

پیش بینی شاخص سهام با استفاده از شبکه‌های عصبی موجکی در بورس اوراق بهادار تهران

سعید فلاح پور^۱، جواد علی پور ریکنده^{۲*}

چکیده

در این تحقیق شاخص کل سهام بورس اوراق بهادار تهران با استفاده از مدل‌های مختلف شبکه‌های عصبی پیش بینی شده است. تحقیق از نوع کاربردی است و دوره زمانی انجام تحقیق از ابتدای سال ۸۱ تا پایان سال ۹۰ است. گردآوری اطلاعات از طریق آمار و داده‌های موجود در پایگاه اطلاعاتی در بورس اوراق بهادار تهران صورت گرفته است. برای ایجاد مدل WDBP از موجک db5 برای نویززدایی داده‌ها و تا پنج مرحله صورت گرفته است. جذر میانگین مربعات خطا (RMSE) معیار ارزیابی برای سنجش خطای پیش بینی است. نتایج این تحقیق نشان می‌دهد، عملکرد شبکه عصبی موجکی در پیش بینی شاخص سهام سطح خطای کمتری دارد و از شبکه عصبی بهتر است.

واژه‌های کلیدی: پیش بینی شاخص سهام، شبکه عصبی، موجک، بورس اوراق بهادار تهران.

طبقه بندی موضوعی: G17, G15, C88, C45

1. استادیار دانشکده مدیریت دانشگاه تهران

Email: sfallahpour@gmail.com

2. نویسنده مسئول، کارشناسی ارشد، رشته MBA پردیس بین‌المللی کیش دانشگاه تهران (نویسنده مسئول)

Email: javad_a_p@yahoo.com

مقدمه

شرکت‌های سرمایه‌گذاری یکی از واسطه‌های مالی هستند که در کلیه بورس‌های پیشرفته دنیا در جهت ایجاد تعادل و نظم در بازار اوراق بهادار، با هدف افزایش کارایی و رونق سرمایه‌گذاری به کار گرفته می‌شوند؛ به طوری که آن منابع به نحوی کارآمد و اثربخش استفاده شوند. بنابراین، تعجب آور نیست که کارهای زیادی برای پیش‌بینی بازار انجام شده باشد. هر سیستمی که بتواند به صورت مداوم برنده و بازنده را در بازار پویای مالی مشخص کند، برای دارنده آن سیستم سود سرشاری حاصل می‌کند.

امروزه، سرمایه‌گذاری در بورس بخش مهمی از اقتصاد کشور را تشکیل می‌دهد. به همین دلیل پیش‌بینی قیمت سهام برای سرمایه‌گذاران اهمیت خاصی دارد تا بتوانند بالاترین بازده را از سرمایه‌گذاری خود کسب کنند. از سوی دیگر، شاخص قیمت سهام نشان‌دهنده وضعیت کلی بازار سهام است و می‌تواند به پیش‌بینی سهامداران برای سرمایه‌گذاری کمک کند (عادل آذر و همکاران، ۱۳۸۵).

مسئله اصلی این پژوهش، بررسی امکان پیش‌بینی بهتر شاخص سهام در بورس اوراق بهادار تهران است. داده‌های قیمت سهام همیشه یکی از مهم‌ترین اطلاعات برای سرمایه‌گذاران است. قیمت‌های سهام اساساً ماهیتی پویا، غیرخطی و غیر پارامتریک دارند. این امر حاکی از آن است که سرمایه‌گذاران باید با سری‌های زمانی متغیر و دارای شکست‌های ساختاری متناوب دست‌وپنجه نرم کنند (وانگ، ۲۰۰۳)؛ بنابراین، پیش‌بینی دقیق تغییرات قیمت سهام نه تنها چالش‌انگیز است، بلکه از علاقه‌مندی‌های جدی سرمایه‌گذاران نیز هست.

در گذشته مدل‌های پیش‌بینی گوناگونی استفاده می‌شدند که از مهم‌ترین آنها می‌توان به فنون رگرسیون خطی یا چندجمله‌ای، میانگین متحرک، مدل‌های باکس و جنکینز، مدل‌های ساختاری و سایر سری‌های زمانی اشاره کرد؛ اما مدل‌های فوق‌ضعف‌هایی دارند که به محقق اجازه نمی‌دهد عوامل پیچیده و غیرخطی مؤثر بر پیش‌بینی را در نظر بگیرد.

شبکه‌های عصبی به دلیل توانایی ترسیم ارتباطات غیرخطی بین ورودی‌ها و خروجی‌ها، برای پیش‌بینی شاخص سهام استفاده می‌شوند. برخلاف تئوری بازار کارا، نتایج پژوهش‌های گوناگون نشان می‌دهند، بازارهای مالی و سایر سیستم‌های پیچیده بی‌نظم هستند. بی‌نظمی فرایند غیرخطی قطعی است که به صورت تصادفی اتفاق می‌افتد؛ زیرا به راحتی نمی‌توان آن را توضیح داد. با استفاده از توانایی شبکه‌های عصبی در آموزش سیستم‌های غیرخطی و بی‌نظم، می‌توان عملکردی بالاتر از آنالیزهای سنتی و سایر روش‌های کامپیوتری دیگر کسب کرد.

نظریه موجک‌ها توانایی تجزیه سری‌های زمانی با مقیاس‌های مختلف را دارد و برای تشخیص سیکل‌ها در سری‌های زمانی با تغییرات ناگهانی در مقایسه با روش‌های دیگر بهتر عمل می‌کند (سعیدی و محمدی، ۱۳۹۱). به همین دلیل، در این پژوهش از مدل شبکه عصبی موجکی برای پیش‌بینی استفاده شده است.

بورس اوراق بهادار از ابزارهای بسیار مهم بازار سرمایه محسوب می‌شود که نقش ویژه‌ای در رشد اقتصادی ایفا می‌کند و با کاهش ریسک، قیمت‌گذاری، تجهیز و تخصیص بهینه منابع و سرمایه، زمینه مناسبی را برای بهبود وضع اقتصادی فراهم می‌کند (پاکدین امیری و همکاران، ۱۳۸۸)؛ لذا موضوع پیش‌بینی، در مدیریت صحیح بورس اوراق بهادار برای رسیدن به توسعه پایدار اهمیت بسزایی دارد که تصمیم‌گیری در وضعیت نامطمئن را برای تصمیم‌گیران اجرایی بورس هموار می‌سازد (طلوعی و همکاران، ۱۳۸۶).

مروری بر مبانی نظری و پیشینه پژوهش

تلاش‌ها برای پیش‌بینی بازار سهام از اوایل قرن بیستم آغاز شد. باور گروهی از دست‌اندرکاران بازارهای اوراق بهادار بر این بود که مطالعه تاریخی قیمت‌ها حاوی اطلاعات مفیدی برای پیش‌بینی قیمت‌ها در آینده است؛ لذا با به‌دست آوردن روند قیمت‌ها، الگوی تغییرات شناخته می‌شود و این طرز فکر را به دلیل اینکه بر نمودارها تمرکز داشتند، چارتریست نامیدند. به نظر آنان تحلیل بنیادی ضرورتی ندارد و حامیان آنها بر این باورند که تاریخ تکرار می‌شود. از دهه ۱۹۳۰، مطالعات دیگری آغاز شد که در نقطه مقابل این دیدگاه قرار داشت. تمرکز اصلی این پژوهش‌ها روی تصادفی بودن رفتار قیمت‌ها بود و اینکه قیمت‌ها از روند خاصی پیروی نمی‌کنند. نتایج این مطالعات به صورت یک جریان فکری و نظری قوی وارد مباحث اقتصاد و سرمایه‌گذاری شد و نظریه رفتار قیمت‌ها شکل گرفت. مکتب گشت تصادفی از طریق آزمون‌های تجربی به اثبات رساند که تغییرات متوالی قیمت‌ها در دوره‌های کوتاه‌مدت، همانند یک روز، یک هفته یا یک ماه، مستقل از یکدیگرند.

پس از دهه ۱۹۶۰، پژوهش‌ها از شکل آماری مطالعه رفتار قیمت‌ها به مسئله ویژگی‌های اقتصادی بازار سهام سوق پیدا کرد که موجب تغییرات تصادفی و پیدایش نظریه بازار کارا شد. بنیادگران باور دارند با تجزیه و تحلیل متغیرهای مالی و اقتصادی کلیدی، می‌توان ارزش واقعی سهم را برآورد کرد. براساس این نظریه، هیچ کس نمی‌تواند در بلندمدت به‌طور سیستماتیک بیشتر از میزان ریسکی که متحمل شده است، بازده کسب کند. در چنین بازاری، قیمت سهام انعکاسی از اطلاعات مربوط به آنهاست و تغییرات قیمت‌ها الگوی خاص و قابل پیش‌بینی ندارد (راعی، ۱۳۸۹، ۴۶۲).

درخصوص مطالعه حاضر، راعی و چاوشی (سال ۱۳۸۲) در پژوهشی با عنوان «پیش‌بینی شاخص سهام در بورس اوراق بهادار تهران: مدل شبکه‌های عصبی و مدل چندعاملی»، به پیش‌بینی پذیری رفتار بازده سهام در بورس اوراق بهادار تهران به وسیله مدل خطی عاملی و شبکه‌های عصبی مصنوعی پرداخته شده که برای آزمون این مسئله، بازده روزانه سهام شرکت توسعه صنایع بهشهر برای نمونه انتخاب شده و متغیرهای مستقل ورودی، پنج متغیر کلان اقتصادی یعنی شاخص کل بازده بورس تهران، نرخ ارز (دلار) در بازار آزاد و بازده نفت و بازده طلاست. در این پژوهش شبکه عصبی به مراتب خطای کمتری از مدل چندعاملی در پیش‌بینی نمونه داشته است.

در پژوهشی دیگر با نام «پیش‌بینی بازده سهام با استفاده از شبکه عصبی مصنوعی: بررسی بازار بورس تهران»، با استفاده از یک مدل شبکه عصبی مصنوعی، ارتباط برخی پارامترهای مستقل را بر روی سطح شاخص بازده سهام به عنوان یک متغیر وابسته کشف و تعیین شد. نتیجه پژوهش آنها نشان داد که مدل‌های شبکه عصبی مصنوعی می‌توانند در مقایسه با سایر مدل‌های پارامتریک مانند رگرسیون و سایر تکنیک‌های آماری سنتی بهتر عمل کنند (دکتر حسین عبده تبریزی و حسن پناهیان).

در مطالعه دیگری با عنوان «پیش‌بینی بازده روزانه سهام شرکت‌های پذیرفته‌شده بورس اوراق بهادار تهران با استفاده از شبکه عصبی مصنوعی»، به بررسی پیش‌بینی رفتار بازده سهام شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تهران و انجام عمل پیش‌بینی با استفاده از شبکه‌های عصبی مصنوعی پرداخته شد. طبق نتایج این پژوهش، رفتار سری زمانی سهام شرکت‌ها در بازه پنج‌ساله ۱۳۷۷ الی ۱۳۸۲ یک فرایند تصادفی نیست و دارای حافظه است؛ همچنین، شبکه‌های عصبی مصنوعی با میزان خطای نسبتاً مناسبی می‌توانند بازده روزانه را پیش‌بینی کنند (نمازی و کیامهر، ۱۳۸۶).

در پژوهشی با عنوان «روش شبکه عصبی مصنوعی برای پیش‌بینی کوتاه‌مدت شاخص قیمت سهام»، کوشیدند تا با استفاده از شبکه عصبی مصنوعی شاخص قیمت سهام تورنتو را پیش‌بینی کنند. در مدل ارائه‌شده آنها چندین شاخص اقتصادی به عنوان ورودی به مدل داده می‌شوند. در مدل ارائه‌شده آنها پیش‌بینی‌ها برای روز آینده، هفته آینده، دو هفته آینده و یک ماه آینده انجام شد. همچنین، معماری شبکه عصبی در مدل آنها یک شبکه عصبی به صورت ۱-۱۰-۱ بود و آنها برای ۲۵ بار آزمایش را تکرار کردند تا وزن‌های اولیه تصادفی متعددی را بررسی کنند. نتیجه پژوهش آنها نشان می‌داد، شبکه‌های عصبی مصنوعی می‌توانند پیش‌بینی‌های کوتاه‌مدت را به خوبی انجام دهند؛ بدین معنی که پیش‌بینی‌های روز بعد و هفته بعد پذیرفتنی بودند؛ اما در پیش‌بینی‌های طولانی‌مدت‌تر، برای مثال پیش‌بینی دو هفته آینده و یک ماه آینده مدل ارائه‌شده در پژوهش آنها نمی‌توانست نتایج خوبی ارائه کند (نادیا اسکندر و رجینا ساسکاتچیوان (۲۰۰۵)).

هوا جیانگ (۲۰۰۳) در پژوهش دیگری با استفاده از شبکه عصبی مصنوعی سعی در پیش‌بینی قیمت پایانی روز آینده سهام داشته است. در این مطالعه سه پرتفوی متفاوت برای مقایسه بین آنها


تشکیل شده است. در پرتفوی اول، از پیش‌بینی قضاوتی و در پرتفوی دوم، از شبکه عصبی برای پیش‌بینی استفاده شد و در پرتفوی سوم، از مدل CAPM بهینه شده توسط شبکه عصبی مصنوعی استفاده شد. نتایج پژوهش وی نشان داد، پرتفوی سوم که بر اساس مدل CAPM بهینه شده توسط شبکه عصبی مصنوعی بود، بازدهی بیشتری از دو پرتفوی دیگر به دست آورده است.

ژیان ژو وانگ و همکاران (۲۰۱۱) در پژوهشی با استفاده از شبکه عصبی موجکی بر پایه کاهش اختلال پس از انتشار خطا به پیش‌بینی شاخص قیمت سهام شانگهای پرداختند. آنها برای ارزیابی، مدل خود را با شبکه عصبی مصنوعی با الگوریتم پس از انتشار خطا مقایسه کردند. آنان دریافتند، تقلیل دادن اختلال در داده‌ها می‌تواند باعث بهبود پیش‌بینی شبکه عصبی مصنوعی شود.

شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی (ANN) نوعی مدل‌سازی ساده‌انگارانه از سیستم‌های عصبی واقعی هستند که کاربرد فراوانی در حل مسائل مختلف در علوم دارند. حوزه کاربرد این شبکه‌ها آنچنان گسترده است که از کاربردهای طبقه‌بندی گرفته تا کاربردهایی نظیر درون‌یابی، تخمین، آشکارسازی و ... را شامل می‌شود. شاید مهم‌ترین مزیت این شبکه‌ها توانایی وافر آنها در کنار سهولت استفاده از آنها باشد (صیادی، ۱۳۸۷).

شبکه‌های عصبی مصنوعی، ساختاری (شبکه‌ای) متشکل از تعدادی واحد (نورون‌های مصنوعی) است که در داخل شبکه به هم وصل شده‌اند. هر واحد دارای یک مشخصه ورودی / خروجی (I/O) است و محاسبه یا عملی جزئی را اجرا می‌کند. خروجی هر واحد با توجه به مشخصه آن، اتصالات درونی‌اش با سایر واحدها و (احتمالاً) ورودی‌های خروجی تعیین می‌شود. از آنجاکه آموزش دستی شبکه امکان‌پذیر است، از این‌رو شبکه معمولاً کارکردی کلی از یک حالت یا حالت‌های بیشتری از آموزش را به دست می‌آورد (جورایان، ۱۳۸۸، ۳).



شکل ۱: شبکه عصبی مصنوعی

تبدیل موجک

موجک‌ها توابع ریاضی‌اند که داده‌ها را به اجزای فراوانی (فرکانس) تفکیک کرده و هر جزء را با نمایش متناسب با مقیاس آن جزء مطالعه می‌کنند. یکی از مزایای موجک‌ها، توان بالای تحلیل آنها در شرایطی است که سیگنال‌ها با گسستگی و جهش‌های سریع همراه‌اند (محمدی و عباسی‌نژاد، ۱۳۸۴).

نظریه موجک در تجزیه و تحلیل فوریه ریشه دارد؛ اما تفاوت‌های مهمی میان این دو وجود دارد. تبدیل موجک پیوسته (CWT) به صورت زیر تعریف می‌شود:

$$CWT_x^{\psi}(\tau, s) = \psi_x^{\psi}(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{+\infty} x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (1)$$

که در آن T و S به ترتیب پارامترهای انتقال و مقیاس هستند. مفهوم انتقال دقیقاً مشابه با مفهوم انتقال زمانی در تبدیل فوریه زمان کوتاه است که میزان جابه‌جایی پنجره را معلوم می‌کند و به وضوح اطلاعات زمانی تبدیل را دربر دارد. در عوض، پارامتر مقیاس به‌طور معکوس با فرکانس ارتباط دارد. به عبارت دیگر، $S=1/f$. در رابطه (۱)، ψ تابع پنجره است که اصطلاحاً موجک مادر (ویولت مادر) نامیده می‌شود. واژه مادر به این منظور به کار برده می‌شود که تمامی نسخه‌های انتقال یافته و مقیاس شده همگی از روی یک تابع اولیه به دست می‌آیند که اصطلاحاً موجک مادر نامیده می‌شود. به بیان علمی، موجک مادر یک تابع الگو جهت تولید سایر پنجره‌هاست.

اصول تبدیل موجک گسسته (DWT) به روشی تحت عنوان کدینگ زیرباند برمی‌گردد که در سال ۱۹۷۶ سنگ بنای اولیه آن گذارده شد. ایده اصلی این روش نیز مشابه تبدیل موجک پیوسته است که در آن نوعی توصیف زمان-مقیاس از سیگنال گسسته با استفاده از فیلترهای دیجیتال ارائه می‌شود. در حالت گسسته، فیلترهایی با فرکانس قطع‌های مختلف برای تحلیل سیگنال در مقیاس‌های متفاوت به کار برده می‌شود. با عبور سیگنال از فیلترهای بالاگذر و پایین‌گذر فرکانس‌های مختلف آن تحلیل می‌شود. در حالت گسسته، رزولوشن سیگنال توسط عملکرد فیلترها تعیین می‌شود (صیادی، ۱۳۸۷).

روند پردازش با تبدیل موجک گسسته چنین آغاز می‌شود؛ در ابتدا سیگنال از یک فیلتر دیجیتال پایین‌گذر نیم‌بلند با پاسخ ضربه $h[n]$ عبور می‌کند و لذا خروجی فیلتر برابر است با کانولوشن ورودی و پاسخ ضربه فیلتر. در نتیجه این عمل فیلترینگ، تمامی مؤلفه‌های فرکانسی که بیشتر از نصف بزرگ‌ترین فرکانس موجود در سیگنال باشند، حذف می‌شوند. با حذف یکی در میان نمونه‌ها، بدون اینکه اطلاعاتی را از دست بدهیم طول سیگنال نصف خواهد شد. روند مشابهی نیز با استفاده از یک فیلتر بالاگذر نیم‌باند با پاسخ ضربه $g[n]$ انجام می‌پذیرد. در نتیجه در خروجی اولین مرحله از اعمال

تبدیل موجک، دو نسخه یکی بالاگذر و دیگری پایین گذر، با طول کاهش یافته (نصف شده) از سیگنال اولیه به فرم زیر به دست می آیند:

$$y_{high}[k] = \sum_n x[n].g[2k - n] \quad (۲)$$

$$y_{low}[k] = \sum_n x[n].h[2k - n]$$

با این عمل، رزولوشن زمانی نصف شده و در مقابل رزولوشن فرکانسی دو برابر می شود. این روند را می توان مجدداً بر روی نسخه پایین گذر شده اعمال کرد و در هر مرحله، با کاهش رزولوشن زمانی به میزان نصف مرحله قبل، رزولوشن فرکانسی را دو برابر کرد. این ایده برای محاسبه تبدیل موجک گسسته، به روش بانک فیلتر مشهور است. ضرایب خروجی فیلتر پایین گذر، شکل اولیه سیگنال را دنبال می کنند؛ به همین دلیل به این ضرایب، تقریب گفته می شود. همچنین، ضرایب خروجی فیلتر بالاگذر، جزئیات فرکانس بالای سیگنال را دربر دارند؛ به همین دلیل به این ضرایب جزئیات گفته می شود. با افزایش تعداد مراحل تبدیل، میزان جزئیات نیز کاهش می یابد (صیادی، ۱۳۸۷).

فرضیه پژوهش

فرضیه این پژوهش بدین صورت است که مقادیر پیش‌بینی شده برای شاخص سهام در مدل WDBP با مقادیر پیش‌بینی شده در مدل BP اختلاف معناداری دارد.

روش شناسی پژوهش

این پژوهش از نظر هدف کاربردی است و روش پژوهش به کار گرفته شده در این پژوهش، روش تحلیلی است.

پس از جمع آوری داده‌ها، با بهره گیری از نرم افزار MATLAB و برنامه نویسی در این محیط به پیش‌بینی پرداخته شد. در این پژوهش از معیار ارزیابی جذر میانگین مربعات خطا (RMSE) برای مقایسه مقادیر پیش‌بینی شده و حقیقی استفاده شد.

روش نمونه گیری

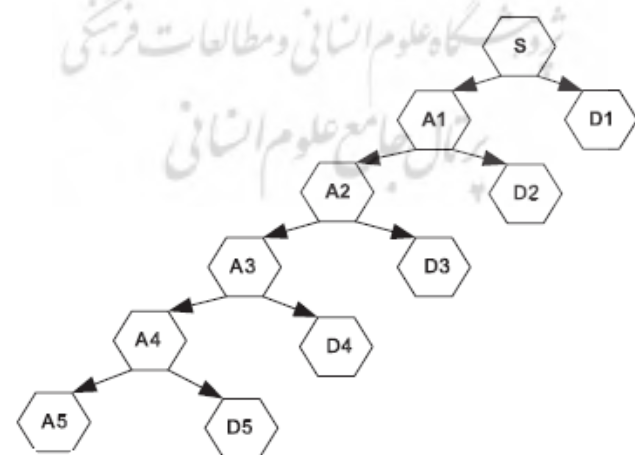
جامعه آماری در این پژوهش شامل تمامی شرکت‌های پذیرفته شده در بورس اوراق بهادار هستند که در دوره زمانی پژوهش در بورس اوراق بهادار تهران فعالیت دارند. نمونه آماری شامل شاخص کل سهام در بورس اوراق بهادار تهران است. دوره زمانی انجام پژوهش از ابتدای سال ۱۳۸۱ تا پایان سال

۱۳۹۰ است. روش نمونه‌گیری به صورت قضاوتی است. برای ایجاد مدل جهت پیش‌بینی شاخص سهام، در این پژوهش از ۲۵۸۵ داده استخراج شده از معاملات روزانه بورس استفاده شده است. در انجام این پژوهش، ۹ گام در طراحی مدل شبکه عصبی موجکی به صورت جدول زیر نشان داده شده است:

جدول ۱: گام‌های طراحی مدل شبکه عصبی موجکی

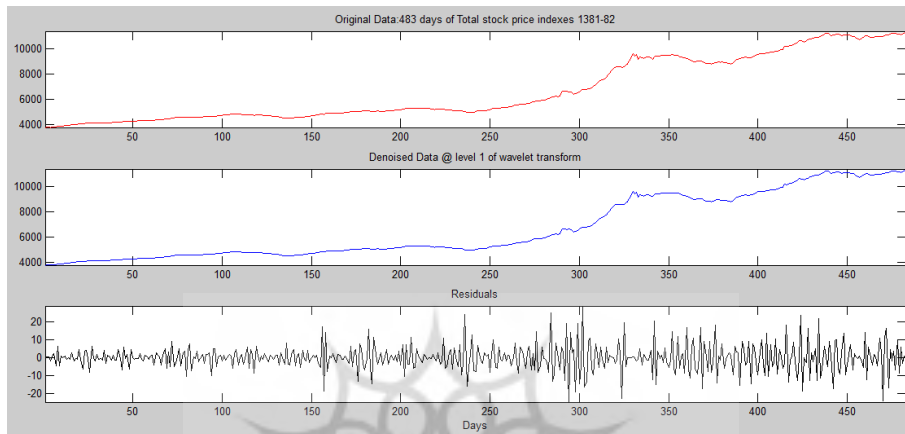
گام ۱	انتخاب متغیر
گام ۲	جمع‌آوری داده‌ها
گام ۳	تبدیل موجک و استخراج داده‌های اصلی
گام ۴	جدا کردن داده‌های یادگیری و آزمایش
گام ۵	مبانی شبکه عصبی شامل تعداد لایه‌های ورودی، پنهان و خروجی و تابع انتقال
گام ۶	معیار ارزیابی
گام ۷	آموزش شبکه عصبی مصنوعی و تعداد تکرار در آموزش شبکه
گام ۸	آزمایش داده‌ها با استفاده از داده‌های جدید
گام ۹	مقایسه پیش‌بینی شبکه عصبی و شبکه عصبی موجکی

داده‌های شاخص سهام آلوده به نویز زیادی است. این نویز می‌تواند با تبدیل موجک گسسته (DWT) از داده‌ها زدوده شود. انواع گوناگونی از ویولت‌ها برای اجرای DWT وجود دارد. هر یک از آنها دامنه عملکردی خود را با قابلیت رزولوشن، کارایی و هزینه محاسباتی و دیگر خصوصیات منحصر به فرد داراست. در این پژوهش، از ویولت Daubechies (db5) استفاده شده است که عملیات تجزیه تا ۵ مرحله صورت گرفته است.



شکل ۲: پنج سطح تجزیه موجک

نویز داده‌های نمونه شاخص سهام در پژوهش حاضر، توسط تجزیه موجک db5 کاهش یافته است. برای نمونه، تجزیه موجک شاخص کل سهام ۸۲-۱۳۸۱ در سطح اول به صورت شکل زیر نشان داده شده است.



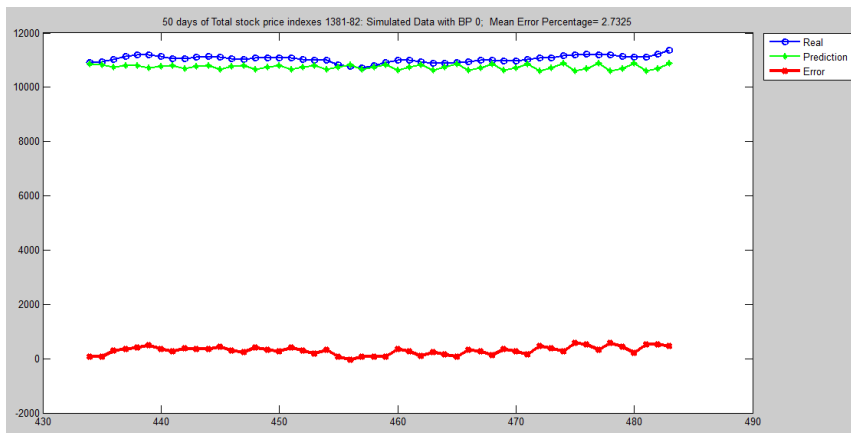
شکل ۳: تجزیه موجک شاخص کل ۱۳۸۱-۱۳۸۲ سطح اول

اگرچه بسیاری از مدل‌های مختلف شبکه عصبی بر سرمایه‌گذاری اعمال شده‌اند، در این پژوهش استفاده از شبکه عصبی BP به دلیل کاربرد عمومی‌اش در موضع پیش‌بینی‌های کوتاه‌مدت برگزیده شده است. برخلاف مدل‌های BP دیگر که مستقیماً از طریق داده‌های اولیه ایجاد می‌شوند، در این پژوهش ابتدا داده‌های اولیه با تبدیل موجک به لایه‌های بسیاری تجزیه می‌شوند.

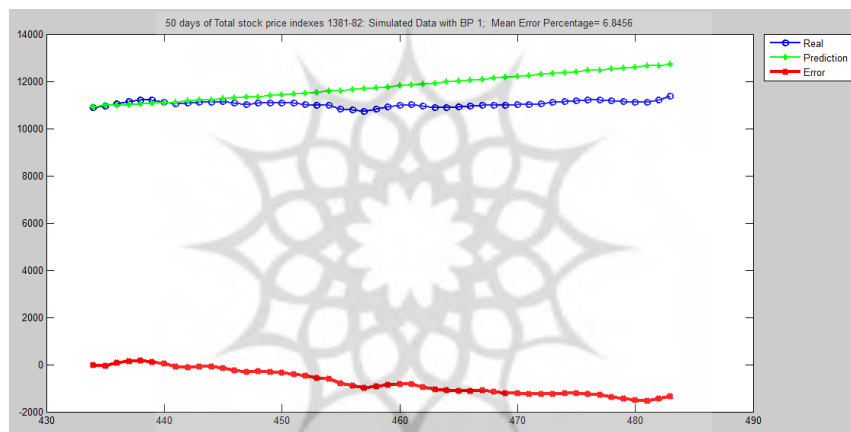
در این مقاله، یک شبکه عصبی BP سه لایه انتخاب شده است که دارای یک لایه ورودی ۳ نورونه، یک لایه پنهان ۱۰ نورونه و یک لایه خروجی ۳ نورونه است.

پس از اجرای برنامه برای شش حالت مختلف داده‌های ورودی در هر بازه دو ساله، پیش‌بینی ۵۰ روز پایانی برای شاخص کل صورت گرفت که برای نمونه برای سال‌های ۱۳۸۱-۱۳۸۲ در شکل‌های زیر نشان داده شده‌اند.

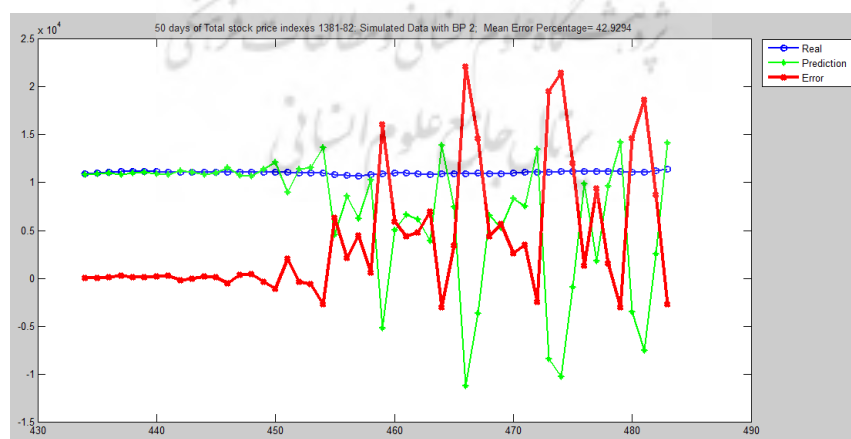
مقادیر به‌دست آمده توسط BP، همان پیش‌بینی شبکه عصبی با داده‌های اصلی است و مقادیر به‌دست آمده توسط BP1 تا BP5، نیز همان پیش‌بینی شبکه عصبی با داده‌های به‌دست آمده از سطوح مختلف تجزیه موجک است.




شکل ۴: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP




شکل ۵: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP1




شکل ۶: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP2



شکل ۷: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP3



شکل ۸: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP4



شکل ۹: پیش‌بینی شاخص کل ۱۳۸۱-۱۳۸۲ با شبکه عصبی BP5

پس از آنکه پیش‌بینی صورت گرفت، با استفاده از معیار ارزیابی مورد نظر یعنی جذر میانگین مربعات خطا (RMSE) نتایج با هم مقایسه می‌شوند. مدلی که کمترین خطا را داشته باشد جواب مطلوب است. میزان خطای هر مدل در جدول زیر نشان داده شده است:

جدول ۲: مقایسه RMSE برای شش مدل پیش‌بینی شاخص کل در هریک از بازه‌ها

	BP5	BP4	BP3	BP2	BP1	BP0	RMSE
۱۲۳/۴۷۱	۲۶۱/۹۸۱	۱۲۳/۴۷۱	۲۷۰/۴۴	۷۷۵۳/۷۷۵	۹۰۴/۲۳۸	۳۳۵/۴۷۹	شاخص ۱۳۸۱-۸۲
۵۸۶/۴۴۷	۶۳۱/۸۱۶	۲۲۴۸/۱۲	۲۵۷۶/۹۷	۵۸۶/۴۴۷	۳۷۵۵/۹۷۴	۳۲۲۲/۴۹۵	شاخص ۱۳۸۳-۸۴
۲۶۴/۲۵۹	۲۶۴/۲۵۹	۱۰۷۳/۸۷	۵۱۳/۶۶۱	۱۳۷۷/۹۰۹	۲۲۶۳/۰۲۲	۳۸۲/۶۱	شاخص ۱۳۸۵-۸۶
۵۵۷/۶۵۵	۴۹۵۷/۹۹۴	۶۷۰/۹۴۶	۵۵۷/۶۵۵	۱۵۴۷/۰۲۷	۳۷۵۹/۷۵۵	۳۲۰۴/۵۹۲	شاخص ۱۳۸۷-۸۸
۶۵۷۴/۱۳۷	۱۸۳۲۱/۵۱۱	۸۵۹۵/۴	۸۸۶۲/۹۹	۶۵۷۴/۱۳۷	۱۱۴۶۰/۶۰۹	۸۴۹۱/۲۷۵	شاخص ۱۳۸۹-۹۰

مقادیر به‌دست‌آمده از ستون BP0، جذر میانگین مربعات خطای شبکه عصبی مصنوعی و مقادیر به‌دست‌آمده از ستون BP1 تا BP5، جذر میانگین مربعات خطای شبکه‌های عصبی موجکی است. همچنین، مقادیر خارج از جدول، کمترین مقدار RMSE بین مدل‌های مختلف شبکه عصبی موجکی است. پس از مشخص شدن میزان خطا توسط RMSE، از آزمون ویلکاکسون استفاده شد تا مشخص شود آیا تفاوت معناداری میان روش پیش‌بینی شبکه عصبی مصنوعی و روش پیش‌بینی شبکه عصبی موجکی وجود دارد یا خیر. ویلکاکسونیک آزمون ناپارامتریک است و برای متغیرهایی با مقیاس رتبه‌ای است. از طریق این آزمون، امکان مقایسه قبل و بعد یک وضعیت تحت تأثیر یک متغیر امکان‌پذیر است.

نتایج به‌دست‌آمده از آزمون ویلکاکسون به‌صورت جداول زیر نشان داده شده است:

جدول ۲: نمایش اطلاعات برای آزمون ویلکاکسون

آماره‌های توصیفی					
تعداد	میانگین	انحراف معیار	مینیم	ماکزیمم	
۵	۳۱۲۷/۲۹۰۲	۳۳۲۰/۹۵۰۶۰	۳۳۵/۴۸	۸۴۹۱/۲۸	b BP0
۵	۱۶۲۱/۱۹۳۸	۲۷۷۵/۶۹۳۹۵	۱۲۳/۴۷	۶۵۷۴/۱۴	b BP1

جدول ۳: نتایج به‌دست آمده توسط آزمون ویلکاکسون

آماره‌های آزمون (آزمون ویلکاکسون)	
b BP0 - b BP1	
-۲/۰۲۳	آماره Z (براساس رتبه‌بندی مثبت)
۰/۰۴۳	سطح معنی‌داری

نتایج تجزیه و تحلیل از طریق SPSS با آزمون ویلکاکسون برای فرضیه پژوهش نشان می‌دهد در سطح معنادار ۰/۰۵، فرض H_0 رد می‌شود؛ در نتیجه، می‌توان گفت پیش‌بینی روش شبکه عصبی موجکی از روش پیش‌بینی شبکه عصبی بهتر است.

بحث و نتیجه‌گیری

پژوهش حاضر می‌کوشد تا شاخص کل سهام شرکت‌های فعال در بورس اوراق بهادار تهران را پیش‌بینی کند. پژوهش‌های قبلی نشان دادند، شبکه‌های عصبی مصنوعی پتانسیل بالایی برای پیش‌بینی دارند. همچنین، تبدیل موجک می‌تواند تا حد زیادی خطای ناشی از پیش‌بینی شاخص سهام را کاهش دهد.

در این پژوهش با بررسی مدل‌های مختلف شبکه‌های عصبی مصنوعی سعی شده است بهترین مدل برای پیش‌بینی شاخص سهام شرکت‌های فعال در بورس اوراق بهادار تهران پیدا شود. با توجه به خصوصیت شبکه عصبی مصنوعی، هنگامی که شبکه عصبی مصنوعی معماری خوبی داشته باشد و با استفاده از داده‌های مناسب آموزش داده شود، می‌تواند آینده کوتاه‌مدت را به خوبی پیش‌بینی کند.

با توجه به اینکه قیمت‌های سهام از بسیاری فاکتورهای اقتصادی کلان مانند رویدادهای سیاسی، سیاست‌های شرکت‌ها، شرایط اقتصادی عمومی، شاخص قیمت کالا، نرخ‌های بانکی، انتظارات سرمایه‌گذاران، گزینش‌های سازمانی سرمایه‌گذاران و فاکتورهای روانی سرمایه‌گذاران تأثیر می‌پذیرد، در نتیجه پیش‌بینی مستقیم شاخص سهام با استفاده از داده‌های دارای نویز، اغلب با خطاهای بزرگ همراه می‌شود. این پژوهش نشان داد، بهره‌گیری از تبدیل موجک برای نویززدایی داده‌ها می‌تواند به پیش‌بینی بهتر و دقیق‌تری منجر شود.

نتایج این پژوهش با نتایج پژوهش‌های تان (تان، ۲۰۰۹) و ژانگ (ژانگ، ۲۰۱۱) در خصوص

استفاده از تبدیل موجک جهت نويززدایی داده‌ها و افزایش دقت شبکه عصبی در پیش‌بینی متغیرهای مالی منطبق هستند. به عبارت دیگر، نويززدایی داده‌ها سبب افزایش دقت شبکه عصبی پیش‌بینی در مدل شبکه عصبی می‌شود.

در این پژوهش، داده‌های شاخص بورس به صورت روزانه استفاده شد. پیشنهاد می‌شود برای مطالعات بعدی از داده‌های هفتگی استفاده شود. زمانی که داده‌ها به صورت هفتگی استفاده می‌شوند در مقایسه با داده‌های روزانه، سری زمانی هموارتری را ارائه می‌کنند. به عبارت دیگر، انتخاب داده‌ها به صورت هفتگی خود سبب کاهش نويز در داده‌ها می‌شود.

همچنین، در پژوهش‌های آتی می‌توان روش‌های دیگر نويززدایی، از جمله تجزیه اجزای مستقل (ICA) را بررسی کرد؛ بنابراین، پیشنهاد می‌شود با عنایت به تأیید فرضیه پژوهش، افرادی که به پیش‌بینی شاخص سهام و یا سایر متغیرهای مالی در قالب سری زمانی اقدام می‌کنند، بهتر است پیش از استفاده از مدل‌های پیش‌بینی، به نويززدایی داده‌ها اقدام کرده و سپس داده‌های نويززدایی شده به عنوان ورودی به مدل‌های پیش‌بینی انتقال یابد.

منابع و مآخذ

- آذر، عادل و همکاران. (۱۳۸۵). «مقایسه روش‌های کلاسیک و هوش مصنوعی در پیش‌بینی شاخص قیمت سهام و طراحی مدل ترکیبی». فصلنامه مدرس علوم انسانی، شماره ۴.
- اسلامی بیدگلی، غلامرضا؛ محمدی، شاپور. (۱۳۸۸). «بررسی زمان مقیاس مدل قیمت‌گذاری دارایی سرمایه‌ای از طریق تبدیل موجک». مجله بررسی‌های حسابداری و حسابرسی، شماره ۵۸.
- افسر، امیر. (۱۳۸۴). «الگوسازی پیش‌بینی شاخص قیمت سهام با استفاده از شبکه‌های عصبی فازی و روش ترکیبی».
- پاکدین امیری، علیرضا و همکاران. (۱۳۸۸). «ارائه مدل پیش‌بینی شاخص کل قیمت سهام با رویکرد شبکه‌های عصبی (مطالعه موردی: بورس اوراق بهادار تهران)». فصلنامه جستارهای اقتصادی، شماره ۱۱.
- جورایان، محمود. (۱۳۸۸). شبکه‌های عصبی مصنوعی، انتشارات دانشگاه شهید چمران.
- راعی، رضا؛ پویان‌فر، احمد. (۱۳۸۹). مدیریت سرمایه‌گذاری پیشرفته، نشر سمت.
- راعی، رضا؛ چاوشی، کاظم. (۱۳۸۲). «پیش‌بینی بازده سهام در بورس اوراق بهادار تهران: مدل شبکه‌های عصبی مصنوعی و مدل چندعاملی». فصلنامه تحقیقات مالی، شماره ۱۵.
- سعیدی، حسین؛ محمدی، شاپور. (۱۳۹۰). «پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ-شبکه عصبی». فصلنامه بورس اوراق بهادار، شماره ۱۶.
- صیادی، امید. (۱۳۸۷). «آشنایی مقدماتی با تبدیل ویولت». مجله تحقیقات اقتصادی، شماره ۸۰.
- طلوعی، عباس و همکاران. (۱۳۸۶). «الگوسازی پیش‌بینی قیمت سهام با استفاده از شبکه عصبی و مقایسه آن با روش‌های پیش‌بینی ریاضی». پژوهشنامه اقتصادی.
- عباسی‌نژاد، حسین؛ محمدی، شاپور. (۱۳۸۴). «تحلیل سیکل‌های تجاری ایران با استفاده از نظریه موجک‌ها». مجله تحقیقات اقتصادی، شماره ۷۵.
- فلاح‌پور، سعید. (۱۳۸۸). «طراحی مدلی برای مدیریت فعال پرتفوی سهام با استفاده از الگوریتم ژنتیک و ارزش در معرض ریسک». دانشگاه تهران.
- کیا، سید مصطفی. (۱۳۸۹). محاسبات نرم در MATLAB، خدمات نشر کیان رایانه.
- محمدی، احمد. (۱۳۸۵). «پیش‌بینی نرخ ارز با استفاده از شبکه عصبی و تبدیل موجک». دانشگاه تهران.
- مشیری، سعید؛ مروت، حبیب. (۱۳۸۵). «پیش‌بینی شاخص کل بازدهی سهام تهران با استفاده از مدل‌های خطی و غیرخطی». فصلنامه پژوهشنامه بازرگانی، شماره ۴۱.

- Azadeh, A. & S. F. Ghaderi (2008). “Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors”, *Energy Conversion and Management*, Vol. 49, No. 7, pp. 787-802.
- Cao. Qing & etc. (2005). “A comparison between Fama and French’s model and artificial neural network in predicting the Chinese stock market”, *Computers & Operational Research*, Vol. 32, No. 2, pp. 150-173.
- Donoho, D. L. & I. M. Johnstone (1995). “Adapting to unknown smoothness by wavelet shrinkage”, *Journal of the American Statistical Association*, Vol. 90, No. 11, pp. 3228-3240.
- Enke, D. & S. Thawornwong (2005). “The use of data mining and neural networks for forecasting stock market returns”, *Expert Systems with Applications*, Vol. 29, No. 3, pp. 142-160.
- Fernandez, Viviana (2006). “The CAPM and value at risk at different time-scales”, *International Review of Financial Analysis*, Vol. 15.
- Gencay, R. & etc. (2001). "An Induction to Wavelets and Other Filtering Methods in Financed Economics", Academic Press, San Digo, Vol. 14, No. 11, pp. 232-252.
- Guresen, E. & etc. (2011). “Using artificial neural network models in stock market index prediction”.
- Hansen, J. V. & R. D. Nelson (2002). “Data mining of time series using stacked generalizers”, *Neurocomputing*, Vol. 43, No. 7, pp. 334-348.
- Haven. Emmanuel & etc. (2012). “De-noising option prices with the wavelet method”, *European Journal of Operational Research*.
- Jammazi, Rania & Chaker Aloui (2011). “Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling”, *Energy Economics* xxx.
- Kaastra, I. & M. Boyd (1996). “Designing a neural network for forecasting financial economic time series”, *Neurocomputing*, Vol. 10, No. 3, pp. 1001-0023.
- Kim, Sangbae & Francis In. (2005). “The relationship between stock return and inflation: new evidence from wavelet analysis”, *Journal of Empirical Finance*, Vol. 12, No. 1, pp. 95-111.
- Misiti, Michel & etc. (2006). “Wavelet and their applications”.
- Mörchen, F. (2003). “Time series feature extraction for data mining using DWT and DFT”, *Department of Mathematics and Computer Science*

Philips-University Marburg. Technical report, Vol. 33, No. 6, pp. 656-674.

- Oh, K. J. & K. J. Kim (2002). "Analyzing stock market tick data using piecewise nonlinear model", Expert System with Applications, Vol. 22, No. 2, pp. 209-222.
- Ramsey, James B. & Camille Lampart (1998). "The decomposition of economic relationships by time scale using wavelet: Expenditure and income", Studies in nonlinear dynamics and econometrics, Vol. 3, No. 5, pp. 1147-1163.
- S. Maia. Andre Luis & etc. (2008). "forecasting models for interval-valued time series", Neurocomputing, Vol. 71, No. 2, pp. 326-341.
- Wang, J. Z. & J. J. Wang (2011). "Forecasting stock indices with back propagation neural network", Expert Systems with Applications, Vol. 38, No. 10, pp. 152-172.
- Wang, Y. (2003). "Mining stock prices using fuzzy rough set system", Expert System with Applications, Vol. 24, No. 8, pp. 2323-2349.
- Wong, Bo. K. & Yakup Selvi (1998). "Neural network application in finance: A review and analysis of literature", Information & Management, Vol. 34, No. 4, pp. 378-400.
- Zhang, Guoqiang & etc. (1998). "Forecasting with artificial neural network: The state of the art", International Journal of Forecasting, Vol. 14, No. 3, pp. 485-501.
- Zhang, G. (2003). "Time series forecasting using a hybrid ARIMA and neural network model", Neurocomputing, Vol. 50, No. 1, pp. 38-52.