

## کاربرد شبکه‌های عصبی مصنوعی در زمان‌بندی معاملات سهام: با رویکرد تحلیل تکنیکی

دکتر رضا تهرانی<sup>۱</sup>  
وحید عباسیون<sup>۲</sup>

تاریخ پذیرش: ۱۳۸۶/۹/۴

تاریخ دریافت: ۱۳۸۶/۱/۲۰

### چکیده

به دلیل پیچیدگی بازار سهام، زمان‌بندی معاملات سهام مسأله‌ای بسیار مهم و مشکل است. آنچه اهمیت دارد پیش‌بینی روند قیمت سهام است که هدف اصلی در مباحث تحلیل تکنیکی است. گرچه این امر به دلیل دخالت عوامل متعدد بازار و روابط بین آنها چندان آسان نیست. به نظر می‌رسد استفاده از ابزارها و الگوریتم‌های محاسباتی پیچیده‌تر مانند شبکه‌های عصبی مصنوعی در مدل‌سازی فرایندهای غیرخطی که منتج به قیمت و روند سهام می‌شوند، می‌تواند بسیار مفید باشد. در این پژوهش، قابلیت شبکه‌های عصبی مصنوعی (ANN) برای ارتقای اثربخشی شاخصهای تحلیل تکنیکی در پیش‌بینی علائم روند قیمت سهام بررسی شده است. نتایج حاصل از مدلها، بر اساس نمونه‌ای شامل ۵۰ شرکت از شرکتهای پذیرفته شده در بورس اوراق بهادار تهران، نشان داد که شبکه‌های عصبی مصنوعی از قابلیت پیش‌بینی علائم تغییر روند کوتاه‌مدت قیمت سهام در بازار اوراق بهادار تهران برخوردار است. در بازار صعودی، پس از کسر هزینه‌های معاملاتی، تفاوت معنی‌داری بین بازده مدل شبکه‌های عصبی مصنوعی، روش خرید و نگهداری و پربازده‌ترین شاخصهای تکنیکی وجود ندارد. اما در بازار نزولی، بازده مدل شبکه‌های عصبی مصنوعی از بازده روش خرید و نگهداری بیشتر است، هر چند در بازار نزولی شاخصهای روند (میانگین متحرک) بیشترین بازده را کسب نمودند.

طبقه‌بندی JEL: G10, G11, G14, C45.

**واژگان کلیدی:** زمان‌بندی معاملات سهام، شبکه‌های عصبی مصنوعی، تحلیل تکنیکی، شاخصهای تکنیکی، روش خرید و نگهداری.

۱. استادیار دانشکده مدیریت دانشگاه تهران

۲. کارشناس ارشد مدیریت مالی

email: V\_Abbasion@yahoo.com

## ۱- مقدمه

تعیین زمان مناسب انجام معاملات سهام که مستلزم پیش‌بینی روند یا پیش‌بینی قیمت سهام می‌باشد، موضوعی مهم در مدیریت سرمایه‌گذاری است که توجه محققان را برای سالهای مدیدی جلب نموده است. دلیل این امر، منافع مهم مالی است که در نتیجه یک مدل پیش‌بینی موفق حاصل می‌شود. با وجود این، پیش‌بینی قیمت یا بازده سهام کار ساده‌ای نیست؛ زیرا عوامل بازاری بسیاری دخالت دارند و روابط ساختاری پیچیده آنها به وضوح قابل تعیین نمی‌باشد.

تحلیل تکنیکی و تحلیل بنیادی، دو روش متداول برای پیش‌بینی رفتار آتی سهام می‌باشند. تحلیل بنیادی بر روی نیروهای اقتصادی عرضه و تقاضا که موجب تغییر قیمت سهام می‌شوند، تمرکز می‌کند. عوامل مرتبط (مانند شرکت، صنعت و شرایط اقتصادی) که بر قیمت سهام تأثیر می‌گذارند جهت تعیین ارزش ذاتی سهام بررسی می‌شوند (Schwager, 1995). از سوی دیگر، تحلیل تکنیکی داده‌های تاریخی مربوط به حرکات قیمت و حجم معاملات سهام را با استفاده از نمودارها و شاخصها به عنوان ابزار اولیه برای پیش‌بینی حرکات آتی قیمت مطالعه می‌کند (Murphy, 1999). سرمایه‌گذاران مبنای مطالعات خود را بر این فرض قرار می‌دهند که الگوهای تاریخی قیمت‌های سهام در آینده تکرار می‌شوند و بنابراین از این الگوها می‌توان به منظور اهداف پیش‌بینی استفاده کرد. انگیزه ماورای تحلیل تکنیکی، توانایی آن در شناسایی تغییرات روندها در مراحل اولیه و حفظ یک سرمایه‌گذاری است تا زمانی که علائم حاکی از تغییرات روند است (Pring, 1998). هدف هر دو روش پیش‌بینی حرکات سهام از دیدگاههای مختلف است. تحلیل بنیادی، دلایل حرکت بازار و تحلیل تکنیکی اثر آن را بررسی می‌کند.

تحلیل تکنیکی سابقه طولانی در پیش‌بینی حرکات در سریهای زمانی مالی دارد (Plummer, 1989) با وجود این، سالهای طولانی است که از سوی محققین دانشگاهی و کاربران مورد انتقاد قرار گرفته است. اساس این انتقاد بر دو حقیقت نهاده شده است: حقیقت اول نظریه بازارهای کاراست که بیان می‌کند «قیمتها همیشه اطلاعات موجود را به‌طور کامل منعکس می‌کنند». این نظریه نشان می‌دهد که هر تلاشی برای کسب سود با بهره‌گیری از اطلاعات موجود بیهوده است (Fama, 1970). حقیقت دوم این است که تحلیل تکنیکی مبتنی بر اصول ضعیفی است. برای مثال این انتظار که بعضی الگوهای تاریخی قیمت سهم در آینده تکرار خواهد شد ممکن است ضرورتاً به وقوع نپیوندد زیرا شرایط بازار در طی زمان تغییر می‌یابد (Wong & Ng, 1994) و هیچ توضیحی برای این موضوع که چرا باید انتظار داشت این الگوها تکرار شوند وجود ندارد (Lo et al, 2000).

با وجود حقایق مذکور، در سالهای اخیر تحلیل تکنیکی به‌طور گسترده به عنوان یکی از گزینه‌های مهم تحلیلی در بین متخصصان مالی و شرکتهای کارگزاری پذیرفته شده است (Achelis, 1995). در واقع سرمایه‌گذاری‌های عمده به ندرت بدون بهره‌گیری از این ابزار فنی انجام می‌شوند زیرا بسیاری از محققان این ایده را مطرح کرده‌اند که بازارها ممکن است به‌طور کامل کارا نباشند و قیمت‌ها ممکن است تحت تأثیر احساسات انسانی<sup>۱</sup> قرار گیرند (Barberis et al, 1998).

به نظر می‌رسد که تحلیل تکنیکی یک ابزار بینابینی<sup>۲</sup> باشد زیرا یک ترکیب نسبی را از رویدادهای انسانی، سیاسی و اقتصادی ارائه می‌دهد. از لحاظ نظری، تحلیل تکنیکی تلاش می‌کند تا روند قیمت‌های سهم را با استفاده از داده‌های قیمت‌ها و حجم معاملات گذشته پیش‌بینی کند. مشکل اصلی این روش این است که به شدت بر کشف قواعد تجربی قوی در حرکات قیمت و حجم متکی است (Liu & Lee, 1997). به عبارت دیگر، حامیان این روش تنها علاقمند به شناسایی نقاط برگشت اصلی برای ارزیابی حرکت اوراق بهادار هستند. در دنیای واقعی، این قواعد همیشه مشهود نیستند، اغلب با نوسانات<sup>۳</sup> پوشیده شده‌اند و از سهمی به سهم دیگر متفاوتند. بنابراین، برای سرمایه‌گذاران مشکل است تا با استفاده از این روش به‌طور مستمر و صحیح قیمت‌های آتی را پیش‌بینی کنند.

علاوه بر استفاده گسترده از تحلیل تکنیکی، سرمایه‌گذاران امروزه به الگوریتم‌ها و روشهای کامپیوتری بسیار وابسته شده‌اند تا بتوانند از طیف وسیعتری از گزینه‌های سرمایه‌گذاری بهره‌مند شوند. شبکه‌های عصبی مصنوعی<sup>۴</sup>، یکی از فناوری‌هایی هستند که بیشترین جذابیت را در این حوزه مالی ایجاد نموده‌اند. آنها روش جالبی را ارائه می‌دهند که به لحاظ نظری می‌تواند هر تابع پیوسته غیرخطی را در یک دامنه محدود که با هر درجه صحت طراحی شده، تخمین بزنند (Cybenko, 1989). بدعت شبکه‌های عصبی در توانایی مدل‌سازی فرایندهای غیرخطی بدون فرض اولیه در مورد ماهیت فرایند ایجاد نهفته است. این امر در سرمایه‌گذاری اوراق بهادار و سایر حوزه‌های مالی که مفروضات زیاد و اطلاعات کمی در مورد ماهیت فرایندهای تعیین قیمت‌های دارایی وجود دارد، مفید است (Burrell & Folarin, 1997) و ارزشمندی آن در حوزه تحلیل تکنیکی باید آزمون شود. شبکه‌های عصبی همچنین از لحاظ انواع ساختار، الگوریتم‌های یادگیری و رویه‌های اعتبار انعطاف‌پذیرند.

1. Human Sentiments

2. Compromising

3. Noises

4. Artificial Neural Networks

در این پژوهش، قصد داریم تا از مزایای شبکه‌های عصبی برای ارتقای اثربخشی شاخصهای تحلیل تکنیکی در پیش‌بینی علائم روند قیمت سهام بهره بگیریم. چند شاخص تکنیکی عمده و مشهور را به عنوان متغیرهای ورودی برای آموزش شبکه‌های عصبی به کار می‌بریم. هدف، بررسی این موضوع است که آیا از شبکه‌های عصبی می‌توان برای تصمیم‌گیری در کشف قواعد نهفته در حرکات قیمت و حجم استفاده نمود. توانمندی یکی از مشهورترین مدل‌های شبکه‌های عصبی یعنی شبکه عصبی پیشخور<sup>۱</sup> (FNN) در ارائه پیش‌بینی مؤثر علائم روند آتی سهام نیز بررسی می‌شود. بدین منظور نمونه‌ای مشتمل بر ۵۰ سهم مختلف که در بورس اوراق بهادار تهران معامله می‌شوند انتخاب و علائم معاملاتی ایجادشده توسط مدل شبکه عصبی مصنوعی بررسی می‌شود. در نهایت بازده حاصل از مدل شبکه‌های عصبی مصنوعی با بازده حاصل از هریک از شاخصهای تکنیکی و بازده حاصل از روش خرید و نگهداری<sup>۲</sup> مقایسه می‌شود.

## ۲- پیشینه تحقیق

در طی سالیان اخیر حجم قابل ملاحظه‌ای از مطالعات در تلاش برای تعیین قابلیت شبکه‌های عصبی برای پیش‌بینی حرکات آتی سهام با استفاده از عوامل بنیادی، انجام شده است. برای نمونه می‌توان به این پژوهشها اشاره کرد: (Desai & Bharati, 1998؛ Drosy, 1996؛ Podding & Rehkogler, 1996؛ Motiwalla & Wahab, 2000؛ Leung et al, 2000؛ Qi, 1999؛ و Qi & Maddala, 1999). افزایش علاقه در به‌کارگیری شبکه‌های عصبی مصنوعی به دلیل این حقیقت است که غیرخطی بودن به وسیله محققان مختلف و تحلیلگران مالی مختلف مورد تأکید قرار گرفته است و شبکه‌های عصبی قادرند مدل‌سازی غیرخطی را بدون دانش قبلی در مورد روابط بین عوامل انجام دهند.

ورای استفاده محض از عوامل بنیادی، مطالعاتی نیز شامل تعداد کمی از شاخصهای تکنیکی بوده‌اند، مانند (Austin et al, 1997؛ Chenoweth & Obradovic, 1996؛ Kuo, 1998؛ Longo & Long, 1997؛ و Quah & Srinivasan, 1999). علاوه بر این، از سریهای زمانی تاریخی بازده سهام و ارزشهای شاخص نیز در تعدادی از مطالعات به عنوان جایگزینی برای روش تحلیل تکنیکی استفاده شده است (Brown et al, 1998؛ Chandra & Reeb, 1999؛ Cogger et al, 1997؛ Darrat & Zhong, 2000؛ Fernandez et al, 2000؛ Saad et al, 1998؛ و Zemke, 1999).

1. Feed-Forward Neural Network

2. Buy and Hold

تنها مطالعات اندکی توانایی شبکه‌های عصبی را برای پیش‌بینی حرکات قیمت سهم با استفاده از نظریه‌های مشهور تحلیل تکنیکی بررسی کرده‌اند.

گنکی و استنگوس استفاده از دو قاعده معاملاتی ساده یعنی میانگین‌های متحرک و شکستهای طیف معاملات<sup>۱</sup> را با استفاده از یک شبکه عصبی پیش‌خور برای پیش‌بینی بازده روزانه شاخص متوسط صنعت داو- جونز (DJIA) با هم ترکیب کردند. علائم خرید و فروش ایجاد شده توسط قواعد معاملاتی به عنوان داده‌های مدل پیش‌بینی استفاده شدند (Gencay & Stengos, 1998). تسای و همکاران بر مبنای قواعد نوسان نگار تصادفی<sup>۲</sup> و شاخص قدرت نسبی<sup>۳</sup> با استفاده از شبکه‌های عصبی به پیش‌بینی جهت‌های روزانه تغییر قیمت در شاخص قراردادهای آتی S&P500 پرداختند (Tsaih et al., 1998).

میزونو و همکاران از شاخصهای میانگین متحرک، انحراف قیمت‌ها از میانگین متحرک، خط روان‌شناسی<sup>۴</sup> و شاخص قدرت نسبی جهت پیش‌بینی روند و ایجاد علائم خرید و فروش برای شاخص قیمت بازار سهام توکیو (TOPIX) استفاده نمودند (Mizuno et al., 1998).

کیم و هان ارزشهای چندین شاخص پیوسته را (مانند شاخص قدرت نسبی، نوسان نگار تصادفی،  $R\%$  ویلیام<sup>۵</sup>، مومنتوم<sup>۶</sup> و کمودیتی کانال<sup>۷</sup>) به ارزشهای گسسته در ارتباط با آستانه‌های خاص تبدیل کردند. جهت تغییرات شاخص قیمت سهام کره با استفاده از یک شبکه عصبی پیش‌خور پیش‌بینی شده است (Kim & Han, 2000).

لم و لم تفاوت‌های میانگین متحرک ۲۰ روزه و قیمت‌های سهام را به عنوان داده برای آموزش یک شبکه عصبی پیش‌خور به کار گرفتند تا قیمت پایانی بعدی شاخص قراردادهای آتی هانگ سنگ<sup>۸</sup> را در هنگ‌کنگ پیش‌بینی کنند (Lam & Lam, 2000).

گرچه در بیشتر مطالعات فوق، یافته‌های ارزشمندی به دست آمده، اما در هر یک از آنها تنها تعداد اندکی از شاخصهای تکنیکی مشهور مورد استفاده قرار گرفته است. از سوی دیگر، نمونه مورد استفاده در اکثر این پژوهشها تنها شامل یک شاخص بازار، یک یا چند جفت ارز، یا قیمت سهام

- |                            |                          |               |
|----------------------------|--------------------------|---------------|
| 1. Trading range breaks    | 2. Stochastic Oscillator |               |
| 3. Relative Strength Index | 4. Psychological Line    | 5. William R% |
| 6. Momentum                | 7. Commodity Channel     | 8. Hang Seng  |

یک یا چند شرکت محدود در بازارهای مورد بررسی، بوده است. هدف از این تحقیق، بررسی سودمندی شبکه‌های عصبی پیشخور در ارتقای اثربخشی ۵ شاخص مشهور و متداول تحلیل تکنیکی در پیش‌بینی علائم روند سهام با استفاده از نمونه‌ای مشتمل بر ۵۰ شرکت مورد معامله در بورس اوراق بهادار تهران می‌باشد.

### ۳- روش تحقیق

هدف اصلی این پژوهش، بررسی توانایی شبکه‌های عصبی در پیش‌بینی تغییرات کوتاه‌مدت روند قیمت سهام با استفاده از شاخصهای تحلیل تکنیکی، به منظور زمان‌بندی معاملات سهام می‌باشد. یک روش ممکن برای ارزیابی عملکرد پیش‌بینی، استفاده از معیارهای متداول و سنتی خطا، مانند جذر میانگین مجذور خطا<sup>۱</sup> و همبستگی بین ارزشهای واقعی متغیر وابسته و ارزشهای تخمینی، می‌باشد. اما شواهدی در پژوهشهای مالی پیشنهاد می‌کند که معیارهای سنتی عملکرد پیش‌بینی ممکن است با سودهای حاصل از معاملات، رابطه محکمی نداشته باشد (Pesaran & Timmermann, 1995).

یک روش جایگزین، بررسی درصد علائم صحیح پیش‌بینی شده می‌باشد. در واقع عملکرد پیش‌بینی بر مبنای معیار درصد علائم صحیح نسبت به معیارهای سنتی، با عملکرد سودآوری رابطه قویتری دارد (Pesaran & Timmermann, 1995). بنابراین، برای ارزیابی قدرت پیش‌بینی شبکه‌های عصبی طراحی شده از معیار درصد علائم صحیح استفاده می‌شود.

از آنجا که هدف از زمان‌بندی معاملات سهام یا همان تعیین زمان مناسب انجام معاملات سهام، بهبود و یا حفظ بازده در معاملات می‌باشد، روش دیگری که در این پژوهش از آن استفاده می‌شود مقایسه بازدهی حاصل از ترکیب شبکه‌های عصبی و شاخصهای تحلیل تکنیکی با بازده سایر روشهای جایگزین است. در پژوهشهای مالی، دو روش خرید و نگهداری و روش خرید و فروش به عنوان جایگزین یکدیگر مطرح می‌باشند و در اکثر پژوهشهای انجام شده، بازده حاصل از این دو روش با هم مقایسه شده است. بنابراین، روش خرید و نگهداری به عنوان یکی از معیارهای قضاوت در این پژوهش مطرح می‌باشد. از سوی دیگر، هدف از کاربرد شبکه‌های عصبی در این پژوهش، استفاده از چند شاخص تحلیل تکنیکی به صورت همزمان برای دستیابی به پیش‌بینی صحیح‌تر و بازده بالاتر می‌باشد. لذا هر یک از شاخصهای تکنیکی مورد استفاده نیز، به تنهایی، به عنوان معیار قضاوت مطرح می‌باشد.

جامعه مورد مطالعه در این پژوهش کلیه شرکتهای پذیرفته شده در بورس اوراق بهادار تهران

#### 1. Root Mean Square Error (RMSE)

است. برای نمونه‌گیری باید نکات زیر را در نظر داشت:

- ۱- برای مدلسازی شبکه‌های عصبی، احتیاج به تعداد زیادی داده داریم لذا باید نمونه‌ای که انتخاب می‌شود در کل دوره پژوهش دارای تعداد روز معاملاتی نسبتاً بالایی باشد.
- ۲- برای اجرای یک استراتژی فعال در خرید و فروش سهام، نقد شوندگی سهم بسیار مهم است و همچنین برای استفاده از روشهای تحلیل تکنیکی باید نمونه مورد نظر دارای تعداد روز معاملاتی نسبتاً زیادی در هر سال باشد.

با در نظر گرفتن موارد فوق نمونه‌گیری به شرح زیر می‌باشد:

برای انتخاب نمونه، ابتدا کل روزهای معاملاتی دوره ۱۳۸۰/۰۷/۰۱ تا ۱۳۸۴/۰۷/۳۰ محاسبه گردید که جمعاً ۹۸۹ روز معاملاتی را شامل می‌شد. سپس شرکتهایی که در هر سال حضور پررنگ داشتند و در تمام سالها در بیش از ۶۰ درصد روزهای معاملاتی، معامله شده بودند انتخاب شدند. بدین ترتیب، تعداد کل نمونه‌ها شامل ۵۰ شرکت از شرکتهای بورس اوراق بهادار تهران می‌باشد که میانگین حسابی تعداد روزهای معاملاتی آنها در کل دوره ۷۸۵ روز محاسبه شد. سپس داده‌ها، به سه دوره تقسیم شدند. دوره اول بیانگر یک بازار صعودی<sup>۱</sup> از ۱۳۸۲/۰۸/۰۱ تا ۱۳۸۳/۰۷/۳۰ و شامل ۲۴۰ روز معاملاتی می‌باشد و دوره دوم بیانگر یک بازار نزولی<sup>۲</sup> از ۱۳۸۳/۰۸/۰۱ تا ۱۳۸۴/۰۷/۳۰ و شامل ۲۴۴ روز معاملاتی است. دوره سوم نیز شامل ۵۰۵ روز معاملاتی از ۱۳۸۰/۰۷/۰۱ تا ۱۳۸۲/۰۷/۳۰ برای آموزش شبکه عصبی در بازار صعودی و ۵۰۳ روز معاملاتی از ۱۳۸۱/۰۷/۰۱ تا ۱۳۸۳/۰۷/۳۰ برای آموزش شبکه عصبی در بازار نزولی می‌باشد. از دوره‌های اول و دوم برای آزمون برون نمونه‌ای و مقایسه بین عملکرد شبکه‌های عصبی، شاخصهای تکنیکی و روش خرید و نگهداری استفاده می‌گردد. جدول (۱) کل نمونه‌های انتخاب شده و تعداد روز معاملاتی آنها را در دوره آموزش شبکه عصبی و دوره‌های اول و دوم آزمون شبکه نشان می‌دهد.

---

1. Bull Market

2. Bear Market

جدول ۱. تعداد روز معاملاتی نمونه‌های تهیه شده برای انجام پژوهش

ردیف	نام شرکت	تعداد روزهای معاملاتی		
		دوره آموزش	دوره اول	دوره دوم
۱	گروه بهمن	۴۷۷	۲۲۵	۱۸۰
۲	سرمایه گذاری ملی	۴۷۴	۲۱۵	۲۰۸
۳	شهد ایران	۴۷۱	۲۰۹	۱۸۲
۴	توسعه صنایع بهشهر	۴۷۰	۲۰۱	۱۸۵
۵	سرمایه گذاری البرز	۴۶۵	۲۰۵	۱۴۴
۶	ایران خودرو	۴۶۵	۲۰۲	۲۱۲
۷	سرمایه گذاری پتروشیمی	۴۵۵	۲۰۱	۲۰۴
۸	سرمایه گذاری سپه	۴۴۳	۲۰۳	۱۹۵
۹	لینیات پاک	۴۳۸	۱۶۵	۱۶۲
۱۰	معادن و فلزات	۴۳۷	۲۱۲	۱۸۳
۱۱	پتروشیمی خارک	۴۳۶	۲۲۶	۱۹۹
۱۲	پتروشیمی آبادان	۴۳۵	۲۰۷	۱۷۶
۱۳	کف	۴۳۴	۲۱۳	۱۸۵
۱۴	سرمایه گذاری صنعت و معدن	۴۳۳	۲۰۷	۲۰۹
۱۵	سرمایه گذاری ساختمان	۴۳۱	۲۰۵	۱۸۸
۱۶	سرمایه گذاری رنا	۴۳۰	۲۰۲	۱۹۷
۱۷	سرمایه گذاری غدیر	۴۲۸	۱۸۵	۲۱۷
۱۸	سایپا	۴۲۴	۱۹۹	۲۱۵
۱۹	رازک	۴۲۲	۱۹۸	۱۸۴
۲۰	سرما آفرین	۴۲۰	۱۵۸	۱۸۹
۲۱	سیمان فارس و خوزستان	۴۱۹	۱۸۰	۱۹۰
۲۲	محورسازان	۴۱۴	۲۲۸	۲۰۱
۲۳	داروسازی جابر ابن حیان	۴۱۳	۲۱۸	۱۸۸
۲۴	سیمان تهران	۴۱۲	۱۹۷	۱۹۷
۲۵	پتروشیمی اراک	۴۱۲	۲۰۷	۲۱۲
۲۶	سرمایه گذاری ملت	۴۰۶	۱۹۶	۱۵۷
۲۷	معادن روی	۴۰۶	۱۹۵	۲۰۲
۲۸	موتوژن	۴۰۰	۱۶۵	۲۰۴
۲۹	چینی ایران	۴۰۰	۱۸۰	۱۷۷




## ادامه جدول ۱.

تعداد روزهای معاملاتی				نام شرکت	ردیف
جمع	دوره دوم	دوره اول	دوره آموزش		
۷۹۴	۱۸۱	۲۱۴	۳۹۹	لوله و ماشین سازی	۳۰
۸۳۵	۲۲۱	۲۱۸	۳۹۶	پارس دارو	۳۱
۸۲۸	۲۲۷	۲۱۱	۳۹۰	نفت بهران	۳۲
۷۲۹	۱۵۳	۱۸۸	۳۸۸	کربن ایران	۳۳
۶۶۳	۱۲۵	۱۵۱	۳۸۷	داروپخش	۳۴
۷۷۰	۱۷۲	۲۱۲	۳۸۶	کیمیدارو	۳۵
۷۱۸	۱۴۲	۱۹۱	۳۸۵	سیمان شرق	۳۶
۷۲۹	۱۶۳	۱۸۲	۳۸۴	سرمایه گذاری پارس توشه	۳۷
۷۶۱	۱۵۵	۲۲۳	۳۸۳	صنعتی بهشهر	۳۸
۷۳۳	۱۴۸	۲۰۶	۳۷۹	سرمایه گذاری بانک ملی	۳۹
۷۲۵	۱۸۲	۱۶۷	۳۷۶	صنعتی نیرومحرکه	۴۰
۶۶۴	۱۳۶	۱۵۷	۳۷۱	داروسازی اسوه	۴۱
۸۱۸	۲۳۰	۲۲۵	۳۶۳	سرمایه گذاری بیمه	۴۲
۷۷۲	۲۱۱	۲۰۳	۳۵۸	زامیاد	۴۳
۷۱۳	۱۷۲	۱۸۳	۳۵۸	پتروشیمی اصفهان	۴۴
۷۰۱	۱۶۴	۱۸۵	۳۵۲	داروسازی کوثر	۴۵
۶۸۱	۱۸۸	۱۴۵	۳۴۸	لاستیکی سهند	۴۶
۶۹۷	۱۳۶	۲۱۶	۳۴۵	سایپا آذین	۴۷
۶۴۲	۱۳۵	۱۶۶	۳۴۱	سیمان کرمان	۴۸
۶۹۸	۱۷۰	۱۹۶	۳۳۲	سیمان سپاهان	۴۹
۶۶۶	۱۴۸	۲۱۵	۳۰۳	ساختمان اصفهان	۵۰
۹۸۹	۲۴۴	۲۴۰	۵۰۵	کل بورس	
۵۹۳	۱۴۶	۱۴۴	۳۰۳	۶۰٪ تعداد روزهای معاملاتی	

شکل (۱) نمودار شاخص کل بورس اوراق بهادار تهران را در دوره پژوهش به همراه دوره‌های اول (بازار صعودی) و دوم (بازار نزولی) مورد استفاده در پژوهش نشان می‌دهد.

شکل ۱. شاخص کل بورس اوراق بهادار تهران در دوره پژوهش



### ۳-۱- فرضیه‌های تحقیق

برای بررسی اینکه آیا پیش‌بینی مدلها تفاوت معنی‌داری با حالت تصادفی دارد یا خیر، یک فرضیه آماری به صورت زیر تعریف می‌شود:

فرضیه ۱: درصد پیش‌بینی صحیح مدل‌های شبکه عصبی طراحی شده بیشتر از حالت تصادفی می‌باشد. برای بررسی اینکه آیا پیش‌بینی مدل بهتر از حالت تصادفی (۵۰٪) است، از آزمون فرضیه نسبت موفقیت در جامعه ( $p$ ) استفاده می‌شود. بنابراین فرضیه پژوهشی به این صورت است که: «درصد پیش‌بینی صحیح مدل‌های شبکه عصبی طراحی شده بیشتر از ۵۰٪ می‌باشد». طراحی فرضیه این ادعا به صورت زیر است:

$$H_0: p \leq p_0 \quad \text{صحت پیش‌بینی مورد نظر حداکثر ۵۰ درصد است.}$$

$$H_1: p > p_0 \quad \text{صحت پیش‌بینی مورد نظر بیشتر از ۵۰ درصد است.}$$

فرضیه ۲: بین بازده روشهای معاملاتی  $MACD$ ،  $SO$ ،  $ROC$ ،  $MA$ ،  $RSI$ ، خرید و نگهداری و شبکه عصبی پیش‌خور ( $FNN$ ) پیش از کسر هزینه‌های معاملاتی، تفاوت معنی‌داری وجود دارد.

$$\begin{cases} H_0: \mu_1 = \mu_2 = \dots = \mu_8 \\ H_1: \mu_i \neq \mu_j \end{cases} \quad \text{طراحی فرضیه:}$$

فرضیه ۳: بین بازده روشهای معاملاتی  $MACD$ ،  $SO$ ،  $ROC$ ،  $MA$ ،  $RSI$ ، خرید و نگهداری و شبکه عصبی پیش خور ( $FNN$ ) پس از کسر هزینه‌های معاملاتی تفاوت معنی‌داری وجود دارد.

$$\begin{cases} H_0: \mu_1 = \mu_2 = \dots = \mu_8 \\ H_1: \mu_i \neq \mu_j \end{cases} \quad \text{طراحی فرضیه:}$$

برای آزمون فرضیه‌های (۲) و (۳) از آزمون طرح اندازه‌های تکراری<sup>۱</sup> و مقایسه‌های پس از تجربه<sup>۲</sup> استفاده می‌شود.

### ۲-۳- متغیرهای مورد استفاده

از آنجایی که تحلیلگران تکنیکی مختلف بر مبنای تجربه خود از معیارها و شاخصهای متفاوتی برای تعیین علائم خرید و فروش استفاده می‌کنند و تعداد این شاخصها بسیار زیاد است، در این تحقیق از ۵ شاخص میانگین متحرک ساده ( $MA$ ) ۱۰ روزه، قدرت نسبی ( $RSI$ ) ۱۴ روزه، نرخ تغییر ( $ROC$ ) ۱۲ روزه، نوسان نگار تصادفی ( $SO$ ) و میانگین متحرک همگرا - واگرا ( $MACD$ ) که بیش از سایر شاخصها در تحلیل تکنیکی استفاده می‌شود و در بیشتر مطالعات انجام شده نیز مورد استفاده قرار گرفته‌اند، بهره‌گیری می‌شود. روش محاسبه و چگونگی ایجاد علائم خرید و فروش این شاخصها در جدول (۲) خلاصه شده است. شرح کامل این ۵ شاخص در این منابع موجود می‌باشد (محمدی، ۱۳۸۳؛ Murphy, 1999؛ Pring, 1998).

### جدول ۲. روش محاسبه و چگونگی ایجاد علائم خرید و فروش در شاخصهای تکنیکی

شاخص	روش محاسبه	سفارش خرید	سفارش فروش
$MA$	$MA_t(n) = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i}$	قیمت سهم میانگین متحرکش را از پایین به بالا قطع می‌کند	قیمت سهم به پایین میانگین متحرک سقوط می‌کند
$RSI$	$RSI = 100 - \frac{100}{1 + RS}$ $RS = \frac{\text{متوسط منفعت های قیمت در } n \text{ دوره}}{\text{متوسط زیان های قیمت در } n \text{ دوره}}$	حرکت خط $RSI$ از اعداد زیر ۳۰ به اعداد بالای ۳۰	حرکت خط $RSI$ از اعداد بالای ۷۰ به اعداد زیر ۷۰

#### 1. Repeated Measures Design

#### 2. Post Hoc Comparisons

ادامهٔ جدول ۲.

شاخص	روش محاسبه	سفارش خرید	سفارش فروش
ROC	$ROC_n = \left( \frac{P_n}{P_1} - 1 \right) * 100$	هنگامی که ROC خط صفر را از پایین به بالا قطع می‌کند	هنگامی که ROC خط صفر را از بالا به پایین قطع می‌کند
SO	$K\% = \left( \frac{C - L}{H - L} \right) * 100$ %D میانگین متحرک (معمولاً ۳ دوره‌ای) استوکاستیک %K است	هنگامی که خط %K در زیر سطح ۲۰ خط %D را از پایین به بالا قطع می‌کند	علامت فروش با سقوط خط %K به زیر خط %D در بالای سطح ۸۰ ظاهر می‌شود
MACD	$MACD = EMA_{(\alpha=1/15)} - EMA_{(\alpha=1/75)}$ میانگین متحرک نمایی ۹ دوره‌ای SL = MACD	هنگامی که MACD خط علامت <sup>۱</sup> (SL) را از پایین به بالا قطع می‌کند	هنگامی که MACD خط علامت (SL) را از بالا به پایین قطع می‌کند

در جدول فوق  $MA_t(n)$  میانگین متحرک  $n$  دوره‌ای در روز  $t$ :  $C, H$  و  $L$  به ترتیب قیمت‌های پایانی، حداکثر و حداقل در  $n$  دوره،  $EMA_{(\alpha=1/15)}$  میانگین متحرک نمایی ۱۲ روزه قیمت پایانی و  $EMA_{(\alpha=1/75)}$  میانگین متحرک نمایی ۲۶ روزه قیمت پایانی می‌باشند. با توجه به ۵ شاخص تکنیکی، کلاً ۸ متغیر وجود دارد که برای تعیین علائم خرید و فروش سهام لازمند. این متغیرها عبارتند از قیمت پایانی ( $CP$ )، شاخص قدرت نسبی ( $RSI$ )، شاخص درصد تغییرات ( $ROC$ )، میانگین متحرک ساده ( $MA$ )، خط %K، خط %D، میانگین متحرک همگرا-واگرا ( $MACD$ ) و خط سیگنال ( $SL$ ). در بسیاری از پژوهش‌های صورت گرفته، ثابت شده است که چنانچه یک پردازش اولیه روی متغیرهای ورودی شبکه‌های عصبی انجام گیرد، این شبکه‌ها می‌توانند مؤثرتر واقع شوند (Halliday, 2004; Mizuno et al, 1998). در این پژوهش یک پردازش اولیه روی متغیرهای فوق صورت می‌گیرد و ۶ متغیر  $CP_t - CP_{t-1}$ ،  $RSI_t$ ،  $ROC_t$ ،  $MACD_t - SL_t$ ،  $\%K_t - \%D_t$ ،  $CP_t - MA_t$  به عنوان متغیرهای درون‌داد شبکه عصبی مصنوعی تعریف می‌گردند.

۳-۳- طرح‌ریزی شبکه عصبی

نظریه محاسبات شبکه عصبی، روش‌های جالبی را ارائه می‌کند که از مغز انسان و سیستم عصبی

1. Signal Line

الهام گرفته‌اند. شبکه‌های عصبی توسط الگوی ارتباطات بین لایه‌های مختلف شبکه، تعداد نرونها در هر لایه، الگوریتم یادگیری و تابع فعال‌سازی نرون مشخص می‌شوند. به بیان عام، شبکه عصبی مجموعه‌ای از ارتباطات بین واحدهای ورودی و خروجی است که در آن هر ارتباط دارای وزنی است که به آن تخصیص داده شده است. در طی مرحله یادگیری، شبکه از طریق تعدیل وزنها آموزش می‌بیند تا قادر به پیش‌بینی یا طبقه‌بندی صحیح برون داده‌های هدف بر اساس مجموعه‌ای از نمونه‌های درون‌داد باشد (Thawornwong et al, 2003).

از بین انواع گوناگون شبکه‌های عصبی مصنوعی، در این پژوهش از شبکه عصبی پیش‌خور (FNN) که در حل مسائل دسته‌بندی به کار می‌رود، استفاده می‌شود. شبکه عصبی پیش‌خور به علت قابلیت طبقه‌بندی و پیش‌بینی صحیح متغیر وابسته، در پیش‌بینی‌های مالی به‌طور گسترده‌ای مورد استفاده قرار گرفته است (Vellido et al, 1999).

برای هر آموزشی، متغیرهای ورودی همزمان به لایه‌ای از واحدهای نرونی به نام لایه ورودی و برون‌دادهای موزون این واحدها همزمان به لایه دیگری از واحدها به نام واحد پنهان خورنده می‌شوند. برون‌دادهای موزون لایه پنهان می‌توانند به لایه پنهان دیگری وارد شوند و الی آخر. برون‌دادهای آخرین لایه پنهان به واحدهای لایه خروجی وارد می‌شوند که پیش‌بینی شبکه را برای مجموعه مشخصی از نمونه‌ها ارائه می‌کند. در این تحقیق از الگوریتم پس انتشار خطا<sup>۱</sup> برای آموزش شبکه عصبی استفاده می‌شود. در این روش برای هر انطباق نادرست به هر یک از عناصر پردازشی در شبکه، مسؤلیتی تخصیص داده می‌شود، که از طریق پس انتشار گرادیانت تابع فعال‌سازی در طول شبکه به هر لایه پنهان تا اولین لایه پنهان به دست می‌آید. سپس وزنها و بایاس‌ها<sup>۲</sup> به گونه‌ای تعدیل می‌گردند که میانگین مجذور خطا بین پیش‌بینی شبکه و هدف واقعی حداقل گردد. تعریف پارامترهای شبکه یک فرایند تجربی است. در بیشتر موارد یک روش ابتکاری است که در آن شبکه‌های چندین شبکه با نرخهای یادگیری گوناگون، تعداد متفاوت لایه‌های پنهان، مومنتوم‌های مختلف و توابع تبدیل گوناگون آموزش می‌بینند و سپس بهترین شبکه انتخاب می‌شود (فلاح‌پور، ۱۳۸۳). در این تحقیق از تابع تبدیل زیگموئیدی برای ایجاد یک توزیع یکنواخت روی ارزشهای ورودی استفاده می‌گردد که به صورت رابطه زیر می‌باشد:

$$f(NE T) = (1 + e^{-NE T})^{-1} \quad (1)$$


منظور از  $NE T$ ، مجموع وزنی متغیرهای ورودی از لایه قبلی است. با استفاده از این تابع، مقدار متغیر خروجی، عددی بین صفر تا یک خواهد شد. برای مدل شبکه عصبی نیز از یک لایه پنهان

استفاده می‌شود؛ زیرا در مسائل مربوط به پیش‌بینی و دسته‌بندی در پژوهش‌های مالی بسیار موفق بوده است (Swales, 1992).

بر این اساس، شبکه عصبی پیش‌خور از سه لایه شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل می‌گردد. هر یک از شش متغیر ورودی به یک نرون ورودی مجزا در لایه ورودی خورنده می‌شود. از آنجا که دو طبقه وجود دارد (علامت خرید و فروش) از دو نرون خروجی در لایه خروجی استفاده می‌شود که نمایانگر طبقه‌های مختلف پیش‌بینی (جهت خرید یا فروش) می‌باشند. تعیین تعداد نرون‌های لایه پنهان، کار ساده‌ای نیست و بیشتر با استفاده از سعی و خطا به دست می‌آید، به گونه‌ای که عملکرد کلی شبکه بهبود یابد. البته در این زمینه یک سری قواعد سرانگشتی مانند  $n/2$ ،  $n$ ،  $n+1$  و  $2n+1$  نرون ( $n$  نشان‌دهنده تعداد نرون‌های لایه ورودی است) نیز وجود دارد (فلاح پور، ۱۳۸۳).

پس از بارها آزمایش، تعداد نرون‌های مختلف در لایه پنهان، همراه با تنظیم سایر پارامترها، این نتیجه حاصل شد که تعداد هفت نرون در لایه پنهان به عملکرد بهتر منجر می‌شود. در مورد نرخ یادگیری باید گفت که اگر نرخ یادگیری کوچک باشد، یادگیری به کندی انجام می‌شود و اگر بزرگ انتخاب شود، باعث نوسان زیاد و ناپایداری سیستم می‌گردد. نرخ یادگیری مورد استفاده در این پژوهش با توجه به دو مسأله مذکور و پس از آزمون و خطا،  $0/01$  انتخاب گردید. تعداد تکرارها به نرخ یادگیری و هدف مورد نظر در ارتباط با تابع عملکرد بستگی دارد. با نرخ یادگیری  $0/01$ ، تعداد تکرارها برای شبکه‌ها حداکثر برابر با ۱۰ هزار در نظر گرفته شد. بر اساس موارد مذکور، شمای کلی شبکه عصبی پیش‌خور در این پژوهش به صورت شکل (۲) می‌باشد.

شکل ۲. شمای کلی شبکه عصبی پیش‌خور مورد استفاده در پژوهش



## ۳-۴- شبیه‌سازی معاملات

به منظور تحلیل داده‌ها، ابتدا داده‌های روزانه مربوط به هر سهم نسبت به کلیه افزایش سرمایه‌ها، تقسیم سودها، سهام جایزه و ... تعدیل می‌گردند. سپس متغیرهای مورد نظر با استفاده از داده‌های تعدیل شده برای تک تک شرکتها محاسبه می‌شوند.

در این پژوهش، یک بار بازده بدون در نظر گرفتن هزینه‌های معاملاتی محاسبه می‌گردد و یک بار نیز برای دستیابی به نتایج واقعی‌تر، کلیه هزینه‌های معاملاتی مورد توجه قرار می‌گیرد، زیرا سودآوری معاملات ممکن است به وسیله هزینه‌های معاملاتی، بیش از حد از بین برود بویژه هنگامی که تعداد معاملات زیاد و بازده هر معامله پایین باشد. برای این منظور، هزینه معاملاتی در هنگام خرید معادل  $0.75\%$  ارزش سهام خریداری شده و در هنگام فروش معادل  $1.25\%$  ارزش سهام فروخته شده در نظر گرفته می‌شود.

برای بررسی اینکه آیا شبکه‌های عصبی قادر به ایجاد بازده بالاتر در مرحله عمل هستند، یک استراتژی معاملاتی در ارتباط با علائم پیش‌بینی شده شبکه‌های عصبی به عنوان معیاری برای خرید و فروش تعیین گردید. در این استراتژی، فرض می‌شود که یک سرمایه‌گذار خرید را با قیمت آغازین و در ابتدای هر روز که سیگنال خرید ظاهر می‌شود انجام می‌دهد (با توجه به محدودیت داده‌های مربوط به قیمت سهام در ایران، قیمت آغازین هر سهم برابر با قیمت پایانی روز قبل در نظر گرفته می‌شود) و فروش را نیز با قیمت پایانی هر سهم در پایان روز معاملاتی که سیگنال فروش ظاهر می‌شود، انجام می‌دهد.

معیار انجام معاملات با در نظر گرفتن علائم پیش‌بینی شده در شبکه‌های عصبی به صورت زیر می‌باشد:

خرید: اگر  $\hat{Y} = +1$

فروش: اگر  $\hat{Y} = -1$

که در آن  $\hat{Y}$  جهت پیش‌بینی شده قیمت سهم در روز آتی به وسیله شبکه‌های عصبی می‌باشد. (+1) نشان‌دهنده پیش‌بینی جهت رو به بالا و (-1) نشان‌دهنده پیش‌بینی جهت رو به پایین است. فرایند شبیه‌سازی برای مقایسه بازده حاصل از معاملات انجام شده با استفاده از شبکه‌های عصبی با بازده حاصل از شاخصهای متداول تحلیل تکنیکی و بازده حاصل از روش خرید و نگهداری انجام می‌شود. برای انجام این شبیه‌سازی، فرض می‌گردد که سرمایه‌گذار یک سهم را با اولین سیگنال خرید یا فروش، می‌خرد یا می‌فروشد. همچنین وضعیت فعلی سرمایه‌گذاری تا زمانی که سیگنال فروش یا خرید بعدی ظاهر نشود، حفظ می‌شود و اگر سیگنال بعدی مشابه سیگنال قبلی بود (یعنی دو سیگنال خرید یا دو سیگنال فروش متوالی ظاهر شد) هیچ عمل معاملاتی برای سیگنال

بعدی رخ نمی‌دهد. سرمایه‌گذار در تمام دوره معاملاتی، در بازار فعال است و ممکن است در وضعیت نگهداری، خرید یا فروش باشد. نهایتاً سرمایه‌گذار در پایان آخرین روز معاملاتی سهامی را که در اختیار دارد بدون توجه به آخرین سیگنال دریافتی می‌فروشد و از بازار خارج می‌شود.

#### ۴- نتایج تجربی

عملکرد پیش‌بینی شبکه‌های عصبی طراحی شده با استفاده از داده‌های برون نمونه‌ای دوره‌های آزمون ارزیابی شد. جدول (۳) نتایج پیش‌بینی مدل شبکه عصبی پیش‌خور را نشان می‌دهد. همان‌گونه که ملاحظه می‌شود، میانگین درصد پیش‌بینی‌های صحیح در هر دو دوره در حدود ۷۰٪ می‌باشد.

#### جدول ۳. نتایج پیش‌بینی صحیح (درصد صحت)

##### مدل شبکه عصبی پیش‌خور در دوره‌های اول و دوم

نمونه	دوره اول			دوره دوم		
	خرید	فروش	کل	خرید	فروش	کل
۱	۷۲/۸۳	۵۷/۸۹	۶۴/۰۰	۶۴/۵۱	۸۴/۸۸	۷۴/۳۰
۲	۶۹/۵۷	۷۱/۰۰	۷۰/۲۳	۶۵/۷۹	۹۲/۰۵	۸۶/۷۷
۳	۸۱/۵۵	۷۱/۷۰	۷۶/۵۶	۷۳/۴۴	۶۵/۵۲	۶۸/۳۳
۴	۶۵/۱۴	۶۹/۵۷	۶۷/۱۶	۵۶/۹۲	۸۴/۸۷	۷۵/۰۰
۵	۷۴/۵۱	۴۰/۷۸	۵۷/۵۶	۵۲/۰۸	۶۹/۱۵	۶۳/۳۸
۶	۸۰/۰۰	۵۷/۹۴	۶۸/۳۱	۶۸/۹۳	۷۷/۵۷	۷۳/۳۳
۷	۱۹/۸۲	۸۵/۳۹	۴۸/۲۹	۴۷/۱۴	۸۰/۳۱	۶۸/۵۳
۸	۷۵/۷۰	۴۸/۹۶	۶۳/۰۵	۶۳/۹۵	۷۸/۵۰	۷۲/۰۲
۹	۸۸/۴۱	۴۸/۹۶	۶۵/۴۵	۷۱/۴۳	۵۷/۱۴	۶۳/۹۸
۱۰	۸۰/۸۷	۵۹/۸۰	۷۱/۲۳	۵۹/۷۰	۸۴/۳۵	۷۴/۴۶
۱۱	۷۸/۵۲	۶۳/۶۴	۷۳/۴۵	۶۲/۰۷	۸۷/۸۶	۸۰/۳۰
۱۲	۷۶/۳۶	۵۶/۷۰	۶۷/۱۵	۷۰/۳۷	۴۶/۸۱	۵۷/۷۱
۱۳	۷۲/۳۲	۸۱/۱۹	۷۶/۵۳	۶۴/۲۰	۸۰/۳۹	۷۳/۲۲
۱۴	۸۲/۱۴	۵۶/۸۴	۷۰/۵۳	۷۵/۶۴	۸۹/۹۲	۸۴/۵۴
۱۵	۸۲/۲۶	۴۹/۳۸	۶۹/۲۷	۷۸/۳۱	۴۱/۷۵	۵۸/۰۶
۱۶	۷۰/۰۰	۶۵/۲۵	۶۶/۶	۷۵/۳۲	۷۹/۸۳	۷۸/۰۹
۱۷	۷۸/۴۳	۴۶/۹۹	۶۴/۳۲	۶۹/۵۰	۷۰/۶۷	۶۹/۹۰
۱۸	۷۲/۴۱	۸۶/۵۲	۸۲/۴۱	۶۸/۱۸	۹۳/۲۴	۸۵/۵۱



## ادامه جدول ۳.

نمونه	دوره اول			دوره دوم		
	خرید	فروش	کل	خرید	فروش	کل
۱۹	۸۳/۲۱	۶۰/۶۶	۷۲/۲۶	۶۸/۱۲	۷۱/۹۳	۷۰/۴۹
۲۰	۶۵/۲۲	۷۷/۵۳	۷۲/۱۵	۵۷/۳۱	۷۶/۱۹	۷۶/۹۱
۲۱	۷۶/۰۶	۶۸/۸۱	۷۱/۶۷	۳۲/۸۱	۹۳/۶۰	۷۳/۰۲
۲۲	۶۶/۶۷	۷۶/۳۰	۷۲/۳۷	۶۳/۵۴	۵۸/۲۵	۶۰/۸۰
۲۳	۷۳/۷۳	۷۳/۰۰	۷۳/۳۹	۵۰/۰۰	۸۹/۷۴	۷۴/۸۷
۲۴	۷۵/۹۰	۷۶/۳۲	۷۶/۱۴	۸۱/۰۳	۹۳/۴۳	۸۹/۷۴
۲۵	۵۶/۹۹	۷۷/۱۹	۶۸/۱۱	۵۸/۴۶	۸۴/۹۳	۷۶/۷۸
۲۶	۶۸/۲۷	۶۸/۴۸	۶۸/۳۷	۵۸/۴۶	۶۹/۲۳	۶۴/۷۴
۲۷	۴۵/۰۵	۷۷/۳۸	۵۹/۰۰	۵۴/۹۴	۵۷/۷۹	۵۶/۵۰
۲۸	۵۶/۱۶	۶۶/۳۰	۶۱/۸۲	۳۸/۳۰	۷۳/۱۵	۵۶/۹۳
۲۹	۵۰/۰۰	۹۲/۲۵	۸۳/۳۳	۵۷/۶۲	۸۹/۷۴	۷۸/۹۷
۳۰	۷۲/۴۱	۶۴/۵۷	۶۷/۷۶	۳۷/۹۷	۸۸/۱۲	۶۶/۱۱
۳۱	۷۳/۳۹	۷۷/۰۶	۷۵/۲۲	۶۷/۷۹	۷۹/۴۱	۷۳/۱۸
۳۲	۷۶/۵۲	۸۲/۳۰	۷/۶۲	۷۳/۶۸	۸۹/۹۳	۸۴/۴۴
۳۳	۶۴/۶۳	۶۷/۹۲	۶۶/۴۸	۵۵/۲۲	۷۸/۸۲	۶۸/۴۲
۳۴	۶۸/۱۱	۹۱/۴۶	۸۰/۷۹	۵۰/۰۰	۹۱/۸۹	۷۵/۰۰
۳۵	۵۹/۶۵	۶۷/۳۵	۶۳/۲۰	۵۲/۸۳	۸۷/۲۹	۷۶/۹۱
۳۶	۷۸/۱۲	۶۲/۱۱	۷۰/۱۶	۴۰/۳۸	۶۸/۵۴	۵۸/۱۵
۳۷	۸۳/۳۳	۶۲/۷۹	۷۳/۶۲	۷۲/۰۹	۸۹/۷۴	۸۵/۰۰
۳۸	۸۰/۳۴	۷۳/۵۸	۷۷/۱۳	۷۲/۰۶	۸۹/۵۳	۸۱/۸۲
۳۹	۶۷/۸۹	۷۵/۲۶	۷۱/۳۶	۵۷/۱۴	۸۸/۳۱	۷۳/۴۶
۴۰	۶۰/۴۷	۸۸/۷۱	۸۱/۴۴	۴۴/۵۹	۷۶/۴۲	۶۳/۳۳
۴۱	۶۴/۸۴	۷۱/۲۱	۶۷/۵۲	۵۶/۶۳	۷۵/۰۰	۶۳/۷۰
۴۲	۸۳/۹۶	۴۳/۷۰	۶۲/۶۷	۴۶/۱۵	۷۹/۴۷	۶۸/۱۲
۴۳	۶۹/۸۸	۷۷/۵۰	۷۴/۳۸	۶۴/۶۴	۸۰/۰۰	۷۲/۷۳
۴۴	۶۷/۳۵	۷۰/۵۹	۶۸/۸۵	۶۳/۸۹	۶۶/۶۷	۶۵/۴۹
۴۵	۷۷/۴۱	۶۷/۴۷	۷۰/۸۱	۶۸/۱۸	۸۷/۵۰	۷۹/۶۲
۴۶	۶۵/۷۹	۶۲/۸۶	۶۴/۳۸	۴۴/۲۹	۷۶/۷۲	۶۴/۵۲
۴۷	۵۹/۷۴	۷۲/۶۶	۶۸/۰۶	۴۴/۹۰	۸۲/۵۶	۶۸/۸۹
۴۸	۸۰/۹۵	۶۲/۲۰	۸۱/۶۹	۵۴/۹۰	۶۶/۲۷	۶۱/۹۴
۴۹	۸۲/۱۴	۷۶/۷۹	۷۹/۰۸	۵۰/۰۰	۹۰/۶۰	۷۸/۱۱
۵۰	۸۹/۵۸	۵۴/۹۳	۷۸/۱۴	۷۶/۳۹	۶۱/۳۳	۶۸/۷۱
میانگین	۷۱/۲۹	۶۸/۱۱	۷۰/۲۶	۶۰/۰۴	۷۸/۳۴	۷۱/۵۱

جدول (۴) آماره های آزمون را برای پیش‌بینی مدل شبکه عصبی پیش‌خور (FNN) در دوره‌های اول و دوم به همراه مقادیر بحرانی در سطح ۹۵٪ اطمینان نشان می‌دهد. آماره آزمون به صورت زیر تعریف می‌شود:

$$Z = \frac{\bar{P} - P_i}{\sqrt{\frac{P_i(1-P_i)}{n}}} = \frac{\bar{P} - 0.5}{\sqrt{\frac{0.5(1-0.5)}{50}}}$$

جدول ۴. آماره‌های آزمون محاسبه شده برای پیش‌بینی مدل در هر یک از دوره‌ها

دوره مورد آزمون	$\bar{P}$	$P_i$	$n$	مقدار بحرانی	آماره $Z$
دوره اول	٪۷۰/۲۶	٪۵۰	۵۰	۱/۹۶	۲/۸۶۵
دوره دوم	٪۷۱/۵۱	٪۵۰	۵۰	۱/۹۶	۳/۰۴۱

همان‌گونه که ملاحظه می‌شود، آماره آزمون در همه موارد در سطح معناداری ۵٪، در سمت راست مقدار بحرانی می‌باشد و بنابراین می‌توان گفت که در فرضیه ۱، فرض  $H_0$  رد و فرض  $H_1$  تأیید می‌شود، یعنی میانگین پیش‌بینی صحیح مورد انتظار بزرگتر از ۵۰ درصد می‌باشد. در حقیقت این نتایج نشان می‌دهد که علائم صحیح ایجاد شده به وسیله شبکه عصبی مورد بررسی بهتر از حالت تصادفی می‌باشد.

بعد از شبیه‌سازی معاملات در دوره‌های اول و دوم، تعداد کل معاملات و بازده کل ناشی از هر یک از روشها در هر دوره محاسبه گردید. جداول (۵) و (۶) میانگین بازده حاصل از روشهای مورد استفاده را در دوره‌های اول و دوم نشان می‌دهد.  $r_{i,1}$  میانگین بازده حاصل از روش  $i$  در حالت پیش از کسر هزینه‌های معاملاتی و  $r_{i,2}$  میانگین بازده حاصل از روش  $i$  در حالت پس از کسر هزینه‌های معاملاتی می‌باشد.

جدول ۵. بازده روشهای مختلف در دوره اول (بازار صعودی)

روش	میانگین تعداد معاملات	میانگین $r_{i,1}$	انحراف معیار $r_{i,1}$	میانگین $r_{i,2}$	انحراف معیار $r_{i,2}$
BH	۲	۱۰۳/۲۳	۱۳۶/۶۵	۹۹/۹۶	۱۳۴/۴۹
MA	۸	۱۰۵/۶۹	۸۵/۶۳	۹۱/۳۳	۹۹/۹۶
RSI	۲	۱۵/۵۶	۲۸/۹۲	۱۰/۸۸	۹۱/۳۳

## ادامه جدول ۵.

روش	میانگین تعداد معاملات	میانگین $F_{i,1}$	انحراف معیار $F_{i,1}$	میانگین $F_{i,2}$	انحراف معیار $F_{i,2}$
ROC	۹	۶۶/۹۴	۸۲/۱۱	۵۵/۸۲	۱۰/۸۸
SO	۱۴	۱۰۴/۸۱	۱۲۳/۰۶	۸۲/۹۰	۵۵/۸۲
MACD	۶	۵۳/۶۲	۶۴/۶۲	۴۵/۹۴	۸۲/۹۰
FNN	۴۵	۱۸۰/۱۸	۱۳۳/۳۰	۹۱/۶۲	۴۵/۹۴

## جدول ۶. بازده روشهای مختلف در دوره دوم (بازار نزولی)

روش	میانگین تعداد معاملات	میانگین $F_{i,1}$	انحراف معیار $F_{i,1}$	میانگین $F_{i,2}$	انحراف معیار $F_{i,2}$
BH	۲	-۱۲/۲۰	۲۶/۴۲	-۱۳/۵۹	۲۶/۰۰
MA	۶	۳۴/۷۰	۳۰/۴۸	۲۷/۸۹	۲۸/۴۳
RSI	۳	۰/۸۵	۲۴/۰۲	-۰/۱۰	۲۳/۳۶
ROC	۸	۱۱/۸۷	۱۸/۷۱	۵/۴۹	۱۶/۷۷
SO	۱۲	۸/۴۰	۲۸/۲۲	-۱/۷۴	۲۴/۹۸
MACD	۶	۳/۸۷	۲۳/۹۷	-۲/۴	۲۳/۳۵
FNN	۴۰	۴۳/۶۲	۳۳/۶۸	۴/۱۴	۲۲/۸۶

همان گونه که ملاحظه می شود، در حالت پیش از کسر هزینه های معاملاتی، بازده روش شبکه عصبی پیشخور (FNN)، چه در بازار صعودی (۱۸۰/۱۸٪) و چه در بازار نزولی (۴۳/۶۲٪) از سایر روشها به مراتب بیشتر است، اما پس از کسر هزینه های معاملاتی در بازار صعودی، تفاوت چندانی با روش میانگین متحرک (MA) و روش خرید و نگهداری (BH) ندارد. در بازار نزولی، بازده روش شبکه عصبی پیشخور (FNN) پس از کسر هزینه های معاملاتی، از بازده روش میانگین متحرک (MA) کمتر، از بازده روش خرید و نگهداری (BH) بیشتر، و با بازده سایر روشها تفاوتی ندارد. به نظر می رسد که تعداد زیاد معاملات انجام شده به وسیله این روش با افزایش هزینه های معاملاتی، موجب کاهش بازده در حالت پس از کسر هزینه های معاملاتی گردیده است.

برای بررسی معناداری تفاوت میانگین بازدهی روشهای معاملاتی، از آزمون طرح اندازه های تکراری استفاده می گردد. جداول (۷) و (۸) خلاصه نتایج آزمون اثرات درون موردی را نشان می دهد:

جدول ۷. آزمون اثرات درون‌موردی<sup>۱</sup> در دوره اول

منبع تغییرات (پراش)	نام آزمون مربوطه	پیش از کسر هزینه‌های معاملاتی			پس از کسر هزینه‌های معاملاتی		
		درجه آزادی	آماره F	عدد معناداری (Sig)	درجه آزادی	آماره F	عدد معناداری (Sig)
روش	<i>Sphericity Assumed</i>	۷	۳۰/۷۸۸	۰/۰۰۰	۷	۱۳/۳۰۳	۰/۰۰۰
	<i>Greenhouse-Geisser</i>	۳/۳۸۷	۳۰/۷۸۸	۰/۰۰۰	۳/۰۲۴	۱۳/۳۰۳	۰/۰۰۰
	<i>Huynh-Feldt</i>	۳/۶۶۹	۳۰/۷۸۸	۰/۰۰۰	۳/۲۴۵	۱۳/۳۰۳	۰/۰۰۰
	<i>Lower-bound</i>	۱/۰۰۰	۳۰/۷۸۸	۰/۰۰۰	۱/۰۰۰	۱۳/۳۰۳	۰/۰۰۱
خطای(روش)	<i>Sphericity Assumed</i>	۳۴۳			۳۴۳		
	<i>Greenhouse-Geisser</i>	۱۶۵/۹۸۱			۱۴۸/۱۶۳		
	<i>Huynh-Feldt</i>	۱۷۹/۷۹۸			۱۵۸/۹۹۸		
	<i>Lower-bound</i>	۴۹/۰۰۰			۴۹/۰۰۰		

جدول ۸. آزمون اثرات درون‌موردی<sup>۲</sup> در دوره دوم

منبع تغییرات (پراش)	نام آزمون مربوطه	پیش از کسر هزینه‌های معاملاتی			پس از کسر هزینه‌های معاملاتی		
		درجه آزادی	آماره F	عدد معناداری (Sig)	درجه آزادی	آماره F	عدد معناداری (Sig)
روش	<i>Sphericity Assumed</i>	۷	۵۸/۹۳۹	۰/۰۰۰	۷	۲۲/۴۳۰	۰/۰۰۰
	<i>Greenhouse-Geisser</i>	۳/۸۵۳	۵۸/۹۳۹	۰/۰۰۰	۴/۵۴۸	۲۲/۴۳۰	۰/۰۰۰
	<i>Huynh-Feldt</i>	۴/۲۲۲	۵۸/۹۳۹	۰/۰۰۰	۵/۰۷۱	۲۲/۴۳۰	۰/۰۰۰
	<i>Lower-bound</i>	۱/۰۰۰	۵۸/۹۳۹	۰/۰۰۰	۱/۰۰۰	۲۲/۴۳۰	۰/۰۰۰
خطای(روش)	<i>Sphericity Assumed</i>	۳۴۳			۳۴۳		
	<i>Greenhouse-Geisser</i>	۱۸۸/۷۷۴			۲۲۲/۸۶۸		
	<i>Huynh-Feldt</i>	۲۰۶/۸۹۳			۲۴۸/۴۸۱		
	<i>Lower-bound</i>	۴۹/۰۰۰			۴۹/۰۰۰		

همان‌گونه که ملاحظه می‌گردد عدد معناداری آزمون اثرات درون‌موردی در چهار آزمون در نظر گرفته شده برابر با صفر و کوچکتر از سطح معناداری ۵٪ می‌باشد. بنابراین در فرضیه‌های ۲ و ۳، فرض  $H_0$  رد و فرض  $H_1$  (عدم برابری میانگین بازده‌ها تحت هفت روش) پذیرفته می‌شود. در ادامه با استفاده از آزمونهای پس‌تبعی مشخص می‌شود که آیا بازده روش  $FNN$  با بازده سایر روشها متفاوت است یا خیر.

جداول (۹) و (۱۰) مقایسات زوجی را بین بازده روش شبکه عصبی پیشخور با سایر روشها در

#### 1. Within Subjects

حالت پیش از کسر هزینه‌های معاملاتی با استفاده از آزمونهای پس‌تبعی نشان می‌دهد. همان‌گونه که ملاحظه می‌شود در بازار صعودی در تمامی موارد عدد معناداری کوچکتر از سطح معناداری ۵٪ می‌باشد که نشان می‌دهد بازده حاصل از مدل شبکه عصبی پیشخور پیش از کسر هزینه‌های معاملاتی، تفاوت معناداری با سایر روشها دارد و در بازار نزولی نیز بجز در مقایسه با روش میانگین متحرک، با سایر موارد، تفاوت معناداری دارد که مثبت‌بودن حد بالا و پایین، نشان‌دهنده بیشتربودن این بازده نسبت به بازده سایر روشها می‌باشد.

#### جدول ۹. مقایسات زوجی بین بازده روش شبکه عصبی با سایر روشها در دوره اول در حالت پیش از کسر هزینه‌ها

روش $i$	روش $j$	تفاوت میانگین ( $i - j$ )	خطای استاندارد	عدد معناداری	۹۵٪ فاصله اطمینان برای تفاوت میانگین	
					حد پایین	حد بالا
<i>FNN</i>	<i>BH</i>	۷۶/۹۵۰ (*)	۱۵/۳۲۶	۰/۰۰۰	۴۶/۱۵۲	۱۰۷/۷۴۸
	<i>MA</i>	۷۴/۴۹۲ (*)	۱۳/۶۲۰	۰/۰۰۰	۴۷/۱۲۲	۱۰۱/۸۶۲
	<i>RSI</i>	۱۶۴/۶۲۲ (*)	۱۸/۳۴۴	۰/۰۰۰	۱۲۷/۷۵۸	۲۰۱/۴۸۶
	<i>ROC</i>	۱۱۳/۳۴۶ (*)	۱۶/۰۱۴	۰/۰۰۰	۸۱/۰۶۴	۱۴۵/۴۲۸
	<i>SO</i>	۷۵/۳۷۶ (*)	۱۷/۵۴۶	۰/۰۰۰	۴۰/۱۱۶	۱۱۰/۶۳۶
	<i>MACD</i>	۱۲۶/۵۶ (*)	۱۶/۳۱۴	۰/۰۰۰	۹۳/۷۷۶	۱۵۹/۳۴۴

مواردی که با ستاره علامت خورده است در سطح ۵٪ معنادار بوده است.

#### جدول ۱۰. مقایسات زوجی بین بازده روش شبکه عصبی با سایر روشها در دوره دوم در حالت پیش از کسر هزینه‌ها

روش $i$	روش $j$	تفاوت میانگین ( $i - j$ )	خطای استاندارد	عدد معناداری	۹۵٪ فاصله اطمینان برای تفاوت میانگین	
					حد پایین	حد بالا
<i>FNN</i>	<i>BH</i>	۴/۴۹۲	۰/۰۰۰	۴۶/۸۰۲	۶۴/۸۵۵	۴/۴۹۲
	<i>MA</i>	۴/۶۸۹	۰/۶۳	۰/۵۰۴	۱۸/۳۴۱	۴/۶۸۹
	<i>RSI</i>	۴/۵۴۶	۰/۰۰۰	۳۳/۶۳۱	۵۱/۹۰۱	۴/۵۴۶
	<i>ROC</i>	۴/۰۰۲	۰/۰۰۰	۲۳/۷۱۰	۳۹/۷۹۵	۴/۰۰۲
	<i>SO</i>	۴/۱۷۴	۰/۰۰۰	۲۶/۸۳۳	۴۳/۶۰۸	۴/۱۷۴
	<i>MACD</i>	۴/۵۷۳	۰/۰۰۰	۳۰/۵۶۳	۴۸/۹۴۲	۴/۵۷۳

مواردی که با ستاره علامت خورده است در سطح ۵٪ معنادار بوده است.

جداول (۱۱) و (۱۲) مقایسات زوجی را بین بازده روش شبکه عصبی پیشخور با سایر روشها در حالت پس از کسر هزینه‌های معاملاتی با استفاده از آزمونهای پس‌تبعی نشان می‌دهد. همان‌گونه که ملاحظه می‌شود در بازار صعودی پس از کسر هزینه‌های معاملاتی، بازده مدل شبکه عصبی با بازده روشهای شاخص قدرت نسبی (*RSI*)، شاخص نرخ تغییر (*ROC*) و میانگین متحرک همگرا-واگرا (*MACD*) تفاوت معناداری دارد و از آنها بیشتر است اما با بازده روشهای خرید و نگهداری، میانگین‌های متحرک و شاخص نوسان نگار تصادفی (*SO*)، تفاوت معناداری ندارد. در بازار نزولی نیز پس از کسر هزینه‌های معاملاتی، بازده مدل شبکه عصبی با بازده روشهای شاخص قدرت نسبی، شاخص نرخ تغییر، میانگین متحرک همگرا-واگرا و شاخص نوسان نگار تصادفی، تفاوت معناداری ندارد اما از بازده روش خرید و نگهداری، بیشتر و از بازده روش میانگین‌های متحرک، کمتر است.

#### جدول ۱۱. مقایسات زوجی بین بازده روش شبکه عصبی با سایر روشها در دوره اول در حالت پس از کسر هزینه‌ها

روش $i$	روش $j$	تفاوت میانگین ( $i - j$ )	خطای استاندارد	عدد معناداری	۹۵٪ فاصله اطمینان برای تفاوت میانگین	
					حد بالا	حد پایین
<i>FNN</i>	<i>BH</i>	-۸/۳۴۲	۱۴/۲۳۳	۰/۵۶۰	۲۰/۲۶۱	-۳۶/۹۴۶
	<i>MA</i>	۰/۲۸۴	۹/۰۶۴	۰/۹۷۵	۱۸/۴۹۸	-۱۷/۹۳۰
	<i>RSI</i>	-۲۳/۷۳۸(*)	۱۱/۴۹۸	۰/۰۰۰	۱۰۳/۸۴۳	۵۷/۶۲۳
	<i>ROC</i>	۳۵/۸۰۲(*)	۱۱/۳۰۴	۰/۰۰۳	۵۸/۵۱۸	۱۳/۰۸۶
	<i>SO</i>	۸/۷۱۸	۱۳/۵۸۶	۰/۵۲۴	۳۶/۳۰	-۱۸/۵۸۴
	<i>MACD</i>	۴۵/۶۷۶(*)	۱۰/۲۹۷	۰/۰۰۰	۶۶/۳۶۹	۲۴/۹۸۳

مواردی که با ستاره علامت خورده است در سطح ۵٪ معنادار بوده است.

#### جدول ۱۲. مقایسات زوجی بین بازده روش شبکه عصبی با سایر روشها در دوره دوم در حالت پس از کسر هزینه‌ها

روش $i$	روش $j$	تفاوت میانگین ( $i - j$ )	خطای استاندارد	عدد معناداری	۹۵٪ فاصله اطمینان برای تفاوت میانگین	
					حد بالا	حد پایین
<i>FNN</i>	<i>BH</i>	۱۷/۷۴۴ (*)	۳/۶۰۶	۰/۰۰۰	۲۴/۹۹۱	۱۰/۴۹۷
	<i>MA</i>	-۲۳/۷۵۲ (*)	۴/۰۲۶	۰/۰۰۰	-۱۵/۶۶۱	-۳۱/۸۴۳
	<i>RSI</i>	۴/۳۵۴	۳/۸۱۱	۰/۲۷۰	۱۱/۹۱۲	-۳/۴۰۴
	<i>ROC</i>	-۱/۳۴۸	۲/۸۰۹	۰/۶۳۳	۴/۲۹۷	-۶/۹۹۳
	<i>SO</i>	۵/۸۸۶	۳/۴۳۷	۰/۰۹۳	۱۲/۷۹۳	-۱/۰۲۱
	<i>MACD</i>	۴/۳۹۴	۳/۴۸۳	۰/۲۱۳	۱۱/۳۹۴	-۲/۶۰۶

مواردی که با ستاره علامت خورده است در سطح ۵٪ معنادار بوده است.

## ۵- نتیجه گیری

در این پژوهش سعی گردید تا قابلیت شبکه‌های عصبی مصنوعی در پیش‌بینی روند کوتاه‌مدت قیمت سهام در بورس اوراق بهادار تهران با استفاده از شاخصهای تکنیکی مورد بررسی قرار گیرد. به طور کلی نتایج بیانگر آن است که شبکه‌های عصبی مصنوعی از قابلیت پیش‌بینی علائم تغییر جهت روند کوتاه‌مدت قیمت سهام در بازار اوراق بهادار تهران چه در بازار صعودی و چه در بازار نزولی برخوردار می‌باشند.

بدون در نظر گرفتن هزینه‌های معاملاتی، بازده حاصل از معاملات صورت گرفته بر اساس این علائم چه در بازار صعودی و چه در بازار نزولی از روش خرید و نگهداری و شاخصهای تکنیکی بیشتر است. با در نظر گرفتن هزینه‌های معاملاتی، در بازار صعودی، بازده حاصل از شبکه‌های عصبی مصنوعی، تفاوت معنی‌داری با بازده حاصل از روش خرید و نگهداری و شاخصهای میانگین متحرک و نوسان نگار تصادفی ندارد و در بازار نزولی از بازده حاصل از روش خرید و نگهداری، بیشتر و از بازده حاصل از میانگین متحرک، کمتر است و تفاوت معنی‌داری با بازده حاصل از سایر شاخصهای تکنیکی ندارد. لذا می‌توان گفت که این روش در هر شرایطی به روش خرید و نگهداری و در بازار صعودی به شاخصهای تکنیکی ارجحیت دارد. در بازار نزولی به استثنای میانگین‌های متحرک، تفاوتی با سایر شاخصهای تکنیکی ندارد.

به نظر می‌رسد که معاملات بسیار زیاد پیشنهاد شده توسط شبکه‌های عصبی، عامل اصلی کاهش بازده معاملاتی در حالت پس از کسر هزینه‌های معاملاتی می‌باشند. از سوی دیگر باید پذیرفت که سودهای معاملاتی بالا در صورتی کسب می‌شوند که تغییرات واقعی قیمت سهام، نوسان زیادی داشته باشند؛ در حالی که شرایط حاکم بر بازار اوراق بهادار تهران از جمله وجود حجم مینا و حد نوسان قیمت، نوسانات روزانه قیمت سهام را محدود می‌سازد. برای سرمایه‌گذاران به صرفه است که تنها هنگامی که عایدات حاصل از هزینه‌های معاملاتی بیشتر باشد، اقدام به معامله نمایند. بنابراین پیشنهاد می‌شود که در پژوهشهای بعدی از عواملی مانند فیلتر حداقل نوسان قیمت برای محدود ساختن معاملات استفاده شود. می‌توان به جای روند کوتاه‌مدت و نوسانات روزانه که با محدودیت‌های حجم مینا و حد نوسان قیمت مواجهند، روند بلندمدت سهام را بررسی نمود. همچنین پیشنهاد می‌شود ترکیب متغیرهای دیگری مانند اندازه شرکت، سهام شناور آزاد، حجم مینا، حد نوسان قیمت و برخی متغیرهای بنیادی با شاخصهای تکنیکی بررسی شوند.

## پیشنهادهای اجرایی

۱. با توجه به یافته‌های پژوهش در خصوص قابلیت شبکه‌های عصبی مصنوعی در پیش‌بینی روند

قیمت سهام، دست‌اندرکاران بورس اوراق بهادار کشور می‌توانند از این قابلیت در جهت کنترل بازار در زمان نوسانات شدید استفاده نمایند.

۲. پیشنهاد می‌شود شرکت‌های سرمایه‌گذاری برای خرید و فروش سهام پرتفوی جاری خود، یعنی آن بخش از مجموعه سرمایه‌گذاریهای شرکت که نقدشوندگی بیشتری دارد و هدف آن کسب منفعت سرمایه‌ای<sup>۱</sup> از راه خرید و فروش سهام می‌باشد، به جای استناد بر شایعات بازار و یا شاخصهای محض تکنیکی از این ابزار ارزشمند بهره‌گیرند.



## فهرست منابع

فلاح پور، سعید (۱۳۸۳) پیش‌بینی درماندگی مالی شرکتها (*Financial Distress*) با استفاده از شبکه‌های عصبی مصنوعی؛ پایان‌نامه کارشناسی ارشد، دانشگاه تهران.  
 محمدی، شاپور (۱۳۸۳) تحلیل تکنیکی در بورس اوراق بهادار تهران؛ فصلنامه تحقیقات مالی، سال ششم، شماره ۱۷.

- Achelis, S.B. (1995) *Technical Analysis from A to Z: Covers Every Trading Tool from the Absolute Breadth Index to the Zig Zag*; Chicago, IL: Probus Publisher.
- Austin, M., C. Looney & J. Zhuo (1997) Security Market Timing Using Neural Network Models; *New Review of Applied Expert Systems*, 3:3-14.
- Barberis, N., A. Sheleifer & R. Vishny (1998) A Model for Investor Sentiment; *Journal of Financial Economics*, 49: 307-343.
- Brown, S.J., W.N. Goetzmann & A. Kumar (1998) The Dow Theory: William Peter Hamilton's Track Record Reconsidered; *Journal of Finance*, 53: 1311-1333.
- Burrell, P. R. & B. O. Folarin (1997) The Impact of Neural Networks in Finance; *Neural Computing & Applications*, 6: 193-200.
- Chandra, K.C.C. & D.M. Reeb (1999) Neural Networks in Market Efficiency Context; *American Business Review*, 17: 39-44.
- Chenoweth, T. & Z. Obradovic (1996) Embedding Technical Analysis into Neural Networks Based Trading Systems; *Applied Artificial Intelligence*, 10: 523-541.
- Cogger, K.O., P.D. Koch & D.M. Lander (1997) A Neural Network Approach to Forecasting Volatile International Equity Markets; *Advances in Financial Economics*, 3: 117-157.
- Cybenko, G. (1989) Approximation by Superpositions of a Sigmoidal Function; *Mathematics of Control, Signals and Systems*, 2: 303-314.
- Darrat, A.F. & M. Zhong (2000) On Testing the Random Walk Hypothesis: A Model-Comparison Approach; *The Financial Review*, 35: 105-124.
- Desai, V. S. & R. Bharati (1998) A Comparison of Linear Regression and Neural Network Methods for Predicting Excess Returns on Large Stocks; *Annals of Operations Research* 78: 127-163.
- Dropsy, V. (1996) Do Macroeconomic Factors Help in Predicting International Equity Risk Premia? Testing the out-of-sample Accuracy of Linear and Nonlinear Forecasts; *Journal of Applied Business Research*, 12: 120-133.

- Fama, Eugene F. (1970) Efficient Capital Markets: A Review of Theory and Empirical Work; *The Journal of Finance*, Vol. 25, 383-417.
- Fernandez-Rodriguez, F., C. Gonzalez-Martel & S. Sosvilla-Rivero (2000) On The Profitability of Technical Trading Rules Based on Artificial Neural Networks: Evidence from the Madrid Stock Market; *Economic Letters*, 69: 89-94.
- Gencay, R. & T. Stengos (1998) Moving Averages Rules, Volume and the Predictability of Security Returns with Feed-Forward Networks; *Journal of Forecasting*, 17: 401-414.
- Halliday, R. (2004) Equity Trend Prediction with Neural Networks; *Res. Lett. Inf. Math. Sci.*, Vol.6, pp 15-29.
- Kim, K.J. & I. Han (2000) Genetic Algorithms Approach to Feature Discretization in Artificial Neural Networks for the Prediction of Stock Price Index; *Expert System with Application*, 19, 125-132.
- Kuo, R.J. (1998) A Decision Support System for the Stock Market through Integrating of Fuzzy Neural Networks and Fuzzy Delphi; *Applied Artificial Intelligence*, 12:501-520.
- Lam, K. & K.C. Lam (2000) Forecasting for the Generation of Trading Signals in Financial Markets; *Journal of Forecasting*, No.19, pp 39-52.
- Leung, M.T., H. Daouk & A.S. Chen (2000) Forecasting Stock Indices: A Comparison of Classification and Level Estimation Models; *International Journal of Forecasting*, 16:173-190.
- Liu, N.K. & K.K. Lee (1997) An Intelligent Business Advisor System for Stock Investment; *Expert Systems*, 14: 129-139.
- Lo, Andrew W., Harry Mamaysky & Jiang Wang (2000) Foundation of Technical Analysis: Computational Algorithms, Statistical Inference, and Empirical Implementation; *Journal of Finance*, Vol. 55, No.4, 1705-1765.
- Longo, J.M. & M.S. Long (1997) Using Neural Networks to Differentiate Between Winner and Loser Stocks; *Journal of Financial Statement Analysis*, 2: 5-15.
- Mizuno, H., M. Kosaka & H. Yajima (1998) *Application of Neural Network to Technical Analysis of Stock Market Prediction*; Department of Information System Engineering, Faculty of Engineering, Japan: Osaka University.
- Motiwalla, L. & M. Wahab (2000) Predictable Variation and Profitable Trading of US Equities: A Trading Simulation Using Neural Networks; *Computer & Operations Research*, 27:1111-1129.

- Murphy, John J. (1999) *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*; New York Institute of Finance.
- Pesaran, M.H. & A. Timmermann (1995) Predictability of Stock Returns: Robustness and Economic Significance; *Journal of Finance*, 50: 1201-1227.
- Plummer, T. (1989) *Forecasting Financial Markets: The Truth Behind Technical Analysis*, UK: London.
- Podding, T. & Rehkugler (1996) A World of Integrated Financial Markets Using Artificial Neural Networks; *Neurocomputing*, 10: 251-273.
- Pring, Martin J. (1998) *Introduction to Technical Analysis*; Mc Grow Hill.
- Qi, M. & G.S. Maddala (1999) Economic Factors and The Stock Market: A New Perspective; *Journal of Forecasting*, 18: 151-166.
- Qi, M. (1999) Nonlinear Predictability of Stock Returns Using Financial and Economic Variables; *Journal of Business & Economic Statistics*, 17:419-429.
- Quah, T. & B. Srinivasan (1999) Improving Returns on Stock Investment Through Neural Network Selection; *Expert Systems with Applications*, 17:295-301.
- Saad, E.W., D.V. Prokhorov & D.C. Wunsch (1998) Comparative Study of Stock Trend Prediction Using Time Delay, Recurrent and Probabilistic Neural Networks; *IEEE Transactions on Neural Networks*, 9: 1456-1470.
- Schwager, J.D. (1995) *Fundamental Analysis*; New York: John Wiley & Sons.
- Swales, G.S. & Y. Yoon (1992) Applying Neural Networks to Investment Analysis; *Financial Analysts Journal*, 48: 78-80.
- Thawornwong, S., D. Enke & C. Dagli (2003) Neural Networks as a Decision Maker for Stock Trading: A Technical Analysis Approach; *International Journal of Smart Engineering System Design*, 5: 313-325.
- Tsaih, Ray, Yenshan Hsu & Charles C. Lai (1998) Forecasting S&P500 Stock Index Futures with a Hybrid AI System; *Decision Support Systems*, 23, 161-174.
- Vellido, A., P.J.G. Lisboa, and J. Vaughan (1999) Neural Networks in Business: A Survey of Application (1992-1998); *Expert Systems with Applications*, 17:51-70.
- Wong, R. K. & P.N. Ng (1994) A Hybrid Approach for Automated Trading Systems; *Proceeding of the IEEE Australian and New Zealand Conference on Intelligent Information Systems*, PP. 278-282.
- Zemke, Stefan (1999) Nonlinear Index Prediction, *Physica A*, Vol. 269.