

کاربرد روش تکنیکال برای پیش‌بینی قیمت سهام: رویکرد مدل‌های احتمال

غیرخطی و شبکه‌های عصبی مصنوعی^۱

حسین خنجرپناه^۲، داود دوروش^۳، سعید شوال‌پور^۴ و آرمین جبارزاده^۵

چکیده

پیش‌بینی حرکت قیمت سهام از جمله مسائلی است که همواره تحلیل‌گران و سرمایه‌گذاران با آن مواجه هستند و آنان از ابزارهای مختلفی از جمله تحلیل‌های بنیادی و تکنیکال برای انتخاب سهام خوب و همچنین پیش‌بینی روند قیمتی در روزهای آینده استفاده می‌کنند. آنچه تحلیل‌گران به آن توجه دارند، توانایی تحلیل تکنیکال در پیش‌بینی‌های کوتاه‌مدت می‌باشد. بدین منظور، در این مقاله، مدل‌هایی با استفاده از ابزارهای شبکه عصبی، لاجیت، پروبیت و مقدار حدی به منظور پیش‌بینی جهت حرکت قیمت سهام در روز بعد ارائه شده است. برای پیاده‌سازی و مقایسه مدل‌های ارائه شده، برخی از شاخص‌های تکنیکال روزانه سهام شرکت ایران خودرو در بورس اوراق بهادار تهران که از جمله سهام‌های مورد اقبال سرمایه‌گذاران می‌باشد، بررسی شده است. بازه زمانی مورد بررسی سال-های ۱۳۹۲ تا ۱۳۹۷ بوده است. نتایج این پژوهش نشان می‌دهد که در آزمون‌ها پارامتری برابری نسبت‌ها، از لحاظ آماری مدل‌های ارائه شده تفاوت معناداری باهم نداشته‌اند، اما معیارهای سنجش خطا بیان می‌کند که مدل پروبیت، خطای کمتری در پیش‌بینی سهام در بازار بورس تهران دارد.

واژه‌های کلیدی: بورس اوراق بهادار تهران، پروبیت، شاخص تکنیکال، شبکه‌های عصبی مصنوعی، لاجیت.

طبقه‌بندی موضوعی: C45, C53, G17

۱. کد DOI مقاله: 10.22051/jfm.2018.19245.1609

۲. دانشجوی دکتری، گروه صنایع، دانشکده مهندسی صنایع، دانشگاه علم و صنعت، تهران، ایران،

E-mail: khanjarpanah@ind.iust.ac.ir

۳. دانش‌آموخته کارشناسی ارشد، گروه سیستم‌های اقتصادی اجتماعی، دانشکده مهندسی پیشرفت، دانشگاه علم و

صنعت، تهران، ایران، E-mail: d.dourvash@gmail.com

۴. استادیار، گروه سیستم‌های اقتصادی اجتماعی، دانشکده مهندسی پیشرفت، دانشگاه علم و صنعت، تهران،

ایران E-mail: shavvalpour@iust.ac.ir

۵. استادیار گروه سیستم‌های اقتصادی اجتماعی دانشکده مهندسی صنایع، دانشگاه علم و صنعت، تهران، ایران،

نویسنده مسئول، E-mail: arminj@iust.ac.ir

مقدمه

پیش‌بینی حرکت قیمتی سهام همواره یکی از دغدغه‌های اصلی سهامداران و فعالان بازار سرمایه بوده است (سارنج و همکاران، ۱۳۹۶). ابزارهای زیادی برای تحلیل و پیش‌بینی بازار سهام موجود است که از جمله آن‌ها می‌توان به تحلیل بنیادی^۱ و تحلیل تکنیکال^۲ اشاره کرد. تحلیل بنیادی به نوعی از تحلیل گفته می‌شود همه‌جانبه و بنیادی شرکت‌های بورسی در سطح خرد و کلان می‌پردازد و تحلیل تکنیکال به تحلیلی گفته می‌شود که از بررسی رفتار گذشته سهام، رفتار آینده آن را پیش‌بینی می‌کند. سرمایه‌گذاران بازار سهام را می‌توان از نظر مدت و دید سرمایه‌گذاری به سه دسته تقسیم‌بندی کرد: سرمایه‌گذار کوتاه‌مدت، سرمایه‌گذار میان‌مدت و سرمایه‌گذار بلندمدت. هر سه دسته سرمایه‌گذاران برای سرمایه‌گذاری از تحلیل‌های مختلفی استفاده می‌کنند، اما آنچه بیشتر به صورت تجربی مشاهده شده است آن است که تکیه سرمایه‌گذاران کوتاه‌مدت بر تحلیل تکنیکال و سرمایه‌گذاران بلندمدت بر تحلیل بنیادی می‌باشد و سرمایه‌گذاران کوتاه‌مدت بر هر دو تحلیل تأکید دارند. لازم به ذکر است، این عقیده که برخی تحلیل تکنیکال را صرفاً برای بازه‌های کوتاه‌مدت کارا می‌دانند، اصلاً درست نیست و تحلیل‌گر تکنیکی با تعیین بازه زمانی موردنظرش می‌تواند بازه مورد پیش‌بینی را مشخص کند. همان‌طور که مشهود است سرمایه‌گذاران کوتاه‌مدت بیشتر به نوسانات سهام و تغییر قیمت‌های روزانه و هفتگی آن توجه می‌کنند. با این شرایط برای بررسی رفتار قیمت روزانه یک سهم و تعیین جهت حرکت آن در یک روز باید به تحلیل تکنیکال آن سهم توجه کرد.

تحلیل تکنیکال یکی از روش‌های معتبر برای بررسی روندهای قیمتی است که بر اساس شاخص‌هایی همچون عرضه و تقاضا، حجم معاملات، تعداد خریداران و قیمت‌های تاریخی استوار است. این نوع تحلیل با در نظر گرفتن نمودار قیمت و شاخص‌های^۳ مختلف انجام می‌شود. تحلیل تکنیکال ابزار کارایی برای پیش‌بینی حرکت روزانه قیمت سهام می‌باشد. تحلیل تکنیکال خود شامل شاخص و ابزارهای مختلف و زیادی است که هر کدام از این شاخص‌ها و ابزارها می‌توانند اطلاعاتی از آینده حرکت سهم در اختیار ما قرار دهند. ممکن است که در تحلیل تکنیکال یک نمودار قیمت، نتایج به‌کارگیری شاخص‌های مختلف باهم متفاوت باشد، در این شرایط تحلیل‌گر دچار شک و تردید

-
1. Fundamental
 2. Technical
 3. Indicators

می‌شود که باید به نتایج پیش‌بینی شده کدام شاخص از تحلیل تکنیکال اعتماد کند؛ بنابراین یک تحلیل‌گر نباید فقط به نتیجه یک شاخص توجه کند و باید چند شاخص مختلف را باهم در نظر بگیرد که این امر باعث پیچیدگی کار یک تحلیل‌گر تکنیکال می‌شود.

برای مقابله با این پیچیدگی، در این مقاله شاخص‌های مهم تحلیل تکنیکال در نظر گرفته شده‌اند و روند قیمتی سهم با توجه به این شاخص‌ها پیش‌بینی شده است؛ بنابراین این پژوهش از آن جهت ضرورت دارد که پیش‌بینی درستی را از آینده سهم با توجه به شاخص‌های تکنیکال ارائه دهد. برای مدل‌سازی در این مقاله، از ابزارهای شبکه عصبی و مدل لاجیت که از کارایی بالایی در مدل‌سازی‌های غیرخطی برخوردارند، استفاده شده است.

همان‌طور که بیان شد، هدف از این مقاله ارائه مدل‌هایی است که بتواند جهت حرکت سهم را با توجه به شاخص‌های تکنیکال پیش‌بینی کند و همچنین عملکرد این مدل‌ها باهم مقایسه گردد و مدل بهتر در این زمینه انتخاب گردد.

مبانی نظری و مروری بر پیشینه پژوهش

در پیشینه پژوهش مقالات معدودی در مورد تحلیل تکنیکال وجود دارد. سلمانی (۱۳۸۹)، ناهمگونی بورس تهران را بر اساس تحلیل تکنیکال بررسی کرد. نتایج این پژوهش بیان‌گر آن بود که بین بازده محاسبه شده با تمامی شاخص‌های تکنیکال با بازده واقعی بازار رابطه مثبت و معناداری وجود دارد. چاشمی و حسن‌زاده (۱۳۹۰)، در مقاله‌ای پاسخ این سؤال که کدام شاخص پیش‌بینی، بهترین روش پیش‌بینی قیمت سهام در بورس تهران است. نتیجه این پژوهش نشان داد که از بین شاخص‌های میانگین متحرک، میانگین متحرک نمایی و میانگین متحرک وزنی، میانگین متحرک نمایی از لحاظ شاخص‌های اعتبار سنجی از اعتبار بالاتری برای پیش‌بینی قیمت سهام برخوردار است؛ اما مطالعات زیادی در مورد پیش‌بینی‌های بازارهای مالی به وسیله الگوریتم‌های فرا ابتکاری و دیگر روش‌ها بیشتر صورت گرفته است. شمس و پارسائیان (۱۳۹۱)، به مقایسه مدل فاما و فرنچ و شبکه‌های عصبی مصنوعی در پیش‌بینی بازده سهام در بورس تهران پرداختند. نتایج این پژوهش نشان از برتری مدل شبکه‌های عصبی مصنوعی بر مدل فاما و فرنچ دارد. فلاح‌پور و همکاران (۱۳۹۲)، در پژوهش خود به پیش‌بینی روند حرکتی قیمت سهام با استفاده از ماشین بردار پشتیبان بر پایه الگوریتم ژنتیک در بورس تهران پرداختند. این پژوهش نشان داد که ماشین بردار پشتیبان بر پایه الگوریتم ژنتیک از دقت بالاتری نسبت به ماشین بردار پشتیبان ساده در پیش‌بینی حرکت قیمت سهام،

برخوردار است. محمدی و همکاران (۱۳۹۷) به ارائه یک مدل ترکیبی از شبکه‌های عصبی مصنوعی و مدل خودرگرسیو میانگین متحرک انباشته پرداختند و کارایی مدل را در پیش‌بینی تغییرات قیمت طلا بررسی کردند. نتایج آن‌ها بیان‌گر آن بوده است که نتایج مدل ترکیبی ارائه‌شده از نتایج مدل‌های شبکه عصبی مصنوعی و خودرگرسیو میانگین متحرک انباشته به‌صورت مجزا، بهتر بوده است. همچنین، شبکه‌های عصبی در سال‌های اخیر در جنبه‌های دیگری از بازار سهام برای پیش‌بینی استفاده شده است. واعظ قاسمی و رمضان پور چهارده (۱۳۹۷) از شبکه‌های عصبی مصنوعی برای پیش‌بینی ورشکستگی شرکت‌های بورس اوراق بهادار استفاده کردند. آن‌ها از نسبت‌های مالی زیمنسکی و متغیرهای کلان اقتصادی برای این پیش‌بینی استفاده کردند. در نهایت نتایج آن‌ها نشان داد که الگوریتم ارائه‌شده می‌تواند با دقت بالایی شرکت‌های ورشکسته را پیش‌بینی کند. از طرف دیگر، پژوهش‌های زیادی با روش لاجیت-پرویت در زمینه بازارهای مالی صورت نگرفته است. از معدود پژوهش‌های در این حوزه می‌توان به پژوهشی اشاره کرد که در آن، پیش‌بینی دست‌کاری قیمت در بورس تهران با مدل‌های لاجیت و شبکه‌های عصبی آزمون شده است. نتایج حاصل از این پژوهش، حاکی از برتری نسبی شبکه عصبی در قدرت پیش‌بینی نسبت مدل‌های لاجیت است (فلاح شمس و کردلوئی، ۱۳۹۰).

پژوهش‌های خارجی گسترده‌ای نیز در زمینه پیش‌بینی در بازارهای مالی انجام گرفته است که از جمله ابزارهای کارا برای پیش‌بینی در این پژوهش‌ها می‌توان به شبکه‌های عصبی اشاره کرد. کائو، لچیو و شیندرجانس (۲۰۰۵)، به مقایسه مدل‌های فاما و فرنچ و شبکه‌های عصبی مصنوعی در پیش‌بینی بازار سهام چین پرداختند. نتایج این پژوهش نشان داد که مدل شبکه‌های عصبی ابزار کارا تر برای پیش‌بینی بازار نوظهور چین می‌باشد. همچنین در پژوهش دیگری به مطالعه حرکت شاخص قیمت سهام و پیش‌بینی آن توسط ابزار شبکه‌های عصبی و ماشین بردار پشتیبان پرداخته شد. نتایج این پژوهش کارایی بالاتر شبکه عصبی در دقت پیش‌بینی نسبت به ماشین بردار پشتیبان را نشان داد (کارا و همکاران، ۲۰۱۱). به علت قدرت پیش‌بینی بالای مدل‌های ترکیبی، این مدل‌ها همواره جایگاه بالایی را در پیش‌بینی بازارهای مالی به خود اختصاص داده‌اند. خاشعی و بیجاری (۲۰۱۱)، یک مدل ترکیبی از شبکه‌های عصبی و مدل خودتوضیح میانگین متحرک انباشته^۱ را برای پیش‌بینی داده‌های سری زمانی ارائه کردند. نتایج حاصله از این پژوهش بیان کرد که مدل ترکیبی پیشنهاد شده، کارایی بالاتری را نسبت به هر کدام از این دو مدل دارد. همچنین در پژوهش دیگری،

ساختار ترکیبی شبکه عصبی مصنوعی و الگوریتم ژنتیک برای پیش‌بینی شاخص‌های سهام ارائه گردید. نتایج حاکی از خوبی عملکرد این ساختار ارائه‌شده داشت و همچنین این روش، همواره عملکرد بهتری نسبت به استراتژی «خرید و نگهداری» داشته است (آرمانو و همکاران، ۲۰۰۵). در سالیان اخیر نیز شبکه‌های عصبی در بازارهای مالی گسترش فراوانی پیدا کرده‌اند. جدهاو و همکاران (۲۰۱۸) شاخص‌های بازار سهام را با الگوریتم‌های پیش‌بینی شبکه‌های عصبی مصنوعی پیش‌بینی کردند. الگوریتم ارائه‌شده توانایی پاسخ‌های خرید/فروش/نگهداری سهام را به شخص سرمایه‌گذار دارد. الگوریتم پیشنهادی در بازار سهام بمبئی آزمایش شده است و نتایج عملکرد خوب مدل ارائه‌شده را نشان می‌دهد. مارک‌جاس و همکاران (۲۰۱۸) به پیش‌بینی حرکت قیمتی برق با استفاده از شبکه‌های عصبی پرداختند. نتایج پژوهش آن‌ها از عملکرد خوب مدل ارائه‌شده برای پیش‌بینی مدنظر حکایت داشته است.

در مورد روش لاجیت-پروبیوت در حوزه بازارهای مالی پژوهش‌های گسترده‌ای صورت نگرفته است. لین (۲۰۰۹)، به مقایسه و بررسی مدل لاجیت-پروبیوت و شبکه عصبی در تایوان پرداخت. نتایج حاصله بیان کرد که مدل پروبیوت بهترین پردازش و عملکرد ایستا و شبکه عصبی در صحت پیش‌بینی عملکرد بهتری داشته است. در حوزه تحلیل تکنیکال نیز مطالعات زیادی صورت نگرفته است. در یکی از پژوهش‌های انجام گرفته، ترکیب خبرها و شاخص‌های تکنیکال در پیش‌بینی روند قیمتی روزانه سهام مورد مطالعه قرار گرفته است. نتایج حاصل از این پژوهش نشان داد که سیستم ارائه‌شده از دقت و بازدهی بالاتری نسبت به سیستم تک منبعی برخوردار است (ژای و همکاران، ۲۰۰۷). در پژوهش دیگر، خان و همکاران (۲۰۰۸)، به بررسی صحت پیش‌بینی سهام با روش‌های شبکه عصبی و الگوریتم ژنتیک بر پایه شبکه عصبی پرداختند. آن‌ها در این پژوهش معیار پیش‌بینی سهام را شاخص‌های تکنیکال قرار داده بودند. نتایج حاصله نشان داد که الگوریتم ژنتیک بر پایه شبکه عصبی از صحت بالاتری نسبت به سایر روش‌ها برخوردار بود. همچنین بازا و ناوال (۲۰۱۱)، به پیشنهاد یک سیستم انجام معامله بر اساس شاخص‌های تکنیکال و با یک روش فرا ابتکاری اقدام کردند. نتایج این پژوهش پتانسیل بالای سیستم ارائه‌شده برای گرفتن تصمیم در مورد سهام را نشان داد.

همان‌طور که در پیشینه پژوهش نیز ملاحظه می‌شود، تاکنون پژوهش‌های گسترده‌ای بر روی بازارهای مالی انجام گرفته است، اما در برخی زمینه‌ها مانند تحلیل تکنیکال و یا پیش‌بینی به‌وسیله مدل لاجیت-پروبیوت در بازارهای مالی، تحقیقات زیادی صورت نگرفته است. تحقیق حاضر با

شناسایی این شکاف سعی در مدل کردن پیش‌بینی حرکت قیمت سهام با استفاده از مدل‌های لاجیت-پرویت و مقایسه آن با شبکه عصبی، بر اساس شاخص‌های تحلیل تکنیکال دارد.

فرضیه پژوهش

در تحقیق حاضر، با توجه به آن‌چه که پیش از این بیان گردید، فرض بر این استوار است که شاخص‌های تکنیکال توانایی بالقوه‌ای در پیش‌بینی جهت حرکت سهام دارد. همچنین فرض دیگر این تحقیق آن است که نتایج حاصله از پیش‌بینی توسط مدل‌های مختلف احتمال غیرخطی از جمله روش‌های لاجیت، پرویت و مقدار بحرانی، تفاوت چشمگیری با یکدیگر ندارند. برای تأیید این موضوع از آزمون برابری نسبت‌ها استفاده می‌گردد. از سوی دیگر، برای مقایسه خطای روش‌های به کار گرفته شده، معیارهای سنجش خطای مجذور میانگین مربعات، خطای میانگین مطلق و شاخص نابرابری تیل به کار گرفته خواهند شد.

روش‌شناسی پژوهش

سه منطق و اصل تحلیل تکنیکال در نظر گرفته شدن همه‌چیز در قیمت، حرکت قیمت‌ها بر اساس روندها و تکرار شدن تاریخ می‌باشد (مورفی، ۱۹۹۹). این تحلیل برای پیش‌بینی خود از شاخص‌هایی استفاده می‌کند که در زیر از جمله بهترین شاخص‌های تکنیکال آورده شده‌اند.

میانگین متحرک انطباقی (AMA^۱): این شاخص برای ساختن یک میانگین متحرک با حساسیت کم نسبت به سری اغتشاشات قیمت، بکار می‌رود. همچنین از نظر شباهت با مدل‌های واریانس GARCH در اقتصادسنجی مورد توجه می‌باشد.

میانگین متحرک وزن دار ده روزه (WMA^۲): میانگین متحرک وزنی، نوعی از میانگین متحرک می‌باشد که در آن داده‌های جدیدتر با اهمیت‌تر از داده‌های سابق می‌باشند و در محاسبه میانگین، وزن بیشتری دارند. لذا شاخص نسبت به تغییر قیمت‌های اخیر حساسیت سریع‌تری نشان می‌دهد.

1. Adaptive Moving Average
2. Weighted Moving Average

نوسانات تصادفی (Stochastic K%): شاخص تکنیکی نوسانات تصادفی برای مقایسه قیمت جاری با یک بازه قیمتی در یک دوره زمانی مشخص استفاده می‌شود.

نوسانات تصادفی (Stochastic D%): این شاخص میانگین ساده حسابی از شاخص Stochastic K% می‌باشد که به همراه Stochastic K% برای دریافت سیگنال‌های خرید و فروش بکار می‌رود.

میانگین متحرک همگرایی/واگرایی (MACD^۱): میانگین متحرک همگرایی/واگرایی یک شاخص روند پویا است که ارتباط بین دو میانگین متحرک از یک قیمت را نشان می‌دهد. شاخص تکنیکی میانگین متحرک همگرایی/واگرایی (MACD) تفاوت بین یک دوره ۲۶ روزه از یک دوره ۱۲ روزه میانگین متحرک نمایی (EMA^۲) است.

فرمول‌های شاخص‌های تکنیکال در جدول ۱ بیان شده است.

جدول ۱. شاخص‌های تحلیل تکنیکال

شاخص‌های تکنیکی	فرمول شاخص‌ها
WMA	$\frac{((10) * C_t + (9) * C_{t-1} + \dots + C_{t-10})}{10 + 9 + \dots + 1}$
Momentum	$C_t - C_{t-n}$
Stochastic D%	$\frac{\sum_{i=0}^{n-1} K_{t-i} \%}{n}$
Stochastic K%	$\frac{C_t - LL_{t-n}}{HH_{t-n} - LL_{t-n}} * 100$
MACD(Moving Average Convergence Divergence)	$MACD(n)_{t-1} + \frac{2}{n+1} * (DIFF_t - MACD(n)_{t-1})$
BW MFI	$\frac{High_t - low_t}{Volume_t}$

1. Moving Average Convergence/Divergence
2. Exponential Moving Average

c_t ، قیمت بسته شدن سهام در روز t ، SSC_i مقدار مسطح‌سازی، LL_{t-n} کمترین مقدار پایین‌ترین قیمت در دوره $t-n$ روز قبل، HH_{t-n} بیشترین مقدار بالاترین قیمت در دوره $t-n$ روز قبل، $DIFF_t$ اختلاف $EMA(26)$ از $EMA(12)$ برابر حجم معاملات، $High$ بالاترین قیمت و low پایین‌ترین قیمت در روز t است. $EMA(26)$ و $EMA(12)$ همان می‌گین متحرک نمایی ۲۶ و ۱۲ روزه، p برابر نسبت روزهای بازگشتی (۲۶ و ۱۲) به کل دوره زمانی است که به شکل زیر محاسبه می‌شود:

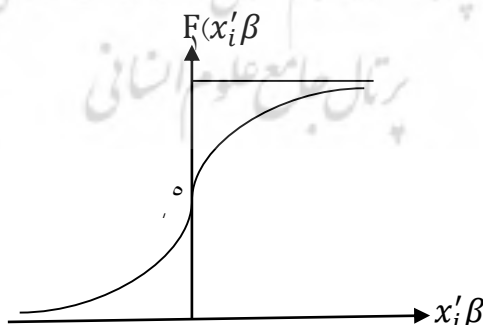
$$EMA(26) = (c_t * p) + (EMA(26)_{t-1} * (100 - p))$$

$$EMA(12) = (c_t * p) + (EMA(12)_{t-1} * (100 - p))$$

از رایج‌ترین تکنیک‌ها جهت مدل‌سازی پیش‌بینی حرکت قیمت سهم، روش‌های آماری می‌باشد. مدل‌های احتمالی غیرخطی نوع خاصی از تحلیل رگرسیون می‌باشند که در آن متغیر وابسته یا تصمیم افراد محدود و تابعی از عوامل اثرگذار بر تصمیم افراد است. پایه و اساس این مدل‌ها بر اساس مدل‌های احتمال می‌باشد. درباره اینکه چگونه توابع احتمال غیرخطی این شرایط را فراهم می‌کنند تا متغیر تصمیم محدود و مقادیری بین صفر و یک را به خود بگیرد، نظریه مطلوبیت تصادفی مطرح می‌گردد. مطلوبیت تصادفی از نظریه انتخاب استفاده می‌کند. هر فرد می‌تواند دو تشخیص در جهت حرکت قیمت داشته باشد. مشخص است که فرد مایل است تشخیص افزایش قیمت را که برای وی مطلوبیت دارد از اطلاعات خود داشته باشد (سوری، ۱۳۹۳).

$$\begin{cases} U_{1i} = 1: \text{مطلوبیت تشخیص افزایش قیمت} \\ U_{0i} = 0: \text{مطلوبیت تشخیص کاهش قیمت} \end{cases}$$

نمودار تابع مطلوبیت غیرخطی به صورت شکل ۱ می‌باشد.



نمودار ۱. نمودار تابع مطلوبیت غیرخطی (سوری، ۱۳۹۳)

با فرض اینکه اطلاعات مربوط به اندیکاتورها در روزهای مورد بررسی تحقیق موجود می‌باشد می‌توان Y_i^* را تشخیص فرد از افزایش و کاهش قیمت به صورت زیر تعریف کرد:

$$Y_i^* = U_{1i} - U_{0i} \quad (1)$$

اگر $Y_i^* \geq 0$ باشد فرد i ام تشخیص به افزایش قیمت و اگر $Y_i^* < 0$ فرد i ام تشخیص به کاهش قیمت می‌دهد. مقدار Y_i^* به مقدار شاخص‌های مشاهده شده فرد بستگی دارد لذا می‌توان آن را به صورت زیر نوشت:

$$Y_i^* = \sum_{k=1}^K \beta_k X_{ki} + u_i = x_i \beta + u_i \quad (2)$$

مشکل مدل فوق این است که مقادیر Y_i^* قابل مشاهده نیستند. متغیر قابل مشاهده Y_i را چنان تعریف می‌کنیم که اگر $Y_i = 1$ باشد فرد تشخیص افزایش قیمت می‌دهد و اگر $Y_i = 0$ باشد فرد تشخیص کاهش قیمت می‌دهد و از رابطه Y_i و Y_i^* برای حل مشکل مدل استفاده می‌شود. رابطه بین این دو در روش پژوهش توضیح داده شده است.

مدل‌های احتمال غیرخطی با اختصاص وزن‌هایی به متغیرهای مستقل، رتبه تغییر قیمت سهم در هرروز را پیش‌بینی کرده و از این رتبه برای تعیین احتمال عضویت در دسته‌بندی تشخیص افزایش یا کاهش قیمت، استفاده می‌شود. احتمال افزایش یا کاهش قیمت به صورت زیر محاسبه می‌گردد:

$$P(Z) = \frac{1}{1 + e^{-Z}} = \frac{1}{1 + e^{-(a + b_1 x_1 + \dots + b_n x_n)}} \quad (3)$$

$P(Z)$ همواره بین صفر و یک است لذا $P(Z) = 0.5$ نقطه مناسبی برای تفکیک جهت حرکت قیمت می‌باشد. مدل پروبیت شبیه مدل لاجیت بوده با این تفاوت که از تابع احتمالی تجمعی نرمال استفاده می‌کند. در مبانی نظری عنوان شد که می‌بایست بین Y_i و Y_i^* رابطه‌ای برقرار کرد. برای برقراری رابطه Y_i و Y_i^* از مفهوم احتمال استفاده می‌شود:

$$P(Y_i = 1) = P(Y_i^* \geq 0) = P(x_i \beta + u_i \geq 0) = P(u_i \geq -x_i \beta) \quad (4)$$

مدل پروبیت فرض می‌کند که u_i دارای توزیع نرمال است:

$$P(Z \leq z) = \int_{-\infty}^z \varphi(z) dz = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{z^2}{2}} dz = \Phi(z) \quad (5)$$

لذا با توجه به فرمول تابع احتمال نرمال استاندارد داریم:

$$\begin{aligned} P(Y_i = 1) &= P(Y_i^* \geq 0) = P(u_i \geq -x_i\beta) = 1 - P(u_i < -x_i\beta) \\ &= 1 - \Phi(-x_i\beta) = \Phi(x_i\beta) \end{aligned} \quad (6)$$

برای تخمین ضرایب β در مدل پروبیت از روش حداکثر درستنمایی^۱ استفاده می‌گردد. پس از تخمین ضرایب، اثرات متغیرهای توضیحی بر متغیر وابسته که بیانگر مطلوبیت است غیر قابل مشاهده می‌باشد اما در مدل پروبیت $P(Y_i = 1) = \Phi(x_i\beta)$ می‌باشد لذا این احتمال را می‌توان به صورت زیر بازنویسی کرد:

$$p_i = P(Y_i = 1|x_i) = \Phi(x_i\hat{\beta}) \quad (7)$$

با تغییر x_i مقادیر احتمال نیز تغییر می‌کند. لذا تفسیر ضرایب بدین صورت است که با افزایش یا کاهش مقادیر x_i چه میزان احتمال تشخیص افزایش قیمت در فرد نام تغییر می‌کند و بر اساس نقطه تفکیک $p_i = 0.5$ فرد چه تشخیصی دارد. در مدل لاجیت بجای تابع نرمال استاندارد که در مدل پروبیت استفاده گردید از تابع لاجستیک استفاده می‌گردد:

$$P(Z \leq z) = \frac{e^z}{1 + e^z} = G(Z) \quad (8)$$


روش تخمین ضرایب و تفسیر مدل لاجیت مانند مدل پروبیت می‌باشد. مدل مقدار حدی^۲ نیز آخرین مدل از مدل‌های احتمال غیرخطی می‌باشد که مورد بررسی قرار می‌گیرد. تابع توزیع این مدل بفرم زیر می‌باشد:

$$P(Z \leq z) = e^{-e^{-z}} = E(Z) \quad (9)$$

در این روش نیز تخمین ضرایب و تفسیر مدل مانند مدل‌های پروبیت لاجیت می‌باشد و تنها تفاوت در توزیع احتمال می‌باشد. متغیر پیش‌بینی شونده در این تحقیق جهت حرکت قیمت سهام می‌باشد که یک متغیر دو مقداری ۰ و ۱ است. در صورت افزایش قیمت بسته‌شده سهم نسبت به روز قبل متغیر مقدار ۱ و در صورت کاهش مقدار ۰ می‌گیرد. با این دسته‌بندی طبق نظریه توزیع آماری متغیر جهت حرکت قیمت دارای توزیع برنولی با پارامتر p می‌باشد. تابع احتمال این متغیر به شکل زیر است:

$$P(y) = p^y(1-p)^{1-y}, y = 0,1 \quad (10)$$

شبکه‌های عصبی روشی کارا و اثربخش در بسیاری از زمینه‌ها و از جمله پیش‌بینی است. این روش که دارای ماهیت غیرخطی است به‌عنوان ابزاری کارآمد در حوزه مالی و بورس شناخته‌شده است. شبکه‌های عصبی توسط پیت (ریاضی‌دان) و مک کولا (عصب‌شناس) در سال ۱۹۴۳ معرفی گردید. شبکه‌های عصبی برنامه‌های نرم‌افزاری هستند که از ساختار زیست‌شناختی مغز انسان، باهمان پیچیدگی‌ها، تقلید می‌کنند. این فن تلاش می‌کند ساختاری مشابه ساختار بیولوژیکی مغز انسان و شبکه اعصاب بدن بسازد تا همانند مغز قدرت یادگیری، تعمیم‌دهی و تصمیم‌گیری داشته باشد. این شبکه‌ها نیازی به مدل ریاضی ندارند زیرا مانند انسان تجربه آموخته و سپس این تجربیات را تعمیم می‌دهند. شبکه‌های عصبی از لایه‌هایی شامل اجزای پردازشگر ساده به نام «نورون» تشکیل شده که به‌صورت موازی باهم عمل می‌کنند. هر لایه ورودی نیز به یک یا تعداد بیش‌تری لایه میانی متصل بوده و لایه‌های میانی نیز به لایه خروجی وصل می‌باشند. نورون مصنوعی، پایه و اساس هر شبکه عصبی است. معماری شبکه دربارۀ تعداد لایه و ارتباط بین نورون‌ها در شبکه عصبی است. این ارتباط به ارتباط بین لایه و درون لایه‌ها تقسیم می‌شوند. در ارتباط بین لایه‌ها، نورون‌های هر لایه می‌توانند تماماً به نورون‌های لایه بعد متصل شده و یا اینکه هر نورون به نورون‌های خاصی از لایه بعد متصل شود اما در ارتباط درون لایه‌ها، یک نورون می‌تواند به سایر نورون‌ها لایه خود نیز متصل شود و یا نشود. همچنین نورون‌های یک لایه می‌توانند تنها به لایه بعد از خود متصل شده و یا اینکه به چند لایه متفاوت متصل شود. در تحقیق حاضر یک مدل شبکه عصبی مصنوعی پیش‌خور سه لایه (۱-۱۵-۳)، به کار گرفته شده است. مدل شماتیک شبکه عصبی به کار گرفته شده در شکل ۲ ارائه شده است.



نمودار ۲. ساختار شبکه عصبی (مأخذ: یافته‌های پژوهش)

همان‌گونه که در شکل فوق نیز قابل مشاهده است، شاخص‌های تحلیل تکنیکال معرفی شده به‌عنوان ورودی‌های شبکه عصبی در نظر گرفته شده‌اند. از طرفی جهت حرکت قیمت سهم به‌عنوان خروجی مدل در نظر گرفته شده است. شبکه عصبی با توجه به ورودی‌ها و خروجی‌های داده شده آموزش می‌بیند. به‌صورت خلاصه، شبکه عصبی به هر یک از ورودی‌ها وزن تخصیص می‌دهد و با توجه به وزن‌های تخصیص داده شده، مقداری از خروجی را برآورد می‌کند و با مقدار خروجی داده شده به شبکه مقایسه می‌کند و مقدار خطای آن را محاسبه می‌کند. با استفاده از الگوریتم یادگیری پس انتشار، شبکه عصبی در وزن دهی بازنگری می‌کند تا به کمترین خطای ممکن برسد؛ بنابراین پس از یادگیری شبکه عصبی، می‌توان پیش‌بینی جهت حرکت قیمت سهام را انجام داد به این صورت که شاخص‌های تکنیکال را به‌عنوان ورودی به شبکه عصبی وارد می‌شوند و جهت حرکت قیمت سهم به‌عنوان خروجی شبکه از سیستم استخراج می‌گردد.

از مهم‌ترین ویژگی‌های شبکه‌های عصبی مصنوعی قدرت یادگیری این شبکه‌ها است. فرآیند یادگیری در شبکه‌های عصبی مصنوعی، به‌نگام سازی وزن‌های ارتباطی می‌باشد به‌نحوی که یک شبکه بتواند وظیفه‌ای خاص را به‌صورت کارا انجام دهد (احمدخان‌بیگی و عبدالوند، ۱۳۹۶). در اینجا از ۸۰ درصد داده‌های موجود جهت آموزش شبکه عصبی و بقیه برای آزمون آن استفاده شده است. برای معماری شبکه عصبی باید این مراحل انجام

گیرد: ابتدا داده‌ها افراز می‌شوند، سپس عمل نرمال‌سازی داده‌ها انجام می‌شوند، در گام بعدی از بین داده‌ها، مقادیری را برای آموزش شبکه تخصیص می‌دهیم و در نهایت آزمون در شبکه عصبی انجام می‌گیرد.

یافته‌های پژوهش

داده‌هایی که در این پژوهش استفاده شده است قیمت‌های باز و بسته شدن و بالاترین و کمترین قیمت و همچنین حجم معاملات سهام ایران خودرو (با نماد «خودرو») از صنعت خودروسازی در بازار بورس اوراق بهادار تهران از تاریخ ۱۳۹۲/۰۳/۱۳ تا ۱۳۹۷/۰۵/۳۰ با تواتر روزانه می‌باشد. علت اینکه سهام شرکت ایران خودرو انتخاب شده است تکنیکال پذیر بودن قیمت این سهم با تأیید نظر خبرگان می‌باشد که با توجه به ماهیت این پژوهش در انتخاب شاخص‌های تکنیکی به‌عنوان متغیرهای ورودی در شبکه عصبی و متغیرهای توضیحی در مدل‌های احتمال غیرخطی، انتخاب مناسبی است. همچنین سهام این شرکت در بازار بورس اوراق بهادار تهران در صنعت خودروسازی لیدر دیگر شرکت‌ها بوده و توجه زیادی در بین معامله‌گران حقیقی و حقوقی به خود جمع کرده است که این امر مزید بر علت انتخاب این سهام برای تحقیق می‌باشد.

در جدول ۲ اطلاعات توصیفی شاخص کل و ایران خودرو شامل مقادیر حداقل، حداکثر، میانه، میانگین و انحراف معیار در بازه مذکور ارائه شده است. همچنین برای بررسی مناسب بودن انتخاب سهام ایران خودرو به‌عنوان سرگروه سهام‌های خودروسازی و سهامی که انطباق بالایی با شاخص کل بازار سهام دارد از آزمون همبستگی پیرسون استفاده شده است.

جدول ۲. اطلاعات توصیفی و آزمون همبستگی پیرسون (مأخذ: یافته‌های پژوهش)

شاخص‌ها	حداقل	حداکثر	میانه	میانگین	انحراف معیار	آزمون همبستگی پیرسون
شاخص کل	۳۸۶۰۲	۱۳۷۰۷۲	۷۶۶۹۲	۷۵۹۰۳	۱۴۶۰۹/۲۶	۳۲/۱۷***
ایران خودرو	۱۰۰۴	۴۶۴۴	۲۷۰۲	۲۷۲۰/۶۶	۵۱۳/۹۶	(۰/۶۱۱۷)

*** سطح معناداری ۱ درصد

همان‌طور که نتایج آزمون نشان می‌دهد آماره t آزمون همبستگی پیرسون برابر ۳۲/۱۷ می‌باشد و در سطح معنی‌داری ۰/۰۱ معنی‌دار و مقدار آن ۰/۶۱۱۷ می‌باشد. در نتیجه انتخاب مناسبی برای بررسی مدل‌های مقاله در

بازار سهم ایران می‌باشد. داده‌های این تحقیق از نرم‌افزار مفیدتریدر^۱ استخراج شده و در پیش‌بینی به روش شبکه عصبی از نرم‌افزار متلب^۲ و در روش مدل‌های احتمال غیرخطی از نرم‌افزار ایویوز^۳ استفاده شده است.

نتایج عددی

پس از برازش مدل مقادیر احتمال هر کدام از مدل‌ها بر اساس تابع احتمال خاصی که دارند برای دوره ۳۹ روزه کاری از تاریخ ۱۳۹۷/۰۴/۰۲ تا ۱۳۹۷/۰۵/۳۰ پیش‌بینی گردیدند و نمودار آن‌ها استخراج گردید. نتایج حاصل از برآورد توسط مدل‌های احتمال غیرخطی، در جدول ۳ ارائه شده است.

جدول ۳. نتایج مدل‌های احتمال غیرخطی (مأخذ: یافته‌های پژوهش)

		پروبیت		لاجیت		مقدار حدی	
		ضریب	Z	ضریب	Z	ضریب	Z
شاخص‌های تکنیکال	WMA	-۰/۰۰۰۱*** (۰/۰۰۰۰۵)	-۳/۴۸۰۰	۰/۰۰۰۰۲*** (۰/۰۰۰۰۸)	-۳/۳۵۸	-۰/۰۰۰۱۰* (۰/۰۰۰۰۵)	-۱/۷۳۹۹
	Momentum	-۰/۰۰۰۹*** (۰/۰۰۰۳۰)	-۳/۱۰۸۹	-۰/۰۰۰۱۵*** (۰/۰۰۰۵۰)	-۳/۱۲۳۴	-۰/۰۰۱۳۷*** (۰/۰۰۰۳۵)	-۳/۹۴۲۸
	Stoch D	-۰/۰۱۸۱*** (۰/۰۰۳۰۰)	-۶/۰۵۲	-۰/۰۳۰۶۷*** (۰/۰۰۵۱۰)	-۶/۰۰۲۷	-۰/۰۱۶۵۹*** (۰/۰۰۳۳۴)	-۴/۹۵۵۴
	Stoch K	۰/۰۳۲۳*** (۰/۰۰۲۳)	۱۳/۶۴۶۹	۰/۰۵۳۳۲*** (۰/۰۰۴۱۴)	۱۲/۸۵۳۱	۰/۰۳۸۲۰*** (۰/۰۰۲۸۱)	۱۳/۵۷۹
	MAC D	۰/۰۱۱۹*** (۰/۰۰۳۸۰)	۳/۱۴۷۷	۰/۰۲۰۱۲*** (۰/۰۰۶۳۴)	۳/۱۷۱۵	۰/۰۰۹۱۲** (۰/۰۰۴۳۷)	۲/۰۸۵۶
	BW MFI	-۲۱۳۳۰*** (۶۵۵۴/۲۵)	-۳/۲۵۴۴	-۳۴۱۲۸/۴*** (۱۰۸۵۶/۸۴)	-۳/۱۴۳۴	-۳۴۱۲۵*** (۷۱۵۶/۸۹)	-۴/۷۶۸۱
معیارهای مدل	McF R ²	۰/۴۹۳۲		۰/۴۹۳۲		۰/۴۹۳۲	
	LR Statistic	۲۰۹/۵۲۲ (۰/۰۰)		۲۰۹/۷۵۳ (۰/۰۰)		۲۱۱/۳۱۹ (۰/۰۰)	

* سطح معناداری ۱۰ درصد

** سطح معناداری ۵ درصد

*** سطح معناداری ۱ درصد

1. Mofid Trader
2. Matlab
3. Eviews


تقریباً متغیرهای توضیحی (شاخص‌ها) در هر سه مدل در سطح ۰/۰۱ معنی‌دار هستند و شاخص MACD در دو مدل پرویت و لاجیت در سطح ۰/۰۱ معنی‌دار و در مدل مقدار حدی در سطح ۰/۰۵ معنی‌دار می‌باشد و برای شاخص WMA نیز در دو مدل پرویت و لاجیت در سطح ۰/۰۱ و در مدل مقدار حدی در سطح ۰/۱ معنی‌دار است. علامت متغیرها در هر سه مدل نیز باهم مطابقت دارند. طبق تابع احتمال مدل‌ها انتظار می‌رود با افزایش ضرایب، احتمال تشخیص افزایش قیمت نیز افزایش یابد.

$MCF R^2$ شاخص نسبت درستی که به روش زیر محاسبه می‌شود:

$$MCF R^2 = 1 - \frac{l}{l'}$$

که نسبت l به l' نشان‌دهنده این است که چند درصد از تغییرات متغیر وابسته توسط متغیرهای توضیحی، توضیح داده شده است. مقدار آماره $MCF R^2$ در سه مدل نسبتاً خوب و بسیار به هم نزدیک می‌باشند. همچنین معنی‌دار بودن مدل نیز با مقادیر بالای آماره LR Statistic و مقدار احتمال صفر آن‌ها در همه مدل‌ها مورد تأیید قرار گرفته است.

همان‌طور که گفته شد، داده‌های خروجی شبکه عصبی به صورت ۰ و ۱ می‌باشند. پیش‌بینی صورت گرفته در مدل شبکه عصبی حاضر به گونه‌ای انجام می‌گیرد که خروجی‌ها بر اساس احتمال هستند، یعنی عددی بین ۰ و ۱ هستند. شکل ۳ این مسئله را به خوبی بیان می‌کند. در این شکل دایره‌های قرمز نشان‌دهنده داده‌های واقعی ما هستند و مربع‌های آبی پیش‌بینی‌های شبکه عصبی می‌باشند. به منظور ۰ و ۱ بیان کردن این خروجی‌ها، نقاط با احتمال بالاتر از ۰/۵ را ۱ و نقاط با احتمال پایین‌تر از ۰/۵ را ۰ در نظر می‌گیریم.



نمودار ۳. نمودار پیش‌بینی احتمال جهت قیمت در مدل شبکه عصبی (مأخذ: یافته‌های پژوهش)

پس از اینکه بر اساس نقطه تفکیک $p=0.5$ مقادیر پیش‌بینی شده از هر کدام از مدل‌ها به اعداد ۱ و ۰ تبدیل شدند نسبت تطابق مقادیر پیش‌بینی شده با واقعیت در این مدل‌ها با آزمون نا پارامتری برابری نسبت‌ها، انجام و نتایج در خروجی زیر نمایش داده شده است. همچنین آزمون نا پارامتری برابری نسبت پیش‌بینی تشخیص افزایش قیمت هر کدام از مدل‌ها با یکدیگر مقایسه گردیده‌اند که نتایج این آزمون در جدول ۴ آورده شده است.

جدول ۴. آزمون‌های برابری نسبت تشخیص جهت قیمت در مدل‌ها (مأخذ: یافته‌های پژوهش)

مدل‌های احتمال غیرخطی	نسبت پیش‌بینی افزایش قیمت	نسبت تطابق با واقعیت مدل	آزمون برابری نسبت افزایش قیمت در مدل با واقعیت	آزمون برابری نسبت افزایش قیمت در بین مدل‌ها		
				مقدار حدی	لاجیت	شبکه عصبی
پروبیوت	۰/۴۱۰۲	۰/۷۶۹۲	۱/۴۲۱ (۰/۱۲۶)	۰/۰۰ (۱/۰۰)	-۰/۲۵۸ (۰/۸۹۲)	-۱/۱۲۰ (۰/۲۱۹)
				پروبیوت	مقدار حدی	شبکه عصبی
لاجیت	۰/۴۱۰۲	۰/۷۶۹۲	۱/۴۲۱ (۰/۱۲۶)	۰/۰۰ (۱/۰۰)	-۰/۲۵۸ (۰/۸۹۲)	-۱/۱۲۰ (۰/۲۱۹)
				لاجیت	مقدار حدی	شبکه عصبی
مقدار حدی	۰/۴۱۰۲	۰/۷۶۹۲	۱/۴۲۱ (۰/۱۲۶)	پروبیوت	-۰/۲۵۸ (۰/۸۹۲)	-۱/۴۱۲ (۰/۱۵۸)
				لاجیت	پروبیوت	شبکه عصبی
شبکه عصبی	۰/۴۴۱۵	۰/۶۰۱۲	۰/۴۵۱ (۰/۶۰۲)	پروبیوت	-۱/۲۰۱ (۰/۲۱۹)	-۱/۴۱۷ (۰/۱۵۸)
				لاجیت	پروبیوت	شبکه عصبی

آزمون‌های برابری نسبت پیش‌بینی تشخیص افزایش قیمت در بین مدل‌های احتمال غیرخطی و مدل شبکه عصبی مصنوعی در سطح ۰/۰۵ بی‌معنی بوده و نسبت‌ها باهم برابر است. در آزمون‌های برابری نسبت پیش‌بینی تشخیص افزایش قیمت بین خود مدل‌ها نیز همه آزمون‌ها در سطح ۰/۰۵ بی‌معنی بوده و باهم برابر بودند. به‌طور کلی نتایج نشان می‌دهد که ازلحاظ آماری تقریباً نسبت پیش‌بینی تشخیص افزایش قیمت در همه مدل‌ها هم در مقایسه با مقادیر واقعی و هم نسبت با یکدیگر

باهم برابر می‌باشند بنابراین برای مقایسه دقیق‌تر مدل‌ها نیاز به معیارهای سنجش خطا می‌باشد که در ادامه مورد بررسی قرار می‌گیرند.

معیارهای سنجش خطا برای مقایسه مقادیر خطای پیش‌بینی یک سری زمانی که توسط مدل‌های مختلف برآورد شده است محاسبه می‌گردد. در جایگاه مقایسه هرچه مقدار خطا کمتر باشد، قدرت پیش‌بینی مدل بهتر خواهد بود. در اینجا از معیارهای سنجش خطای^۱ RMSE،^۲ MAE و^۳ TIC استفاده شده است. نتیجه مقایسه معیارهای خطا در جدول ۵ آورده شده است.

جدول ۵. مقایسه معیارهای سنجش خطا (مأخذ: یافته‌های پژوهش)

مدل	RMSE	MAE	TIC
پرویت	۰/۴۲۳۰	۰/۳۷۵۳	۰/۳۵۸۸
لاجیت	۰/۴۲۳۲	۰/۳۷۵۹	۰/۳۵۹۱
مقدار بحرانی	۰/۴۲۲۱	۰/۳۷۰۱	۰/۳۶۲۶
شبکه عصبی	۰/۵۰۱۰	۰/۳۷۰۲	۰/۳۶۲۷

همان‌گونه که مشاهده می‌شود مدل مقدار بحرانی از بقیه مدل‌ها دارای RMSE و MAE کمتری است ولی در معیار TIC مدل شبکه عصبی دارای عملکرد بهتری است. بدین ترتیب در بین مدل‌های ارائه شده مدل مقدار بحرانی در پیش‌بینی تشخیص جهت حرکت قیمت سهام خطای کمتری دارد.

نتیجه‌گیری و بحث

در این پژوهش داده‌های سهام شرکت ایران خودرو در بازار بورس اوراق بهادار تهران در نظر گرفته شد و داده‌ها بر اساس افزایش و کاهش حرکت روز بعد به اعداد یک و صفر کدبندی شدند. سپس شاخص‌های تحلیل تکنیکال برای قیمت هرروز به دست آمد و این شاخص‌ها به‌عنوان ورودی به مدل در نظر گرفته شدند. مدل‌های احتمال غیرخطی پرویت، لاجیت و مقدار حدی و مدل فرا ابتکاری شبکه عصبی برای پیش‌بینی جهت حرکت قیمت سهام به کار گرفته شدند. برای بررسی و

-
1. Root Mean Square Error
 2. Mean Absolute Error
 3. Theil Inequality Coefficient

مقایسه مدل‌های ارائه شده آزمون نا پارامتری برابری نسبت و معیارهای سنجش خطای مدل‌ها مشخص گردید. نتایج نشان داد که در قدرت پیش‌بینی مدل‌های احتمال غیرخطی با درصد تطابق ۷۶/۹۲ درصد با واقعیت از مدل شبکه عصبی دارای عملکرد بهتری می‌باشند. در مقایسه برابری نسبت پیش‌بینی جهت افزایش قیمت، مدل‌ها از لحاظ آماری تفاوت معناداری باهم نداشتند. همچنین در آزمون برابری نسبت پیش‌بینی جهت افزایش قیمت با نسبت مقادیر واقعی هم تفاوت معناداری بین مدل‌ها از لحاظ آماری وجود نداشت. از لحاظ معیارهای سنجش خطا این مدل مقدار حدی بود که دارای عملکرد بهتری نسبت به سایر مدل‌ها بود.

برای تحقیقات آینده در این حوزه می‌توان به این موارد اشاره کرد: مدل‌سازی مسئله بیان شده این تحقیق با روش‌های فرا ابتکاری دیگری مانند الگوریتم ژنتیک یا ماشین بردار پشتیبان انجام شود، از شاخص‌های تحلیل تکنیکال دیگری برای مطالعه استفاده گردد، به جای پیش‌بینی جهت حرکت سهام ریسک سرمایه‌گذاری در سهام پیش‌بینی شود و همچنین می‌توان شاخص‌های تحلیل بنیادی را به مدل ارائه شده این مقاله اضافه کرد.

منابع

- احمدخان‌بیگی، سهیل و عبدالوند، ندا، «پیش‌بینی قیمت سهام با رویکرد ترکیبی شبکه عصبی مصنوعی و الگوریتم رقابت استعماری مبتنی بر تئوری آشوب»، فصلنامه راهبرد مدیریت مالی، (۵(۳)، صص ۲۷-۷۳.
- سارنج، علیرضا؛ کریمی، تورج و شهرامی بابکان، مجید، (۱۳۹۶). «کاربرد تئوری مجموعه‌های راف برای پیش‌بینی قیمت سهام (مطالعه موردی: بانک صادرات ایران)»، فصلنامه راهبرد مدیریت مالی، (۵(۳)، صص ۱۱۹-۱۴۴.
- سلمانی، سوده، (۱۳۸۹). «بررسی ناهمگنی در بورس اوراق بهادار تهران بر اساس رویکرد تکنیکال»، مجله مهندسی مالی و مدیریت پرتفوی، (۲)، صص ۱۳۹-۱۶۵.
- سوری، علی، (۱۳۹۳). «اقتصادسنجی (۲)». تهران: فرهنگ‌شناسی.
- شمس، ناصر و پارسائیان، سمیرا، «مقایسه عملکرد مدل فاما و فرنچ و شبکه‌های عصبی مصنوعی در پیش‌بینی بازده سهام در بورس تهران»، مجله مهندسی مالی و مدیریت اوراق بهادار، (۱۸)، صص ۱۰۳-۱۱۸.
- فلاح‌پور، سعید؛ گل‌ارضی، غلامحسین و فتوره‌چیان، ناصر، (۱۳۹۲). «پیش‌بینی روند حرکتی قیمت سهام با استفاده از ماشین بردار پشتیبان بر پایه الگوریتم ژنتیک در بورس اوراق بهادار تهران»، تحقیقات مالی، (۱۵)، صص ۲۶۹-۲۸۸.
- فلاح‌شمس، میرفیض و کردلوئی، حمیدرضا، (۱۳۹۰). «آزمون مدل‌های لاجیت و شبکه عصبی مصنوعی جهت پیش‌بینی دستکاری قیمت در بورس اوراق بهادار تهران»، مجله مهندسی مالی و مدیریت اوراق بهادار، (۷)، صص ۳۷-۶۹.
- محمدی، شاپور؛ راعی، رضا و رحیمی، محمدرضا، (۱۳۹۷). «پیش‌بینی دامنه تغییرات طلا با استفاده از مدل ترکیبی ARIMA و شبکه عصبی»، مجله مهندسی مالی و مدیریت اوراق بهادار، (۳۴)، صص ۳۳۵-۳۵۷.
- نبوی چاشمی، سیدعلی و حسن‌زاده، آیت‌الله، (۱۳۹۰). «بررسی کارایی شاخص MA در تحلیل تکنیکال در پیش‌بینی قیمت سهام»، مجله دانش مالی تحلیل اوراق بهادار، (۱۰)، صص ۸۶-۱۰۶.
- واعظ قاسمی، محسن و رمضانپور چهارده، سعید، (۱۳۹۷). «پیش‌بینی ورشکستگی شرکت‌های پذیرفته شده در سازمان بورس و اوراق بهادار با استفاده از شبکه عصبی مصنوعی»، فصلنامه دانش سرمایه‌گذاری، (۲۶)، صص ۲۷۷-۲۹۶.

- AhmadKhanBeygi, S. & Abdolvand, N. (2017). Stock Price Prediction Modeling Using Artificial Neural Network Approach and Imperialist Competitive Algorithm Based On Chaos Theory. *Financial Management Strategy*, 5(3), pp.27-73 (in Persian).
- Armano, G., Marchesi, M., & Murru, A. (2005). A hybrid genetic-neural architecture for stock indexes forecasting. *Information Sciences* (170), pp.3 - 33.
- Briza, A. C. & Naval Jr, P. C. (2011). Stock trading system based on the multi-objective particle swarm optimization of technical indicators on end-of-day market data. *Applied Soft Computing*(11), pp.1191 - 1201.
- Cao, Q. Leggio, K. B. & Schniederjans, M. j. (2005). A comparison between Fama and French's model and artificial neural networks in predicting the Chinese stock market. *Computers & Operations Research* (32), pp.2499 - 2512.
- Fallahpour, S. Golarzi, G. & Fatourehchian, N. (2014). Prediction of the stock price trend using SVM based on genetic algorithm in Tehran stock exchange. *Financial Research* (15), pp.269 - 288 (in persian).
- FallahShams, M. & KordLouie, H. (2011). Logit analysis and artificial neural network models to predict price manipulation in Tehran Stock Exchange. *The Journal of Portfolio Management and Financial Engineering*(7), pp.37 - 69 (in persian).
- Jadhav, S. Dange, B. & Shikalgar, S. (2018). Prediction of Stock Market Indices by Artificial Neural Networks Using Forecasting Algorithms. *In International Conference on Intelligent Computing and Applications* (pp. 455-464). Springer, Singapore.
- Kara, Y. Boyacioglu, M. & baykan, O. 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*(38), pp.5311 - 5319.
- Khashei, M. & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing* (11), pp.2664 - 2675.
- Lin, T. H. (2009). A cross model study of corporate financial distress prediction in Taiwan: Multiple discriminant analysis,logit,probit and neural networks models. *Neurocomputing*(72), pp.3507 - 3516.
- Marcjasz, G. Uniejewski, B. & Weron, R. (2018). On the importance of the long-term seasonal component in day-ahead electricity price forecasting with NARX neural networks. *International Journal of Forecasting*.
- Mohammadi, Sh. Raeie, R. & Rahimi, R. (2018). Interval Forecasting for Gold Price with hybrid model of ARIMA and Artificial Neural Network. *The Journal of Portfolio Management and Financial Engineering*(34), pp.335-357 (in persian).

- Monfared, J. H. AhmadAliNejad, M. & Metghalchi, S. (2011). The Comparison of neural network and time series Baks- Jenkins models in forecasting Tehran Stock Exchange price index. *The Journal of Financial and Management Engineering Exchange*(11), pp.1-16 (in persian).
- Murphy, J. J. (1999). *Technical Analysis of the Financial Markets*. New York: New York Institute of Finance.
- NabaviChashmi, A. & HassanZadeh, A. (2011). Study of Indicator Performance in technical analysis of stock price forecasting. *The Journal of Financial Knowledge of Securities Analysis*(10), pp.83 - 106 (in persian).
- Salamani, S. (2010). Study of heterogeneity in the stock market based on technical analysis. *The Journal of Portfolio Management and Financial Engineering* (2), pp.139 - 165 (in persian).
- Saranj, A. Karimi, T. & Shahramin Babakan, M. (2017). "The Application of Rough Set Theory in Stock Price Forecasting (Case Study: Iran Saderat Bank). *Financial Management Strategy*, 5(3), pp.119-144 (in persian).
- Shams, N. & Parsaiyan, S. (2011). The Comparison between performance of Fama and French and artificial neural networks models in predicting stock returns in Tehran stock exchange. *The Journal of Financial and Management Engineering Exchange*(18), pp.103 - 118 (in persian).
- Souri, A. (2014). *Econometrics* (2). Tehran: Farhangshenasi (in persian).
- Ullah Khan, A. Bandopadhyaya, T. K. & Sharma, S. (2008). Comparisons of Stock Rates Prediction Accuracy using Different Technical Indicators with Backpropagation Neural Network and Genetic Algorithm Based Backpropagation Neural Network. *First International Conference on Emerging Trends in Engineering and Technology, 16-18 July 2008, India*, pp.575 - 580.
- Vaez-Ghasemi, M. & Ramezanzpour Chardeh, S. (2018). Predicting bankruptcy of companies listed on the Stock Exchange using the artificial neural network. *The Journal of Investment Knowledge* (26), pp.277-296 (in Persian).
- Zhai, Y. Hsu, A. & Halgamuge, S. K. (2007). Combining News and Technical Indicators in Daily Stock Price Trends Prediction. *Lecture Notes In Computer Science*, pp.1087 - 1096.