

**کاربرد شبکه های عصبی مصنوعی در
زمان بندی معاملات سهام: با رویکرد تحلیل تکنیکی**

**A Survey on Artificial Neural Networks Application
in Stock Market Timing: A Technical Analysis Approach**

دکتر رضا تهرانی*
Reza Tehrani (Ph.D)

وحید عباسیون**
Vahid Abbasion

* استادیار دانشکده مدیریت دانشگاه تهران
** کارشناس ارشد مدیریت مالی

نویسنده عهده دار مکاتبات: وحید عباسیون

نشانی پستی: تهران - پل کریمخان - ابتدای خیابان میرزای شیرازی - پلاک ۵ - شرکت مدیریت سرمایه
گذاری سینا

تلفن: ۸۸۸۲۶۰۵۴

تلفن همراه: ۰۹۱۲۲۰۶۹۵۵۵

نمابر: ۸۸۸۲۴۶۶۴

پست الکترونیکی: V_Abbasion@Yahoo.com

کاربرد شبکه های عصبی مصنوعی در زمان بندی معاملات سهام:

با رویکرد تحلیل تکنیکی

چکیده

زمانبندی معاملات سهام مسأله‌ای بسیار مهم و مشکل به دلیل پیچیدگی بازار سهام 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 فرآیندهای غیر خطی 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 کوتاه مدت 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.

واژه های کلیدی: زمان بندی معاملات سهام، شبکه های عصبی مصنوعی، تحلیل تکنیکی،

شاخصهای تکنیکی، روش خرید و نگهداری

طبقه بندی JEL: C45, G14, G11, G10

(1) مقدمه

تعیین زمان مناسب انجام معاملات سهام که مستلزم پیش بینی روند یا پیش بینی قیمت سهام می باشد، موضوعی مهم در مدیریت سرمایه گذاری است که توجه محققان را برای سالهای مدیری جلب نموده است. دلیل این امر، منافع مهم مالی است که در نتیجه یک مدل پیش بینی موفق حاصل می شود. با وجود این، پیش بینی قیمت یا بازده سهام کار ساده ای نیست زیرا عوامل بازاری بسیاری دخالت دارند و روابط ساختاری پیچیده آنها به وضوح قابل تعیین نیست.

تحلیل تکنیکی و تحلیل بنیادی دو روش متداول برای پیش بینی رفتار آتی سهام می باشند. تحلیل بنیادی بر روی نیروهای اقتصادی عرضه و تقاضا که موجب تغییر قیمت سهام می شوند، تمرکز می کند. عوامل مرتبط (مانند شرکت، صنعت و شرایط اقتصادی) که بر قیمت سهام تأثیر می گذارند جهت تعیین ارزش ذاتی سهام بررسی می شوند (Schwager, 1995). از سوی دیگر تحلیل تکنیکی داده های تاریخی مربوط به حرکات قیمت و حجم معاملات سهام را با استفاده از نمودارها و شاخصها به عنوان ابزار اولیه برای پیش بینی حرکات آتی قیمت مطالعه می کند (Murphy, 1999). سرمایه گذاران مبنای مطالعات خود را بر این فرض قرار می دهند که الگوهای تاریخی قیمت های سهام در آینده تکرار می شوند و بنابراین از این الگوها می توان به منظور اهداف پیش بینی استفاده کرد. انگیزه ماورای تحلیل تکنیکی، توانایی آن در شناسایی تغییرات روندها در مراحل اولیه و حفظ یک سرمایه گذاری تا زمانی که علائم حاکی از تغییرات روند می باشد، است (Pring, 1998). هدف هر دو روش پیش بینی حرکات سهام از دیدگاههای مختلف است. تحلیل بنیادی دلایل حرکت بازار را بررسی می کند در حالی که تحلیل تکنیکی اثر آن را بررسی می کند.

تحلیل تکنیکی سابقه طولانی در پیش بینی 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 می کند «قیمتها همیشه اطلاعات موجود را به طور کامل منعکس می کنند». این نظریه نشان می دهد که هر تلاشی برای کسب سود با بهره گیری 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 می یابد (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 به طور گسترده به عنوان یکی از گزینه های مهم تحلیلی در بین متخصصان مالی و شرکتهای کارگزاری پذیرفته شده است (Achelis, 1995). در واقع سرمایه گذارهای عمده بندرت بدون بهره گیری از این ابزار فنی انجام می شوند زیرا بسیاری از محققان این ایده را مطرح کرده اند که بازارها ممکن است به طور کامل کارا نباشند و قیمتها ممکن است تحت تأثیر احساسات انسانی¹ قرار گیرند (Barberis et al, 1998). به نظر می رسد که تحلیل تکنیکی یک ابزار بینابینی² باشد زیرا یک ترکیب نسبی را از رویدادهای انسانی، سیاسی و اقتصادی ارائه می دهد. از لحاظ نظری، تحلیل تکنیکی تلاش می کند تا روند قیمتهای سهم را با استفاده از داده های قیمتها و حجم معاملات گذشته پیش بینی 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 نوسانات³ پوشیده شده اند و از سهمی به سهم دیگر متفاوتند. بنابراین برای سرمایه گذاران مشکل است تا با استفاده از این روش به طور مستمر و صحیح قیمتهای آتی را پیش بینی کنند.

علاوه بر استفاده گسترده از تحلیل تکنیکی، سرمایه گذاران امروزه به الگوریتمهای و روشهای کامپیوتری بسیار وابسته شده اند تا بتوانند از طیف وسیعتری از گزینه های سرمایه گذاری بهره مند شوند. شبکه های عصبی مصنوعی⁴ یکی از فن آوری هایی هستند که بیشترین جذابیت را در این حوزه مالی ایجاد نموده اند. آنها روش جالبی را ارائه می دهند که به لحاظ نظری می تواند هر تابع پیوسته غیر خطی را در یک دامنه محدود با هر درجه صحت طراحی شده، تخمین بزنند (Cybenko, 1989). بدعت شبکه های عصبی در توانایی مدلسازی فرآیندهای غیر خطی بدون فرض اولیه در مورد ماهیت فرآیند ایجاد نهفته است. این امر در سرمایه گذاری اوراق بهادار و سایر حوزه های مالی که مفروضات زیاد و اطلاعات کمی در مورد ماهیت فرآیندهای تعیین قیمتهای دارایی وجود دارد، مفید است (Burrell & Folarin, 1997) و ارزشمندی آن در حوزه تحلیل تکنیکی باید آزمون شود. شبکه های عصبی همچنین از لحاظ انواع ساختار، الگوریتمهای یادگیری و رویه های

¹ Human Sentiments

² Compromising

³ Noises

⁴ Artificial Neural Networks

اعتبار انعطاف پذیرند.

در این پژوهش قصد داریم تا از مزایای شبکه‌های عصبی برای ارتقای اثربخشی شاخصهای تحلیل تکنیکی در پیش بینی 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 پیشخور⁵ (*FNN*) در ارائه پیش بینی مؤثر علائم روند آتی سهام بررسی می‌شود.

بدین منظور نمونه ای مشتمل بر ۵۰ سهم مختلف که در بورس اوراق بهادار تهران معامله می‌شوند انتخاب و علائم معاملاتی ایجاد شده توسط مدل شبکه عصبی مصنوعی بررسی می‌شود. در نهایت بازده حاصل از مدل شبکه‌های عصبی مصنوعی با بازده حاصل از هر یک از شاخصهای تکنیکی و بازده حاصل از روش خرید و نگهداری⁶ 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*؛ *Leung et al, 1996* و *Qi, 1999*؛ *Podding & Rehkogler, 1996*؛ *Motiwalla & Wahab, 2000*؛ *Qi & Maddala, 1999*). افزایش علاقه در به کارگیری شبکه‌های عصبی مصنوعی به دلیل این حقیقت است که غیرخطی بودن بوسیله 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 (*Long, 1997*؛ *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

⁵ Feed-Forward Neural Network

⁶ Buy and Hold

استفاده شده است (Cogger et al, 1997; Chandra & Reeb, 1999; Brown et al, 1998; Saad et al, 1998; Fernandez et al, 2000; Darrat & Zhong, 2000; Zemke, 1999).

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

گنکی و استنگوس (۱۹۹۸) استفاده از دو قاعده معاملاتی ساده یعنی میانگینهای متحرک و شکسته‌های طیف معاملات^۷ 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.

تسای و همکاران (۱۹۹۸) بر مبنای قواعد نوسان نگار تصادفی^۸ و شاخص قدرت نسبی^۹ با استفاده از شبکه‌های عصبی به پیش‌بینی جهت‌های روزانه تغییر قیمت در شاخص قراردادهای آتی S&P500 پرداختند.

میزونو و همکاران (۱۹۹۸) از شاخصهای میانگین متحرک، انحراف قیمت‌ها از میانگین متحرک، خط روانشناسی^{۱۰} و شاخص قدرت نسبی جهت پیش‌بینی روند و ایجاد علائم خرید و فروش برای شاخص قیمت بازار سهام توکیو (TOPIX) استفاده نمودند.

کیم و هان (۲۰۰۰) ارزشهای چندین شاخص پیوسته را (مانند شاخص قدرت نسبی، نوسان نگار تصادفی، $R\%$ ویلیام^{۱۱}، مومنتوم^{۱۲} و کمودیتی کانال^{۱۳}) 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.

لم و لم (۲۰۰۰) 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^{۱۴} را در هنگ کنگ پیش‌بینی کنند.

گرچه در بیشتر مطالعات فوق یافته‌های ارزشمندی به دست آمده است، اما در هر یک از آنها تنها

⁷ Trading range breaks

⁸ Stochastic Oscillator

⁹ Relative Strength Index

¹⁰ Psychological Line

¹¹ William R%

¹² Momentum

¹³ Commodity Channel

¹⁴ Hang Seng

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 یک یا چند شرکت محدود در بازارهای مورد بررسی بوده است. هدف از این تحقیق بررسی سودمندی شبکه‌های عصبی پیشخور در ارتقای اثربخشی پنج شاخص مشهور و متداول تحلیل تکنیکی در پیش بینی علائم روند سهام با استفاده از نمونه ای مشتمل بر پنجاه شرکت مورد معامله در بورس اوراق بهادار تهران می‌باشد.

۳ روش تحقیق

هدف اصلی این پژوهش بررسی توانایی شبکه‌های عصبی در پیش‌بینی تغییرات کوتاه مدت 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^{۱۵} 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. بنابر این 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.

¹⁵ Root Mean Square Error (RMSE)

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 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 می‌باشد 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 پر رنگ 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^{۱۶} از ۱۳۸۲/۰۸/۰۱ تا ۱۳۸۳/۰۷/۳۰ و شامل ۲۴۰ روز معاملاتی می‌باشد و دوره دوم بیانگر یک بازار نزولی^{۱۷} 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.

¹⁶ Bull Market

¹⁷ 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
26	سرمایه گذاری ملت	406	196	157
27	معدن روی	406	195	202
28	موتون	400	165	204
29	چینی ایران	400	180	177
30	لوله و ماشین سازی	399	214	181
31	پارس دارو	396	218	221
32	نفت تهران	390	211	227
33	کربن ایران	388	188	153
34	داروپخش	387	151	125
35	کیمیاوارو	386	212	172
36	سیمان شرق	385	191	142
37	سرمایه گذاری پارس نوشه	384	182	163
38	صنعتی پشه‌پر	383	223	155
39	سرمایه گذاری بانک ملی	379	206	148
40	صنعتی نیرومحرکه	376	167	182
41	داروسازی اسوه	371	157	136
42	سرمایه گذاری بیمه	363	225	230
43	زامیاد	358	203	211
44	پتروشیمی اصفهان	358	183	172
45	داروسازی کوثر	352	185	164
46	لاستیکی سپند	348	145	188
47	سایپا آئین	345	216	136
48	سیمان کرمان	341	166	135
49	سیمان سیاهان	332	196	170
50	ساختن اصفهان	303	215	148

ردیف	نام شرکت	تعداد روزهای معاملاتی		
		دوره آموزش	دوره اول	دوره دوم
1	گروه بهمن	477	225	180
2	سرمایه گذاری ملی	474	215	208
3	شهید ایران	471	209	182
4	توسعه صنایع پشه‌پر	470	201	185
5	سرمایه گذاری البرز	465	205	144
6	ایران خودرو	465	202	212
7	سرمایه گذاری پتروشیمی	455	201	204
8	سرمایه گذاری سپه	443	203	195
9	لیپتات پاک	438	165	162
10	معدن و فلزات	437	212	183
11	پتروشیمی خارک	436	226	199
12	پتروشیمی آبادان	435	207	176
13	کف	434	213	185
14	سرمایه گذاری صنعت و	433	207	209
15	سرمایه گذاری ساختمان	431	205	188
16	سرمایه گذاری رنا	430	197	197
17	سرمایه گذاری غدیر	428	185	217
18	سایپا	424	199	215
19	رازک	422	198	184
20	سوما آفرین	420	158	189
21	سیمان فارس و خوزستان	419	180	190
22	مچورسازان	414	228	201
23	داروسازی جابر ابن حیان	413	218	188
24	سیمان تهران	412	197	197
25	پتروشیمی اراک	412	207	212

کل بورس	505	240	244	989
۶۰٪ تعداد روزهای معاملاتی	303	144	146	593

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). نمودار شاخص کل بورس اوراق بهادار تهران در دوره پژوهش

۱-۳) فرضیه های 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 (۰.۵۰) 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:

$$\begin{aligned} H_0 : p \leq p_0 & \text{ صحت پیش‌بینی مورد حداکثر ۵۰ درصد است.} \\ H_1 : p > p_0 & \text{ صحت پیش‌بینی مورد نظر بیشتر از ۵۰ درصد است.} \end{aligned}$$

فرضیه ۱:

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

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

فرضیه ۳: بین بازده روشهای معاملاتی $MACD$, SO , ROC , MA , RSI خرید و نگهداری و شبکه عصبی پیش‌خور (FNN) پس از کسر هزینه های معاملاتی تفاوت معنی‌داری وجود دارد.

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

برای آزمون فرضیه های ۲ و ۳ از آزمون طرح اندازه های تکراری^{۱۸} و مقایسه های پس از تجربه^{۱۹} 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 پنج شاخص میانگین متحرک ساده (MA) ۱۰ روزه، قدرت نسبی (RSI) ۱۴ روزه، نرخ

¹⁸ Repeated Measures Design

¹⁹ Post Hoc Comparisons

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 استفاده می‌شود. روش محاسبه و چگونگی ایجاد علائم خرید و فروش این شاخصها در جدول (۲) خلاصه شده است. شرح کامل این پنج شاخص در این منابع موجود می‌باشد (محمدی، ۱۳۸۳؛ Murphy, 1999 و 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 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
ROC	$ROC_n = \left(\frac{P_n}{P_0} - 1 \right) * 100$	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 دوره ای) استوکاستیک %K است	هنگامی که خط %K در زیر سطح ۲۰ خط %D را از پایین به بالا قطع می‌کند	هنگامی که خط %K در زیر سطح ۲۰ خط %D را از پایین به بالا قطع می‌کند
MACD	$MACD = EMA_{(\alpha=0.15)} - EMA_{(\alpha=0.075)}$ میانگین متحرک نمایی ۹ دوره ای $SL = MACD$	هنگامی که MACD خط علامت ^{۲۰} (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 دوره ای در روز t ؛ C ، H و L به ترتیب قیمت‌های پایانی، حداکثر و حداقل در n دوره، $EMA_{(\alpha=0.15)}$ میانگین متحرک نمایی ۱۲ روزه قیمت پایانی و $EMA_{(\alpha=0.075)}$ میانگین متحرک نمایی ۲۶ روزه قیمت پایانی می‌باشند.

با توجه به پنج شاخص تکنیکی، کلاً هشت 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 -

²⁰ Signal Line

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 ، $CP_t - MA_t$ ، $MACD_t - SL_t$ ، $\%K_t - \%D_t$ به عنوان متغیرهای درون‌داد شبکه عصبی مصنوعی تعریف می‌گردند.

۳-۳ طرح ریزی شبکه عصبی

نظریه محاسبات شبکه عصبی روش‌های جالبی را ارائه می‌کند که از مغز انسان و سیستم عصبی 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 برون‌دادهای 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 به طور 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 خورنده می‌شوند. 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^{۲۱} 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^{۲۲} به گونه‌ای تعدیل می‌گردند که میانگین مجذور خطا بین پیش‌بینی شبکه و هدف واقعی حداقل گردد.


²¹ Backpropagation Algorithm

²² Biases

تعریف پارامترهای شبکه یک فرایند تجربی است. در بیشتر موارد یک روش ابتکاری است که در آن شبکه های چندین شبکه با نرخهای یادگیری گوناگون، تعداد متفاوت لایه های پنهان، مومنتومهای مختلف و توابع تبدیل گوناگون آموزش می بینند و سپس بهترین شبکه انتخاب می-شود (فلاح پور، ۱۳۸۳). در این تحقیق از تابع تبدیل زیگموئیدی برای ایجاد یک توزیع یکنواخت روی ارزشهای ورودی استفاده می گردد که به صورت رابطه زیر می باشد:

$$f(NE T) = (1 + e^{-NE T})^{-1} \quad \text{رابطه (۱)}$$

که 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 می شود زیرا در مسائل مربوط به پیش بینی و دسته بندی در پژوهشهای مالی بسیار موفق بوده است (Swales, 1992). بر این اساس شبکه عصبی پیش خور از سه لایه شامل لایه ورودی، لایه پنهان و لایه خروجی تشکیل می گردد. هر یک از شش متغیر ورودی به یک نرون ورودی مجزا در لایه ورودی خورنده می شود. از آنجا که دو طبقه وجود دارد (علامت خرید و فروش) از دو نرون خروجی در لایه خروجی استفاده می شود که نمایانگر طبقه های مختلف پیش بینی جهت (خرید یا فروش) می باشند. تعیین تعداد نرونهای لایه پنهان کار ساده ای نیست و بیشتر با استفاده از سعی و خطا به دست می آید، به گونه ای که عملکرد کلی شبکه بهبود یابد. البته در این زمینه یکسری قواعد سرانگشتی مانند $n/2$ ، n ، $n+1$ و $2n+1$ نرون (n نشان دهنده 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 می شود. در مورد نرخ یادگیری باید گفت که اگر نرخ یادگیری کوچک باشد یادگیری به کندی انجام می شود و اگر بزرگ انتخاب شود باعث نوسان زیاد و ناپایداری سیستم می گردد. نرخ یادگیری مورد استفاده در این پژوهش با توجه به دو مسأله مذکور و پس از آزمون و خطا، ۰,۰۱ انتخاب گردید. تعداد تکرارها به نرخ یادگیری و هدف مورد نظر در ارتباط با تابع عملکرد بستگی دارد. با نرخ یادگیری ۰,۰۱، تعداد تکرارها برای شبکه ها حداکثر برابر با ۱۰۰۰۰ در نظر گرفته شد. بر اساس موارد مذکور شمای کلی شبکه عصبی پیشخور در این پژوهش به صورت شکل (۲) می باشد.



شکل (۲). شمای کلی شبکه عصبی پیش خور مورد استفاده در پژوهش

۳-۴) شبیه سازی 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 بوسیله 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 ۰,۷۵٪ ارزش سهام خریداری شده و در هنگام فروش معادل ۱,۲۵٪ 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:

$$\hat{y} = +1 \text{ اگر خرید}$$

$$\hat{y} = -1 \text{ اگر فروش}$$

که در آن \hat{y} جهت پیش‌بینی شده قیمت سهم در روز آتی بوسیله شبکه‌های عصبی می‌باشد. (+1) نشان دهنده پیش‌بینی جهت رو به بالا و (-1) نشان دهنده پیش‌بینی جهت رو به پایین است. فرآیند 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
1	72.83	57.89	64.00	64.51	84.88	74.30
2	69.57	71.00	70.23	65.79	92.05	86.77
3	81.55	71.70	76.56	73.44	65.52	68.33
4	65.14	69.57	67.16	56.92	84.87	75.00
5	74.51	40.78	57.56	52.08	69.15	63.38
6	80.00	57.94	68.31	68.93	77.57	73.33
7	19.82	85.39	48.29	47.14	80.31	68.53
8	75.70	48.96	63.05	63.95	78.50	72.02
9	88.41	48.96	65.45	71.43	57.14	63.98
10	80.87	59.80	71.23	59.70	84.35	74.46
11	78.52	63.64	73.45	62.07	87.86	80.30
12	76.36	56.70	67.15	70.37	46.81	57.71
13	72.32	81.19	76.53	64.20	80.39	73.22
14	82.14	56.84	70.53	75.64	89.92	84.54
15	82.26	49.38	69.27	78.31	41.75	58.06
16	70.00	65.25	66.67	75.32	79.83	78.06
17	78.43	46.99	64.32	69.50	70.67	69.90
18	72.41	86.52	82.41	68.18	93.24	85.51
19	83.21	60.66	72.26	68.12	71.93	70.49
20	65.22	77.53	72.15	57.31	76.19	67.91
21	76.06	68.81	71.67	32.81	93.60	73.02
22	66.67	76.30	72.37	63.54	58.25	60.80
23	73.73	73.00	73.39	50.00	89.74	74.87
24	75.90	76.32	76.14	81.03	93.43	89.74
25	56.99	77.19	68.11	58.46	84.93	76.78
26	68.27	68.48	68.37	58.46	69.23	64.74
27	45.05	77.38	59.00	54.94	57.79	56.50
28	56.16	66.30	61.82	38.30	73.15	56.93
29	50.00	92.25	83.33	57.62	89.74	78.97
30	72.41	64.57	67.76	37.97	88.12	66.11
31	73.39	77.06	75.23	67.79	79.41	73.18
32	76.53	82.30	79.62	73.68	89.93	84.44
33	64.63	67.92	66.48	55.22	78.82	68.42
34	68.11	91.46	80.79	50.00	91.89	75.00
35	59.65	67.35	63.20	52.83	87.29	76.61
36	78.13	62.11	70.16	40.38	68.54	58.15
37	83.33	62.79	73.62	72.09	89.74	85.00
38	80.34	73.58	77.13	72.06	89.53	81.82
39	67.89	75.26	71.36	57.14	88.31	73.46
40	60.47	88.71	81.44	44.59	76.42	63.33
41	64.84	71.21	67.52	56.63	75.00	63.70
42	83.96	43.70	62.67	46.15	79.47	68.12
43	69.88	77.50	74.38	64.64	80.00	72.73
44	67.35	70.59	68.85	63.89	66.67	65.49
45	77.41	67.47	70.81	68.18	87.50	79.62
46	65.79	62.86	64.38	44.29	76.72	64.52
47	59.74	72.66	68.06	44.90	82.56	68.89
48	80.95	62.20	71.69	54.90	66.27	61.94
49	82.14	76.79	79.08	50.00	90.60	78.11
50	89.58	54.93	78.14	76.39	61.33	68.71
میانگین	۷۱.۲۹	۶۸.۱۱	۷۰.۲۶	۶۰.۰۴	۷۸.۳۴	۷۱.۵۱

جدول (۴) آماره‌های آزمون را برای پیش‌بینی مدل شبکه عصبی پیش‌خور (FNN) در دوره‌های

اول و دوم به همراه مقادیر بحرانی در سطح ۰.۰۵٪ اطمینان نشان می‌دهد. آماره آزمون به صورت زیر

تعریف می‌شود:

$$Z = \frac{\bar{P} - P_0}{\sqrt{\frac{P_0(1-P_0)}{n}}} = \frac{\bar{P} - 0.5}{\sqrt{\frac{0.5(1-0.5)}{50}}}$$

جدول (۴). آماره‌های آزمون محاسبه شده برای پیش بینی مدل در هر یک از دوره ها

دوره مورد آزمون	\bar{P}	P_0	n	مقدار بحرانی	آماره Z
دوره اول	٪۷۰٫۲۶	٪۵۰	50	1.96	2.865
دوره دوم	٪۷۱٫۵۱	٪۵۰	50	1.96	3.041

همانگونه که ملاحظه می‌شود آماره آزمون در همه موارد در سطح معناداری ۵٪، در سمت راست مقدار بحرانی می‌باشد 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 بوسیله 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 دوره های اول و دوم نشان می‌دهد. $r_{i,1}$ میانگین بازده حاصل از روش i در حالت پیش از کسر هزینه های معاملاتی و $r_{i,2}$ میانگین بازده حاصل از روش i در حالت پس از کسر هزینه های 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	103.23	136.65	99.96	134.49
MA	۸	105.69	85.63	91.33	99.96
RSI	۲	15.56	28.92	10.88	91.33
ROC	۹	66.94	82.11	55.82	10.88
SO	۱۴	104.81	123.06	82.90	55.82
MACD	۶	53.62	64.62	45.94	82.90
FNN	۴۵	180.18	133.30	91.62	45.94

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

روش	میانگین تعداد معاملات	میانگین $r_{i,1}$	انحراف معیار $r_{i,1}$	میانگین $r_{i,2}$	انحراف معیار $r_{i,2}$
BH	2	-12.20	26.42	-13.59	26.00
MA	6	34.70	30.48	27.89	28.43
RSI	3	.85	24.02	-.10	23.36
ROC	8	11.87	18.71	5.49	16.77
SO	12	8.40	28.22	-1.74	24.98
MACD	6	3.87	23.97	-.24	23.35
FNN	40	43.62	33.68	4.14	22.86

همانگونه که ملاحظه می‌شود 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 می‌رسد که تعداد زیاد معاملات انجام شده بوسیله این روش با افزایش هزینه‌های معاملاتی موجب کاهش بازده در حالت پس از کسر هزینه‌های معاملاتی گردیده است.

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

جدول (۷). آزمون اثرات درون موردی^{۲۳} در دوره اول

منبع تغییرات (پراش)	نام آزمون مربوطه	پیش از کسر هزینه های معاملاتی			پس از کسر هزینه های معاملاتی		
		درجه آزادی	آماره F	عدد معناداری (Sig)	درجه آزادی	آماره F	عدد معناداری (Sig)
روش	<i>Sphericity Assumed</i>	7	30.788	.000	7	13.303	.000
	<i>Greenhouse-Geisser</i>	3.387	30.788	.000	3.024	13.303	.000
	<i>Huynh-Feldt</i>	3.669	30.788	.000	3.245	13.303	.000
	<i>Lower-bound</i>	1.000	30.788	.000	1.000	13.303	.001
خطای (روش)	<i>Sphericity Assumed</i>	343			343		
	<i>Greenhouse-Geisser</i>	165.981			148.163		
	<i>Huynh-Feldt</i>	179.798			158.998		
	<i>Lower-bound</i>	49.000			49.000		

جدول (۸). آزمون اثرات درون موردی در دوره دوم

منبع تغییرات (پراش)	نام آزمون مربوطه	پیش از کسر هزینه های معاملاتی			پس از کسر هزینه های معاملاتی		
		درجه آزادی	آماره F	عدد معناداری (Sig)	درجه آزادی	آماره F	عدد معناداری (Sig)
روش	<i>Sphericity Assumed</i>	7	58.939	.000	7	22.430	.000
	<i>Greenhouse-Geisser</i>	3.853	58.939	.000	4.548	22.430	.000
	<i>Huynh-Feldt</i>	4.222	58.939	.000	5.071	22.430	.000
	<i>Lower-bound</i>	1.000	58.939	.000	1.000	22.430	.000
خطای (روش)	<i>Sphericity Assumed</i>	343			343		
	<i>Greenhouse-Geisser</i>	188.774			222.868		
	<i>Huynh-Feldt</i>	206.893			248.481		
	<i>Lower-bound</i>	49.000			49.000		

همانگونه که ملاحظه می‌گردد عدد معناداری آزمون اثرات درون موردی در چهار آزمون در نظر گرفته شده برابر با صفر و کوچکتر از سطح معناداری ۵٪ می‌باشد. بنابراین در فرضیه های ۲ و ۳،

²³ Within Subjects

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 حالت پیش‌ازکسر 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 مثبت بودن حد بالا و پایین نشان دهنده بیشتر بودن 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 بالا	حد پایین
FNN	BH	76.950(*)	15.326	.000	107.748	46.152
	MA	74.492(*)	13.620	.000	101.862	47.122
	RSI	164.622(*)	18.344	.000	201.486	127.758
	ROC	113.246(*)	16.014	.000	145.428	81.064
	SO	75.376(*)	17.546	.000	110.636	40.116
	MACD	126.560(*)	16.314	.000	159.344	93.776

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 بالا	حد پایین
FNN	BH	4.492	.000	46.802	4.492	64.855
	MA	4.689	.063	-.504	4.689	18.341
	RSI	4.546	.000	33.631	4.546	51.901
	ROC	4.002	.000	23.710	4.002	39.795
	SO	4.174	.000	26.833	4.174	43.608
	MACD	4.573	.000	30.563	4.573	48.942

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 می شود در بازار صعودی پس از کسر هزینه های 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 هزینه های 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
FNN	BH	-8.342	14.233	.560	-36.946	20.261
	MA	.284	9.064	.975	-17.930	18.498
	RSI	80.738(*)	11.498	.000	57.633	103.843
	ROC	35.802(*)	11.304	.003	13.086	58.518
	SO	8.718	13.586	.524	-18.584	36.020
	MACD	45.676(*)	10.297	.000	24.983	66.369

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
FNN	BH	17.744(*)	3.606	.000	10.497	24.991
	MA	-23.752(*)	4.026	.000	-31.843	-15.661
	RSI	4.254	3.811	.270	-3.404	11.912
	ROC	-1.348	2.809	.633	-6.993	4.297
	SO	5.886	3.437	.093	-1.021	12.793
	MACD	4.394	3.483	.213	-2.606	11.394

۵) نتیجه گیری

در این پژوهش سعی گردید تا قابلیت شبکههای عصبی مصنوعی در پیش بینی روند کوتاه مدت قیمت سهام در بورس اوراق بهادار تهران با استفاده از شاخصهای تکنیکی مورد بررسی قرار گیرد. بطور کلی نتایج بیانگر آن است که شبکههای عصبی مصنوعی از قابلیت پیش بینی علائم تغییر جهت روند کوتاه مدت 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 مبنای 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 کوتاه مدت و نوسانات روزانه که با محدودیتهای حجم مبنای و حد نوسان قیمت مواجهند، روند بلند مدت سهام را بررسی نمود. همچنین پیشنهاد می‌شود ترکیب متغیرهای دیگری مانند اندازه شرکت، سهام شناور آزاد، حجم مبنای، 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 پیش بینی روند قیمت سهام، دست اندرکاران 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 نقد شوندگی بیشتری دارد و هدف آن

کسب منفعت سرمایه ای^{۲۴} از راه خرید و فروش سهام می باشد، به جای استناد بر شایعات بازار و یا شاخصهای محض تکنیکی از این ابزار ارزشمند بهره گیرند.

منابع و مأخذ

۱. فلاح پور، سعید (۱۳۸۳). *پیش بینی درماندگی مالی شرکتها (Financial Distress) با استفاده از شبکه های عصبی مصنوعی*. پایان نامه کارشناسی ارشد، دانشگاه تهران
۲. محمدی، شاپور (۱۳۸۳). تحلیل تکنیکی در بورس اوراق بهادار تهران، *فصلنامه تحقیقات مالی*، سال ششم، شماره ۱۷
3. 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.
4. Austin, M., C. Looney & J. Zhuo (1997) Security Market Timing Using Neural Network Models. *New Review of Applied Expert Systems* 3:3-14
5. Barberis, N., A. Sheleifer & R. Vishny (1998). A Model for Investor sentiment. *Journal of Financial Economics* 49: 307-343
6. 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
7. Burrell, P. R. & B. O. Folarin (1997). The Impact of Neural Networks in Finance. *Neural Computing & Applications* 6: 193-200
8. Chandra, K.C.C. & D.M. Reeb (1999). Neural Networks in Market Efficiency Context. *American Business Review* 17: 39-44
9. Chenoweth, T. & Z. Obradovic (1996). Embedding Technical Analysis into Neural Networks Based Trading Systems. *Applied Artificial Intelligence* 10: 523-541
10. 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
11. Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal function. *Mathematics of Control, Signals and Systems* 2: 303-314
12. Darrat, A.F. & M. Zhong (2000) On Testing The Random Walk Hypothesis: A Model-Comparison Approach. *The Financial Review* 35: 105-124
13. 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
14. 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
15. Fama, Eugene F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work, *The Journal of Finance*, Vol. 25, 383-417
16. 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
17. 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
18. Halliday, R. (2004). Equity Trend Prediction with Neural Networks, *Res. Lett. Inf. Math. Sci.*, Vol 6, pp 15-29
19. 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
20. 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
21. Lam, K. & K.C. Lam (2000). Forecasting for the Generation of Trading Signals in Financial Markets, *Journal of Forecasting*, No.19, pp 39-52
22. 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

²⁴ Capital Gain

23. Liu, N.K. & K.K. Lee (1997). An Intelligent Business Advisor System for Stock Investment. *Expert Systems* 14: 129-139
24. 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
25. 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
26. 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, Osaka University, Japan
27. 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
28. Murphy, John J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*, New York Institute of Finance, New York.
29. Pesaran, M.H. & A. Timmermann (1995). Predictability of Stock Returns: Robustness and Economic Significance. *Journal of Finance* 50: 1201-1227
30. Plummer, T (1989). *Forecasting Financial Markets: The Truth Behind Technical Analysis*, London, UK.
31. Podding, T. & Rehkugler (1996). A world of Integrated Financial Markets Using Artificial Neural Networks. *Neurocomputing* 10: 251-273
32. Pring, Martin J. (1998). *Introduction to Technical Analysis*. Mc Grow Hill.
33. Qi, M. (1999) Nonlinear Predictability of Stock Returns Using Financial and Economic Variables. *Journal of Business & Economic Statistics* 17:419-429
34. Qi, M. & G.S. Maddala (1999). Economic Factors and The Stock Market: A New Perspective. *Journal of Forecasting* 18: 151-166
35. Quah, T. & B. Srinivasan (1999) Improving Returns on Stock Investment Through Neural Network Selection. *Expert Systems with Applications* 17:295-301
36. 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
37. Schwager, J.D. (1995). *Fundamental Analysis*. New York, NY: John Wiley & Sons.
38. Swales, G.S. & Y. Yoon (1992). Applying Neural Networks to Investment Analysis. *Financial Analysts Journal* 48: 78-80
39. 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
40. 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
41. 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
42. 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.
43. Zemke, Stefan (1999). Nonlinear Index Prediction, *Physica A*, Volume 269

A Survey on Artificial Neural Networks Application in Stock Market Timing: A Technical Analysis Approach

Reza Tehrani (Ph.D)

Vahid Abbasion

Abstract:

Determining stock market timing is a very difficult problem because of the complexity of stock market. The important subject is stock trend or stock price prediction which is the initial object in technical analysis. However, it is not a simple task, since many market factors are involved and their structural relationships are too complex to be clearly extracted. It seems that it is useful to apply more advanced tools and algorithms such as artificial neural networks (ANN) to model nonlinear processes which determine stock price and trend.

The objective of this study is to explore the abilities of ANN to enhance the effectiveness of technical analysis indicators for predicting stock trend signals.

The results, based on a sample including 50 companies in Tehran stock exchange (TSE), indicate that ANN is capable to predict the direction of short term movements in stock trend. Assuming the transaction costs, there is not any significant difference among the returns gained from ANN method, buy and hold strategy and the most profitable technical indicators for bull market. However, the ANN model yields to higher returns compared to buy and hold strategy for bear market, but the trend indicators (moving averages) achieve the highest returns.

Key words: *Stock Market Timing, Artificial Neural Networks (ANN), Technical Analysis, Technical Indicators*

JEL Classification: *C45, G10, G11, G14*