

مقایسه عملکرد پرتفوی‌های مبتنی بر پیش‌بینی قیمت و پیش‌بینی تغییر جهت قیمت با استفاده از شبکه عصبی

مصطفی هادی دخت

کارشناس حسابداری دانشگاه تهران

چکیده

در پژوهش پیش رو عملکرد پرتفوی‌های تشکیل شده از رویکرد پیش‌بینی قیمت و پیش‌بینی تغییر جهت قیمت با یکدیگر به جهت شناسایی رویکرد مناسب‌تر برای سرمایه‌گذاری، مقایسه می‌شود. بدین منظور در ابتدا با استفاده از متغیرهای تکنیکال، بنیادی و اقتصاد کلان شبکه‌هایی برای هر رویکرد با وقفه‌های مختلف و تعداد نرون‌های لایه مخفی متفاوت تشکیل می‌شود. سپس شبکه‌ای که کمترین مقدار خطا را برای رویکرد پیش‌بینی قیمت و بیشترین مقدار POCID را برای رویکرد پیش‌بینی تغییر جهت دارد به عنوان شبکه بهینه شناخته می‌شود. در نهایت با پیش‌بینی ۲۲ دوره، پرتفوی‌هایی بر مبنای هر دو رویکرد تشکیل می‌گردد. در ادامه برای هر پرتفوی بازده‌ای هم به صورت مرکب و به صورت ساده محاسبه خواهد شد. بعد از انجام دادن آزمون مستقل بودن نتایج دو رویکرد عمل مقایسه انجام می‌شود تا نتیجه‌گیری صورت پذیرد. نتیجه پژوهش صورت گرفته حاکی از تایید فرضیه و عملکرد بهتر رویکرد پیش‌بینی تغییر جهت در مقایسه با پیش‌بینی مقدار قیمت می‌باشد.

واژه‌های کلیدی: پیش‌بینی تغییر جهت قیمت، پیش‌بینی قیمت، شبکه عصبی، بورس اوراق بهادار تهران

۱- مقدمه

عدم آگاهی در مورد آینده یکی از چالش‌هایی می‌باشد که همواره انسان با آن مواجه بوده است. وقایع محتمل که ممکن است به وقوع بپیوندند هر کدام می‌تواند تبعات منفی یا مثبتی برای انسان به همراه داشته باشد. برای اینکه بتوان کمی از اثرات ناشی از وقایع آتی که از بروز و رخداد آنها آگاهی نیست را تحت کنترل در آورد، نیاز به پیش بینی رخدادهای محتمل می‌باشد تا بتوان با آمادگی پیدا کردن از آینده، از تبعات آن بهره جست. توام با این نیاز وجود راهکاری با قابلیت اتکا بیشتر پدیده‌ای غیر قابل انکار می‌باشد که بدین منظور باید از بین تمام راهکارهای موجود، گزینه‌ای که از سایر گزینه‌ها بهتر است انتخاب گردد.

در دنیای مالی و بخصوص بازار سرمایه، شخص سرمایه‌گذار همواره با عدم آگاهی نسبت به آینده و ریسک‌ها و فرصت‌های بسیاری دست به گریبان است که برای پوشش این ریسک‌ها و یا بهره‌مندی از این فرصت‌های پیش رو نیازمند آمادگی نسبت به آنها می‌باشد. این آمادگی تا حدودی با پیش‌بینی آینده امکان‌پذیر می‌شود که در دنیای مالی این عمل یکی از بحث برانگیزترین مباحث می‌باشد.

از جمله دستاوردهایی که این پژوهش در پی خواهد داشت می‌توان به مشخص کردن روشی مناسب و کارا برای پیش بینی آینده وضعیت بازار اشاره نمود. با معرفی رویکرد برتر جهت استفاده از آن در انتخاب فرصت‌های سرمایه‌گذاری، در واقع فرآیند دشوار تصمیم‌گیری در سرمایه‌گذاری به نحوی تسهیل خواهد شد. همچنین با مشخص شدن رویکرد مناسب جهت انتخاب سهام به منظور سرمایه‌گذاری و نتیجه‌بخش بودن آن، فرآیند جذب سرمایه به دلیل اعتماد بیشتر سرمایه‌گذاران، به نحوی راحت‌تر و بیشتر خواهد شد. در این پژوهش سعی شده است تا با استفاده از اطلاعات ورودی مختلف که در سه گروه متفاوت دسته بندی می‌شوند، همه ابعاد تاثیر گذار بر روی وضعیت بازار را مد نظر قرار داد تا بتوان نتیجه‌ای با درجه اطمینان معقول کسب نمود. علت استفاده از این طیف گسترده از اطلاعات ورودی، در نظر گرفتن همه جانبه عوامل تاثیر گذار بر روی قیمت سهام شرکت‌های مورد بررسی می‌باشد تا بتوان خطای برآزش را به حداقل رسانید.

مبانی نظری پیشینه پژوهش

نظریه‌های متفاوتی در خصوص ارزیابی و پیش‌بینی بورس در بازارهای سازمان یافته مطرح شده است. در اوایل قرن بیستم، گروهی از متخصصان صاحب تجربه در ارزیابی اوراق بهادار اعتقاد راسخ بر این امر داشتند که می‌توان از طریق مطالعه و تجزیه و تحلیل روند تاریخی تغییرات قیمت سهام، تصویری را برای پیش‌بینی قیمت آینده سهام ارائه نمود. مطالعات علمی‌تر با تاکید بر شناسایی دقیق رفتار قیمت سهام، گرایش به سمت مدل‌های ارزشیابی قیمت سهام را به وجود آورد. در ابتدا نظریه گام‌های تصادفی^۱ به عنوان یک شروع در تعیین رفتار قیمت توسط فاما مطرح شد (فاما^۲، ۱۹۸۸). سپس ویژگی‌ها و ساختار بازار سرمایه مورد توجه قرار گرفت که نتیجه‌ی آن مطالعات و بررسی‌ها منجر به فرضیه بازار کارای سرمایه گردید. این فرضیه به دلیل ترکیب خاص آن، مورد توجه محافل عمومی قرار گرفت. در بازار کارای سرمایه، اعتقاد بر این است که قیمت سهام انعکاسی از اطلاعات جاری مربوط به آن سهم است و تغییرات قیمت دارای الگوی خاص قابل پیش‌بینی نیست (کاپلند، وستون، ۲۰۰۵). نظریه‌های مطرح شده تا سال ۱۹۸۰ میلادی به خوبی تعیین کننده رفتار قیمت سهام در بازار بودند تا اینکه تحولات بازار سهام نیویورک در سال ۱۹۸۷ میلادی، اعتبار فرضیه بازار کارای سرمایه و مدل‌هایی نظیر تصادفی بودن قیمت‌ها را به شدت زیر سوال برد (منجمی، ۱۳۸۸). در دهه‌ی ۱۹۹۰ میلادی و بعد از آن، بیشتر توجه متخصصان به یک رفتار آشوب-گرانه همراه با نظم معطوف شد و تلاش در جهت طراحی مدل‌های غیرخطی به منظور پیش‌بینی قیمت سهام اهمیت روزافزونی پیدا کرد.

^۱ . Random Walks^۲ Fama

بنابراین، از جمله تکنیک‌هایی که اهمیت بالایی یافتند، سیستم‌های هوشمند بودند؛ زیرا با فرض خطی بودن ساختار بازار، به آسانی می‌توان بسیاری از مدل‌ها را طراحی نمود. با این وجود، بسیار سخت است که بتوان رفتار مجموعه‌های پیچیده‌ای نظیر بازار سرمایه در یک مجموعه‌ی اقتصادی مدرن را به طور کامل در یک مجموعه معادلات ساده و خطی نشان داد. مزیت عمده‌ی سیستم هوشمند نظیر شبکه‌های عصبی مصنوعی، در مدل‌سازی و پیش‌بینی مجموعه‌های نامنظم و غیر خطی است (منجمی، ۱۳۸۸).

کاربرد شبکه‌های عصبی در اقتصاد و اقتصاد سنجی از اواخر دهه ۸۰ میلادی با مطالعه وایت^۳ در بازارهای مالی و شرکت IBM آغاز شد. البته هدف اصلی مطالعه به جای پیش‌بینی، آزمون فرضیه کارایی بازار بود. هر چند که نتایج این مطالعه نشان داد که الگوریتم‌های حداقل سازی استفاده شده در اقتصاد سنجی بهتر از الگوریتم‌های شبکه عصبی است؛ ولی به دلیل ساده بودن شبکه‌ی مورد استفاده، نتایج این مطالعه توسط محققان مختلف به مجادله گرفته شد. پس از وایت مطالعات متعددی در زمینه کاربرد شبکه عصبی مصنوعی با موفقیت انجام شد؛ اما موفقیت شبکه‌های عصبی در حوزه مالی، توجه اقتصاد کلان و اقتصاد سنجی را به خود جلب نمود و استفاده از شبکه‌های عصبی در پیش‌بینی از دهه ۹۰ آغاز شد (پاکدین امیری، علیرضا، ۱۳۸۸).

لونگ، داک و چن^۴ در پژوهشی که برای مقایسه بین مدل‌های طبقه بندی و تخمین زننده مقدار قیمت انجام دادند به این نتیجه رسیدند که روش‌های طبقه بندی بازده بیشتری برای سرمایه گذار به وجود می‌آورند تا روش‌های تخمین زننده مقدار. آنها با استفاده داده های ماهانه بین سال‌های ۱۹۶۷ تا ۱۹۹۵ که شامل نرخ بهره کوتاه مدت، نرخ بهره بلند مدت، وقفه‌های شاخص، شاخص قیمت مصرف کننده و مقدار تولیدات صنعتی به عنوان متغیر ورودی و بازده شاخص و احتمال تغییر جهت روند شاخص به عنوان متغیر خروجی بودند، کار خود را به صورت موازی برای انجام مقایسه شروع کردند. در ابتدا با به کارگیری روش‌های تجزیه و تحلیل تفکیک خطی^۵، مدل‌های دو انتخابی شامل رگرسیون لاجیت و پروبیت^۶ و شبکه‌های عصبی احتمالاتی^۷ اقدام به پیش‌بینی جهت شاخص‌های US S&P 500، UK FTSE 100، Japan Nikkei 225 کردند. سپس با استفاده از هموار نمایی تطبیقی^۸، اتورگرسیون برداری با به بروز رسانی فیلتر کالمن^۹، تابع انتقال چند متغیره^{۱۰} و شبکه عصبی چندلایه پیشخور مقدار بازده شاخص‌های مذکور را محاسبه کردند. در نهایت با در نظر گرفتن تعداد پیش‌بینی‌های برون نمونه‌ای مدل‌های اجرا شده و همچنین بازده مازادی که از مبادله شاخص‌ها به دست می‌آمد، برتری مدل‌های پیش‌بینی کننده جهت از نظر تعداد پیش‌بینی‌های صحیح و ایجاد بازده مازاد مشخص شد. همچنین در این پژوهش برتری مدل‌های مبتنی بر شبکه عصبی چه در پیش‌بینی مقداری قیمت و چه در پیش‌بینی تغییر جهت نسبت به سایر مدل‌ها، مشخص شد.

در پژوهشی دیگر که عملکرد بین دو مدل شبکه عصبی و مدل ماشین بردار پشتیبان (SVM)^{۱۱} در پیش‌بینی جهت قیمت روزانه شاخص ISE National 100 در استانبول مورد بررسی قرار گرفت، برتری عملکرد مدل شبکه عصبی نسبت به مدل ماشین بردار پشتیبان منتج شد. کارا و همکاران^{۱۲} ده اندیکاتور تکنیکال را به عنوان متغیر ورودی انتخاب کردند. پس از آن داده‌های قیمت مربوط به سال‌های ۱۹۹۷ تا ۲۰۰۷ را با تفکیک کردن به کاهشی یا افزایشی به عنوان متغیر خروجی در نظر گرفتند و با تخصیص دادن عدد ۱ به هر بار افزایش و عدد ۰ به هر بار کاهش، متغیر خروجی یا هدف را تعیین نمودند. در

³ White, 1988

⁴ Leung, M. T., Daouk, H., & Chen, A. S., 2000

⁵ Linear discriminant analysis

⁶ Binary choice models: logit and probit

⁷ Probabilistic neural networks

⁸ Adaptive exponential smoothing

⁹ Vector autoregression with Kalman filter updating

¹⁰ Multivariate transfer function

¹¹ Support vector machine

¹² Kara, Boyacioglu & Baykan, 2011

نهایت عملکرد شبکه عصبی در پیش‌بینی جهت قیمت با ۷۵.۷۴٪ موفقیت و عملکرد ماشین بردار پشتیبان با ۷۱.۵۲٪ موفقیت نتیجه این پژوهش انجام شده بود که مهر تاییدی بر برتری شبکه عصبی نسبت به مدل ماشین بردار پشتیبان می‌باشد. الیورا و همکاران با پژوهشی که بر روی سهام یک شرکت نفتی برزلی انجام دادند، بهترین متغیرهای ورودی و همچنین بهترین وقفه‌های آنها را بدست آوردن. آنها با ارائه پرسشنامه‌ای به خبرگان بازار سرمایه نظر آنها را در مورد متغیرهای مورد استفاده برای تصمیم‌گیری در خصوص قیمت سهام جویا شدند و در نهایت چهل و شش متغیر تاثیر گذار در تصمیم‌گیری، نتیجه این پژوهش شد. سپس با بررسی همبستگی متغیرهای ارائه شده با قیمت شرکت PETR4 بیست و شش متغیر به عنوان متغیر ورودی به مدل شبکه عصبی پیشخور انتخاب شد که در سه زمره تکنیکال، بنیادین و اقتصاد کلان دسته‌بندی می‌شدند. در نهایت با بررسی وقفه‌های مختلف متغیرها و بهینه کردن معیار عملکرد POCID، متوجه شدند که سه وقفه قبلی متغیرهای ورودی بیشترین تاثیر را در پیش‌بینی جهت قیمت سهام مذکور دارد. در این پژوهش سعی شده است با بهره‌گیری از پژوهش‌های صورت گرفته مذکور عملکرد پیش‌بینی تغییر جهت در مقایسه با پیش‌بینی مقدار قیمت بررسی شود که فرض این پژوهش عملکرد بهتر پیش‌بینی تغییر جهت می‌باشد. علت استفاده از شبکه عصبی به عنوان مدل پیش‌بینی کننده، موفقیت این در مقایسه با سایر مدل‌ها در پیش‌بینی می‌باشد.

فرضیه

فرضیه پژوهش پیش رو این است که در مدل‌های پیش‌بینی کننده، تغییر جهت قیمت قابلیت تخمین بیشتری در مقایسه با مقدار قیمت دارد.

روش‌شناسی پژوهش

جامعه آماری مورد بررسی بورس اوراق بهادار تهران می‌باشد که شاخص ۳۰ شرکت بزرگ به عنوان نمونه مورد آزمایش قرار می‌گیرد. علت انتخاب نمونه مذکور، شفافیت بیشتر شرکت‌های لیست شده در این شاخص می‌باشد. در ابتدا پژوهش پیش رو با تواتر فصلی متغیرهای ورودی انجام پذیرفت که عملکرد شبکه عصبی حاکی از ناتوانی در پیش‌بینی بود. سپس با تغییر تواتر فصلی به تواتر روزانه بار دیگر مدل شبکه اجرا شد که این بار نتایج قابل اتکا بود. برای محاسبه متغیرهای تکنیکال ورودی ابتدا از نرم افزار TSE Client قیمت‌های تعدیل شده استخراج شده و سپس با استفاده از نرم افزار Excel اندیکاتورهای محاسبه گردیده‌اند. متغیرهای بنیادین استفاده شده در پژوهش از نرم افزار ره‌آورد نوین اخذ شده‌اند که پس از شکست آزمایش در تواتر فصلی از مقادیر فصلی آنها در تواتر روزانه استفاده شده است. متغیرهای اقتصادی با مراجعه به اداره بررسی‌های اقتصادی و اداره حساب‌های ملی بانک مرکزی اخذ شده‌اند. قیمت نفت اوپک از سایت quandl.com اخذ گردیده است.

به منظور یکنواختی و توانایی اتکا به اطلاعات شرکت‌ها دو شرط زیر برای استخراج نمادهای مورد آزمایش لحاظ شده است:

- شرکت‌های مورد بررسی از گروه واسطه مالی نباشند

- پایان سال مالی شرکت‌های مورد بررسی منتهی به ۲۹ اسفند باشد

پس از لحاظ نمودن ۲ شرط فوق ۱۴ نماد از ۳۰ نماد لیست شده در سال ۸۶ (سال شکل‌گیری شاخص ۳۰ شرکت بزرگ) استخراج شدند که خلاصه‌ای از وضعیت آنها در جدول ذیل نمایش داده شده است:

جدول ۱. آماره‌های توصیفی نمونه

نماد	تعداد روزهای معامله شده	میانگین حجم معامله شده	بیشترین قیمت (ریال)	کمترین قیمت (ریال)	میانگین تعداد معاملات
خازین	۲,۹۶۴	۵۵۹,۸۹۱	۲,۳۴۴	۳۸	۶۲
کچینی	۲,۶۷۶	۱۷۰,۳۷۱	۱۰,۷۵۴	۱۵۵	۴۶
دالبر	۲,۲۵۴	۸۵,۹۳۸	۷,۵۸۹	۱۵۴	۲۹
دکوثر	۲,۹۳۶	۱۷۲,۲۶۱	۵,۷۶۴	۴۱۰	۴۳
خاور	۲,۹۴۷	۵,۰۵۵,۴۸۱	۱,۹۴۹	۱۷۳	۳۰۵
فاسمین	۲,۶۷۶	۱,۰۴۸,۲۷۳	۳,۹۸۰	۶۸	۲۱۶
شلعاب	۲,۱۴۳	۹۱,۳۰۱	۵,۶۵۹	۱۷۱	۲۷
شاراک	۳,۰۲۳	۶۹۷,۰۳۰	۱۴,۵۱۳	۱,۰۷۸	۱۱۴
شخارک	۲,۸۲۹	۵۱۹,۷۶۹	۱۳,۲۶۷	۲۱۱	۹۸
کروی	۲,۸۸۸	۱,۵۴۸,۳۷۶	۱۱,۰۵۵	۹۰۱	۲۳۱
خساپا	۳,۱۱۰	۷,۵۵۲,۳۹۶	۲,۳۲۰	۱۱۹	۵۳۵
ستران	۳,۰۰۰	۵۰۰,۴۰۵	۱۰,۶۷۷	۴۱۹	۸۳
بترانس	۲,۵۶۷	۱,۳۰۶,۷۱۱	۸,۴۸۳	۳۲۷	۱۸۸
شتولی	۱,۷۹۷	۱۴۴,۳۳۱	۴,۹۹۱	۸۹۰	۱۷


بازه مورد نظر برای محاسبه آماره‌های جدول ۱-۴ سالهای ۱۳۸۰ تا فصل سوم ۱۳۹۴ می‌باشد. لازم به ذکر است که در محاسبه میانگین تعداد معاملات، روزهای بدون معامله از مخرج کسر حذف شده است. پس از استخراج نمادهای فوق، مقادیر متغیرهای ورودی شبکه برای هر نماد محاسبه شده است. مقادیر ورودی به سه دسته تقسیم می‌شوند که شامل موارد زیر می‌باشند:

- متغیرهای بنیادی
- متغیرهای تکنیکال
- متغیرهای اقتصاد کلان

جدول ۲. متغیرهای ورودی

تکنیکال	بنیادی	اقتصاد کلان
MACD	ROE	CPI
Relative strength index	درصد حاشیه سود خالص	GNP
Stochastic index	نسبت جاری	نرخ دلار
OBV index	نسبت آنی	نرخ نفت خام
Moving averages	نسبت بدهی	نرخ سکه
Bollinger bands	P/E	
Momentum	EPS	
Williams' percent range (%R)	سود عملیاتی	
	سود تقسیمی	

پس از آماده سازی متغیرهای ورودی و خروجی شبکه عصبی حال نوبت به پیش‌بینی و تجزیه و تحلیل نتایج می‌رسد که بدین منظور ابتدا به پیش‌بینی قیمت نمادهای مورد بررسی و سپس به پیش‌بینی تغییر جهت آنها پرداخته خواهد شد. در شکل‌های زیر شمای کلی از الگوریتم کدهای نوشته شده برای پیش‌بینی قیمت و پیش‌بینی تغییر جهت قیمت در نرم افزار MATLAB را مشاهده می‌کنید.



شکل ۱. الگوریتم کد رویکرد پیش‌بینی قیمت



شکل ۲. الگوریتم کد رویکرد پیش‌بینی تغییر جهت قیمت

لازم به توضیح است که POCID اولین بار توسط فردی به نام نتو^{۱۳} در سال ۲۰۱۰ ارائه گردید که این تابع در واقع میزان موفقیت شبکه در پیش‌بینی تغییر جهت را مورد سنجش قرار می‌دهد (نتو، ۲۰۱۰). نحوه محاسبه POCID بدین صورت است:

$$POICD = \frac{100 \sum_{i=1}^N D_i}{N}$$

Where:

$$D_i = \begin{cases} 1 & \text{if } (T_{t+1} - T_t)(O_{t+1} - O_t) > 0 \\ 0 & \text{Otherwise} \end{cases}$$

در آخر با مقایسه مقادیر بدست آمده از تابع عملکرد MSE و POICD مقدار مینیمم آن‌ها یافت می‌شود تا با تشکیل دو حلقه مقادیر لایه مخفی بهینه و مقدار وقفه بهینه شناسایی گردد. جدول‌های زیر مقادیر بهینه یافت شده توام با مقادیر تابع عملکرد بهینه را نمایش می‌دهند:

جدول ۳. مقادیر بهینه پیش‌بینی مقدار قیمت


نماد	تابع عملکرد بهینه در یادگیری	تعداد نرون بهینه	وقفه بهینه	تابع عملکرد مقادیر پیش‌بینی شده
بترانس	7927	14	1	13,006
دالبر	2456	14	2	174,128
دکوثر	6846	12	1	1,067
فاسمین	1549	18	1	1,907
کچینی	11916	17	5	17,968
کروی	13937	13	1	10,561
خارک	18531	10	5	67,605
خاور	1059	3	1	470
خاذین	87	17	1	81
خسپا	2246	8	3	409
ستران	18082	10	1	1,635
شازند	40000	14	1	3,103
شلعاب	3252	15	1	2,676
شتولی	7611	16	1	5,486

¹³ Neto

جدول ۴. مقادیر بهینه رویکرد پیش‌بینی تغییر جهت


نماد	تابع عملکرد بهینه در یادگیری	تعداد نرون بهینه	وقفه بهینه	تابع عملکرد دوره پیش‌بینی
بترانس	۵۵%	20	1	50%
دالبر	۶۳%	10	1	45%
دکوثر	۵۷%	12	2	55%
فاسمین	۴۳%	8	2	45%
کچینی	۵۴%	19	5	50%
کروی	۶۷%	16	1	45%
خارک	42%	16	1	64%
خاور	۶۶%	14	2	50%
خاذین	۵۵%	19	3	45%
خساپا	40%	9	1	59%
ستران	53%	19	2	63%
شازند	48%	16	3	42%
شلعاب	36%	12	1	64%
شتولی	۶۹%	14	5	43%

پس از یافتن شبکه بهینه، در ادامه با آن شبکه‌ها ۲۲ دوره آینده پیش‌بینی می‌گردد و سپس از نمادهایی که در پیش‌بینی با نتیجه مطلوبی همراه بودند پرتفویی تشکیل می‌شود تا بدین وسیله عملکرد آنها با یکدیگر مورد مقایسه قرار بگیرد. لازم به ذکر است که پرتفوی‌های مذکور با فرض وزن مساوی دارایی‌ها تشکیل شده‌اند و روزانه نمادهای داخل آنها بازبینی می‌شود. مدل مورد استفاده در این پژوهش مدل شبکه عصبی مصنوعی از نوع پیشخور می‌باشد که نحوه عملکرد آن در شکل زیر نمایش داده شده است:




شکل ۳. نحوه عملکرد شبکه‌های عصبی

در واقع شبکه عصبی با مشاهده متغیرهای ورودی و مقایسه آنها با مقادیر متغیرهای خروجی عمل یادگیری را انجام می‌دهد. در عمل یادگیری، اتفاقی که می‌افتد این است که شبکه با تغییر وزن مقادیر ورودی سعی در پیدا کردن وزن بهینه دارد که این عمل توسط الگوریتم یادگیری انجام می‌شود. یک شبکه عصبی مصنوعی متشکل از نرون‌های مصنوعی می‌باشد که در واقع همان عناصر پردازشی هستند. در شکل زیر به طور ساده یک عنصر پردازشی نمایش داده شده است.



شکل ۴. پردازش اطلاعات در یک نرون مصنوعی

X ها ورودی‌های شبکه، w ها وزن‌های اختصاص یافته به هر ورودی، f تابع انتقال و y ها مقادیر خروجی نرون می‌باشند. تابع مجموع، مجموع موزون ورودی‌ها را محاسبه می‌کند. رابطه بین سطح فعال شدن و برون داد با استفاده از تابع تبدیل توصیف می‌شود که دارای انواع مختلفی از جمله تانژانت هیپربولیک، سیگموئید، و ... می‌باشد. شبکه‌های پیشخور شبکه‌هایی هستند که ارتباط آنها یکطرفه می‌باشد و از هر نرون داده‌ها تنها به نرون بعدی انتقال می‌یابند اما در شبکه پسخور ارتباط دوطرفه است. پرسپترون چند لایه معماری از شبکه‌های عصبی مصنوعی می‌باشند که پیشخور بوده و پردازنده‌های شبکه به چند لایه مختلف تقسیم می‌شوند. در این شبکه‌ها لایه اول ورودی، لایه آخر خروجی و لایه‌های میانی، لایه‌های پنهان نامیده می‌شوند. این معماری را پرکاربردترین معماری شبکه‌های عصبی می‌توان نامید، شکل زیر نمای عمومی پرسپترون چند لایه را نشان می‌دهد:



شکل ۵. شبکه عصبی با یک لایه پنهان

الگوریتم یادگیری که در این پژوهش از آن استفاده شده است الگوریتم لونیبرگ مارکوات^{۱۴} می باشد. تعداد لایه های مخفی مورد استفاده در این شبکه یک لایه مخفی می باشد. همچنین تابع تبدیل لایه مخفی از نوع تانژانت هیپربولیک و تابع تبدیل لایه خروجی از نوع خط مستقیم می باشد.

تجزیه و تحلیل داده ها و آزمون فرضیه

در ادامه با تشکیل پرتفوی ها، عملکرد آنها با یکدیگر مقایسه شد تا بدین منظور رویکرد بهتر شناسایی شود. جدول زیر نتایج حاکی از این دو رویکرد را به ازای هر روز و دوره مورد بررسی نمایش می دهد.

جدول ۵. مقایسه بازده رویکردها

پیش بینی مقدار قیمت		پیش بینی تغییر جهت		شماره دوره
بازده ساده	بازده مرکب	بازده ساده	بازده مرکب	
0.14%	0.14%	-0.40%	-0.40%	۱
0.99%	1.13%	0.12%	-0.29%	۲
-0.61%	0.51%	0.49%	0.20%	۳
-0.42%	0.09%	-0.28%	-0.08%	۴
1.44%	1.53%	3.73%	3.71%	۵
-2.93%	-1.45%	-1.65%	2.21%	۶
0.12%	-1.33%	-0.57%	1.63%	۷
0.33%	-1.00%	0.37%	2.01%	۸
-0.09%	-1.09%	0.87%	2.91%	۹
0.41%	-0.69%	0.82%	3.76%	۱۰
-0.85%	-1.54%	2.17%	6.06%	۱۱
-0.25%	-1.78%	-0.05%	6.01%	۱۲
-0.42%	-2.20%	0.00%	6.01%	۱۳
0.37%	-1.83%	0.00%	6.01%	۱۴
-0.42%	-2.24%	0.00%	6.01%	۱۵
-0.17%	-2.41%	0.00%	6.01%	۱۶

¹⁴ Levenberg-Marquadt

۱۷	5.97%	-0.04%	-2.46%	-0.05%
۱۸	5.95%	-0.02%	-2.09%	0.38%
۱۹	7.27%	1.23%	-3.33%	-1.27%
۲۰	7.06%	-0.19%	-4.66%	-1.38%
۲۱	6.51%	-0.51%	-5.98%	-1.38%
میانگین بازده		0.31%	-0.29%	

به منظور بررسی قابل مقایسه بودن نتایج دو رویکرد آزمون معناداری انجام می‌شود تا استقلال نتایج دو رویکرد از یکدیگر بررسی شود. مراحل این آزمون به شرح ذیل می‌باشد.

در ابتدا شبکه‌هایی به منظور پیش‌بینی قیمت و پیش‌بینی تغییر جهت نمونه تشکیل می‌شود و پس از بهینه نمودن شبکه‌ها عمل پیش‌بینی صورت می‌گیرد. پس از اتخاذ روش برتر جهت پیش‌بینی تغییر جهت، قیمت و تغییر جهت قیمت برای ۲۲ دوره (معادل ۱ ماه کاری) پیش‌بینی می‌شود.

برای بررسی هم توضیعی داده‌های اخذ شده از پیش‌بینی با توزیع نرمال، از آزمون کولموگروف-اسمیرنوف استفاده گردید که با رد فرض صفر این آزمون، غیر نرمال بودن توزیع این داده‌ها تایید گردید. در ادامه با بررسی‌های صورت گرفته توسط روش‌های موجود نظیر تبدیل لگاریتمی و تبدیل کاکس-بکس امکان تبدیل توزیع نمونه‌ها به توزیع نرمال فراهم نگردید. در نهایت از آزمون ناپارامتریک متناظر با آزمون t زوجی که همان آزمون ویلکاکسون می‌باشد استفاده شد که نتایج حاکی از استقلال نتایج دو مدل بود. در ادامه لازم به ذکر است که فرضیه پژوهش که همان عملکرد بهتر پیش‌بینی تغییر جهت در مقایسه با پیش-بینی قیمت بود مورد تایید واقع شد. ($P\text{-value} = 0.0032$).

نتیجه‌گیری و بحث

در نهایت پس از بررسی هم توضیعی داده‌های اخذ شده از پرتفوی‌های روزانه، با مقایسه عملکرد دو رویکرد این نتیجه بدست می‌آید که عملکرد رویکرد پیش‌بینی تغییر جهت از رویکرد پیش‌بینی مقدار قیمت بهتر است. چراکه میانگین بازده روزانه رویکرد پیش‌بینی تغییر جهت معادل ۰.۳۱٪ و میانگین بازده روزانه رویکرد پیش‌بینی مقدار قیمت برابر با ۰.۲۹٪ می‌باشد. همچنین مقدار بازده مرکب کسب شده در دوره پیش‌بینی برای رویکرد پیش‌بینی مقدار قیمت معادل ۵.۹۸٪ و برای رویکرد پیش‌بینی تغییر جهت برابر با ۶.۵۱٪ می‌باشد که این پیام را مخابره می‌کند که پیش‌بینی تغییر جهت در طول دوره مورد بررسی از عملکرد بهتری برخوردار می‌باشد.

نتیجه این پژوهش به منزله پیشنهادی برای انتخاب رویکرد پیش‌بینی به سهامداران و سرمایه‌گذاران می‌باشد. همچنین در گرو عملیات مدلسازی این پژوهش به محققین توصیه می‌شود که در استفاده از مدل شبکه عصبی به تعداد خاصی از نرون‌های لایه مخفی بسنده نکنند و همچنین در انتخاب وقفه متغیرهای ورودی، بررسی وقفه‌های مختلف را چاشنی کار خود قرار دهند.

منابع

1. Jahankhani, A., Tabrizi, A. (1372). "Capital Market Efficiency Theory", *Financial Researches*, 1, 1, Tehran, 7-23
2. Raie, R., Chavoshi, Kazem., (1382). "Forcasting Stock Returns in Tehran Stock Exchange: Model of Artificial Neural Networks and Multivariate Model", *Financial Researches*, 5, 1, Tehran, 97-120
3. Pakdin Amiri, A., Pakdin Amiri, M., Pakdin Amiri, A., "Presenting Model of Stock Price Index with Neural Networks Approach (Case Study of Tehran Stock Exchange)", *Journal of Iran's Economic Essays*, 6, 11, Tehran, 83-108
4. Ghalibaf Asl, H., Masoumzade, N., (1388). "Prediction of stock price change probability by using logistic regression in Tehran Stock Exchange", *Journal of Iranian Accounting Association*, 1, 5, Tehran, 56-70
5. Monajemi, A., Abzari, M., Rayati Shavazi, A. (1388). "Modeling of Stock Price Forecasting in Stock Exchange Market, using Fuzzy Neural Networks and Genetic Algorithms", *Journal of Quantitative Economics*, 6, 4, 1-28
6. Ghezelbash, A., (1390). "Forecasting Changes in Stock Indexes and Gold Prices through Neural Networks", *Second National Conference on Soft Computing and Information Technology*
7. Gujarati, D. N., (2009). Basic econometrics, Abrishami, H., Boston, Mass: McGraw-Hill
8. Kiyani Mavi, R., Sayadi Nik, K. (2015). "Using different learning algorithms in the stock price prediction by using neural networks". *Journal of Development & Evolution Mnagement*, 1393(special issue). 75-81.
9. Menhaj, MB., (1393). The Basics of Neural Networks, Tehran, Amir Kabir University
10. Fama, E. (1970). Eefficient Capital Market: A Review of Theory and Empricial Work, *Journla of Finance*, 15, 383-417
11. Fama, E., & French K. (1988). "Permanent and Temporary Components of Stock Price" *Journal of Political Economy*, 96, 246-273
12. White, H. (1988). "Economic Prediction Using Neural Network: The Case of IBM Daily Stock Returns". *Proceeding of the IEEE International Confrence on Neural Network*
13. Refenes, A.N., (1995). "Neural Networks in the Capital Markets". *International Journal of Forecasting*, Vol. 11, Issue 4, p 602-603
14. Gately, E., (1996). "Neural Networks for Financial Forecasting". *Review of Economic Sciences*, Vol.6, P 161-176
15. Kaastra I. Boyd M., (1996). "Designing a neural network for forecasting financial and economic time series". *Neurocomputing*, Vol. 10, 215-236
16. Zhang, G., Hu, M. Y., Patuwo, B. E., Indro, D. C., (1999). "Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-validation Analysis". *European Journal of Operational Research*, Vol. 116, Issue 1, P 16-32

17. Leung, M. T., Daouk, H., & Chen, A. S., (2000). "Forecasting stock indices: a comparison of classification and level estimation models". *International Journal of Forecasting*, Vol. 16, Issue 2, P 173-190
18. Achelis, Steven B., (2000). *Technical Analysis A to Z*, MG Hill Education
19. Roh, T. H, (2007). "Forecasting the Volatility of Stock Price Index", *Expert System with Applications*, Vol. 33, no. 4, P 916-922
20. Demuth, H., Beale, M., & Hagan, M., (2008). *Neural network toolbox™ 6. User's guide*
21. Atsalakis, G. S., & Valavanis, K. P., (2009). "Surveying stock market forecasting techniques-Part II: Soft computing methods". *Expert Systems with Applications*, Vol. 36, No. 3, P 5932-5941
22. Mostafa, M. M., (2010). "Forecasting stock exchange movements using neural networks: Empirical evidence from Kuwait". *Expert systems with applications*, Vol. 37, Issue 9, P 6302-6309
23. Neto, M. C. A., Tavares, G., Alves, V. M., Cavalcanti, G. D., & Ren, T. I., (2010). "Improving financial time series prediction using exogenous series and neural networks committees. In Neural Networks (IJCNN)". *The 2010 International Joint Conference on IEEE*, P 1-8
24. Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). "Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange". *Expert systems with Applications*, Vol. 38, Issue 5, P 5311-5319
25. de Oliveira, F. A., Nobre, C. N., & Zárata, L. E., (2013). "Applying Artificial Neural Networks to prediction of stock price and improvement of the directional prediction index-Case study of PETR4, Petrobras". *Brazil. Expert Systems with Applications*, Vol. 40, Issue 18, P 7596-7606
26. Patel, J., Shah, S., Thakkar, P., & Kotecha, K., (2015). "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques". *Expert Systems with Applications*, Vol. 42, Issue 1, P 259-268