرهایی بنیادی از قبیل، نرخ ارز، قیمت نفت و نسبت حاصل تقسیم قیمت بر عایدی هر سهم (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 ۱۳۸۰-۱۳۷۹ و شامل ۳۷۹ مشاهده است. نمودار مربوط به سری قیمت سهام ایران خودرو (IKSEP) در طول زمان در شکل (۲) به نمایش درآمده است.

همانطور که شکل (۲) نشان می‌دهد سری دارای نوسان ناگهانی (شوک) در دوره زمانی مذبور است، شماره نقاط این شوک‌ها در جدول (۲) آمده است

تابع تبدیل: تابع تبدیل یا فعال‌ساز یا فشرده‌ساز، ارتباط بین ورودی و خروجی یک گره و یک شبکه را مشخص می‌کند. این توابع درجه‌ای از غیرخطی بودن را به شبکه تزریق می‌کنند که برای اکثر کاربردهای شبکه عصبی ارزشمند و مهم است. توابع تبدیل به کار گرفته شده توسط محققان در پیش‌بینی اغلب سیگموید (لジستیک)، تائزانت هیپرپولیک و خطی بوده‌اند [۱۸],[۱۲],[۴].

نرمال کردن داده‌ها: نرمال‌سازی داده‌ها باعث می‌شود داده‌های مورد استفاده در دامنه‌ای خاص، فشرده و هماهنگ شوند. برای نرمال‌سازی، به خصوص در موقعی که از توابع سیگموید یا تائزانت هیپرپولیک به عنوان تابع تبدیل شبکه استفاده می‌گردد، معمولاً از روش‌های زیر استفاده می‌شود [۱۸].

(۱) نرمال کردن خطی به دامنه [۰,۱]:

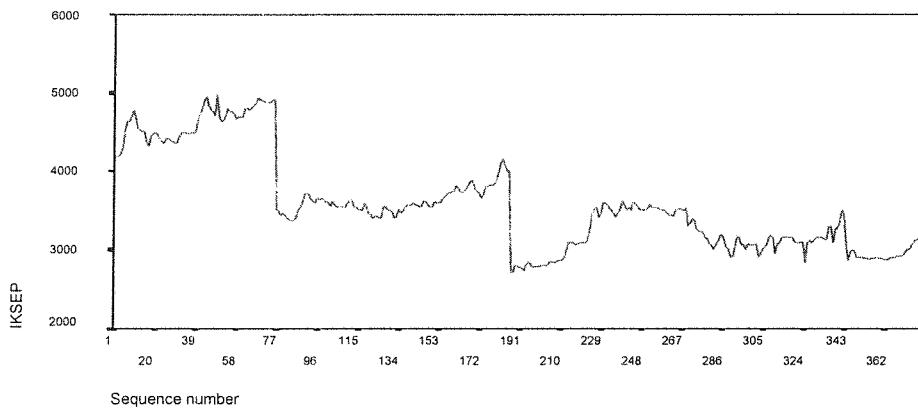
$$x_n = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

که در آن x مقدار خام و x_n مقدار نرمال شده در بازه $[x_{\min}, x_{\max}]$ است. برای دامنه [۰,۱] نرمال کردن خطی با

$$x_n = \frac{(b-a)(x - x_{\min})}{x_{\max} - x_{\min}} + a$$

(۲) نرمال کردن آماری x_n که \bar{x} و δ به ترتیب میانگین و انحراف معیار داده‌ها هستند.

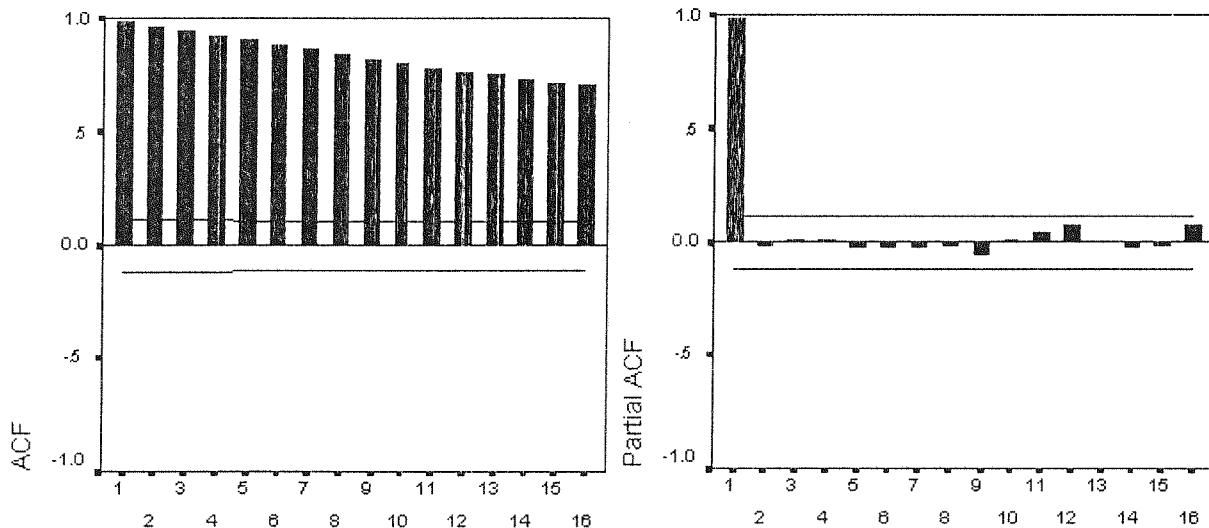
مجموعه تست و آموزش: برای استفاده از شبکه‌های عصبی مجموعه داده‌ها معمولاً به دو مجموعه تست و آموزش تقسیم می‌شوند. محققان در مسائل پیش‌بینی و تقریب توابع درصد از کل داده‌ها را به عنوان مجموعه تست در نظر می‌گیرند و بقیه را برای آموزش استفاده می‌کنند. گاهی اوقات از مجموعه سومی به نام مجموعه اعتبار (Valid Set) و تکنیک Cross Validation استفاده می‌شود. بدین ترتیب که قسمتی از مجموعه داده‌ها به عنوان مجموعه اعتبار در نظر گرفته می‌شود و همان طور که یادگیری شبکه به وسیله مجموعه آموزش بنبال 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 حال، در شبکه پدیده Overfitting در حال اتفاق افتادن است. این روش اغلب برای مجموعه داده‌های زیاد مورد استفاده است و در مجموعه داده‌های کم و معمولی همان دو مجموعه تست و آموزش کافی است [۱۸].



شکل(۲): نمودار سری زمانی IKSEP

جدول(۲): نقاط شوک سری

شماره	مقدار	تاریخ	نقاط
۱	۱۴۲۷	۷۹/۵/۲۴ و ۷۹/۴/۲۵	۷۶ و ۷۷
۲	۱۲۹۹	۷۹/۱۲/۹ و ۷۹/۱۱/۳۰	۱۸۶ و ۱۸۷
۳	۲۵۸	۸۰/۱۱/۱ و ۸۰/۱۰/۱۰	۲۴۲ و ۲۴۴



شکل(۳): نمودار ضریب خودهمبستگی و خودهمبستگی جزیی

IKSEP نشان می‌دهد که نرخ ارز بیشتر از بقیه با قیمت سهام IKSEP همبستگی دارد. همان طور که قبلًا عنوان شد برای امکان پیش‌بینی قیمت سهام، باید نشان داده شود در اطلاعات گذشته قیمت سهام، الگویی وجود دارد که با کشف این الگو، بتوان قیمت سهام شرکت را پیش‌بینی کرد. بدین منظور باید نشان داده شود که سری زمانی قیمت سهام شرکت ایران‌خودرو تصادفی نیست.

در شکل (۳) منحنی مربوط به توابع خود همبستگی (ACF^{۱۱}) و خود همبستگی جزئی (PACF^{۱۲}) سری IKSEP نشان داده شده است که نشان دهنده همبستگی بسیار زیاد میان تغییرهای سری IKSEP و نیز بیان‌کننده نایستایی^{۱۳} خیلی زیاد در سری مربوطه است. ضرایب همبستگی مقابل (CrossCorrelation) میان متغیرهای بنیادی و قیمت سهام

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 Elman، GRNN و RBFN آزمایش می‌شوند 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 تابی به شبکه ارائه و سپس خطای شبکه بر اساس اختلاف بین خروجی شبکه و مشاهده $p+1$ ام محاسبه می‌شود. شبکه MLP سعی می‌کند، مقدار مجموع مرיבعات (خطا) حاصل از تمام الگوهای ورودی به شبکه را می‌نیم کند. این عمل با تنظیم پارامترهای وزن و بایاس شبکه صورت می‌گیرد. 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.

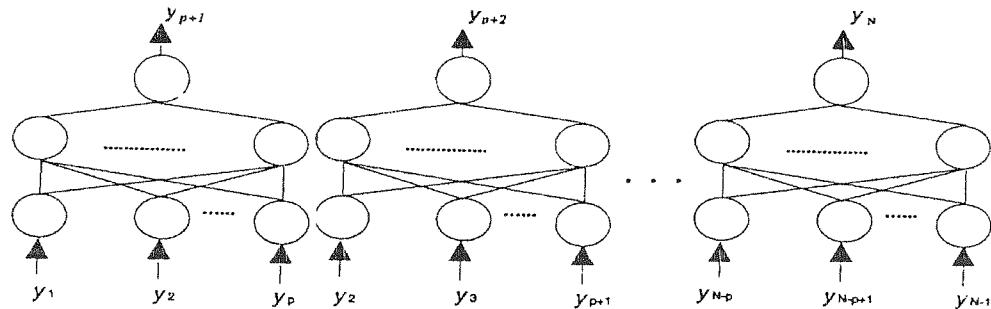
در این صورت امکان کشف الگو و پیش‌بینی قیمت سهام وجود دارد.

آزمون‌هایی از قبیل گردش^{۱۵}، فراوانی، فریال^{۱۶}، گپ^{۱۷} و همبستگی دنباله‌ای^{۱۸}، برای بررسی تصادفی بودن یا نبودن یک سری زمانی وجود دارد. روش‌هایی هم مانند تخمین بعد همبستگی^{۱۹}، روش محاسبه بزرگترین نمای لیاپانوف^{۲۰} و تحلیل R/S^{۲۱} 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 $-16/15$ است که از مقدار $-1/96$ 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) را به خاطر



شکل (۴): ساختار شبکه برای پیش‌بینی یک روز بعد

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 (آماری) نرمالیزه شوند. در قدم بعدی شبکه با استفاده از این داده‌ها آموزش می‌بینند 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.

۴-۱- نرمال‌سازی داده‌ها

برای بررسی ضرورت نرمال کردن داده‌ها، ابتدا از داده‌های خام برای ورود به شبکه استفاده می‌شود. 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

جدول(۳): بهترین عملکرد شبکه با داده‌های نرمال شده

بهترین تعداد گردها		معیار عملکرد							روش نرمال‌سازی
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)		
۱	۲	۸۲/۴	۴۶/۰۰	۱/۰۲	۰/۰۸	۰/۷۸	۵۰/۷	خطی	
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۰۷	۰/۷	۴۷/۹۵	استاندارد	

۲- تابع تبدیل خطی برای لایه خروجی

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

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

۴- توابع تبدیل

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

۱- تابع تبدیل سیگموید یا تائزانت هیپربولیک برای لایه مخفی

جدول(۴): بهترین عملکرد شبکه با انواع تابع

بهترین تعداد گردها		معیار عملکرد							تابع
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)		
۲	۲۳۰۴۰۰۰	۱۱۴/۲	۶۱/۸	۲/۰۱	۱/۱۶	۰/۶	۵۲	خطی برای تمام لایه‌ها	
۰	۳	۹۱/۷۸	۵۷/۷	۱/۸۶	۱/۰۱	۰/۶۱	۵۰/۶۷	Tanh برای تمام لایه‌ها	
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۰۷	۰/۷	۴۷/۹۵	آبرای مخفی - خطی برای خروجی Tanh	

(سیگموید یا تائزانت هیپربولیک) برای لایه مخفی و خطی برای لایه خروجی است و تحقیقات با این ترکیب بهینه ادامه می‌یابد.

۴-۳- انتخاب مجموعه آموزش و آزمایش

۸۰ درصد مجموعه داده‌ها به عنوان مجموعه آموزش (۳۰۲ داده) و بقیه داده‌ها برای لایه مخفی استفاده می‌شوند (۷۷ داده). جدول (۵) بهترین نتایج معیارهای عملکرد را به ترتیب در برابر مجموعه آزمایش و آموزش نشان می‌دهد. با توجه به جدول، مقدار R² حداقل برابر با ۰/۷ می‌باشد و این بدین معنی است که ۷۰ درصد از پراکنده‌گی داده‌ها به وسیله تقسیم‌بندی مذکور پوشانده شده است. بنابراین در قدم اول ارزیابی عملکرد شبکه فوق سعی می‌شود تا مقدار R² بهبود داده شود.

با توجه به آزمایش‌های اجرا شده، مشاهده شده است که همراه با استفاده از تابع تبدیل خطی برای لایه مخفی، تعداد گره‌های مخفی بر عملکرد شبکه بی‌تأثیر می‌شوند یا به عبارت دیگر، عملًا لایه مخفی از شبکه MLP کنار گذاشته می‌شود و همچنین عملکرد شبکه رو به وحامت می‌نهد. این مسئله ضرورت استفاده از تابع تبدیل غیرخطی (سیگموید یا تائزانت هیپربولیک) را برای لایه مخفی نشان می‌دهد تا لایه مخفی هم به عنوان یک عنصر مؤثر بر عملکرد شبکه تأثیر گذارد باشد. به همین ترتیب استفاده از تابع تبدیل غیرخطی برای لایه خروجی شبکه، تأثیر نامطلوب بر عملکرد شبکه داشته است. بنابراین بهترین تابع تبدیل برای شبکه، تابع تبدیل غیرخطی

جدول(۵): معیارهای عملکرد برای بهترین معماری

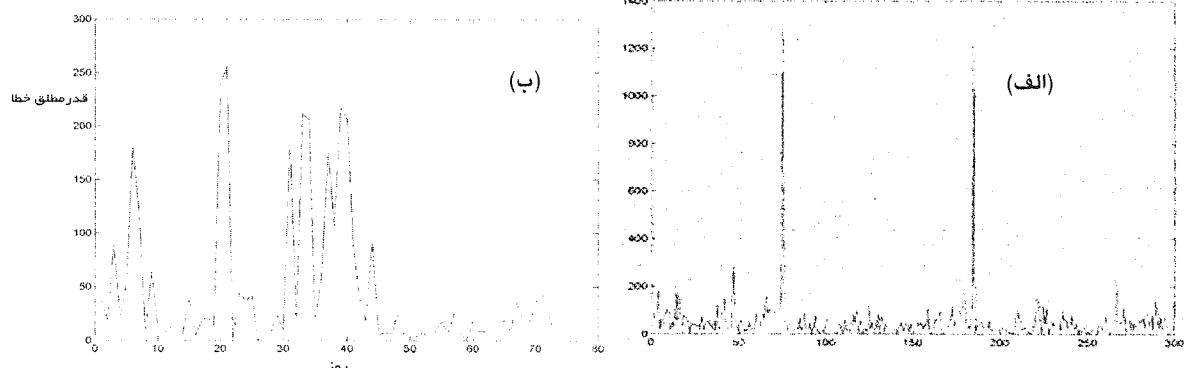
بهترین تعداد گردها		معیار عملکرد							مجموعه
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)		
۲	۲	۸۱	۴۵/۹۷	۱/۴۹	۰/۰۷	۰/۷	۴۷/۹۵	آزمایش	
۲	۲	۱۲۲/۲۴	۵۳/۲	۱/۴۶	۰/۹۳	۰/۹۶	۵۵	آموزش	

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 آزمایش 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.

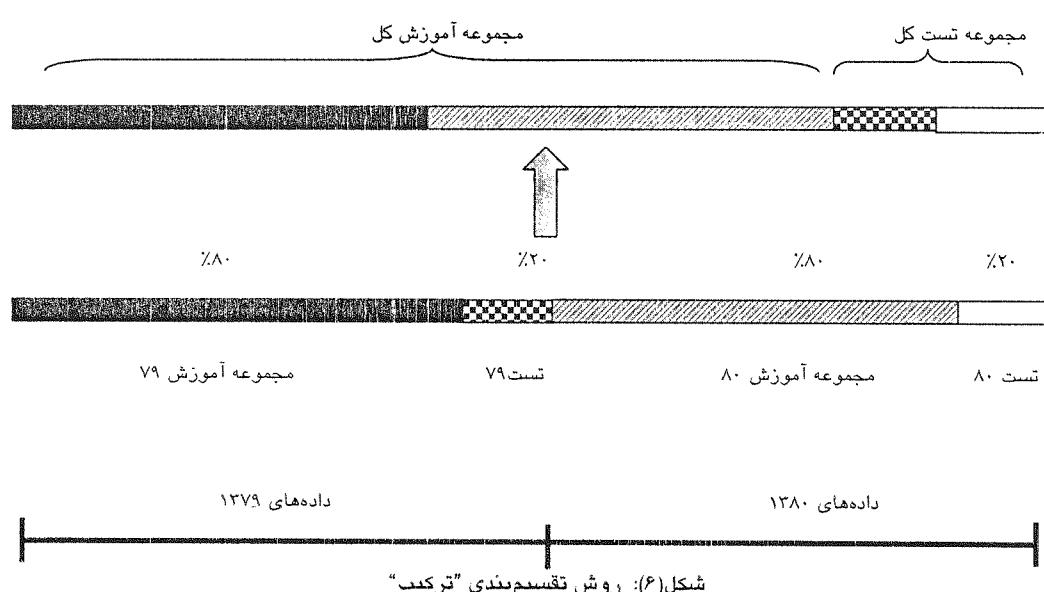
با استفاده از تقسیم‌بندی مذکور، مجموعه آموزش از مناطق مختلف بیشتری از فضای ورودی داده‌ها، انتخاب می‌شود و باعث می‌شود که داده‌های متنوع‌تری از مجموعه داده‌ها برای آموزش شبکه انتخاب شوند و در نتیجه الگوهای بیشتری از داده‌ها توسط شبکه یاد گرفته می‌شود. با یادگیری بیشتر، قدرت توضیح پراکنده‌گی داده‌ها به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

همچنین شکل (۵) 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 بر می‌گردد. این شوک‌های ناگهانی و زیاد، تأثیر نامطلوب بر عملکرد شبکه در هر دو مرحله آموزش و آزمایش می‌گذاردند. در نتیجه شبکه قادر نخواهد بود پراکنده‌گی داده‌ها را در اطراف نقاط شوک به نحو مطلوبی توضیح دهد و باعث می‌شود مقدار R^2 با وجود تنظیمات مختلف در شبکه، مقدار ۷/۰ باقی بماند.

برای کاستن از تأثیر این شوک‌های ناگهانی و در نتیجه توضیح بهتر پراکنده‌گی‌های اطراف نقاط شوک (افزایش مقدار R^2) مجموعه داده‌ها برای سالهای ۱۳۷۹ و ۱۳۸۰ به صورت جداگانه بررسی می‌شود. سپس از هر دو مجموعه،



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



شکل(۶): روش تقسیم‌بندی "ترکیب"

مجموعه آزمایش و آموزش برای بهترین معماری در جدول (۶) گرهای ورودی و مخفی مختلف و روش یادگیری لونبرگ آمده است.

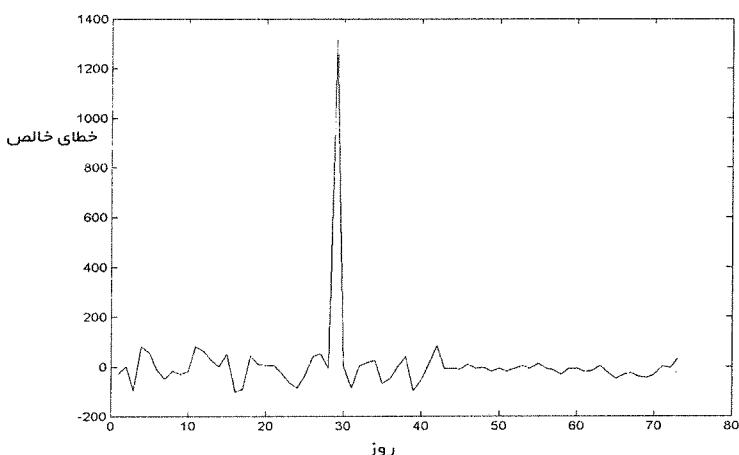
شبکه MLP سه لایه با استفاده از این داده‌ها با تعداد گرهای ورودی و مخفی مختلف و روش یادگیری لونبرگ مارکوارت آموزش داده می‌شود. شاخص‌های خطا در مقابل

جدول(۶): معیارهای عملکرد بهترین معماری در تقسیم‌بندی دوم

بهترین تعداد گرهای مخفی		معیار عملکرد							مجموعه
ورودی	مخفی	MSE	MAE	MAPE	MDAPE	R ²	Trend(%)		
۲	۲	۱۶۰/۰۹	۴۷/۳۹	۱/۵۴	.۰/۷	.۰/۸۹	۵۶/۲۴		آزمایش
۲	۲	۱۰۰/۱۵	۵۱/۲	۱/۲۵	.۰/۸۵	.۰/۹۷	۵۲/۲۲		آموزش

مشاهده نشود. خطا خیلی زیاد حاصل از نقطه شوک باعث شده است معیارهای عملکرد شبکه دچار اختلال شوند. به گونه‌ای که آنها گویای عملکرد واقعی تقسیم‌بندی جدید می‌باشد. با حذف این مقدار خطا، معیارهای عملکرد با مقدار R^2 که نشان دهنده میزان پراکنگی داده‌ها توسط مدل جدید می‌باشد، همخوانی خواهد داشت. جدول (۷) مقدار این معیارهای عملکرد را در مجموعه آزمایش و آموزش نشان می‌دهد.

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 R^2 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 خطا خیلی زیاد باعث شده است، با وجود بهبود در مقدار R^2 در بقیه معیارهای عملکرد بهبودی



شکل(۷): خطای خالص در تقسیم‌بندی دوم

جدول(۷): مقادیر معیارهای عملکرد اصلاح شده

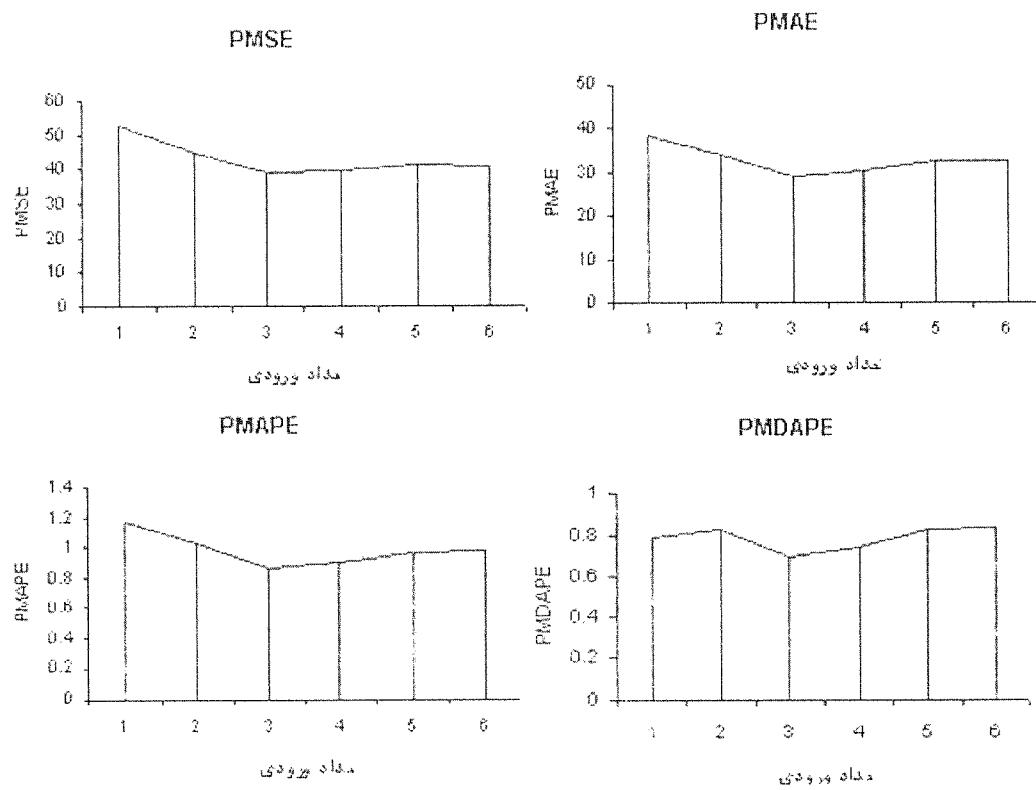
بهترین تعداد گرهای مخفی		معیار عملکرد							مجموعه
ورودی	مخفی	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)		
۲	۲	۶۲/۹۰	۴۵	۱/۲۶	.۰/۸۶	.۰/۹۹	۵۶/۶۱		آموزش
۲	۲	۳۹/۲	۲۹/۲	۰/۰۸۷	.۰/۷۹	.۰/۹۹	۶۰		آزمایش

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

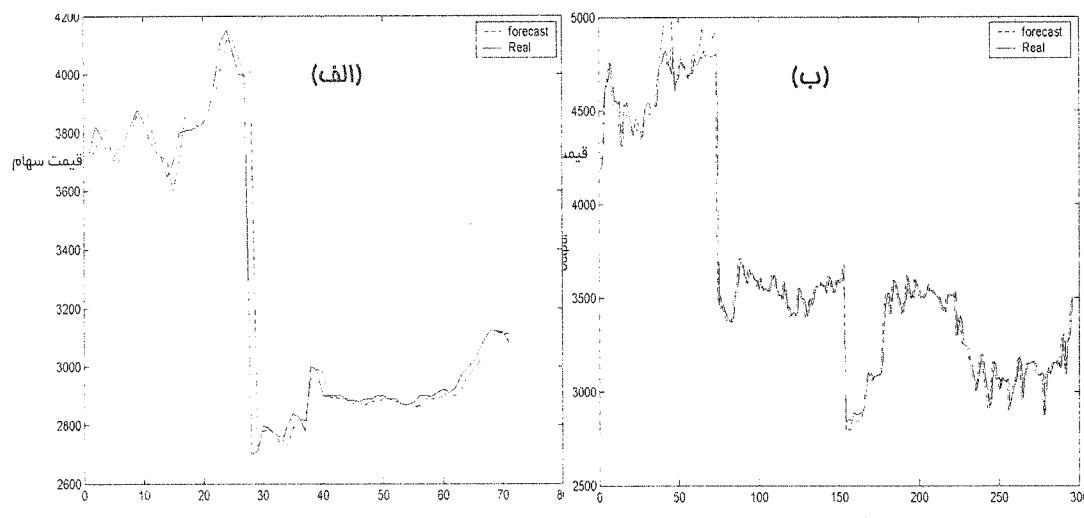
به منظور ارائه عملکرد شبکه با تقسیم‌بندی جدید، معیارهای MAPE, MSE, MAE, MDAPE, PR², PMDAPE, PMAPE, PMAE, PMSE (Pure MSE)

حداقل مقدار خود می‌رسند، بنابراین بهترین معماری شبکه با تعداد ورودی سه به دست می‌آید و معماری ۲-۲-۱ در بین معمارهای موجود بهترین جواب را ارائه می‌دهد. شکل (۹) عملکرد شبکه را در شبیه‌سازی و پیش‌بینی برای بهترین معماری (۲-۲-۱) نشان می‌دهد.

پیش‌بینی (پیش‌بینی در مجموعه آزمایش) و شبیه‌سازی (پیش‌بینی در مجموعه آموزش) مورد بررسی قرار داد.
نمودارهای PMAPE, PMAE, PMSE مربوط به تأثیر تعداد ورودی بر عملکرد شبکه بر مجموعه آزمایش در شکل (۸) آمده است. هر چهار معیار با تعداد ورودی سه به



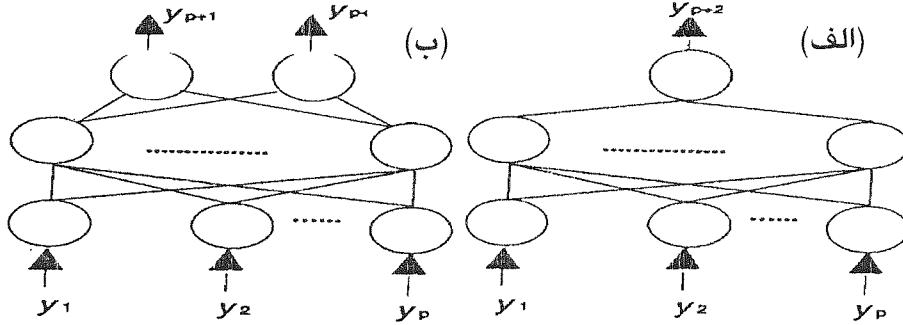
شکل(۸): تأثیر تعداد ورودی بر معیارهای عملکرد



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

پیش‌بینی با یک خروجی است. همانند شکل (۱۰ 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 (۸) نشان داده شده است.

در قسمت قبل با داشتن اطلاعات سری قیمت IKSEP مربوط به p روز قبل، پیش‌بینی مقدار سری در روز $p+1$ ام انجام گرفت. در عمل با توجه به زمان بری فرآیند 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



شکل (۱۰): الگوی ورودی به شبکه برای پیش‌بینی دو روز بعد

جدول (۸): بهترین معیارهای عملکرد در پیش‌بینی دو روز بعد با دو روش

بهترین تعداد گره‌ها		معیار عملکرد						تعداد گره خروجی
ورودی	مخفي	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	
۳	۲	۶۹/۲	۵۲/۱	۱/۰۸	۱/۲۴	۰/۹۸	۵۲/۲۴	یک
۲	۳	۶۴/۹	۵۰/۶	۱/۵	۱/۲۵	۰/۹۸	۴۹/۲۸	دو

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 (۹) آمده است.

دوم، پیش‌بینی با دو خروجی است. آموزش و تست شبکه بر اساس ساختار موجود در شکل (۱۰ ب) است. نتایج نشان می‌دهد که شبکه با دو خروجی برای پیش‌بینی دو گام به جلو موفق‌تر از شبکه با یک خروجی عمل کرده است.

جدول (۹): بهترین معیارهای عملکرد در پیش‌بینی هفت روز بعد با دو روش

بهترین تعداد گره‌ها		معیار عملکرد						تعداد گره خروجی
ورودی	مخفي	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	
۱	۲	۱۲۹/۲	۱۱۰/۷۶	۲/۲	۲/۴۶	۰/۹۵	۴۶/۴	یک
۱	۴	۱۲۰/۴	۹۴/۴	۲/۸	۲/۲	۰/۹۵	۴۶/۴۲	هفت

ارز به عنوان یکی از کالاهای مرتبه با سهام می‌تواند در قیمت سهام مؤثر باشد. در این تحقیق مقادیر ضریب همبستگی نرخ ارز بیشتر از بقیه متغیرهای ذکر شده بوده است. بنابراین انتظار می‌رود با ورود نرخ ارز به شبکه، مقادیر پیش‌بینی شبکه بهبود یابد. بدین منظور نرخ ارز به عنوان ورودی به شبکه اعمال می‌شود. جدول (۱۰) نتایج مربوط به تأثیر نرخ ارز بر پیش‌بینی قیمت سهام را برای بهترین معماری شبکه نشان می‌دهد. با توجه به این جدول شبکه MLP با ورود نرخ ارز در

۵- پیش‌بینی با استفاده از متغیرهای بنیادی و فنی

همان طور که قبلاً ذکر شد متغیرهای مؤثر بر بازار بورس متعدد هستند. در این بخش تأثیر دو متغیر نرخ ارز و قیمت نفت را به عنوان کالاهای مرتبه با سهام متغیر p/e, p, را به عنوان یکی از ابزارهای رایج برای تحلیل وضعیت شرکت و متغیر حجم مبادلات سهام در پیش‌بینی قیمت سهام بررسی می‌کنیم.

آزمایش قرار گرفته و نتایج آن در جدول (۱۰) آمده است. در پیش‌بینی هفت روز بعد، نرخ ارز توانست بهبود قابل توجهی در معیارهای عملکرد شبکه ایجاد نماید.

دو متغیر PMSE و درصد تشخیص صحیح جهت حرکت قیمت سهام بهبود یافته است. همچنین قابلیت شبکه در تشخیص صحیح جهت حرکت قیمت سهام، بهبود قابل ملاحظه‌ای یافته است. در ادامه تأثیر نرخ بر پیش‌بینی هفت روز بعد مورد جدول (۱۰) بهترین معیارهای عملکرد با ورود نرخ ارز به شبکه در پیش‌بینی یک و هفت روز بعد

بهترین تعداد گره‌ها		معیار عملکرد						افق پیش‌بینی (روز)
ورودی	مخفي	PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	
۲	۴	۴۴/۴	۲۲/۶	۰/۹۶	۰/۷۷	۰/۹۹	۵۹/۷۲	یک
۲	۲	۷۲/۰۴	۵۹/۶	۲/۰۴	۲/۷۶	۰/۹	۴۹/۲	هفت

۶- پیش‌بینی با انواع مختلف شبکه‌های عصبی

در بخش قبل از عمومی‌ترین و پراستفاده‌ترین شبکه به منظور پیش‌بینی قیمت سهام استفاده شد. در این بخش از چند شبکه دیگر که در تقریب توابع مورد استفاده قرار می‌گیرند برای پیش‌بینی قیمت سهام استفاده می‌شود.

۶-۱- شبکه Cascade

شبکه Cascade در واقع همان شبکه MLP است که از یک اتصال ورودی به خروجی نیز در معماری خود استفاده می‌کند. بهترین معماری شبکه Cascade برای پیش‌بینی یک روز بعد، معماری ۳-۲-۱ است. در این معماری تمامی معیارهای عملکرد نسبت به شبکه MLP بهبود یافته‌اند. این شبکه توانسته است اندکی از پراکنده‌گی داده‌ها را که شبکه MLP توانسته است تبیین کند، توضیح دهد. البته قابلیت تشخیص صحیح جهت حرکت قیمت در این شبکه نسبت به MLP کاهش داشته است. بهبود حاصل شده توسط شبکه Cascade را می‌توان به این صورت تشرییح نمود: که شبکه Cascade در حقیقت ترکیب دو شبکه MLP و آدلاین است.

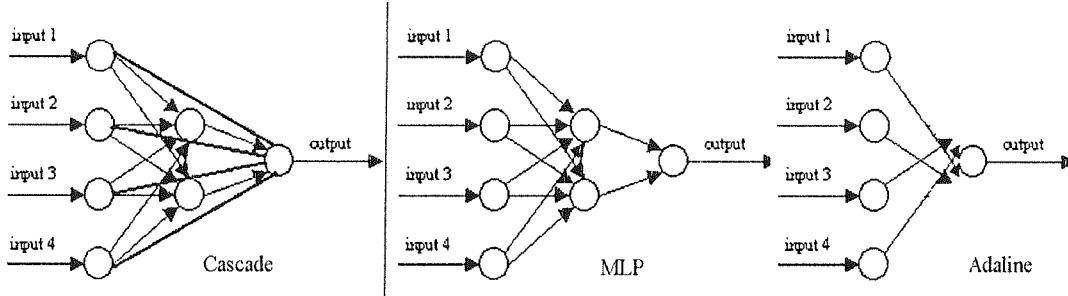
شبکه Cascade با استفاده از شبکه آدلاین که دو لایه با تابع تبدیل خطی است، توانسته است در کشف روابط خطی میان داده‌ها به شکل قوی‌تر و بهتری نسبت به شبکه MLP عمل نماید و در نتیجه، پیش‌بینی بهتری را ارائه داده است. در حقیقت شبکه Cascade بهترین نمونه از یک مدل ترکیبی برای پیش‌بینی قیمت سهام می‌باشد. شکل (۱۱) این موضوع را نشان می‌دهد. در جدول (۱۱)، درصد بهبود معیارهای عملکرد مدل پیش‌بینی پوسیله شبکه Cascade ارائه شده است. در پیش‌بینی چند روز بعد، شبکه Cascade دقیقاً مانند شبکه MLP عمل نموده است.

با ورود قیمت نفت تنها پارامتری که بهبود یافته است قابلیت تشخیص صحیح جهت حرکت قیمت سهام است. در بقیه معیارهای عملکرد، قیمت نفت تأثیری نداشته است. همچنین از قیمت نفت در پیش‌بینی چند گام به جلو نیز استفاده شده است که نتایج هیچ بهبودی را در معیارهای عملکرد نشان نداده است. نسبت p/e حاصل تقسیم قیمت بر عایدی هر سهم است. نسبت p/e بهترین نقطه شروع در تحلیل سرمایه‌گذاری در اوراق بهادر است. سادگی محاسبه، عدم دخالت عوامل ذهنی و ایجاد قابلیت مقایسه و ضعیت شرکت‌ها، صنایع و بازار از جمله مزیت‌هایی است که موجب شده است این نسبت به عنوان یکی از ابزارهای متدالو جهانی در ارزشیابی اوراق بهادر مطرح باشد. نتایج حاصل از ورود این نسبت به شبکه، بهبودی را در معیارهای خطأ و همین‌طور قابلیت تشخیص جهت حرکت قیمت نشان نداده است. همین‌طور از این متغیر در پیش‌بینی چند گام به جلو هم استفاده شده است که بهبودی در این زمینه حاصل نشده است.

بر اساس تحقیقات انجام شده در بورس نیویورک به طور معمول حجم مبادلات و تغییرات قیمت سهام با یکدیگر رابطه دارند. این رابطه در شرایط مختلف و در فاصله‌های زمانی مختلف با اوراق بهادر مورد بررسی قرار گرفته است و نشان داده شده است که در بورس نیویورک رابطه بین تغییر قیمت سهام روز بعد و حجم مبادلات سهام هر روز وجود دارد. نتایج حاصل از ورود این متغیر به شبکه نشان می‌دهد. حجم مبادلات سهام، تأثیری بر عملکرد شبکه نداشته است. همچنین برای پیش‌بینی چند گام به جلو هم بهبودی مشاهده نشده است.

جدول(۱۱): درصد بهبود معیارهای عملکرد شبکه MLP

PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)
۲/۳۰	۲/۷۰	۹/۲	۱۱/۸	-	-۴/۸



شکل(۱۱): شبکه Cascade بعنوان یک شبکه ترکیبی

مربوط به پیش‌بینی ۷ روز بعد، بهبود در معیارهای عملکرد را نسبت به شبکه MLP نشان می‌دهد.

از شبکه‌های GRNN و RBFN هم برای پیش‌بینی قیمت سهام استفاده شد ولی نه تنها بهبودی با این شبکه‌ها حاصل نشد، بلکه نتایج به مراتب بدتری نسبت به سه شبکه ذکر شده در قبل داشتند. بنابراین به طور خلاصه بهترین شبکه‌ها برای افق‌های پیش‌بینی یک، دو و هفت روز بعد عبارتند از:

۶-۲- شبکه المان

این شبکه می‌تواند الگوهای موقت را ذخیره نماید. الگوریتم آموزشی که این شبکه استفاده می‌نماید الگوریتم آموزشی لوونبرگ مارکوارت می‌باشد [۷]. در شبکه المان پیش‌بینی‌ها تقریباً مانند شبکه MLP بود. این شبکه نیاز به استفاده از گره‌های مخفی بیشتری از شبکه MLP و Cascade دارد. استفاده از گره‌های مخفی بیشتر در پیش‌بینی یک روز و چند روز برای رسیدن شبکه به بهترین جواب لازم است. نتیجه

جدول(۱۲): بهترین شبکه‌ها در افق‌های مختلف

نوع شبکه	افق پیش‌بینی	معیار عملکرد							بهترین تعداد گره‌ها	ورودی	محضی
		PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)				
Cascade	یک روز بعد	۲۷/۹	۲۸/۱	۰/۷۹	۰/۶۱	۰/۹۹	۵۷/۱	۲	۲	پیش‌بینی	
MLP	دو روز بعد	۶۴/۹	۵۰/۶	۱/۵	۱/۲۵	۰/۹۸	۴۹/۲۸	۲	۲	پیش‌بینی	
با نرخ ارز MLP	هفت روز بعد	۷۳/۰۴	۵۹/۶	۲/۰۴	۲/۷۶	۰/۹۷	۴۹/۲	۱+۱ (قیمت سهام و نرخ ارز)	۲	پیش‌بینی	

۷-۱- پیش‌بینی با روش هموارسازی نمایی

پیش‌بینی نمایی یکی از روش‌هایی است که گستردگرین کاربرد را در میان روش‌های مختلف پیش‌بینی سری‌های زمانی گسترش کوتاه‌مدت دارد و آینده فوری و نزدیک را پیش‌بینی می‌کند. این عمومیت استفاده به علت سادگی، کارایی محاسباتی و دقت قابل قبول آن است [۲].

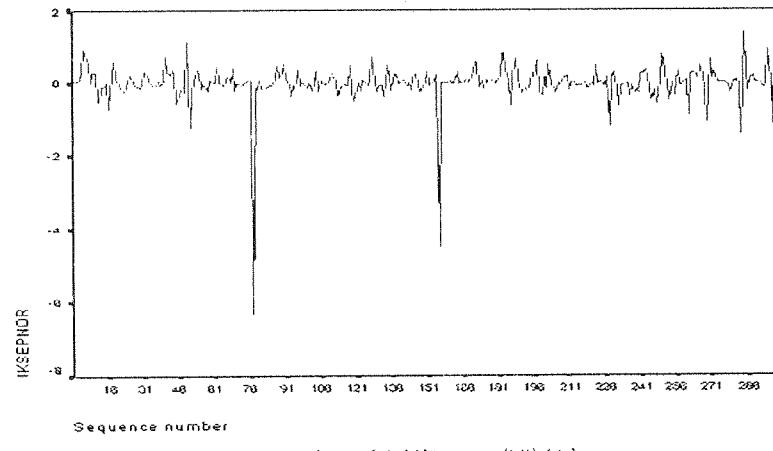
سری IKSEP با روش هموارسازی نمایی مورد پیش‌بینی قرار گرفت. جدول (۱۳)، درصد بهبود مدل هموارسازی نمایی را بوسیله مدل شبکه نشان می‌دهد.

۷- پیش‌بینی با روش‌های خطی

در قسمت‌های قبل مدل‌های شبکه عصبی برای داده‌های IKSEP ارائه شد. در این قسمت به منظور مقایسه قابلیت مدل‌سازی شبکه عصبی با روش‌های خطی، به مدل‌سازی سری IKSEP با دو روش خطی هموارسازی نمایی و باکس‌جنکنیز پرداخته می‌شود.

۷-۲- پیش‌بینی با روش باکس جنکینز

برای استفاده از رویه باکس جنکینز ابتدا نرمال بودن سری زمانی بررسی می‌شود. آزمون کلموگروف-اسمیرنوف نشان می‌دهد که سری IKSEP نرمال نیست. به منظور نرمال کردن سری از تبدیل Box-Cox استفاده و سری نرمال شده برای ادامه فرایند مدل‌سازی در نظر گرفته می‌شود. با توجه به شکل ۲ مشاهده می‌شود که مقدار سری با افزایش زمان به طور متوسط کاهش می‌یابد. در تائید این حدس، نمودار ضرایب خود همبستگی سری زمانی در شکل (۳) نشان می‌دهد که



شکل(۱۲): سری تفاضل‌گیری شده

معنی است که مقادیر باقی‌ماندها مستقل از هم بوده و برازش مناسب است. پیش‌بینی یک روز بعد توسط مدل ذکر شده انجام می‌شود. جدول (۱۲)، درصد بهبود معیارهای عملکرد روش باکس جنکینز را بوسیله مدل شبکه نشان می‌دهد؛ با توجه به آن می‌توان نتیجه گرفت که شبکه عصبی در مدل‌سازی و پیش‌بینی سری IKSEP به مراتب بهتر و قوی‌تر از بهترین روش خطی (باکس جنکینز)، عمل کرده است.

نمودار ضرایب خود همبستگی و خود همبستگی جزیی سری پس از یکبار تفاضل‌گیری نشان می‌دهد که فقط ضریب خود همبستگی مرتبه اول معنی‌دار است، بنابر این مقدار ρ در ARIMA(p,d,q)، یک خواهد بود. همچنین مقدار q برابر با یک است و مدل باکس جنکینز سری ARIMA(1,1,1) است. در نهایت، نمودار ACF و PACF مربوط به باقی‌ماندهای مدل نشان می‌دهد که هیچ‌کدام از ضرایب خود همبستگی و خود همبستگی جزیی سری باقی‌مانده معنی‌دار نیست، این بدین

جدول(۱۳): درصد بهبود مدل شبکه نسبت به دو روش خطی

معیار عملکرد						نوع مدل خطی
PMSE	PMAE	PMAPE	PMDAPE	PR ²	Ptrend(%)	
۵۹	۵۴	۵۶	۵۴	۱۵	۲۷	هموارسازی‌نمایی
۴۹	۴۸	۵۱	۵۲	۱۴	۲۰	ARIMA (1,1,1)

عصبی و انواع متغیرهای بنیادی و فنی پرداخته شد. در ابتدا به کمک آزمون گردنش، تصادفی نبودن داده‌ها و در نتیجه وجود داشتن الگو بین داده‌ها به اثبات رسید.

در ادامه به طراحی مدل پیش‌بینی به کمک شبکه عصبی با توجه به فاکتورهایی نظیر نرمال‌سازی داده‌ها، توابع تبدیل و انتخاب مجموعه آموزش و آزمایش پرداخته شد. طبق

۸- نتیجه گیری

در این مقاله با توجه به اهمیت پیش‌بینی قیمت سهام ایران خودرو به عنوان بزرگترین واحد خودروسازی کشور و بکی از بزرگترین شرکت‌های عضو بازار بورس تهران، به مدل‌سازی و پیش‌بینی قیمت سهام آن به وسیله انواع شبکه‌های

توانست در پیش‌بینی هفت روز بعد، نتایج شبکه MLP را به طور قابل ملاحظه‌ای بهبود ببخشد. در خاتمه از شبکه‌های عصبی RBFN و Cascade، Elman، GRNN تقریب توابع مورد استفاده قرار می‌گیرند، جهت پیش‌بینی قیمت سهام ایران خودرو استفاده شد. در این میان شبکه Cascade توانست نتایج حاصل از شبکه MLP را در پیش‌بینی یک روز بعد، بهبود ببخشد. در خاتمه، بهترین مدل خطی یعنی مدل باکس-جنکینز نیز برای پیش‌بینی قیمت سهام شرکت ایران-خودرو مورد استفاده قرار گرفت. نتایج نشان دادند که مدل شبکه به مراتب بهتر از مدل باکس-جنکینز عمل می‌کند [۲].

آزمایش‌های انجام شده، نرمال‌سازی استاندارد و استفاده از تابع تبدیل سیگموئید یا هیبروبولیک برای لایه مخفی و تابع تبدیل خطی برای لایه خروجی قدرت شبکه را به نحو چشمگیری بهبود می‌دهد. در انتخاب مجموعه آموزش و آزمایش استفاده از روش ارائه شده در مقاله، باعث شده است مجموعه آموزش از مناطق مختلفی از فضای ورودی داده‌ها، انتخاب شود و در نتیجه الگوهای بیشتری از داده‌ها توسط شبکه یادگرفته شود. همچنین بجز پیش‌بینی روز بعد، پیش‌بینی دو و هفت روز بعد هم مورد بررسی قرار گرفت. در ادامه از چهار متغیر بنیادی؛ نرخ ارز، قیمت نفت، p/e و حجم مبادلات سهام برای ورود به شبکه استفاده شد. در بین متغیرهای بنیادی، نرخ ارز

۹- مراجع

- [۱] Khaloozadeh H; Sedigh AK.; "Long Term Prediction of Tehran Price Index (TEPIX) using Neural Networks", ieeexplore.ieee.org, 2001.
- [۲] Kohzadi N.; Boyd M.; Kermanshahi B.; Kaastra I.; "A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices", Neurocomputing, Vol.15, 1996.
- [۳] The Mathworks Web Site; <http://www.mathworks.com>
- [۴] Tseng F.; Yu H.; Tzeng G.; "Combining Neural Network Model with Seasonal Time Series ARIMA Model", Technological Forecasting & Social Change, Vol.69, 2002.
- [۵] Wang G.; Leu J.; "Stock Market Trend Prediction Using ARIMA Based Neural Networks", IEEE, 1996.
- [۶] White H.; "Economic Prediction Using Neural Networks: The case of IBM Daily Stock Returns", <http://www.citeseer.nj.nec.com/context>, 1993.
- [۷] Yao J.; Poh H.; "Forecasting The KLSE Index Using Neural Networks", Department of Information System and Computer Sience, National University of Singapore, 1996.
- [۸] Zhang G.; HU M.; "Neural Network Forecasting of the British pound/US Dollar Exchang Rate", Omega, Vol. 26, No.4., 1998, P.495-509.
- [۹] Zhang G.; Pattuwo E.B.; "Forecasting with Artificial Neural Networks: the State of the Art", International Journal of forecasting, Vol.14, P.35-62, 1998.
- [۱۰] [۱۱] [۱۲] [۱۳] [۱۴] [۱۵] [۱۶] [۱۷] [۱۸]
- [۱۰] [۱۱] [۱۲] [۱۳] [۱۴] [۱۵] [۱۶] [۱۷] [۱۸]
- [۱] جهان‌خانی، علی؛ پارسائیان، علی؛ "مدیریت سرمایه‌گذاری و ارزیابی اوراق بهادر"، انتشارات دانشکده مدیریت دانشگاه تهران، ۱۳۷۶.
- [۲] عباس‌پور، محمدرضا؛ "پیش‌بینی قیمت سهام شرکت ایران‌خودرو با شبکه عصبی"، پایان‌نامه کارشناسی ارشد مهندسی صنایع-سیستم‌های اقتصادی، دانشگاه تربیت مدرس، مهر ۱۳۸۱.
- [۳] فاطمی قمی، محمدتقی؛ "پیش‌بینی و تجزیه و تحلیل سری‌های زمانی"، شردانش امروز، ۱۳۷۳.
- [۴] Boyd M.; Kaastra I.; "Designing a Neural Network for Forecasting Financial and Economic Time Series", Vol.10, 1996.
- [۵] Chenoweth T.; Obradovic Z.; "A Multi-Component Nonlinear Prediction System for the S&P 500 Index", Neurocomputing, Vol. 10, P.275-290, 1996.
- [۶] Diniz H.; "Architecture Design of Artificial Neural Networks Based on Box & Jenkins Models for Time Series Prediction", IEEE, 1999.
- [۷] Haykin S.; "Neural Networks: A Comprehensive Foundation", Prentice-Hall, 1999.
- [۸] Jang J.R.; Sun C.; Mizutani E.; "Neuro-Fuzzy and Soft Computing", Prentice-Hall, 1997.
- [۹] Kanas A.; Yannopoulos A.; "Comparing Linear and Nonlinear Forecasts for Stock Returns", Vol.10, 2001.

- ^ Data-Driven
- ^ Model Based
- ^ Widrow
- ^ Backpropagation
- ^ Universal Function Approximation
- ^ Parsimony Principle
- ^ Complex Autocorrelation
- ^ Mean Absolute Error
- ^ Mean Standard Error
- ^ Mean Absolute Percentage Error
- ^ Median Absolute Percentage Error
- ^ Autocorrelation Function
- ^ Partial Autocorrelation Function
- ^ Nonstationary
- ^ Runs Test
- ^ Ferial Test
- ^ Gap
- ^ Serial Correlation
- ^ Correlation Dimension Estimate
- ^ Largest Lyapunov Exponent
- ^ Rescaled Range Analysis

