



مقاله پژوهشی

مقایسه دقیق هوشمندی الگوریتم‌های مبتنی بر داده‌کاوی جهت برآورد قیمت سهام^۱حسین کیانی‌زاده^۲، علی باغانی^۳، محسن حمیدیان^۴

تاریخ دریافت: ۱۴۰۳/۰۵/۱۹

تاریخ پذیرش: ۱۴۰۲/۰۲/۱۹

چکیده

حجم اطلاعات بازار سرمایه به طرز چشمگیری در حال گسترش می‌باشد و بلون استفاده از الگوریتم‌های داده‌کاوی و مدل‌های کلان داده، به مرداری از این داده‌ها امکان پذیر نخواهد بود. معاملات گذشته بیانگر امکان پیش‌بینی قیمت سهام توسط مدل‌های یادگیری ماشین می‌باشد؛ اما دقیق پیش‌بینی این مدل‌ها مورد ارزیابی قرار نگرفته است. هدف از این پژوهش مقایسه دقیق هوشمندی پنج الگوریتم پرکاربرد داده‌کاوی شامل شبکه عصبی، رگرسیون لجستیک، نزدیکترین همسایه^۵ ماشین بردار پشتیبان و اعتبارسنجی ضربه‌دری می‌باشد. از بین ۳۸۵ شرکت فعال در بورس اوراق بهادار تهران، ۷۲ شرکت به روش حنف سیستماتیک انتخاب و دقیق مدل‌های فوق برای پیش‌بینی قیمت سهام بر روی داده‌های روزانه سهام منتخب برای سال‌های ۱۳۹۹ تا ۱۳۸۸ پیاده‌سازی شده است. متغیر قیمت سهام به عنوان متغیر وابسته و متغیرهای قیمت باز شدن، قیمت بسته شدن، بالاترین قیمت و حجم معاملات، قیمت روزانه ارز آزاد، قیمت طلا و قیمت نفت به عنوان متغیر مستقل استفاده شده است. برای ارزیابی دقیق برآورد قیمت سهام از سه شاخص MSE و $RMSE$ و R^2 استفاده شده و از تحلیل واریانس با استفاده از آماره F برای برآذنش دقیق مدل‌ها و از آماره t برای مقایسه دو مدل‌ها با یکدیگر استفاده شده است. نتایج پژوهش نشان داد از بین الگوریتم‌های هوشمند استفاده شده، الگوریتم ماشین بردار پشتیبان بیشترین قدرت برآورد قیمت سهام را به خود اختصاص داده است.

واژگان کلیدی: بورس اوراق بهادار، برآورد، قیمت سهام، الگوریتم‌های هوشمند، یادگیری ماشین، داده‌کاوی.

طبقه‌بندی موضوعی: C02, C13, C53, C55, C58, G17

۱. کد DOI مقاله: 10.22051/jfm.2024.40333.2685

۲. دانشجوی دکتری، گروه مدیریت مالی، واحد بین الملل کیش، دانشگاه آزاد اسلامی، جزیره کیش، ایران. Email: kianizaceh@gmail.com

۳. استادیار، گروه مدیریت مالی، واحد بین الملل کیش، دانشگاه آزاد اسلامی، جزیره کیش، ایران. Email: ali.baghani.85@gmail.com

۴. دانشیار، گروه مدیریت مالی، واحد بین الملل کیش، دانشگاه آزاد اسلامی، جزیره کیش، ایران. Email: hamidian_2002@yahoo.com

مطالعات پیشین در حوزه مدل‌های یادگیری ماشین برای پیش‌بینی قیمت سهام را می‌توان به دو دسته کلی تقسیم نمود: الف- استفاده از یک الگوریتم یادگیری ماشین برای پیش‌بینی قیمت سهام و ب- بهینه سازی مدل یادگیری ماشین برای برآورد قیمت سهام (نتایج پژوهش حاضر) و در همه این مطالعات امکان استفاده از مدل استفاده شده برای پیش‌بینی قیمت سهام تأیید گردیده است، ولی مقایسه دقت پیش‌بینی این مدل‌ها علی‌رغم ضرورت و اهمیت آن، در مطالعات پیشین کمتر مورد توجه قرار گرفته است. هدف از این پژوهش مقایسه دقت هوشمندی الگوریتم‌های مبتنی بر داده‌کاوی برای پیش‌بینی قیمت سهام می‌باشد؛ از این رو ابتدا با بررسی مطالعات پیشین، پرکاربردترین مدل‌های یادگیری ماشین^۱ مشتمل بر ماشین‌های بردار پشتیبان^۲، شبکه‌های عصبی، نزدیکترین همسایه‌های K^۳، رگرسیون لجستیک^۴ و اعتبارسنجی متقابل^۵ احصاء گردیده و سپس، با استفاده از روش‌های آماری، دقت مدل‌های موصوف در برآورد قیمت سهام در بورس اوراق بهادار تهران مورد سنجش قرار گرفته است.

لذا در پژوهش حاضر، علاوه بر ارزیابی امکان پیش‌بینی قیمت سهام توسط الگوریتم‌های داده کاوی که در پژوهش‌های پیشین به صورت مستقل انجام گرفته است، ارزیابی میزان دقت مدل‌های موصوف، نوآوری اصلی این پژوهش این است و راهنمایی است برای فعالان بازار سرمایه که با استفاده از کدام مدل می‌توانند به پیش‌بینی بهتری دست پیدا کنند.

با بررسی ادبیات موضوع و مطالعه پژوهش‌های پیشین، برای مقایسه دقت مدل‌های استفاده شده در برآورد قیمت سهام از سه شاخص R^2 , MSE و RMSE استفاده شده است (سرمد، ۱۳۹۹) و سپس، با استفاده از تحلیل واریانس مبتنی بر آماره F برازش دقت مدل‌ها و از آماره t برای مقایسه دو به دوی مدل‌ها با یکدیگر استفاده شده است. با طبقه‌بندی شاخص‌های موصوف این نتیجه حاصل گردید که ماشین بردار پشتیبان دارای بیشترین دقت در پیش‌بینی قیمت سهام می‌باشد و پس از آن به ترتیب شبکه‌های عصبی، رگرسیون لجستیک، اعتبارسنجی متقابل و نزدیکترین همسایه‌های K قرار گرفته‌اند.

-
1. Machin learning
 2. Support Vector Machines (SVM)
 3. K Nearest Neighbors (KNN)
 4. Logistic Regression (LR)
 5. Cross Validation (CV)

در ادامه، پس از بررسی مبانی نظری و پیشینه پژوهش، روش‌شناسی پژوهش تشریح گردیده و سپس، با بررسی آزمون فرضیه‌ها، به بحث و نتیجه گیری پرداخته و راهکارهایی برای مطالعات آنچه پیشنهاد گردیده است.

مبانی نظری و مروری بر پیشینه پژوهش

طبق نظریه بازار کارای سرمایه که در اوایل قرن بیستم برای برآورد قیمت سهام مطرح شد، چنین جمع‌بندی شده است که با مطالعه رفتار پیشین قیمت سهام، امکان دست‌یابی به بازده غیرعادی وجود ندارد و تغییرات قیمت سهام از یک الگوی قابل پیش‌بینی تعییت نمی‌کند (راغی، ۱۴۰۰). سرمایه‌گذاران مدت‌های طولانی فرضیه بازار کارا را قبول کرده بودند و این نظریه تا دهه ۱۹۸۰ میلادی به خوبی رفتار قیمت سهام در بازار را توضیح می‌داد؛ ولی پس از آن تحولات بازار سهام نیویورک در سال ۱۹۸۷، اعتبار این نظریه را با ابهام مواجه نمود. (آمپوماه، ۲۰۲۰). از این رو پس از دهه ۱۹۹۰ میلادی، توجه متخصصان بیشتر به یک رفتار آشوب‌گرایانه همراه با نظم متمایل گردید و طراحی مدل‌های غیرخطی برای پیش‌بینی قیمت سهام مورد توجه بیشتری قرار گرفت و مطالعات اخیر نشان دادند که با بررسی رفتار سهام برآورد قیمت امکان‌پذیر می‌باشد (احمدخان بیگی و عبدالوند، ۱۳۹۶).

یکی از مشکلات اصلی در برآورد قیمت سهام، حجم بالای داده‌های موجود در بازار سرمایه است. مجموعه داده‌ها به قدری عظیم است که نمی‌توان آن را با استفاده از روش‌های غیر داده‌کاوی اداره کرد (لانگ^۱، ۲۰۱۹). از آنجا که بازار سرمایه به سرعت به اطلاعات واکنش نشان داده و این اطلاعات به صورت لحظه‌ای قیمت سهام را متأثر می‌نماید، امکان تجزیه و تحلیل حجم عظیم داده‌ها توسعه کاربر و وجود ندارد (کانتارزیک، ۱۳۹۲). در همین خصوص لازم است جهت تحلیل اطلاعات از ماشین استفاده نمود؛ از این‌رو، استفاده از مدل‌های هوشمند داده‌کاوی و یادگیری ماشین روز به روز توسعه یافته و امکان استفاده از تکنیک‌ها و الگوریتم‌های هوشمند و مدل‌های یادگیری ماشین برای برآورد هوشمند قیمت سهام فراهم گردید و محبوبیت داده‌کاوی در دنیای مالی افزایش یافت (احمدخان بیگی و عبدالوند، ۱۳۹۶). در همین راستا، روش‌های تجزیه و تحلیل فنی، پیش‌بینی سری‌های زمانی و داده‌کاوی برای برآورد قیمت سهام گسترش روزافزون یافت (ون‌لونگ^۲، ۲۰۱۹).

داده‌کاوی و یادگیری ماشین با بررسی حجم عظیمی از داده‌ها و با بهره گیری از الگوریتم‌های خاص برای ساخت مدل‌های خود یادگیرنده مورد استفاده قرار می‌گیرد. برخلاف یک سیستم معمولی که با پیروی از قوانین مشخص یک وظیفه را انجام می‌دهد، یک سیستم هوشمند مبتنی بر داده‌کاوی وظایف خود را از طریق تجربه کردن یاد می‌گیرد و عملکرد آن از طریق یادگیری و تمرین بهبود پیدا می‌کند. الگوریتم‌های یادگیری ماشین با فرآگیری از داده‌هایی که دریافت کرده می‌توانند مسائلی را حل کنند که بسیار پیچیده‌تر از آن است که بتوان آن را با برنامه‌نویسی معمولی حل نمود (سیگو، ۲۰۲۰). از الگوریتم‌های یادگیری ماشین می‌توان به الگوریتم‌های طبقه‌بندی، الگوریتم‌های رگرسیون،

-
- 1. Long
 - 2. Wen Long
 - 3. Sigo

الگوریتم‌های خوشبیندی و الگوریتم‌های کاهش ابعاد اشاره نمود (حسین، ۲۰۲۱). روش معمول برای داده‌کاوی تقسیم مجموعه داده‌ها به زیرمجموعه‌هایی برای آموزش، اعتبارسنجی و آزمایش است (بالینگر، ۲۰۱۵). آموزش فرآیندی است که در آن مانشین، الگوی موجود در ورودی را که به صورت مجموعه داده‌های آموزشی است با استفاده از مجموعه قوانینی که تعلوی یادگیری را تعریف نموده می‌آموزد. اعتبارسنجی، توانایی الگوریتم را برای ارائه جواب قابل قبول در مقابل ورودی‌هایی که جزء مجموعه آموزشی نبوده‌اند و میزان دقت الگوریتم را برای برآورد این داده‌ها مورد سنجش قرار می‌دهد. استفاده از الگوریتم برای انجام وظیفه‌ای که به آن منظور طراحی شده است را آزمایش گویند (bagbanی، ۱۳۹۶).

در طول چند سال اخیر با معرفی ابزارهای سازوکار و پدیده‌های نو اهمیت بازار سرمایه در اقتصاد ایران ارتقاء یافته و برآورد قیمت سهام به عنوان یکی از مسائل جذاب و مهم توجه بسیاری از پژوهشگران دانشگاهی و کارشناسان این حوزه را به خود جلب نموده است و فعالان بازار در صدد بکارگیری روش‌های برآورد قیمت سهام، برای افزایش سود سرمایه خود بوده‌اند؛ لیکن عدمه مطالعات به بررسی تحلیلهای تکنیکی و نموداری محدود شده است (افشاری راد، ۱۳۹۷) و استفاده از الگوریتم‌های داده‌کاوی کمتر مورد استفاده قرار گرفته و پژوهش‌های انجام گرفته برای پیش‌بینی‌های مالی در این حوزه عمدتاً با محوریت شبکه‌های عصبی مصنوعی و در برخی موارد ماشین‌های بردار پشتیبان صورت گرفته و مقایسه دقت چند مدل پرکاربرد به صورت یکجا صورت نگرفته است که این موضوع یکی از نواوری این پژوهش می‌باشد و هدف از انجام این پژوهش مقایسه دقت چند مدل پرکاربرد با یکدیگر در برآورد قیمت سهام می‌باشد.

مدل‌های انتخاب شده برای پیش‌بینی قسمت سهام در این پژوهش جزء مدل‌های پرکاربرد در حوزه یادگیری ماشین می‌باشد؛ به طوری که با جستجوی هریک از واژگان در پایگاه جستجوی علمی گوگل این موضوع به خوبی مشخص می‌شود. جدول زیر نتیجه جستجوی هریک از واژگان می‌باشد. برای جستجوی کلی صرفاً نام واژه جستجو شده است و برای جستجوی تخصصی در حوزه بازار سرمایه نام مدل به علاوه stock price جستجو شده است.

جدول ۱. فراوانی کاربرد مدل‌های استفاده شده در پژوهش در مطالعات علمی

عنوان	تعداد مطالعات	تعداد مطالعات کلی
Machine learning	۴,۹۷۰,۰۰۰	۷۲۴,۰۰۰
Logistic Regression (LR)	۳,۶۵۰,۰۰۰	۹۰,۰۰۰
Artificial Neural Networks (ANN)	۲,۰۴۰,۰۰۰	۷۴,۳۰۰
Support Vector Machines (SVM)	۳,۰۲۰,۰۰۰	۸۲,۹۰۰
Cross Validation (CV)	۴,۰۲۰,۰۰۰	۱۶۰,۰۰۰
K Nearest Neighbors (KNN)	۲,۰۱۳,۰۰۰	۴۹,۲۰۰

منبع: نتایج پژوهش

1. Houssein
2. Ballings

تعاریف مدل‌های به کار گرفته شده در پژوهش حاضر عبارتند از:

الگوریتم ماشین بردار پشتیبان: یکی از روش‌های یادگیری با ناظارت است که برای طبقه‌بندی و دسته‌بندی الگوها از طریق کم کردن خطای‌های طبقه‌بندی و بهینه کردن الگوها استفاده می‌شود (نیوتا، ۲۰۱۷).

الگوریتم شبکه‌های عصبی: سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها، اعمال داشت به دست آمده در جهت بیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند (سیگو، ۲۰۲۰).

رگرسیون لجستیک: یک مدل آماری رگرسیون برای متغیرهای وابسته دوسویی است. این مدل را می‌توان به عنوان مدل خطی تعیین‌یافته‌ای که ازتابع لوجیت به عنوان تابع پیوند استفاده می‌کند و خطایش از توزیع چندجمله‌ای پیروی می‌کند، به حساب آورد (ژائو، ۲۰۱۹).

الگوریتم نزدیک‌ترین همسایه: یک روش آماری است که برای طبقه‌بندی آماری و رگرسیون استفاده می‌شود. در حالت طبقه‌بندی با توجه به مقدار مشخص شده برای K به محاسبه فاصله نقطه‌های که می‌خواهیم برچسب آن را مشخص کنیم با نزدیک‌ترین نقاط می‌پردازد و با توجه به تعداد حداقلی این نقاط همسایه، در رابطه با برچسب نقطه موردنظر تصمیم‌گیری می‌شود (پیریونسی، ۲۰۲۰).

اعتبارسنجی متقابل: یک روش ارزیابی مدل است که تعیین می‌نماید نتایج تحلیل آماری بر مجموعه‌ای از داده‌ها تا چه میزان امکان تعمیم دارد و از داده‌های آموزشی مستقل می‌باشد. این روش عموماً برای پیش‌بینی تغییرات استفاده می‌شود تا تعیین شود مدل موردنظر به چه میزان در عمل مفید خواهد بود (ون لونگ، ۲۰۱۹).

پیشینه پژوهش‌های صورت گرفته در خصوص مدل‌های مورد استفاده در این پژوهش به صورت خلاصه در جداول ۲ و ۳ ارائه گردیده است:

جدول ۲. پیشینه پژوهش‌های داخلی

نویسنده و سال	عنوان مقاله	نتیجه
زارعی؛ محمدیان؛ حاضری نیری و باشکوه اجیرلو (۱۳۹۷)	مقایسه روش‌های شبکه‌های عصبی فازی با شبکه‌های عصبی موجک فازی در پیش‌بینی قیمت سهام	نتایج حاصل از مدل با استفاده ازتابع هزینه بروز رسانی شده انجام گرفته است. نتایج پژوهش در مقایسه شبکه‌های عصبی فازی موجک و شبکه‌های عصبی فازی بیانگر آن است که میزان اطمینان پیش‌بینی قیمت سهام بانک‌ها با استفاده از شبکه‌های عصبی موجک فازی بالای ۹۰ درصد و با شبکه‌های عصبی فازی بالای ۸۰ درصد است. در نتیجه برای پیش‌بینی قیمت سهام شبکه‌های عصبی موجک فازی از درصد اطمینان بالاتری نسبت به شبکه‌های عصبی فازی برخوردار می‌باشد.

1. Nivetha
2. Zhou
3. Piryonesi
4. Wen Long

نويسنده و سال	عنوان مقاله	نتیجه
بيات و باقری (۱۳۹۷)	پيش‌بيني قيمت سهام بالاستفاده از الگوريتم كرم شب تاب (FA)	محاسبات ايجام خطای كمتر از ۶٪ را برای پيش‌بيني نشان می‌دهد. بنابراین الگوريتم كرم شب تاب قابلیت پيش‌بيني قيمت سهام را دارد.
احمدخان بيگي و عبدالوند (۱۳۹۸)	پيش‌بيني قيمت سهام با رويرك در ترکيب شبکه‌های عصبي مصنوعی و الگوريتم رقابت استعماری مبتنی بر تئوري آشوب	نتایج حاکی از آن است که رویرک در ترکيب شبکه‌های از عملکرد بهتری نسبت به سایر رویرک‌های پيش‌بینی برخوردار می‌باشد.
رجب پور؛ تقوا و حسين زاده يزدي (۱۳۹۸)	پيش‌بيني قيمت سهام شركت‌هاي بورس اوراق بهادر تهران با استفاده از شبکه‌های عصبي مصنوعی	نتایج اين پژوهش نشان می‌دهد که معماری ۳ لایه با ۸ نورون در لایه اول، ۴ نورون در لایه دوم و ۲ خروجي و معماری ۲ لایه با ۱۲ نورون در لایه اول و ۲ خروجي مدل‌های مناسبی می‌باشند.
مكيان و موسوي (۱۳۹۹)	پيش‌بيني قيمت سهام شركت فراورده‌های نفتی پارس با استفاده از شبکه‌های عصبي و روش رگرسیون؛ مطالعه موردی: قيمت سهام شركت فراورده‌های نفتی پارس	نتایج حاصل از مدل شبکه‌های عصبي خطای كمتر، توضیح‌دهنده‌گی پيش‌بیني و بنابراین قدرت پيش‌بیني بالاتری نسبت به مدل‌های رگرسیونی دارد.
تاجيك (۱۳۹۹)	بررسی تحليل تکنيکال هوشمند با استفاده از رگرسیون تعیین يافته شبکه عصبي	معامله‌گری با استفاده از شبکه عصبي VAM و EMV بهتر از نتیجه‌های معامله‌گری است که توسط VAMA و EMV بدون شبکه عصبي و همچنین ميانگين متاخر ساده و استراتژي‌های خريد و فروش عمل می‌کند
فلاح شمس، دلنواز (۱۳۹۹)	پيش‌بيني شاخص كل بورس اوراق بهادر با استفاده از شبکه‌های عصبي	نتایج پيش‌بیني همه مدل‌های استفاده شده در اين پژوهش نيز حاکی از آن است که در بورس اوراق بهادر تهران پيش‌بیني کوتاه مدت با فاصله زمانی كمتر، مناسب‌تر از پيش‌بیني بلندمدت با فاصله زمانی طولاني تر است
خالو زاده (۱۳۹۹)	مدل‌سازی غيرخطی و پيش‌بیني رفتار قيمت سهام در بورس ايران	در پخش پيش‌بیني انتداز یک شبکه عصبي پيش رو ۳ لایه با تيوپلوزي ۱-۵-۱-۵ پري پيش‌بیني يك روز بعد، پري سري زمانی قيمت و يارده و شاخص قيمت برابر ۰/۹۸۹۰، ۰/۹۷۹۰، ۰/۹۰۱۰، ۰/۹۹۷۹ بدست آمد. سپس از يك شبکه سه لایه با اتصالات برگشتی پري پيش‌بیني بافق ۳۰ روز پري سري زمانی قيمت استفاده نموده که نتیجه $R^2 = 78/76$ از آن حاصل شده است.
افشاري راد، علوی و سينائي (۱۳۹۹)	مدلي هوشمند برای پيش‌بیني روند سهام با استفاده از روش‌های تحليل تکنيکال	پنج روش هوشمند ماشين بردار پشتيبان ططي، مانشين بردار پشتيبان كريل گوسی، درخت تصميم، نزدیک ترين K همسایه و نشوی بیز استفاده شده و اين نتیجه حاصل شد که روش پيش‌بیني دار به طور متوسط نرخ پيش‌بیني صحيح ۹۷ درصد دارد.

منبع: نتایج پژوهش

جدول ۳. پيش‌بینه پژوهش‌های خارجی

نويسنده و سال	عنوان مقاله	نتیجه
لانگ، سان و تيان (۲۰۱۹)	يک روش جديد هسته گرافيكى برای پيش‌بیني گرایش قيمت سهام بر اساس مفهوم مالي و شبهات ساختاري	با مقایسه صحت پيش‌بیني كريل با هسته‌های ديگر مثل هسته خطی، نشان داده شد که روش پيش‌بیني داده حداقل به ۵٪ روی دقت عمل می‌کند که يك ارتقا کاملاً معنی دار است
لين (۲۰۱۸)	تحليل تکنيکال و پيش‌بیني سود سهام	تجزیه بازده سهام مبتنی بر آتورگرسیون برداری نشان می‌دهد که منشا اقتصادي قدرت پيش‌بیني، عمدهاً از تغیيرات زمانی در جريان نقدی آينده (يعني کمال جريان نقدی) می‌آيد.

عنوان مقاله	نويسنده و سال
پيش‌بياني قيمت آتي سهام (اس‌اندي) با استفاده از شبکه‌های عصبي و نويزدابي موچك شبكه‌های عصبي اگر با آموزش و داده‌های ورودی مناسب همراه باشند، امکان دستیابی به سودآوری بالا را در صندوق‌های قابل معامله در بورس (مبتنی بر اس‌اندي) فراهم می‌کنند.	وانگ و گوپتا (۲۰۲۰)
مطالعه سистемهای شبکه‌های عصبي خفashی در پيش‌بياني قيمت سهام: مطالعه DAX موردي در قيمت سهام	حافظي، شهرavi و هداوندي (۲۰۱۵)
پيش‌بياني قيمت آتي سهام (اس‌اندي) با استفاده از شبکه‌های عصبي و نويزدابي موچك نتایج حاصل از اين پژوهش بيانگ آن است که شبکه‌های عصبي اگر با آموزش و داده‌های ورودی مناسب همراه باشند، می‌توانند سودآوری بالاتر در صندوق‌های قابل معامله در بورس (مبتنی بر اس‌اندي) را به همراه داشته باشند.	وانگ و گوپتا (۲۰۱۹)
شبکه‌های عصبي مصنوعی بر پيش‌بياني بازار سهام: مروری جامع	حسينيان، ديرار، حسين و محمد (۲۰۲۱)
پيش‌بياني جهت حرکت شاخص قيمت سهام بورس استانبول با مدل‌های شبکه‌های عصبي - فاري و ماشين‌های بردارپشتيبان (SVM) از اطلاعات روزانه ۱۹۹۷ تا ۲۰۰۷ همراه با دشخاص فني به عنوان متغيرهای ورودی مدل استفاده شده است. شبکه‌های عصبي - فاري ۷۵/۷۴٪ و مدل ماشين‌های بردار پشتيبان ۱۱/۵۲٪ را به خوبی پيش‌بياني نمودند و حاصل اين پژوهش، عملکرد بهتر شبکه‌های عصبي - فاري در قياس با مدل ماشين‌های بردار پشتيبان بود و بهترین عملکرد پيش‌بياني مربوط به سال ۲۰۰۱ می‌باشد.	كارا، بيسقلو و بابكان (۲۰۱۹)
استفاده از شبکه‌های عصبي مصنوعی به منظور بهبود سیستمهای معامله گري بر مبناي تجزيء و تحليل تكنيكال	روديگر گنزالس و همكاران (۲۰۱۹)
پيش‌بياني مدل شاخص بورس جهاني بوسيله شبكه عصبي متاثر از زمان تصادفي در اين پژوهش تكن尼克 داده‌گاوی بر مبناي يادگيري ماشين اميدبخش، جهت كشف روابط پيش‌بياني بين متغيرهای اقتصادي و مالي فراوان ارائه شده است.	ليايو و وانگ (۲۰۲۱)
مقاييسه بين مدل فاما و مدل فرانسوی و شبکه‌های عصبي مصنوعی در پيش‌بياني بازار سهام چين	كانو، لغيو و شنيدرجانز (۲۰۱۵)
استفاده از يادگيري ماشين با استفاده از تجزيء و تحليل داده‌های پيش‌بياني كننده بازار سهام هند	سيگو و همكاران (۲۰۲۰)
ارزياي مدل‌های يادگيري ماشين مبتنی بر درخت تصميم در پيش‌بياني جهت حرکت سهام	آمپوماه و همكاران (۲۰۲۰)

منبع: نتایج پژوهش

فرضيه پژوهش

دقت پيش‌بياني مدل‌های ماشين‌های بردار پشتيبان، شبکه‌های عصبي، روش نزديک‌ترین همسایه‌های k ، رگرسيون لجستيک و اعتبارسنجي متقابل با يكديگر تفاوت دارد.

روش شناسی پژوهش

روش گردآوری اطلاعات در این پژوهش روش کتابخانه‌ای است. مباحث تئوریک پژوهش از مسیر مطالعه منابع، نشریات، منابع داخلی و خارجی موجود در کتابها و استفاده از اینترنت جمع‌آوری شده است. داده‌های پژوهش از نرم‌افزار ره آورد نوین و پایگاه اطلاع‌رسانی tsetmc.com به صورت روزانه استخراج شده است و از آمارهای پایگاه اطلاع‌رسانی طلا و ارز برای استخراج نرخ ارز آزاد و قیمت هر اونس طلا و قیمت نفت استفاده شده است. جامعه آماری این پژوهش شامل شرکت‌های پذیرفته شده در تابلوی اصلی بورس برای دوره زمانی ۱۳۸۸ تا ۱۳۹۹ است. به علت گستردگی حجم جامعه آماری وجود برخی ناهمانگی‌ها میان اعضاء جامعه، برای گزینش نمونه از روش حذف سیستماتیک استفاده شد (سرمد، ۱۳۹۹) و معیارهای اعمال شده برای بدست آوردن نمونه به شرح زیر است:

شرکت قبل از سال ۱۳۸۸ در بورس اوراق بهادار تهران پذیرفته شده باشد.

سال مالی شرکت منتهی به پایان اسفندماه هر سال باشد. (به لحاظ افزایش قابلیت مقایسه)

شرکت در طی سال‌های ۱۳۸۸ تا ۱۳۹۹ تغییر سال مالی نداده باشد.

در طول سال مالی دارای وقفه معاملاتی بیشتر از ۶ ماه نباشد.

بیش از ششصد هزار سهم آنها در هر سال معامله شده باشد.

با اعمال معیارهای فوق، تعداد ۷۲ شرکت فعال در تابلوی اصلی بورس به عنوان نمونه آماری انتخاب

گردید.

جدول ۴. نحوه محاسبه نمونه در پژوهش

فیلتر	تعداد شرکت‌ها	مانده شرکت‌ها
تعداد کل سهام موجود در بازار در سال ۱۳۹۹	۳۸۵	۳۸۵
تعداد سهام پذیرفته شده پس از سال ۱۳۸۸	۲۷۳	۱۱۲
شرکت‌هایی که سال مالی آن اسفند هر سال نیست	۱۵	۹۷
شرکت‌هایی که تغییر سال مالی داشته‌اند	۲	۹۵
شرکت‌هایی که بیش از شش ماه وقفه معاملاتی داشته‌اند	۴	۹۱
شرکت‌هایی که کمتر از ۴۰۰ هزار سهم در سال معامله کرده‌اند	۱۹	۷۲
تعداد شرکت‌های باقی مانده	۷۲	

منبع: نتایج پژوهش

با توجه به اینکه ۷۲ شرکت پس از اعمال فیلتر باقی مانده است، کل ۷۲ سهم به عنوان نمونه مورد مطالعه این پژوهش در نظر گرفته شد. به این ترتیب ۸۶۴ سال شرکت به عنوان نمونه این پژوهش در نظر گرفته شده است.

پس از بررسی‌های فراوان برای شناسایی متغیرهای، ۸ متغیر تاثیرگذار بر قیمت سهام در دو گروه به شرح زیر دسته‌بندی شدند.



گروه اول: متغیرهای فنی شامل بالاترین قیمت سهم، پایین‌ترین قیمت سهم، قیمت باز شدن سهم، قیمت بسته شدن سهم و حجم معاملات سهم.

گروه دوم: متغیرهای اقتصادی شامل نرخ ارز، قیمت هر اونس طلا و قیمت نفت در سبد اوپک ورودی‌های هر کدام از شرکت‌ها به طور متوسط شامل ۲۰۰۰۰ داده هستند که ابتدا پس از انتخاب متغیرها و جمع آوری داده‌ها، به منظور آماده‌سازی داده‌ها برای آموزش و آزمایش هر کدام از متغیرها با استفاده از رابطه (۱) نرمال گردید تا تأثیر اعداد بزرگ کاهش یابد.

$$\hat{S}_t = \frac{(S_t - S_{min})}{S_{max} - S_{min}} \quad (1)$$

پس از نرمال‌سازی داده‌ها، توسط روش k-Fold Cross-Validation، داده‌های آموزشی و داده‌های آزمایشی تفکیک و ۸۰ درصد داده‌ها به عنوان داده‌های آموزشی و ۲۰ درصد مابقی به عنوان داده‌های آزمایشی استفاده و الگوریتم ۱۰ مرتبه تکرار گردید. در این روش از تمامی داده‌ها برای یادگیری مدل استفاده می‌شود و هر بار بخشی از داده‌ها به عنوان مجموعه آزمایش توانایی مدل را ارزیابی می‌کند. سپس، برای ارزیابی دقت برآورد سه شاخص R^2 ، MSE و RMSE طبق جدول ۵، مورد استفاده قرار گرفت و در پایان بر اساس تحلیل واریانس با استفاده از آماره F برای برآش دقت مدل‌های برآورد سهام و از آماره t برای مقایسه دو به دو مدل‌های پیش‌بینی با یکدیگر استفاده شد. تحلیل‌ها با استفاده از نرم‌افزار Matlab انجام گرفته است.

جدول ۵. معیارهای ارزیابی دقت مدل

معیار	رابطه
MSE	$MSE = \frac{\sum_{i=1}^n (e_i)^2}{n}$
RMSE	$\sqrt{\frac{1}{N} * \sum_{i=1}^N (f_i - y_i)^2}$
R^2	$R^2 = 1 - \frac{SSE}{SSy}$

منبع: روش‌های پژوهش در علوم رفتاری

رگرسیون لجستیک

رگرسیون لجستیک نوعی از رگرسیون است که متغیرهای پیش‌بین (مستقل) می‌تواند در مقیاس کمی و مقیاس مقوله‌ای مورد استفاده قرار گیرد؛ لیکن متغیر وابسته مقوله‌ای دو سطحی است. این دو مقوله بیانگر عضویت یا عدم عضویت در یک گروه می‌باشد. (نیوتا، ۲۰۱۷) این مدل رگرسیون، شبیه رگرسیون معمولی است با این تفاوت که روش تخمین ضرایب یکسان نمی‌باشد و به جای حداقل کردن مجدد خطایها

(که در رگرسیون معمولی انجام می‌شود، احتمالی که یک واقعه رخ می‌دهد را حداکثر می‌نماید)، در رگرسیون لجستیک از مفهوم بخت برای میزان متغیر وابسته استفاده می‌شود. در اصطلاح آماری بخت، احتمال رخداد یک پیشامد (P_i) بر احتمال عدم رخداد ($I - P_i$) آن پیشامد را نشان می‌دهد به نحوی که احتمال بین ۰ و ۱ در نوسان است؛ در حالی که بخت می‌تواند بیش از یک باشد. واژه کلیدی در تحلیل رگرسیون لجستیک سازه‌ای به نام لوچیت است که لگاریتم طبیعی بخت می‌باشد (پیریونسی، ۲۰۲۰).

رگرسیون لجستیک به صورت فرمول (۲) تعریف می‌شود:

$$Z_i = In \left[\frac{P_i}{1-P_i} \right] = \beta_0 + \sum \beta_i X_i \quad (2)$$

در معادله ۲ In بیانگر لگاریتم طبیعی است. در مدل رگرسیون لجستیک احتمال رخداد پیشامد بر اساس رابطه (۳) محاسبه می‌شود:

$$P_i = IIi(x_1 x_2, \dots, x_k) = e^{\beta_0 + \sum \beta_i X_i} \quad (3)$$

یکی از منافع رگرسیون لجستیک بی نیازی آن به مفروضات محدود کننده آماری در رابطه با متغیرهاست. مسئله اصلی که در این مدل وجود دارد این است که تغییرات یکسان وضعیت موجود همیشه تغییرات یکسانی را در احتمال به دست آمده به دنبال ندارد. این موضوع زمانی که احتمال نزدیک مقدار ۱ یا ۰/۵ باشد اهمیت بیشتری پیدا می‌کند (زارعی، ۱۳۹۷).

الگوریتم شبکه‌های عصبی

در سال‌های اخیر پیش‌بینی و مدل‌سازی به وسیله شبکه‌های عصبی رشد یافته است. یک شبکه‌های عصبی مصنوعی، مجموعه‌ای از نرونهاست که هم متصل در لایه‌های مختلف (چند لایه، MLP) است که اطلاعاتی را برای یکدیگر ارسال می‌کنند. ساده ترین شکل شبکه فقط دو لایه دارد، لایه ورودی و لایه خروجی. ارتباط بین هر ورودی و خروجی به وسیله وزنی که حاکی از اهمیت نسبی ورودی برای محاسبه ارزش خروجی است، تعیین می‌گردد. بر این اساس، ارزش نرون خروجی Net از ورودی مشاهده t از طریق رابطه (۴) به دست می‌آید:

$$Net_t = a_0 x_0 + a_1 x_{1t} + a_2 x_{2t} = \sum_{i=0}^2 a_i x_{it} \quad (4)$$

پس از آن نرون خروجی، ارزش حاصله را با استفاده از یک تابع فعال‌سازی (محرك) یا تبدیل که با f نشان داده می‌شود - پردازش می‌کند (مکیان و همکاران، ۱۳۹۰). تابع فعال‌سازی خطی ساده‌ترین شکل شبکه‌های عصبی است. ارزش به دست آمده از رابطه (۴) با یک تابع فعال‌سازی خطی، خروجی نهایی شبکه برای مشاهده t را به صورت رابطه (۵) می‌سازد.

$$y_t = f(Net_t = a_0 x_{0t} + a_1 x_{1t} + a_2 x_{2t}) = a_0 x_{0t} + a_1 x_{1t} + a_2 x_{2t} \quad (5)$$

تقریباً تمام شبکه‌های عصبی در بخش‌هایی از شبکه از توابع فعال‌سازی غیرخطی استفاده می‌کنند. این مسئله باعث می‌شود شبکه الگوهای غیرخطی مناسبی از مجموعه داده‌های پیچیده تولید نماید (زارعی، ۱۳۹۷). رایج‌ترین تابع فعال‌سازی مورد استفاده در ادبیات شبکه‌های عصبی تابع سیگموئیدی است:

$$f(x) = \frac{1}{1+e^{-x}} \quad (6)$$

در این پژوهش، برای پیش‌بینی از طریق شبکه‌های عصبی،تابع فعال‌سازی لایه میانی و لایه خروجی به ترتیب سیگموئید و خطی در نظر گرفته شده است (زارعی، ۱۳۹۷).

از مزیت‌های شبکه‌های عصبی می‌توان به قابلیت آن در حل مسائل غیرخطی اشاره کرد. هم‌چنان شبکه‌های عصبی ابزار مناسبی برای مواردی است که در آنها جواب‌ها مهم‌تر از درک روابط علت و معلولی است. اما شبکه‌های عصبی قادر به ارائه معادله‌ای با ضرایب معین نمی‌باشد؛ ولی رگرسیون از جهت برآورد ضرائب متغیرهای تاثیرگذار بر هدف ما برتری بهتری دارد (بوناکرسو، ۲۰۱۷).

ماشین‌های بردار پشتیبان

نخستین روش طبقه‌بندی الگوها در سال ۱۹۳۶ توسط فیشر^۱ بر اساس کاهش خطای طبقه‌بندی داده‌های آموزشی برای بهینه‌سازی الگوها ارائه گردید. سپس ولادیمیر وینیک^۲ در سال ۱۹۶۵ الگوریتم ماشین‌های بردار پشتیبان را مبتنی بر نظریه آماری یادگیری ارائه نمود (حسینی نسب، ۱۳۹۲). الگوریتم ماشین‌های بردار پشتیبان کاربردهای زیادی در تقریب توابع از جمله خوشبندی، طبقه‌بندی و رگرسیون دارد. الگوریتم ماشین بردار پشتیبان در زمان ایجاد، تنها شامل طبقه‌بندی دو کلاسه بود که در ادامه به طبقه‌بندی چند کلاسه نیز تعمیم یافت.

ماشین‌های بردار پشتیبان داده‌ها را به صورت بردار پردازش می‌کنند و همواره در میان تمام ابرصفحات تفکیک داده‌ها، ابرصفحه‌ای را انتخاب می‌کنند که بیشترین تفکیک‌پذیری با بیشترین حاشیه را میان داده‌های کلاس‌های مختلف حاصل می‌کنند. ابرصفحه مطلوب به نحوی انتخاب می‌شود که فاصله آن از نزدیک ترین داده حداقل شود. به نزدیک ترین نقاط آموزشی با بیشترین حاشیه ابرصفحه، بردارهای پشتیبان اطلاق می‌شود. چنین ابرصفحه‌ای در صورت وجود، ابرصفحه با بیشترین حاشیه نامیده می‌شود. در صورتی که نقاط آموزشی را به صورت $[x_i, y_i]$ ، بردار ورودی را $x_i \in R^n$ و ارزش طبقه را $y_i \in \{-1, 1\}$ نشان دهیم، آنگاه صفحه بهینه‌ای که طبقات تصمیم‌گیری باینتری را تفکیک می‌کند، به صورت رابطه (۷) خواهد بود.

$$y = sign(\sum_{i=1}^N y_i a_i (X \cdot X) + b) \quad (7)$$

که در آن y خروجی معادله، y_i ارزش طبقه نمونه آموزشی و X_i ضریب داخلی هستند.
بردار (x_1, x_2, \dots, x_n) بیانگر یک داده ورودی و بردارهای $X_i: i = 1, \dots, N$ بردارهای پشتیبان هستند. در رابطه ۱ پارامترهای a_i و b تعیین کننده ابرصفحه هستند.

1. Bonaccorso

2. Fisher

3. Vladimir N. Vapnik



در صورتی که امکان تفکیک داده ها به صورت خطی نباشد، رابطه (۷) به صورت رابطه (۸) تغییر می کند.

$$Y = \text{sign}(\sum_{i=1}^N y_i a_i K(X_i X_i) + b) \quad (8)$$

تابع $K(X_i X_i)$ تابع کرنل^۱ است که برای ماشین هایی با سطوح مختلف تصمیم گیری غیرخطی مبتنی بر داده های موجود، ضربهای داخلی تولید می کند (ابراهیمی هروی، ۱۳۹۶). برای مثال سه نوع تابع کرنل که در الگوریتم ماشین های بردار پشتیبان به کار می روند عبارتند از: تابع کرنل پایه شعاعی، تابع کرنل پرسپترون چند لایه و تابع کرنل چند جمله ای. قابلیت بکار گیری کرنلها به عنوان نقطه قوت کلیدی ماشین های بردار پشتیبان باعث می شود ماشین های بردار پشتیبان، انعطاف بالایی برای حل انواع مختلف مسائل با دشواری های مختلف داشته باشند (نیوتا، ۲۰۱۷).

بعضی از ویژگی های ماشین های بردار پشتیبان عبارتند از: آموزش آسان ماشین های بردار پشتیبان، نتایج خوب با نمونه های آموزشی اندک، عدم نیاز به بهینه سازی محلی برخلاف شبکه های عصبی و یافتن بهترین مدل. البته برای دستیابی به این مزیت ها باید در انتخاب تابع هسته ای مناسب دقت لازم صورت گیرد. (لانگ، ۲۰۱۹)

الگوریتم اعتبار سنجی ضربدری (k-f)

در الگوریتم اعتبار سنجی ضربدری، داده ها به K زیر مجموعه تقسیم می شوند. از این K زیر مجموعه، در هر بار یک زیر مجموعه برای اعتبار سنجی و $K-1$ زیر مجموعه دیگر برای آموزش مورد استفاده قرار می گیرند. این فرایند K بار تکرار می شود و همه داده ها دقیقاً یک بار برای آموزش و یک بار برای اعتبار سنجی استفاده می شوند. در پایان میانگین حاصل از این K بار اعتبار سنجی به عنوان تخمین پایانی برگزیده می شود. البته می توان از روش های دیگر نیز برای ترکیب نتایج استفاده کرد. بطور معمول از ۱۰ Fold طبقه بندی داده ها استفاده می شود.

سعی می شود در روش K-Fold طبقه های نسبت داده های هر کلاس در هر زیر مجموعه و مجموعه اصلی یکسان باشد.

مساحت زیر منحنی مشخصه عملیاتی گیرنده AUC به عنوان یک معیار عملکرد طبقه بندی کننده مناسب و دقیق دیده می شود. AUC می تواند از ۰ تا ۱ ارزش داشته باشد. یک مقدار ۰.۵ به این معنی است که پیش بینی ها دقیق نیستند، در حالی که مقدار ۱ به این معنی است که پیش بینی ها عالی هستند. مزیت AUC بر دیگر معیار های عملکرد (مانند درصد به طور کامل طبقه بندی نشده این است که همه مقادیر قطع شده را شامل می شود به صورت رابطه (۹) تعریف می شود (امامی، ۱۳۹۳)

$$AUC = \int_0^1 \frac{TP}{(TP+FN)} d \frac{FP}{(FP+TN)} = \int_0^1 \frac{TP}{P} d \frac{FP}{N} \quad (9)$$

-
- 1. Kernel
 - 2. Long

الگوریتم نزدیک ترین همسایه‌های K

الگوریتم نزدیکترین همسایه‌های K الگوریتمی است که در آن بر اساس الگوهای آموزش، داده‌های آزمون طبقه‌بندی شوند. در این روش داده‌های مشابه در نزدیکی یکدیگر قرار می‌گیرند، به این ترتیب فاصله بین داده‌ها بر اساس عدم مشابهت آنها اندازه گیری و تفسیر می‌شود. به این ترتیب داده‌های کنار هم، همسایه نامیده شده و فاصله هر داده جدیدی که به الگوریتم معرفی می‌شود، با دیگر داده‌ها محاسبه و در دسته‌ای که در نزدیکترین فاصله قرار دارد، جای می‌گیرد (لین^۱، ۲۰۱۸). K به تعداد همسایگانی که در فرایند دسته بندی نقش مهمی ایفا می‌کنند اطلاق می‌گردد. تعداد صحیح متغیر K بستگی به اندازه داده‌ها به عنوان پارامتری مهم در این فرایند دارد. یکی از روش‌های معمول در انتخاب صحیح، استفاده از الگوریتم تپه نورده است (سیگو، ۲۰۲۰). در این روش میزان k را مرتب افزایش داده تا به بهترین انتخاب برسد. معیار بهبود در این روش فاصله‌ها می‌باشد که از طریق مجموع قدر مطلق فاصله‌ها، فاصله اقلیدسی یا فاصله همینگ برای تعیین این معیار استفاده می‌شود. به طور خلاصه مراحل زیر برای انجام روند برآورد با الگوریتم نزدیک ترین همسایه‌های K مورد استفاده قرار می‌گیرد:

الف: تعیین تعداد k اولیه در نرم افزار

ب: محاسبه فاصله بین نمونه مورد بررسی با تمام داده‌های ورودی

ج: مرتب سازی فاصله‌ها بر اساس کمترین آن‌ها و مشخص نمودن نزدیکترین‌ها بر حسب k

د: استفاده از بیشترین نزدیکترین همسایه‌ها جهت برآورد مقادیر جدید (لانگ، ۲۰۱۹).

تجزیه و تحلیل داده‌ها و آزمون فرضیه‌ها

در جدول زیر شاخص‌های آمار توصیفی پنج مدل مورد استفاده در پژوهش ارائه گردیده است. بر اساس شاخص‌های موصوف میانگین^۲ R در روش ماشین بردار پشتیبان دارای بیشترین میزان و معادل ۰/۹۴ با انحراف معیار ۰/۰۰۱ می‌باشد. پس از آن به ترتیب مدل شبکه‌های عصبی مصنوعی، رگرسیون لجستیک، اعتبارسنجی متقابل و در نهایت، نزدیکترین همسایه‌های k قرار دارند. سایر آمارهای توصیفی نیز پایایی و روایی داده‌ها را تأیید می‌نماید.

جدول ۶. آمار توصیفی مدل‌های مورد استفاده در پژوهش

شاخص‌های آمار توصیفی	میانگین	انحراف معیار	حداقل	حداکثر	میانه	چولگی	کشیدگی
مشین بردار پشتیبان	۰/۹۴	۰/۰۱	۰/۹۱	۰/۹۹	۰/۹۶	۰/۰۲۴	۱/۱۴-
	۹۶/۲۴	۲۲/۰۷	۵۸/۰۳۳	۱۳۱/۰۹۳	۹۷/۰۲۸	۰/۰۲۴-	۱/۱۶-
	۵۵/۰۴۹	۱۸/۰۸۲	۲۳	۸۵	۵۷	۰/۰۲۶-	۱/۱۵-
رگرسیون	۰/۰۸۹	۰/۰۰۲	۰/۰۸۳	۰/۰۹۵	۰/۰۸۹	۰/۰۰۱-	۱/۲۱-

منبع: نتایج پژوهش

کشیدگی	چولگی	میانه	حداکثر	حداقل	انحراف معیار	میانگین	شاخص های آمار توصیفی	
							MSE	Lجستیک
۰,۹۴-	۰,۱۳-	۱۲۲,۵۳	۱۵۰,۸۵	۸۷,۰۶	۱۷,۹	۱۲۱,۰۷		
۰,۹۳-	۰,۱۴-	۸۶,۵	۱۱۳	۵۳	۱۶,۸۹	۸۵,۴۶	RMSE	
۱,۱۹-	۰,۰۲-	۰,۸۷	۰,۹۲	۰,۸۳	۰,۰۲	۰,۸۷	R^2	اعتبارستحی متقابل
۰,۹۸-	۰,۰۲-	۱۵۲,۴۲	۱۸۳,۵۵	۱۱۹,۹۷	۱۷,۹	۱۵۲,۱۹	MSE	
۰,۹۸-	۰,۰۵-	۱۱۵,۵	۱۴۵	۸۴	۱۶,۹۹	۱۱۵,۱۳	RMSE	
۱,۱۵-	۰,۰۱	۰,۸۵	۰,۸۸	۰,۸۲	۰,۰۲	۰,۸۵	R^2	نزدیکترین همسايه هاي k
۱,۰۵-	۰,۱۷-	۱۸۱,۷۴	۲۱۹,۱	۱۳۷,۴	۲۳,۸۴	۱۸۱,۳۳	MSE	
۱,۰۵-	۰,۱۶-	۱۴۳,۵	۱۷۹	۱۰۱	۲۲,۶۹	۱۴۲,۷۹	RMSE	
۱,۲۱-	۰,۰۱-	۰,۹۱	۰,۹۶	۰,۸۸	۰,۰۲	۰,۹۱	R^2	شبکه هاي عصبي
۱,۲۸-	۰,۰۱	۹۸,۱۵	۱۳۱,۱۷	۶۶,۴۹	۱۹,۰۱	۹۸,۱۳	MSE	
۱,۲۷-	۰,۰۱	۶۴	۹۵	۳۳	۱۸,۵۸	۶۳,۷۸	RMSE	

بررسی فرضیه پژوهش

فرضیه پژوهش بیان می کند که "دقت پیش بینی مدل های ماشین های بردار پشتیبان، شبکه های عصبی، روش نزدیک ترین همسایه های k، رگرسیون لجستیک و اعتبارستحی متقابل با یکدیگر تفاوت دارد." برای بررسی اعتبار این فرضیه از آزمون تفاوت میانگین ها (تحلیل واریانس) استفاده شده است که با توجه به نتایج مندرج در جدول زیر سطح معنی داری در شاخص R^2 برابر با $0/0440$ و کمتر از $0/05$ درصد است و فرضیه H1 مبنی بر اینکه "بین دقت مدل های ماشین بردار پشتیبان، اعتبارستحی متقابل، رگرسیون لجستیک، شبکه های عصبی و نزدیک ترین همسایه اختلاف معنی داری وجود دارد." پذیرش و فرض صفر پژوهش مبنی بر عدم اختلاف معنی دار دمی شود. این موضوع برای شاخص های MSE و RMSE نیز صادق است و سطح معنی داری در این دو شاخص نیز به ترتیب $0/027$ و $0/031$ است که کمتر از $0/05$ است.

با بررسی میزان دقت R^2 در جدول زیر میزان دقت مدل های یادگیری ماشین قابل رتبه بندی می باشد به نحوی که مدل ماشین های بردار پشتیبان با $0/944$ رتبه اول، مدل شبکه های عصبی با $0/908$ رتبه دوم، مدل رگرسیون لجستیک با $0/888$ رتبه سوم، مدل اعتبارستحی متقابل با $0/868$ رتبه چهارم و روش نزدیک ترین همسایه های K با $0/848$ در رتبه پنجم از نظر میزان دقت قرار دارد. این موضوع در دو شاخص MSE و RMSE نیز با بزرگتر شدن اعداد در جدول همین موضوع را تصدیق می نماید. یعنی عدد کوچکتر در هر دو شاخص بیانگر بودن دقت بیشتر مدل می باشد.

جدول ۷. نتایج آزمون آماری تحلیل واریانس در خصوص دقت مدل‌های یادگیری ماشین

سطح معنی داری	F آزمون	KNN	EM	Log	GANN	SVM	
۰,۰۴۴۰	۳,۵	۰,۸۴۸	۰,۸۶۸	۰,۸۸۸	۰,۹۰۸	۰,۹۴۴	R^2
۰,۰۲۷	۶,۳۸	۱۸۱,۳۳	۱۵۲,۱۹	۱۲۱,۰۷	۹۸,۱۳	۹۶,۲۴	MSE
۰,۰۳۱	۵,۶۴	۱۴۲,۷۹	۱۱۵,۱۳	۸۵,۴۶	۶۳,۷۸	۵۵,۴۹	RMSE

منبع: نتایج پژوهش

بحث و نتیجه‌گیری

بر اساس بررسی‌های صورت گرفته، در پژوهش حاضر امکان استفاده از مدل‌های یادگیری ماشین برای برآورد قیمت سهام در بازار سرمایه وجود دارد و دقت برآورد قیمت سهام در مدل‌های مختلف با یکدیگر متفاوت می‌باشد. برای بررسی اعتبار این فرضیه از آزمون تفاوت میانگین‌ها (تحلیل واریانس) استفاده شده است که با توجه به نتایج مندرج در جدول، سطح معنی‌داری در شاخص R^2 برابر با ۰/۰۴۴۰ و کمتر از ۰/۰۵ درصد است و فرضیه H1 مبنی بر اینکه "بین دقت مدل‌های ماشین بردار پشتیبان، اعتبارسنجی متقابل، رگرسیون لجستیک، شبکه‌های عصبی و نزدیکترین همسایه اختلاف معنی‌داری وجود دارد." پذیرش و فرض صفر پژوهش مبنی بر عدم اختلاف معنی‌دار رد می‌شود.

بر اساس نتایج پژوهش مدل ماشین بردار پشتیبان دارای بیشترین دقت در برآورد قیمت سهام می‌باشد و با $۰,۹۴۴R^2$ در رتبه اول قرار دارد. سایر مدل‌ها به ترتیب عبارتند از روش شبکه‌های عصبی مصنوعی با ۰,۹۰۸، رگرسیون لجستیک با ۰,۸۸۸، اعتبارسنجی متقابل با ۰,۸۶۸ و نزدیکترین همسایه‌های K با ۰,۸۴۸. این رتبه‌بندی بر اساس روش RMSE و روش MSE نیز تأیید می‌شود. به طوری که در جدول فوق مشاهده می‌شود در روش ماشین بردار پشتیبان به عنوان بهترین روش میزان این دو شاخص کمترین مقدار را به خود اختصاص داده و با کاهش دقت با همان ترتیبی که در R^2 به آن دست یافته مقدار شاخص بیشتر می‌شود.

نتایج حاصل از این پژوهش با نتایج تجربی قبلی از این بابت مشابهت دارد که مدل‌های استفاده شده امکان پیش‌بینی قیمت سهام را فراهم می‌آورد که در جداول مربوط به پیشنهاد پژوهش عنوان گردید؛ لیکن از آنجا که از روش مقایسه‌ای بین مدل‌های مورد استفاده در این پژوهش، در پژوهش‌های پیشین وجود ندارد نمی‌توان در خصوص قبول یا رد پژوهش‌های پیشین مطلبی بیان نمود؛ چرا که در واقع مقایسه طیفی از مدل‌های یادگیری ماشین نواوری اصلی این پژوهش بوده است.

پیشنهاد برای پژوهش‌های آتی

با توجه به حجم بسیار زیاد داده‌های موجود در بازار سرمایه، عدم امکان محاسبه دستی این داده‌ها و امكان پیش‌بینی قیمت سهام در بورس اوراق بهادار از طریق مدل‌های یادگیری ماشین به سازمان بورس، شرکت بورس اوراق بهادار و فرابورس، شرکتهای تأمین سرمایه، کارگزاری، سبدگردان و مشاور سرمایه گذاری پیشنهاد می‌شود از مدل‌های یادگیری ماشین جهت بهبود سرمایه گذاری خود و مشتریان و سرمایه گذاران استفاده نمایند.

همچنین، در معاملات الگوریتمی که روش جدیدی در بازار سرمایه ایران به حساب می‌آید، می‌توان از مدل‌های یادگیری ماشین جهت انجام خودکار معاملات استفاده نمود که به طور قطعی بر افزایش راندمان معاملات تأثیر مثبت خواهد داشت.

با توجه به گستردگی روش‌های یادگیری ماشین، در پژوهش‌های آینده می‌توان سایر روش‌های یادگیری ماشین نظیر جنگل تصادفی، سایر روش‌های شبکه عصبی را جهت پیش‌بینی قیمت سهام مورد استفاده قرار داد. در این پژوهش از قیمت باز، بسته، بالاترین و پایین‌ترین قیمت و همچنین نرخ ارز، قیمت نفت و قیمت طلا به عنوان متغیرهای مستقل استفاده شده است، محققین محترم می‌توانند از انديکاتورهای نظير؛ Simple Moving Average (SMA)، Exponential Moving Average (EMA)، Weighted Close (WTCL)، Weighted 10-day Moving Average (WMA)، Moving Average Convergence Divergence (MACD)، Stochastic Oscillator، Average True Range (ATR)، Average Directional Index (ADX)، Relative Strength Index (RSI)، Momentum، Williams R%， Commodity Channel Index (CCI)، Money Flow Index (MFI)، On Balance Volume (OBV)، Accumulation/Distribution (A/D)، Rate Moving Average (VMA)، Variable Moving Average (VMA) Weighted، Parabolic SAR، مستقل استفاده نمایند.

در این پژوهش از داده‌های روزانه برای یادگیری استفاده شده است؛ محققین محترم می‌توانند از داده‌های چهار ساعته، ساعتی و لحظه‌ای برای یادگیری استفاده نمایند. این داده‌ها در پایگاه اطلاع‌رسانی TSETMC موجود می‌باشد و قابل استفاده است؛ لیکن نیازمند قدرت پردازش بیشتر سیستم می‌باشد که با توجه به رشد فناورانه در حوزه رایانه این موضوع قابل انجام می‌باشد.

نتایج حاصل شده برای دوره زمانی ۱۲ ساله ۱۳۸۸ تا ۱۳۹۹ صادق است، لذا برای بررسی اينکه آيا مدل مزبور برای همه بازه‌های زمانی کاربرد دارد یا خير، می‌توان دوره‌های زمانی کوتاه‌تر یا طولانی‌تر و انجام تقسيم‌بندی‌های جزئی‌تر را ملاک عمل قرار داد. برای مثال، می‌توان دوره زمانی دوازده ساله را به شش دوره دو ساله یا دو دوره شش ساله اقدام به پیش‌بینی نمود و سپس، نتایج را مقایسه کرد.

پژوهشگران محترم می‌توانند در پژوهش‌های آتی از نسبت‌های مالی و سایر متغیرهای بنیادی به عنوان متغیر مستقل استفاده نمایند و تأثیر این متغیرها را در پیش‌بینی قیمت سهام مورد سنجش قرار دهند.

ترکیب کردن شبکه عصبی و ماشین بردار پشتیبان، به این صورت که باقیمانده‌های پیش‌بینی با شبکه عصبی توسط ماشین بردار پشتیبان پیش‌بینی گردد یا استفاده از سایر روش‌های پیش‌بینی به صورت ترکیبی می‌تواند به ارتقای دقت پیش‌بینی کمک نماید.

ملاحظات اخلاقی

حامی مالی: مقاله حامی مالی ندارد.

مشارکت نویسنده‌گان: تمام نویسنده‌گان در آماده‌سازی مقاله مشارکت داشته‌اند.

تعارض منافع: بنا بر اظهار نویسنده‌گان در این مقاله هیچ‌گونه تعارض منافع وجود ندارد.

تعهد کپی‌رایت: طبق تعهد نویسنده‌گان حق کپی‌رایت رعایت شده است.



References

- Ahmadvand, Neda, Sohail, Ahmadkhan Beigi, and Abdulvand. (2016). Stock price forecasting with a combined approach of artificial neural networks and colonial competition algorithm based on chaos theory. *Financial Management Strategy*, 5 (3), 27- 73. Doi: 10.22051/jfm.2017.14635.1319. (In Persian).
- Afshari Rad, Elham, Alavi, Seyed Enayat A. and Sinaii, Hassan Ali. (2017). "An intelligent model for predicting stock trends using technical analysis methods" *Financial Research*, Summer 2017, Volume 20, Number 249. (In Persian)
- Ahmadvand, Neda, Sohail, and Ahmadkhan Beigi. (2016). "Stock price forecasting with a hybrid approach of artificial neural networks and colonial competition algorithm based on chaos theory." *Financial management strategy*, number 5. (In Persian)
- Ampomah, E. K; Z. Qin, and G. Nyame. (2020). "Evaluation of tree-based ensemble machine learning models in predicting stock price direction of movement." *Information*, 11(6), 332.
- Ballings, M, D Van den Poel, N Hespeels, and R. Gryp. (2015). "Evaluating multiple classifiers for stock price direction prediction." *Expert systems with Applications*, 42(20), 7046-7056.
- Bonacorso, G. (2017). Machine learning algorithms. Packt Publishing Ltd.
- Ebrahimi Heravi, Behrouz, Kazem Rangzan, Mostafa Kabuli, Hassan Daneshian. (2016). "Comparison of Artificial Neural Network and Fuzzy System Methods in Determining Flood Early Warning Time of the Yellow River Watershed Sub-basin - Khuzestan Province" *Geography and Environmental Planning*, Volume 28, Number 1, Pages 1-20. (In Persian)
- Emami, Mohammad, Yatharbi, Seyyed Shahabuddin. (2013). "The use of artificial neural network in the interpretation of barometric test results". *Scientific Research Journal of Imran Modares*, 14th period, special issue (In Persian)
- Gardening, Shahnaz. (2016). "Techniques and methods of machine learning on big data." National conference of new technologies in electrical and computer engineering. (In Persian)
- Hafezi, R; J. Shahrabi, and E. Hadavandi. (2015). "A bat-neural network multi-agent system (BNNMAS) for stock price prediction: Case study of DAX stock price ." *Applied Soft Computing*, 29 196-210.
- Hosseini-nasab, Hojjat, Karimi Teklo, Salim and Yousefinejad, Marzieh. (2012). "Comparison of the accuracy of support vector machines and artificial neural networks approaches in predicting the profit per share of companies listed on the Tehran Stock Exchange." *Bi-Quarterly Economic Essays*, 109-134-10 (In Persian)
- Houssein, E. H; M. Dirar, K. Hussain, and W. M. mohamed. (2021). "Artificial Neural Networks for Stock Market Prediction: A Comprehensive Review ." *Metaheuristics in Machine Learning: Theory and Applications* 409-444.
- Kantardzik, Mehmed. (2012). Data mining, translated by Amir Alikhanzadeh, Computer Sciences Publishing. (In Persian)
- Lin, Q. (2018). "Technical analysis and stock return predictability: An aligned approach." *Journal of financial markets*, 38 103-123.
- Long, W; L Song, and Y Tian. (2019). "A new graphic kernel method of stock price trend prediction based on financial news semantic and structural similarity ." *Expert Systems with Applications*, 118 411-424.

- Nivetha, R. Y; and C. Dhaya. (2017). "Developing a prediction model for stock analysis." International Conference on Technical Advancements in Computers and Communications (ICTACC). IEEE.
- Piryonese, S. M; and T. E. El-Diraby. (2020). "Data analytics in asset management: Cost-effective prediction of the pavement condition index." *Journal of Infrastructure Systems*, 26(1), 04019036.
- Rai, Reza, Pouyanfar, Ahmed. (1400), Advanced Investment Management. Side Publications (In Persian)
- Sarmad, Zahra, Bazargan, Abbas and Hijazi, Elaha. (2019). Research methods in behavioral sciences. Post an ad. (In Persian)
- Sigo, M. O; M. Selvam, S. Venkateswar, and C. Kathiravan. (2020). "Application of ensemble machine learning in the predictive data analytics of indian stock market." CIFR Paper Forthcoming.
- Wen Long Zhichen Lu Lingxiao Cui. (2019). "Deep learning-based feature engineering for stock price movement prediction.." Knowledge-Based Systems Volume 164 .163-173.
- Zarei, Qasim, Mohammadian, Rana, Hashedi Neiri, Hatef and Ajirlu, Mohammad. (2017) "Comparison of fuzzy neural network methods with fuzzy wavelet neural networks in predicting stock prices of banks listed on the Tehran Stock Exchange" *Journal of Financial Management Strategy*, Fall 6th Year 2017 Number 2. (In Persian)
- Zhou, X, L Wang, H Liao, S Wang, and B Lev. (2019). "A prospect theory-based group decision approach considering consensus for portfolio selection with hesitant fuzzy information

COPYRIGHTS



This license allows others to download the works and share them with others as long as they credit them, but they can't change them in any way or use them commercially.