



پیش‌بینی شاخص روزانه بورس اوراق بهادار تهران با استفاده از انتخاب ویژگی‌های مناسب برای شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM)

سمیه محبی^۱

محمداسماعیل فدائی نژاد^۲

محمد اصولیان^۳

محمد رضا حمیدی‌زاده^۴

تاریخ دریافت مقاله: ۱۴۰۱/۰۳/۲۹ تاریخ پذیرش مقاله: ۱۴۰۱/۰۶/۲۱

چکیده

شاخص بورس یکی از عوامل مؤثر در سرمایه‌گذاری محسوب می‌شود. زیرا می‌تواند نشان‌دهنده وضعیت سلامت و روند تغییرات کلان اقتصادی یک کشور باشد. ویژگی‌های متنوعی بر شاخص تأثیر می‌گذارند. ترکیب‌های مختلف این ویژگی‌ها، یک فضای حالت گسترده ایجاد می‌کنند. از این‌رو، فراهم کردن یک مجموعه داده شامل همه‌ی این ترکیب‌ها برای آموزش مدل پیش‌بینی شاخص بورس، غیرعملی است. در این پژوهش تلاش شده است پس از جمع‌آوری تعداد قابل توجهی از ویژگی‌های مؤثر بر شاخص بورس (۵۳ ویژگی)، روشی برای انتخاب ویژگی‌های مناسب مدل پیش‌بینی شاخص بورس با هدف افزایش دقت پیش‌بینی ارائه شود. بدین منظور، از الگوریتم mRMR به عنوان الگوریتم پایه استفاده شده است. همچنین برای انتخاب مدل مناسب، به مقایسه‌ی تعدادی از پرکاربردترین مدل‌های هوش مصنوعی در پیش‌بینی شاخص بورس اقدام شد و با توجه به نتایج حاصل شده، شبکه‌ی LSTM برای پیش‌بینی شاخص بورس انتخاب گردید. نتایج این مطالعه نشان می‌دهد که با استفاده از شبکه‌ی LSTM و روش پیشنهادی در گزینش ویژگی‌ها، می‌توان با ۸ ویژگی انتخابی به دقت بالایی در پیش‌بینی روزانه شاخص کل بورس اوراق بهادار تهران دست‌یافت. به‌طوری‌که میانگین درصد خطا حدود ۲/۶۶ محاسبه شده است.

کلمات کلیدی

پیش‌بینی شاخص بورس، انتخاب ویژگی، یادگیری عمیق، شبکه عصبی حافظه کوتاه‌مدت ماندگار

۱-دانشجوی دکتری رشته مدیریت مالی، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. somayeh.mohebi@gmail.com

۲-دانشیار گروه مدیریت مالی و بیمه، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. (نویسنده مسئول). m-fadaei@sbu.ac.ir

۳-استادیار گروه مدیریت مالی و بیمه، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. m_oozolian@sbu.ac.ir

۴-استاد گروه مدیریت بازرگانی، دانشکده مدیریت و حسابداری، دانشگاه شهید بهشتی، تهران، ایران. m-hamidzadeh@sbu.ac.ir

مقدمه

روند بازار سهام کشورها می‌تواند منعکس‌کننده توسعه اقتصادی آن‌ها باشد. با پیش‌بینی بازارهای سهام و اقدامات به موقع و درست درخصوص تغییرات بازار می‌توان کمک به روند توسعه اقتصادی کشورها نمود. در این راستا، یک روش پیش‌بینی خوب و دقیق بازار سهام می‌تواند به مسئولان و تحلیل‌گران بازارهای مالی کمک کرده تا به موقع به تغییرات غیرعادی بازار سهام توجه کرده و اقدامات هدفمندی را انجام دهند که به طور موثر زیان بازار سهام را کاهش داده و دامنه ریسک را محدود کنند. از آنجایی که بازار سهام تحت تاثیر عوامل مختلفی می‌باشد که بسیاری از آن‌ها ممکن است به‌عنوان متغیر ورودی در پیش‌بینی آن مورد استفاده قرار گیرند، بنابراین پیش‌بینی بازار سهام همواره موضوعی چالش برانگیز برای سرمایه‌گذاران، معامله‌گران سهام و تحلیل‌گران بازارهای مالی بوده است. پژوهش‌های پیشین نشان دادند شبکه‌های عصبی مصنوعی به دلیل توانایی ذاتی آن‌ها در تخمین روابط غیرخطی با دقت بالا، تحلیل‌های چند متغیره بدون هیچ فرض از پیش تعیین شده‌ای و سهولت تعمیم، پتانسیل بالایی برای پیش‌بینی دارند. اخیراً نیز، رویکردهای یادگیری عمیق^۲ با نتایجی ظاهر شده‌اند که عملکرد بهتری نسبت به هم‌تایان سنتی خود دارند (سزر و همکاران^۱، ۲۰۲۰). یادگیری عمیق گونه‌ای از شبکه‌های عصبی مصنوعی است که شامل چندین لایه پردازش اطلاعات است که مفاهیم انتزاعی سطح بالا را با استفاده از یادگیری در سطوح و لایه‌های مختلف مدل می‌کند (لاری دشت و محمدی، ۱۳۹۵). مهم‌ترین مزیت الگوریتم‌های یادگیری عمیق نسبت به مدل‌های سنتی شبکه‌های عصبی، استخراج خودکار ویژگی‌های مناسب از ورودی‌های خام می‌باشد که از آن برای روند یادگیری مدل استفاده می‌کند (هیران‌شا و همکاران^۲، ۲۰۱۸). از میان تکنیک‌های مختلف یادگیری عمیق که در علوم مختلف کاربردهای فراوانی دارند، پژوهشگران حوزه مالی جهت پیش‌بینی قیمت با توجه به ویژگی‌های سری‌های زمانی مالی، عمدتاً از معماری‌های بخصوصی نظیر شبکه عصبی حافظه کوتاه‌مدت ماندگار^۳ (LSTM) استفاده کرده‌اند (شریف‌فر و همکاران، ۱۴۰۰).

در پژوهش‌های پیشین، درجه متفاوتی از موفقیت در مورد دقت مدل‌های شبکه عصبی دیده می‌شود، که یکی از دلایل احتمالی عدم دستیابی به نتیجه مورد انتظار می‌تواند فرآیند انتخاب متغیرهای ورودی‌های مدل پیش‌بینی باشد، زیرا عملکرد شبکه‌های عصبی، به‌طور مستقیم به کیفیت ویژگی‌ها مرتبط است و قرار دادن تعداد بیش از اندازه متغیر مستقل در رگرسیون، علاوه بر مختل کردن یادگیری شبکه‌های عصبی، زمان یادگیری را نیز افزایش می‌دهد. بنابراین، انتخاب ورودی‌های درست یکی از عوامل اصلی تأثیرگذار در کارایی شبکه‌های عصبی می‌باشد. به‌طوریکه اگر ترکیب خوبی

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

از ویژگی‌ها در نظر گرفته شود، احتمال بیشتری وجود دارد که مدل شبکه عصبی عملکرد بهتری داشته باشد و بتواند قیمت سهام را به خوبی پیش‌بینی کرده و وضعیت بازار را بهتر اطلاع دهد. از این رو، هدف این مطالعه ارائه یک مدل مناسب توسعه‌یافته با مجموعه‌ای از ویژگی‌های بهینه به‌منظور پیش‌بینی شاخص روزانه بورس اوراق بهادار تهران می‌باشد. در این راستا این پژوهش بر روی سه موضوع تمرکز می‌کند:

- ۱- به منظور مشخص شدن دقت مدل LSTM برای پیش‌بینی شاخص بورس، به مقایسه آن با تعدادی از مناسب‌ترین مدل‌های هوش مصنوعی مورد استفاده در پیش‌بینی بازار سهام، پرداخته می‌شود.
- ۲- برای انتخاب مجموعه‌ی ویژگی‌های ورودی مدل LSTM یک روش مناسب ارائه می‌گردد. برای این منظور، از یک روش تخمین کمینه‌ی افزونگی، بیشینه‌ی وابستگی^۴ (mRMR)، به عنوان الگوریتم پایه بهره گرفته می‌شود.
- ۳- به شناسایی ویژگی‌های موثر برای مدل پیش‌بینی شاخص روزانه بورس اوراق بهادار تهران، اقدام می‌شود.

بنابراین، متدولوژی پیشنهاد شده در این پژوهش جهت شناسایی، اولویت‌بندی و انتخاب ویژگی‌های مناسب برای بهبود عملکرد مدل پیش‌بینی شاخص بورس با توجه به سادگی و اثربخشی استفاده از آن بیانگر سهم علمی این پژوهش در پیشبرد مرزهای دانش می‌باشد.

در ادامه ساختار مقاله به شرح زیر می‌باشد، در بخش بعدی، مروری کوتاه بر مبانی نظری و مطالعات تجربی مرتبط با موضوع پژوهش صورت می‌گیرد. سوال‌ها و روش‌شناسی پژوهش به ترتیب در بخش ۳ و ۴ توضیح داده می‌شوند. در بخش ۵ تجزیه و تحلیل داده‌ها و رویکرد پیشنهادی برای پیش‌بینی شاخص بورس ارائه می‌شود. در نهایت در بخش ۶ به بحث و نتیجه‌گیری، و توصیه‌های کاربردی پژوهش پرداخته می‌شود.

مبانی نظری و پیشینه تحقیق

در گذشته پژوهشگران از دانش آماری برای تجزیه و تحلیل داده‌های مالی استفاده می‌کردند. لازمه این مدل‌ها وجود رابطه خطی، توزیع نرمال و مانا بودن داده‌هاست که معمولاً این شرایط در بازارهای مالی مهیا نیست. زیرا بازارهای مالی یک سیستم پویا، پیچیده، تکاملی، نویزی، غیرخطی و ناپارامتریک هستند که تحلیل و پیش‌بینی این بازارها را بسیار پیچیده کرده است (ژونگ و انکه، ۲۰۱۷:۵). بنابراین روش‌های محاسبات نرم، مکانیسم‌های سازگارتر و انعطاف‌پذیرتری برای بهبود دقت پیش‌بینی هستند.

شبکه‌های عصبی مصنوعی، از جمله تکنیک‌های مجاسباتی نرم می‌باشند که با موفقیت نسبی در مدل‌سازی و پیش‌بینی بخش‌های متعدد بازارهای مالی به کار گرفته شده‌اند (لی، ۲۰۰۹). شبکه‌های یادگیری عمیق یکی از انواع شبکه‌های عصبی مصنوعی است که به علت استفاده از چندین لایه پردازش اطلاعات، امکان استخراج خودکار ویژگی‌های مناسب برای پیش‌بینی الگوهای پیچیده را فراهم کرده است (سزر، و اوزبایوگلو، ۲۰۱۸). از شبکه‌های عصبی عمیق، نتایج بسیار خوبی در پردازش بصری و کاربردهای صوتی به دست آمده است. محققان بازار سهام سعی نموده از این فناوری جدید برای پیش‌بینی قیمت سهام استفاده کرده تا دقت پیش‌بینی آن را بهبود بخشند. با بررسی تحقیقات مرتبط، می‌توان دریافت که رایج‌ترین شبکه‌های عصبی عمیق بکارگرفته شده برای پیش‌بینی قیمت سهام، شبکه عصبی پیچشی^۸ (CNN)، شبکه عصبی بازگشتی^۹ (RNN) و شبکه حافظه کوتاه‌مدت ماندگار (LSTM) هستند (دینگ و همکاران، ۲۰۲۲).

در سال ۲۰۰۶، هینتون و همکاران^{۱۱} شبکه باور عمیق^{۱۲} (DBN) را پیشنهاد کردند که از آن زمان به بعد، شبکه‌های عصبی عمیق به سرعت توسعه یافته‌اند. جی و ژنگ^{۱۳} (۲۰۱۷)، یک مدل پیش‌بینی مبتنی بر شبکه عصبی CNN و شبکه عصبی BP برای پیش‌بینی قیمت‌های آتی فلز روی شانگهای ایجاد کرده و بر اساس شواهد تجربی نشان داده که مدل ارائه شده از درجه دقت نسبتاً بالایی برای انتظارات قیمت آتی برخوردار است. پلنگی و همکاران^{۱۴} (۲۰۱۶)، تایید کردند که مدل RNN می‌تواند اطلاعات سری‌های زمانی را پردازش کند، اما از آنجا که این شبکه مشکل محو شدن گرادیان را دارد، تجزیه و تحلیل داده‌های سری زمانی طولانی مدت با آن مشکل است. برای حل مشکل شبکه عصبی RNN، شبکه LSTM ارائه شد که قابلیت استخراج الگوهای مخفی در فواصل بلندمدت را دارد. این شبکه با بهره‌گیری از سلول‌های حافظه، توانایی به‌خاطر سپاری و کنترل اطلاعات را دارد و با بهره‌گیری از دروازه‌های کنترلی، زمان مناسب را برای فراموش کردن اطلاعات مشخص می‌کند. بنابراین امکان دستیابی به نتایج دقیق‌تر در سری‌های زمانی و پیش‌بینی‌ها در محدوده بزرگتر را فراهم می‌کند. از این رو، LSTM برای پیش‌بینی قیمت محصولات مالی مانند سهام و صندوق‌ها بسیار مناسب است.

هرچند طبق مطالعات انجام شده، شبکه عصبی LSTM اغلب می‌تواند در مدل‌سازی و پیش‌بینی سری‌های زمانی، مانند توالی کلماتی که جملات را در زبان طبیعی تشکیل می‌دهند، و روند قیمت سهام در طول زمان، عملکرد جالب توجه و مناسبی را ارائه دهد، اما دقت عملکرد آن مانند سایر شبکه‌های عصبی، به میزان قابل توجهی تحت تأثیر نوع و تعداد ویژگی‌های ورودی آن است. بنابراین

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

لازم است برای یک پیش‌بینی دقیق و کارآمد، ویژگی‌هایی که حاوی مفیدترین اطلاعات باشند به‌عنوان ورودی‌های مدل LSTM انتخاب شوند.

برای انتخاب ویژگی، راه‌حل‌ها و الگوریتم‌های فراوانی ارائه شده است. تمامی روش‌ها تلاش می‌کنند مجموعه‌ای از ویژگی‌ها را انتخاب کنند که علاوه بر توصیف کارآمد داده‌های ورودی، در عین حفظ دقت نتایج پیش‌بینی، متغیرهای نویزی و نامربوط را کاهش دهند. یکی از روش‌های انتخاب ویژگی، جستجوی مکاشفه‌ای می‌باشد. در این روش، از بحث همبستگی بین ویژگی‌های ورودی با یکدیگر و نیز با ویژگی خروجی، برای انتخاب ویژگی‌ها استفاده می‌کنند، که در علم آمار با دو اصطلاح توضیح داده می‌شود. اولی بحث ارتباط می‌باشد، که وابستگی بین ویژگی انتخابی به‌عنوان ورودی با خروجی مدل را نشان می‌دهد، و دومی افزونگی می‌باشد، که وابستگی بین ویژگی انتخابی به‌عنوان ورودی با ویژگی‌هایی که تاکنون به‌عنوان ورودی مدل انتخاب شده‌اند، را نشان می‌دهد. در این راستا از یک الگو دقیق استفاده می‌شود که به‌حداکثر شدن وابستگی بین ویژگی ورودی با ویژگی خروجی، و حداقل شدن وابستگی بین ویژگی که قرار است انتخاب شود با ویژگی‌هایی که تاکنون انتخاب شده‌اند، منجر می‌گردد (صدیقی‌ناو، ۱۳۹۱).

پیشینه تحقیق

روند مطالعات در پژوهش‌های داخلی و خارجی، برتری انواع شبکه‌های عصبی عمیق را به سایر تکنیک‌های محاسباتی هوشمند و نیز روش‌های آماری نشان می‌دهد. در ادامه به ذکر چند نمونه از مطالعاتی پرداخته می‌شود که بیشترین ارتباط را با موضوع پژوهش دارند.

شریف فر و همکاران (۱۴۰۰) در مقاله‌ای، توانایی معماری‌های الگوریتم LSTM جهت پیش‌بینی قیمت سهام را مورد بررسی قرار دادند. برای اجرای مدل از سه گروه داده‌های قیمتی، شاخص‌های تکنیکال و معاملات سهامداران حقیقی و حقوقی استفاده شده است. نتایج تحقیق نشان از عملکرد بهتر معماری LSTM همراه با لایه Drop Out نسبت به مدل ساده آن و همچنین مدل RNN دارد. ذوالفقاری، سحابی و بختیاران (۱۳۹۹)، مدلی ترکیبی از شبکه یادگیری عمیق و مدل‌های منتخب خانواده GARCH جهت پیش‌بینی کوتاه‌مدت بازدهی روزانه شاخص کل بورس اوراق بهادار تهران معرفی نمودند. در این پژوهش از میان مدل‌های شبکه یادگیری عمیق، شبکه عصبی بازگشتی مبتنی بر حافظه کوتاه مدت ماندگار (RNN-LSTM) انتخاب و از مدل‌های دارای حافظه کوتاه مدت، GARCH و EGARCH در ساختار مدل استفاده شده است. نتایج تحقیق نشان می‌دهد که مدل‌های ترکیبی دقت پیش‌بینی بالاتری نسبت به مدل‌های منفرد دارند.

امینی‌مهر و همکاران (۱۴۰۰)، به‌منظور پیش‌بینی داده‌های سری زمانی مالی با استفاده از شبکه LSTM، تاثیر روش‌های مختلف پیش‌پردازش داده‌ها را با همدیگر مقایسه کردند. سپس با استفاده از مدل یادگیری عمیق، سری زمانی تغذیه شده توسط وقفه‌های متغیر وابسته، یک بار با کمک موجک و نوفه‌زدایی و بار دیگر بدون موجک پیش‌بینی انجام شده است. نتایج این تحقیق نشان داد که با وجود این که مدل‌های یادگیری عمیق توان خوبی برای استخراج دانش از میان داده‌های سری زمانی مربوط به شاخص بورس تهران را دارند، عملکرد آن‌ها با استفاده از تکنیک نوفه‌زدایی موجک بهبود می‌یابد.

بانداری و همکاران^{۱۵} (۲۰۲۲)، در مطالعه‌ای به پیش‌بینی قیمت پایانی روز آینده شاخص S&P 500 با استفاده از مدل‌های LSTM تک لایه و چندلایه پرداختند و از داده‌های اقتصاد کلان، شاخص‌های تکنیکال و داده‌های قیمتی به‌عنوان متغیرهای ورودی برای اجرای مدل استفاده کردند. نتایج تجربی نشان داد که مدل LSTM تک لایه نسبت به مدل‌های LSTM چند لایه، دقت پیش‌بینی بالاتری را ارائه می‌دهد. یداو، جها، و شران^{۱۶} (۲۰۲۰)، مدل LSTM را با لایه‌های پنهان مختلف در داده‌های بازار سهام هند پیاده‌سازی کرده و به این نتیجه رسیدند که مدل LSTM تک لایه دقت پیش‌بینی بهتری دارد. فیشر و کراوس^{۱۷} (۲۰۱۸)، از شبکه LSTM برای پیش‌بینی جهت حرکات شاخص S&P500 از سال ۱۹۹۲ تا ۲۰۱۵ استفاده کردند. آن‌ها به این نتیجه رسیدند که شبکه LSTM از جنگل‌های تصادفی، شبکه‌های عمیق استاندارد و رگرسیون لجستیک بهتر عمل می‌کند. کرمیانی و همکاران^{۱۸} (۲۰۱۹)، مدل‌های LSTM، پس‌انتشار، ماشین بردار پشتیبان، و فیلتر کالمن را برای پیش‌بینی قیمت سهام ۹ شرکت منتخب مقایسه کردند. براساس یافته‌های پژوهش، LSTM بهترین دقت پیش‌بینی را ارائه کرده است. لی و یو^{۱۹} (۲۰۱۸)، به پیش‌بینی قیمت سهام با استفاده از شبکه LSTM، RNN، و واحد بازگشتی دروازه‌ای (GRU) اقدام نمودند. نتایج تجربی نشان داد که مدل پیش‌بینی مبتنی بر LSTM از نظر دقت نسبت به دو مدل دیگر بهتر عمل می‌کند.

چن و زو^{۲۰} (۲۰۱۸)، براساس یادگیری عمیق، به پیش‌بینی شاخص شانگهای و شنژن ۳۰۰ اقدام نمودند. آن‌ها نتایج پیش‌بینی را با ۱۹ مدل پیش‌بینی نوسان مقایسه کردند و به طور تجربی ثابت کرده که دقت پیش‌بینی یادگیری عمیق بهتر از سایر مدل‌های رایج پیش‌بینی است. یوکسو و لی^{۲۱} (۲۰۱۹)، از مدل LSTM برای مطالعه روند شاخص‌های سهام استفاده کردند و آن را با مدل‌هایی مانند SVR مقایسه کردند و دریافتند که مدل LSTM دقت پیش‌بینی بهتری دارد.

سوالات پژوهش

(۱) دقت مدل LSTM در پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران در مقایسه با سایر

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

مدل‌های هوش مصنوعی مورد استفاده در بازارهای مالی چگونه است؟

۲) عملکرد الگوریتم معرفی شده در این پژوهش جهت انتخاب تعداد و نوع ویژگی‌های ورودی به مدل LSTM در مقایسه با روش mRMR-MID در میزان دقت پیش‌بینی شاخص بورس اوراق بهادار تهران چگونه است؟

روش‌شناسی پژوهش

در این بخش از مقاله، مجموعه داده، تکنیک انتخاب ویژگی با الگوریتم تفاضل اطلاعات متقابل، شبکه عصبی حافظه کوتاه‌مدت ماندگار و معیارهای ارزیابی عملکرد مدل‌های پیش‌بینی مورد استفاده در این پژوهش، معرفی می‌شوند.

ایجاد مجموعه داده

داده‌های مالی و اقتصادی مورد استفاده در این پژوهش که از مبانی تئوریک استخراج شده و در مطالعات پیشین مورد تأیید واقع شده‌اند، بصورت روزانه به مدت ۱۱۰۸ روز کاری بورس تهران جمع‌آوری شده‌اند. این داده‌ها در جدول ۱ شرح داده شده‌اند.

جدول ۱- فهرست ویژگی‌های مورد بررسی برای پیش‌بینی شاخص کل بورس اوراق بهادار تهران

نام ویژگی	توصیف مختصر ویژگی
Tehran Exchange Dividend and Price Index	بازده شاخص کل در سه روز گذشته
Trading Volume	تغییر نسبی حجم معاملات در سه روز گذشته
Index of 50 more active Companies	بازده شاخص ۵۰ شرکت فعال بورس در سه روز گذشته
30 Largest Companies Index	بازده شاخص ۳۰ شرکت بزرگ در سه روز گذشته
Exponential Moving Average	میانگین متحرک نمایی قیمت پایانی ۱۰، ۲۰، ۵۰ و ۲۰۰ روز گذشته
Moving Average	میانگین متحرک قیمت پایانی ۵، ۱۰، ۳۰ روز گذشته
Relative Difference in Percentage	تفاوت نسبی در درصد بازده شاخص در ۵، ۱۵، ۳۰ و ۲۰ روز گذشته
Moving Price level Percentage	شاخص سطح حمایت و مقاومت قیمت برای ۳۰ و ۱۲۰ روز گذشته
OPEC Oil Prices	قیمت نفت اوپک با ۴ وقفه و تغییرات نسبی ۳ روز گذشته آن
USD/IRR	قیمت دلار با ۴ وقفه و تغییرات نسبی ۳ روز گذشته آن
Euro/IRR	قیمت یورو با ۴ وقفه و تغییرات نسبی ۳ روز گذشته آن
Gold Coin Price	قیمت سکه طلا با ۴ وقفه و تغییرات نسبی ۳ روز گذشته آن

آماده سازی مجموعه داده

ترتیب نمونه‌ها در داده‌های جمع‌آوری شده، الگوی معنی‌دار مشخصی ندارند. از این رو در مدل پیشنهادی، برای پیش‌بینی شاخص، بر وابستگی بین نمونه‌های متوالی توجه می‌شود. سپس به منظور

یکسان کردن مقیاس پارامترها، اقدام به نرمال‌سازی داده‌ها می‌شود. برای نرمال‌سازی پارامترها که شامل تعیین مقدار هر پارامتر در بازه‌ی بین صفر و یک است، از رابطه‌ی ساده ۱ استفاده می‌شود:

$$\eta_{i,j} = \frac{v_{i,j} - \min(V_j)}{\max(V_j) - \min(V_j)} \quad (1)$$

که V_j مجموعه‌ی مقادیر پارامتر j ام و $v_{i,j} \in V_j$ که i شماره‌ی نمونه در مجموعه داده است. پس $\eta_{i,j}$ مقدار نرمال‌شده‌ی نمونه‌ی i ام از پارامتر j است.

برای استفاده از مدل LSTM، نیاز است که داده‌های ورودی مدل، از آرایه ۲ بعدی (تعداد نمونه‌ها، تعداد ویژگی‌های ورودی) به آرایه ۳ بعدی (تعداد نمونه‌ها، اندازه مرحله زمانی، تعداد ویژگی‌های ورودی) تبدیل شوند. بدین منظور، عمق آرایه سه‌بعدی، برابر با تعداد ویژگی‌ها در نظر گرفته شده است. همچنین، تعداد سطرها در این آرایه برابر با تعداد نمونه‌ها است و تعداد ستون‌های این آرایه برابر با عدد ۵ در نظر گرفته شده است. در واقع، برای هر نمونه شاخص، برای هر ویژگی، از ۵ مقدار اخیر آن استفاده می‌شود. در نهایت، جهت اجرای مدل، داده‌ها به دو بخش داده‌های آموزش (۷۵ درصد) برای ساخت مدل و داده‌های آزمایش (۲۵ درصد) برای آزمون مدل تقسیم شده است.

انتخاب ویژگی با الگوریتم تفاضل اطلاعات متقابل

تغییرات شاخص بورس به ویژگی‌های مختلفی وابسته است. استفاده از تمامی این ویژگی‌ها به عنوان ورودی‌های مدل پیش‌بینی شاخص، علاوه بر اینکه باعث افزایش زمان آموزش مدل می‌شود، ممکن است دقت پیش‌بینی را نیز کاهش دهد. یکی از روش‌های ارائه‌شده برای انتخاب ویژگی‌های مناسب، mRMR است که به وابستگی بین ویژگی‌ها توجه دارد. بدین منظور، تلاش کرده تا مجموعه ویژگی‌هایی انتخاب شوند که حداقل وابستگی را با یکدیگر و حداکثر وابستگی را با خروجی مدل پیش‌بینی، داشته باشند. استفاده از mRMR برای مجموعه داده‌ای که دارای تعداد ویژگی‌های زیاد و تعداد نمونه‌های قابل توجه است، به دلیل نمایی بودن تعداد محاسبات لازم، غیر عملی است. از این رو، روش‌هایی مانند تفاضل اطلاعات متقابل^{۳۳} (MID) برای تخمین این رابطه معرفی شده است. MID، با اینکه پیچیدگی محاسباتی بسیار کمی دارد، می‌تواند تخمین قابل قبولی از mRMR ارائه کند. شایان ذکر است که MID، دارای سربار محاسباتی کم و سرعت و قابلیت اطمینان بالا است. در روش MID، ویژگی‌های موجود در مجموعه داده‌های ورودی در بردار \vec{X} براساس حداکثر وابستگی ویژگی‌ها با مقدار خروجی و حداقل همبستگی بین ویژگی‌های ورودی با یکدیگر، اولویت‌بندی می‌شوند. سپس در $|\vec{X}|$ گام، زیرمجموعه‌ای از ویژگی‌ها شامل

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

$|Z| \leq 1$ عنصر ابتدایی از Z انتخاب شده و به عنوان ورودی‌های مدل پیش‌بینی به آن تزریق می‌شوند. آن‌گاه ارزیابی مدل انجام شده و خطای پیش‌بینی شاخص بورس با توجه به ویژگی‌های انتخابی محاسبه می‌شود. شایان ذکر است که برای استفاده از الگوریتم mRMR-MID نیاز به گسسته‌سازی داده‌ها است. برای این مسئله، کلیه ویژگی‌ها به ۱۵ دسته تقسیم‌بندی شده‌اند.

شبکه عصبی حافظه کوتاه مدت ماندگار (LSTM)

برای ایجاد مدل LSTM، نیاز است که معماری مناسبی برای آن انتخاب گردد. بدین منظور ابتدا ویژگی‌های مختلف شبکه از جمله تعداد لایه‌ها، تعداد نورون‌ها در هر لایه، نوع تابع فعالیت، اندازه دسته و تعداد تکرارها بصورت تجربی و با انجام آزمایش‌های مختلف تعیین می‌شود. شبکه‌ی LSTM مورد استفاده در این پژوهش، شامل ۶ لایه می‌باشد. تعداد نورون‌های لایه‌ی ورودی با توجه به تعداد ویژگی‌های انتخابی برای مدل پیش‌بینی شاخص انتخاب می‌شوند. لایه خروجی نیز تنها شامل یک نورون است که مقدار پیش‌بینی را برمی‌گرداند. از تابع فعالیت Sigmoid برای این نورون استفاده شده است. همچنین از ۴ لایه مخفی استفاده شده که به ترتیب دارای ۶۴، ۳۲، ۱۹ و ۱۰ نورون است. از تابع فعالیت tanh برای نورون‌های این لایه‌ها بهره برده شده است. همچنین، مقدار return_sequance در این لایه‌ها True است. برای آموزش مدل از بهینه‌ساز Adam استفاده شده و MSE به عنوان معیار تابع ضرر تعریف شده است. اندازه دسته برابر با ۱۰۰ و تعداد تکرار ۲۰۰۰ در نظر گرفته شده است.

معیارهای ارزیابی مدل‌های پیش‌بینی

برای بررسی دقت پیش‌بینی شاخص بورس، از معیارهای میانگین قدر مطلق خطا^{۲۳} (MAE)، میانگین مربع خطا^{۲۴} (MSE) و میانگین درصد خطا^{۲۵} (MPE) استفاده شده است. که با رابطه‌ی ۲، ۳ و ۴ محاسبه می‌شوند.

$$MAE = \frac{1}{N} \sum_{i=1}^N |t_i - y_i| \quad (2)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (3)$$

$$MPE = \frac{1}{N} \sum_{i=1}^N \frac{|t_i - y_i|}{|t_i|} * 100 \quad (4)$$

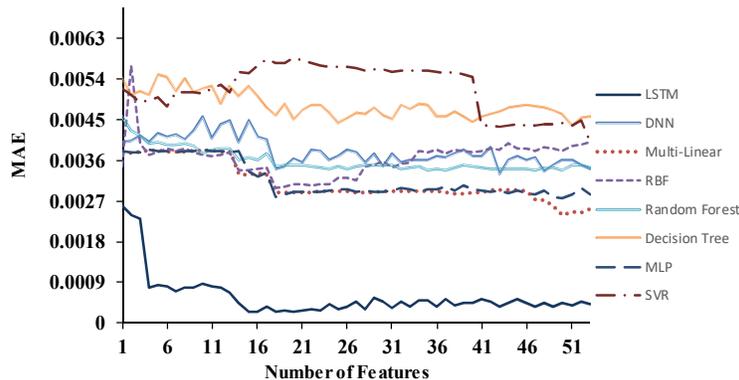
N تعداد نمونه‌ها، t_i شاخص بورس مشاهده شده و y_i شاخص پیش‌بینی شده برای نمونه‌ی i ام است.

تجزیه و تحلیل داده‌ها

مقایسه عملکرد مدل LSTM با سایر مدل‌های هوش مصنوعی در پیش‌بینی شاخص بورس

برای انتخاب مدل مناسب برای پیش‌بینی شاخص بورس، چندین مدل هوشمند که تاکنون برای

پیش‌بینی شاخص بورس استفاده شده‌اند، مورد بررسی قرار گرفتند که عبارتند از: شبکه عصبی پرسپترون چندلایه^{۲۶} (MLP)، شبکه عصبی تابع پایه شعاعی^{۲۷} (RBF)، رگرسیون بردار پشتیبان^{۲۸} (SVR)، درخت تصمیم‌گیری^{۲۹} (DT)، جنگل تصادفی^{۳۰} (RF)، رگرسیون خطی چندگانه^{۳۱} (ML)، شبکه عصبی عمیق^{۳۲} (DNN). نتایج مقایسه دقت مدل‌ها در شکل ۱ نشان داده شده‌است. این شکل، به وضوح دقت بالای مدل LSTM را نسبت به سایر مدل‌ها نشان می‌دهد. برای مقایسه‌ی دقیق‌تر این مدل‌ها، نتایج در جدول ۲ نمایش داده شده است. با اختلاف بسیار، بهترین نتیجه با LSTM به دست آمده است. بنابراین می‌توان نتیجه گرفت شبکه عصبی LSTM در مقایسه با تعداد قابل توجهی از مدل‌های یادگیری ماشین، عملکرد بهتری در پیش‌بینی شاخص روزانه بورس ارائه می‌کند.



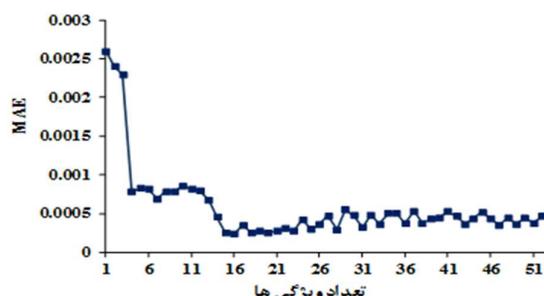
شکل ۱- مقایسه تعدادی از مدل‌های محاسباتی نرم برای پیش‌بینی شاخص بورس روز آینده
جدول ۲: مقایسه دقت تعدادی از مدل‌های یادگیری ماشین برای پیش‌بینی شاخص بورس روز آینده

MPE	MSE	MAE	مدل
۶/۲۷	۰/۰۰۰۰۰۱۸	۰/۰۰۰۴۳	LSTM
۲۵/۱	۰/۰۰۰۰۲۷	۰/۰۰۳۶	SVR
۲۰/۰۷	۰/۰۰۰۰۲۵	۰/۰۰۳۴	RBF
۱۶/۴	۰/۰۰۰۰۲۳	۰/۰۰۳۱	DNN
۱۳/۷	۰/۰۰۰۰۱۱	۰/۰۰۲۴	MLP
۱۴/۱	۰/۰۰۰۰۱۸	۰/۰۰۲۸	Multi-Linear
۲۸/۴	۰/۰۰۰۰۴۴	۰/۰۰۴۱	Decision Tree
۲۰/۲	۰/۰۰۰۰۱۷	۰/۰۰۲۷	Random Forest

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

بررسی تأثیر تعداد و نوع ویژگی‌های ورودی بر عملکرد مدل LSTM در پیش‌بینی شاخص بورس اوراق بهادار تهران

به‌منظور ارزیابی اثر تعداد و نوع ویژگی‌های مورد بررسی در دقت شبکه عصبی LSTM، به اولویت‌بندی ویژگی‌ها با استفاده از روش MID، اقدام می‌شود و به عنوان ورودی‌های مدل LSTM به آن تزریق می‌شوند. سپس ارزیابی مدل انجام شده و خطای پیش‌بینی شاخص بورس با توجه به ویژگی‌های انتخابی محاسبه می‌شود. نتیجه در شکل ۲ نمایش داده شده است. همان‌طور که در شکل مشاهده می‌شود، افزایش تعداد ویژگی‌ها تا ۱۶ ویژگی، منجر به افزایش دقت پیش‌بینی شده است. اما از این نقطه به بعد، افزایش تعداد ویژگی‌ها نتوانسته بهبودی در دقت مدل ایجاد کند.



شکل ۲- استفاده از مدل LSTM و ویژگی‌های اولویت‌بندی شده با mRMR-MID برای پیش‌بینی روزانه شاخص بورس

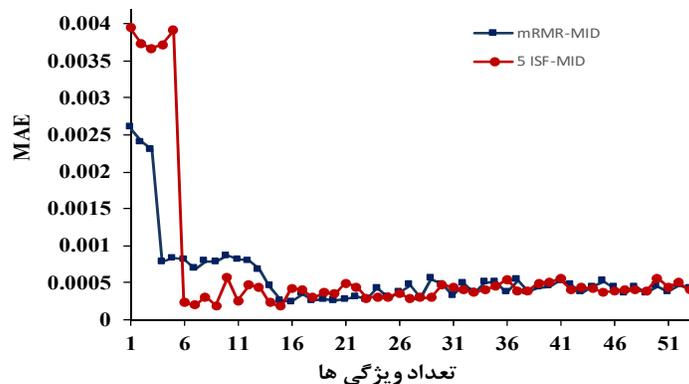
الگوریتم پیشنهادی برای انتخاب ویژگی‌های مؤثر در پیش‌بینی شاخص بورس

همان‌طور که در شکل ۲ مشاهده می‌گردد، افزایش تعداد ویژگی‌ها تا ۱۶ ویژگی، منجر به افزایش دقت پیش‌بینی شده است. بر این اساس، در ادامه الگوریتمی برای انتخاب ویژگی‌های مؤثر بر شاخص بورس پیشنهاد می‌شود. به‌طوری‌که از بین ۱۶ ویژگی ابتدایی، تعداد ۵ ویژگی انتخاب می‌شوند. این ۵ ویژگی شامل ویژگی شماره ۴، ۷، ۱۴، ۱۵ و ۱۶ می‌باشند که منجر به کاهش خطای مدل شده‌اند. این ویژگی‌ها به عنوان ویژگی‌های ابتدایی انتخاب شده و سپس با استفاده از الگوریتم mRMR-MID، مجدد به اولویت‌بندی سایر ویژگی‌ها اقدام می‌شود. در ادامه، مشابه با مرحله قبل، با توجه به اولویت به دست آمده، یکی یکی ویژگی‌ها به مجموعه ویژگی‌های انتخابی اضافه شده و به عنوان ورودی‌های مدل پیش‌بینی شاخص بورس استفاده می‌شوند. با افزایش تعداد ویژگی‌ها، ارزیابی مدل انجام شده و مقدار خطای آن محاسبه می‌شود. الگوریتم پیشنهادی به شرح زیر می‌باشد:

```

FS = {Initial Selected Features}
SPE = StockPredictionError(FS)
 $\zeta$  = mRMR – MID(AllFeatures, FS)
idx = 1
while idx  $\leq$  | $\zeta$ |
FS = FS  $\cup$   $\zeta$ (idx)
SPE = SPE  $\cup$  StockPredictionError(FS)
idx = idx + 1
end
Plot(SPE)
    
```

در شکل ۳ نتیجه این ارزیابی نمایش داده شده است. در این شکل، دو حالت با هم مقایسه شده‌اند. در حالت اول، پس از اولویت‌بندی ویژگی‌ها با الگوریتم mRMR-MID، اثر افزایش تعداد ویژگی‌ها در دقت مدل LSTM، مجدد نشان داده شده است. در حالت دوم، اثر افزایش تعداد ویژگی‌ها در دقت مدل پیش‌بینی شاخص بورس پس از اولویت‌بندی ویژگی‌ها با استفاده از الگوریتم پیشنهادی تحت عنوان ویژگی‌های انتخابی اولیه_تفاضل اطلاعات متقابل ISF_MID ^{۳۳} نمایش داده شده است. همان‌طور که مشاهده می‌شود، ابتدا به نظر می‌رسد که ۵ ویژگی ابتدایی که با توجه به نتایج قبلی انتخاب شده‌اند، نمی‌توانند در افزایش دقت پیش‌بینی تأثیر قابل قبولی داشته باشند. در صورتی که با ورود ویژگی ۶ ام تأثیر ۵ ویژگی ابتدایی قبلی مشخص می‌شود. به طوری که، دقت قابل توجهی از مدل حاصل شده که نسبت به بهترین نتیجه به دست آمده در مرحله قبل، خطای کمتری دارد.



شکل ۳- مقایسه نتیجه استفاده از الگوریتم ISF_MID با الگوریتم MID در انتخاب ورودی‌های مدل LSTM برای پیش‌بینی روزانه شاخص کل بورس

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

در ادامه، مجدداً از این رویکرد در انتخاب ویژگی‌های بیشتر، به‌منظور بهبود دقت مدل پیش‌بینی شاخص بورس استفاده می‌شود. همان‌طور که در شکل ۳ دیده می‌شود، دو ویژگی شماره ۶ و ۱۱ نیز، باعث کاهش خطای مدل شده‌اند. براین اساس این دو ویژگی نیز به مجموعه‌ی ویژگی‌های اولیه انتخابی اضافه شده و برای بار دیگر، با توجه به رویکرد معرفی شده، این بار ۷ ویژگی اولیه انتخاب می‌شوند. باقی ویژگی‌ها با استفاده از الگوریتم mRMR-MID اولویت‌بندی شده و به عنوان ورودی‌های مدل به شبکه LSTM داده می‌شوند. نتایج حاکی از این است که با افزایش تعداد ویژگی‌های اولیه تا ۸ ویژگی، مقدار خطا کاهش قابل توجهی پیدا می‌کند و از آن نقطه به بعد، افزایش تعداد ویژگی‌ها نتوانسته باعث کاهش خطا گردد. نتیجه در جدول ۳ ارائه شده است.

جدول ۳- نتیجه استفاده از الگوریتم ISF_MID در انتخاب ورودی‌های مدل LSTM

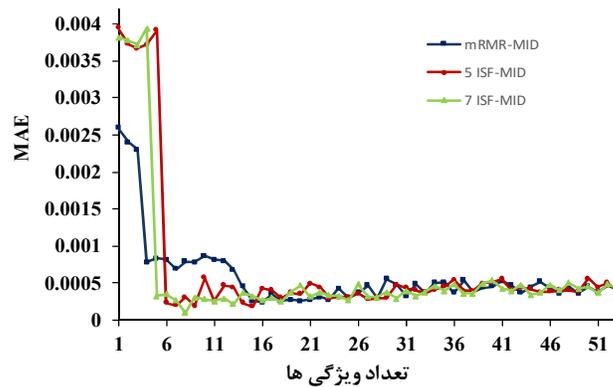
برای پیش‌بینی شاخص بورس

MPE	MSE	MAE	تعداد ویژگی‌های ورودی مدل
۲/۶۶	۰/۰۰۰۰۰۰۰۰۲۷	۰/۰۰۰۰۹۷	۸

با توجه به این که استفاده از این رویکرد برای انتخاب ویژگی‌های بیشتر، دیگر تاثیری در بهبود دقت مدل پیش‌بینی شاخص بورس ندارد به همین دلیل، این ۸ ویژگی به عنوان ویژگی‌های نهایی موثر بر دقت مدل LSTM در پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران انتخاب می‌شوند. این ویژگی‌ها به ترتیب عبارتند از: بازده شاخص ۵۰ شرکت فعال بورس در یک روز گذشته، تغییر قیمت دلار در دو روز گذشته، بازده شاخص کل در سه روز گذشته، تغییر قیمت نفت در دو روز گذشته و بازده شاخص کل در یک روز گذشته، تفاوت نسبی در صد بازده شاخص در ۵ روز گذشته، تغییر قیمت نفت در سه روز گذشته و تغییر حجم معاملات در یک روز گذشته.

نتیجه این محاسبات که اثر افزایش تعداد ویژگی‌ها با اولویت مشخص شده را در دقت مدل LSTM نشان می‌دهد، در شکل ۴ نمایش داده شده است. در این شکل، سه حالت با هم مقایسه شده‌اند. در حالت اول و دوم نتایج ارزیابی نمایش داده شده در شکل ۳ مجدداً ارائه شده است، در حالت سوم، مجدداً اثر افزایش تعداد ویژگی‌ها در دقت مدل LSTM پس از اولویت‌بندی ویژگی‌ها با استفاده از الگوریتم ISF_MID ارائه شده است. در این حالت، ابتدا ۷ ویژگی براساس نتایج حاصل از حالت دوم، به‌عنوان ویژگی‌های معرفی شده انتخاب شده و سپس سایر ویژگی‌ها با الگوریتم MID اولویت‌بندی می‌شوند. ویژگی‌ها با اولویت جدیدی که برای آن‌ها به‌دست آمده است، به مدل LSTM به‌منظور پیش‌بینی شاخص بورس به ترتیب داده می‌شوند. با مقایسه‌ی نمودارهای موجود در شکل ۴ می‌توان به این نتیجه

رسید که، مدل LSTM با ویژگی‌های انتخابی توسط الگوریتم ISF_MID، تنها با ۸ ویژگی، بهترین نتیجه و دقت را ارائه کرده است. در جدول ۴ نیز، مقدار خطاهای موجود در مدل پیش‌بینی بر پایه تعداد و نوع ویژگی‌های انتخابی، ارائه گردیده است. نتایج نشان‌دهنده افزایش دقت مدل پیش‌بینی شاخص بورس با رویکرد پیشنهادی در انتخاب ویژگی‌های مناسب برای آن است.



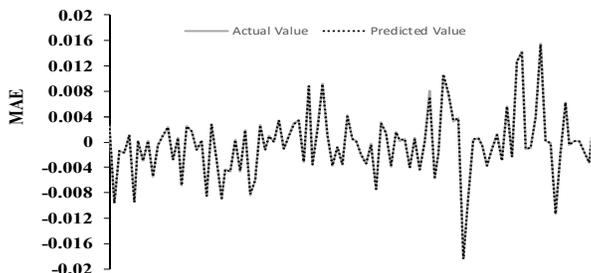
شکل ۴- مقایسه نتایج استفاده از الگوریتم‌های انتخاب ویژگی در انتخاب ورودی‌های مدل LSTM برای پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران
جدول ۴- نتایج حاصل از ارزیابی مدل LSTM در پیش‌بینی شاخص بورس با استفاده از ویژگی‌های مختلف

MAE	تعداد ویژگی‌ها	ویژگی‌های ورودی مدل
۰/۰۰۰۴۳	۵۳	تمام ویژگی‌ها
۰/۰۰۰۲۴	۱۶	ویژگی‌های انتخابی با الگوریتم mRMR-MID
۰/۰۰۰۲۳	۶	ویژگی‌های انتخابی با الگوریتم پیشنهادی 5 ISF-MID
۰/۰۰۰۰۹۷	۸	ویژگی‌های انتخابی با الگوریتم پیشنهادی 7 ISF-MID

ارزیابی عملکرد مدل LSTM در پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران

برای نمایش عملکرد مدل پیش‌بینی شاخص بورس با توجه به ویژگی‌های انتخابی، از نمایش هم‌زمان مقدار واقعی و مقدار پیش‌بینی شده استفاده می‌شود. که در شکل ۵ نمایش داده شده است. نتایج نشان‌دهنده آن است که مدل توانسته است عملکرد مطلوبی در پیش‌بینی شاخص، ارائه دهد.

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان



شکل ۶- نمایش مقدار مشاهده‌شده و مقدار پیش‌بینی شده شاخص بورس

ارزیابی اعتبار مدل پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران

به‌منظور بررسی معناداری نتایج به‌دست آمده و صحت پیش‌بینی، از آزمون فریدمن استفاده می‌شود. آزمون فریدمن یکی از آزمون‌های آماری است که برای تجزیه واریانس دو طرفه (برای داده‌های غیر پارامتری) به روش رتبه‌بندی به کار می‌رود، و از آن برای مقایسه میانگین رتبه‌بندی گروه‌های مختلف استفاده می‌شود. در این آزمون، سطح معنی‌داری کمتر از ۰/۰۵ نشان دهنده تفاوت معنی‌دار در خطاهای مدل‌های مورد مطالعه است. نتایج در جدول ۵ نشان می‌دهد که مدل LSTM نسبت به سایر مدل‌های مورد بررسی خطای کمتری دارد. زیرا سطح معنی‌داری کمتر از ۰/۰۵ است و با توجه به میانگین رتبه به‌دست آمده، مدل LSTM به ترتیب با ۸ و ۵ ویژگی، میانگین رتبه کمتری دارد.

جدول ۵: مقایسه میانگین خطای مدل‌های مورد مطالعه بر اساس آزمون فریدمن

میانگین رتبه	خطاهای مدل
۶/۱۶	RBF
۶/۴۱	SVR
۵/۹۶	DNN
۵/۵۳	MLP
۵/۰۵	LM
۶/۳۲	DT
۵/۶۴	RF
۲/۳۷	LSTM53
۱/۵۷	LSTM8
۹۳۴/۹۶۹	آماره کی دو
۸	درجه آزادی
۰/۰۰۰	سطح معنی‌دار

بحث و نتیجه‌گیری

یکی از پیش‌پردازش‌های با اهمیت برای ایجاد یک مدل پیش‌بینی، انتخاب ویژگی‌های مناسب برای آن است. چنانچه یک مدل با استفاده از داده‌های مناسب آموزش داده شود می‌تواند عملکرد درستی داشته باشد؛ بنابراین در خصوص پیش‌بینی شاخص سهام انتخاب عوامل موثر بر شاخص اهمیت بسزایی دارد، در این پژوهش سعی شده است با رویکردی کاملاً جدید، به انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی روزانه شاخص کل بورس اوراق بهادار تهران اقدام شود. در این راستا، ابتدا یک مجموعه کامل از ویژگی‌های تأثیرگذار بر شاخص بورس که بر اساس مبانی تئوریک و مطالعات پیشین مورد تأیید واقع شده‌اند، جمع‌آوری گردید. به‌منظور تعریف عملیاتی متغیرها از پژوهش ژونگ و انکه (۲۰۱۷) استفاده شد. بعد از نرمال‌سازی داده‌ها، به‌منظور استفاده از مدل LSTM، که از بدیع‌ترین شبکه‌های یادگیری عمیق بوده و برای پیش‌بینی داده‌های سری زمانی بسیار مناسب می‌باشد، به تبدیل داده‌های ورودی مدل، از آرایه ۲ بعدی به آرایه ۳ بعدی اقدام گردید. سپس، برای بررسی دقت مدل LSTM در پیش‌بینی شاخص بورس، تعداد قابل توجهی از مدل‌های یادگیری ماشین، مورد ارزیابی قرار گرفته و عملکرد مناسب مدل LSTM در پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران در مقایسه با آن‌ها، مورد تأیید واقع شد که با پژوهش‌های صورت گرفته توسط شریف فر و همکاران (۱۴۰۰)، ذوالفقاری، سحابی و بختیاران (۱۳۹۹)، کرمانی و همکاران (۲۰۱۹)، یوکسو و لی (۲۰۱۹)، چن و زو (۲۰۱۸)، فیشر و کراوس (۲۰۱۸) مطابقت دارد. در ادامه، برای بهبود دقت مدل LSTM، به انتخاب ویژگی‌های مناسب برای آن اقدام گردید. برای این منظور، نظیر پژوهش گوندوز و کتلتیه^{۳۴} (۲۰۱۵)، از یک روش تخمین mRMR برای اولویت‌بندی و انتخاب ویژگی‌های مناسب استفاده شد. این الگوریتم آماری در زمان کمتری نسبت به الگوریتم‌های هوشمند اجرا شده و برای هر یک از ویژگی‌ها اولویت مشخصی را تعیین می‌کند. همچنین در انتخاب ویژگی‌های مناسب مدل پیش‌بینی، نه تنها به همبستگی ویژگی‌های ورودی نسبت به خروجی مدل توجه می‌کند، بلکه وابستگی بین ویژگی‌های ورودی با یکدیگر را نیز بررسی می‌کند. به طوری که ویژگی‌ها با توجه به بیشینه‌سازی معیار وابستگی آماری مجموعه ویژگی‌ها با ویژگی هدف، و کمینه‌کردن اطلاعات متقابل در بین مجموعه ویژگی‌های انتخابی، گزینش می‌شوند که این امر باعث می‌شود احتمال انتخاب زیرمجموعه‌ای با افزونگی از بین رود. براساس نتایج مشاهده گردید، با انتخاب ۱۶ ویژگی با بیشترین اولویت با الگوریتم mRMR-MID می‌توان افزون بر کاهش زمان اجرای مدل، به دقت مناسب در پیش‌بینی شاخص بورس دست یافت. این نتیجه همراستا با نتایج پژوهش‌های امینی‌مهر و همکاران (۱۴۰۰)، الحق و

پیش‌بینی شاخص روزانه بورس اوراق بهادار ... / محبی، فدائی نژاد، حمیدی زاده و اصولیان

همکاران (۲۰۲۱)، می‌باشد که برای بهبود دقت مدل یادگیری عمیق به تولید زیر مجموعه‌ای بهینه از ویژگی‌ها اقدام نمودند. در ادامه با توجه به نتایج استفاده از mRMR-MID در اولویت‌بندی ویژگی‌های موثر بر پیش‌بینی شاخص بورس، الگوریتمی تحت عنوان ISF_MID به‌منظور انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی روزانه شاخص بورس اوراق بهادار تهران پیشنهاد گردید که با توجه به این الگوریتم می‌توان با تعداد معدودی ویژگی (۸ ویژگی) به پیش‌بینی با بیشترین دقت اقدام نمود. ۸ ویژگی شناسایی شده در این مطالعه با تعدادی از ویژگی‌های مورد تایید برخی از محققین از جمله پشتوتنی‌زاده و همکاران (۱۳۹۹)، دهقانی، قاسم‌زاده و انصاری‌سامانی (۱۳۹۸)، صالحی و گرشاسبی (۱۳۹۸)، واشقانی فراهانی (۱۳۹۸)، فقیهی‌نژاد و مینایی (۱۳۹۷)، ولی‌زاده‌لاریجانی و بهبهانی‌نیا (۱۳۹۷)، بدیعی، رضازاده و محمودی (۱۳۹۶)، ناهیل و لیحیایی (۲۰۱۸)، ژونگ و انکه (۲۰۱۷) مطابقت دارد.

با توجه به نتایج این مطالعه، به پژوهشگران بازار سهام پیشنهاد می‌شود از مدل LSTM و روش انتخاب ویژگی‌های مناسب برای آن، به‌منظور متن‌کاوی و پیش‌پردازش ورودی‌های غیر ساختاری مانند اخبار و شبکه‌های اجتماعی که حجم داده‌ها برای پردازش بسیار زیاد است و ممکن است از میلیون‌ها رکورد تجاوز کرده و باعث ایجاد چالش‌های محاسباتی شود، جهت پیش‌بینی قیمت سهام استفاده کنند. به محققان حوزه مدل‌سازی نیز پیشنهاد می‌گردد در تحلیل و پیش‌بینی‌های خود از این روش به منظور انتخاب ویژگی‌های مناسب برای مدل پیش‌بینی استفاده کنند. زیرا روش پیشنهاد شده نه تنها باعث کاهش هزینه و بار محاسباتی، و افزایش دقت مدل‌های هوشمند می‌گردد، بلکه امکان اولویت‌بندی ویژگی‌های شناسایی شده را نیز فراهم می‌کند. همچنین به معامله‌گران سهام، سرمایه‌گذاران و مدیران پرتفوی توصیه می‌شود تا پس از بررسی شرایط مختلف بازار و مشخص کردن آستانه تحمل ریسک، از نتایج انتخاب ویژگی این پژوهش به عنوان اطلاعات تکمیلی جهت تصمیمات سرمایه‌گذاری خود استفاده کنند.

منابع

- ۱) ذوالفقاری، مهدی. سحابی، بهرام. بختیاران، محمد جواد. (۱۳۹۹). طراحی مدلی جهت پیش بینی بازده شاخص کل بورس اوراق بهادار با تاکید بر مدل های ترکیبی شبکه یادگیری عمیق و مدل های خانواده (GARCH)، مهندسی مالی و مدیریت اوراق بهادار، ۱۱(۴۲): ۱۳۸-۱۷۱.
- ۲) شریف فر، امیر. خلیلی عراقی، مریم. رئیسی وانانی، ایمان، فلاح، میرفیض. (۱۴۰۰). ارزیابی و اعتبارسنجی معماری بهینه یادگیری عمیق در پیش بینی قیمت سهام (رویکرد الگوریتم حافظه کوتاه مدت ماندگار (LSTM)، مهندسی مالی و مدیریت اوراق بهادار، ۱۲(۴۸): ۳۴۸-۳۷۰.
- ۳) صدیقی ناو، محسن. (۱۳۹۱). کاهش ویژگی با استفاده از الگوریتم بهینه سازی توده ذرات و کلاسه بندی با ماشین بردار پشتیبان. پایان نامه دوره کارشناسی ارشد مهندسی برق الکترونیک، دانشگاه صنعتی شاهرود، دانشکده مهندسی برق و رباتیک.
- ۴) لاری دشت بیاض، محمود، محمدی، شعبان. (۱۳۹۵). یک شبکه عصبی مصنوعی منظم بیزی برای پیش بینی بازار سهام. پژوهش حسابداری، ۳(۲۳): ۴۷-۷۱.
- ۵) پشتوتنی زاده، هومن. رعنائی کرد شولی، حبیب الله. عباسی، عباس. موسوی حقیقی، محمد هاشم. (۱۳۹۹). شبیه سازی الگوی تأثیرات عوامل رفتاری و کلان اقتصادی بر شاخص کل بورس اوراق بهادار تهران با استفاده از رویکرد پویایی شناسی سیستمی. چشم انداز مدیریت مالی. ۱۰(۲۹): ۸۹-۱۲۴.
- ۶) تقوی، رضا. داداشی، ایمان. زارع بهنمیری، محمدجواد. حمیدرضا، غلام نیا روشن. (۱۳۹۹). پیش بینی گرایش احساسی سرمایه گذاران با استفاده از تکنیک های ماشین بردار پشتیبان (SVM) و درخت تصمیم (DT). مهندسی مالی و مدیریت اوراق بهادار، ۱۱(۴۵): ۵۴۴-۵۷۰.
- ۷) دهقانی، مریم. قاسم زاده، محمد. انصاری سامانی، حبیب. (۱۳۹۸). الگوریتم های یادگیری ماشین برای سری های زمانی در بازارهای مالی. رایانش نرم و فناوری اطلاعات، ۸(۳): ۶۰-۶۷.
- ۸) صالحی، مجتبی. فاطمه، گر شاسبی. (۱۳۹۸). پیش بینی شاخص کل بورس اوراق بهادار تهران با رویکرد سیستم استنتاج عصبی- فازی انطباق پذیر و الگوریتم رقابت استعماری. مطالعات مدیریت کسب و کار هوشمند، ۸(۲۹): ۵-۳۴.
- ۹) واشقانی فراهانی، آرش. (۱۳۹۸). بررسی رابطه متغیر های کلان اقتصادی و شاخص کل بورس اوراق بهادار تهران. پایان نامه دوره کارشناسی ارشد مدیریت مالی، دانشگاه شهید بهشتی تهران.
- ۱۰) ولی زاده لاریجانی، اعظم. بهبهانی نیا، پریسا سادات. (۱۳۹۷). بررسی تجربی عوامل مؤثر بر بازده سهام: جنبه های مختلف اثرگذار بر تصمیم گیری. دانش حسابداری مالی، ۵(۴): ۶۹-۱۰۲.

- 11) Aminimehr, A., Raoofi, A., Aminimehr, A., Aminimehr, A. (2020). "The Role of Feature Engineering in Prediction of Tehran Stock Exchange Index Based on LSTM". Iranian Journal of Economic Studies, 9(2), 527-548.
- 12) Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., Khatri, R. K. C. (2022). Predicting stock market index using LSTM, Machine Learning with Applications, 9: 100320.
- 13) Chen. W. Xu, G. (2018). "Research on stock market volatility prediction accuracy based on deep learning and stock forum data," Management World, 34(1), 180-181.
- 14) Ding, Y., Sun, N., Xu, J., Li, P., Wu, J, Tang, S. (2022). "Research on Shanghai Stock Exchange 50 Index Forecast Based on Deep Learning". Hindawi Mathematical Problems in Engineering, 1367920, 9 pages. <https://doi.org/10.1155/2022/1367920>
- 15) Fischer, T., Krauss, C. (2018). "Deep learning with long short-term memory networks for financial market predictions". European Journal of Operational Research, 270(2), 654-669.
- 16) Gunduz, H., Cataltepe, Z. (2015). "Borsa Istanbul (BIST) daily prediction using financial news and balanced feature selection". Expert Systems with Applications, 42(22), 9001-9011.
- 17) Hinton, G. E., Osindero, S. and The, Y-W. (2006). "A fast learning algorithm for deep Belief nets". Neural Computation, 18(7), 1527-1554.
- 18) Hiransha, M., Gopalakrishnan, E. A., Menon, V. K., Soman, K.P. (2018). "Nse stock market prediction using deep-learning models". Procedia Computer Science, 132: 1351-1362.
- 19) Jie, L., Zheng, G. (2017). "Research on Shanghai zinc futures price forecast based on artificial neural network". Finance Theory and Practice, 3802: 54-57.
- 20) Karmiani, D., Kazi, R., Nambisan, A., Shah, A. & Kamble, V. (2019). "Comparison of predictive algorithms: Backpropagation, SVM, LSTM and Kalman filter for stock market". In 2019 amity international conference on artificial intelligence (AICAI), 228-234.
- 21) Lee, M. C. (2009). "Using support vector machine with a hybrid feature selection method to the stock trend prediction." Expert Systems with Applications, 36(8): 10896-10904.
- 22) Lee, Sang II., Yoo, Seong Joon. (2018). "Threshold-based portfolio: the role of the threshold and its applications". The Journal of Supercomputing, September. <https://doi.org/10.48550/arXiv.1709.09822>
- 23) Nahil, A., Lyhyaoui, A. (2018). "Short-term stock price forecasting using kernel principal component analysis and support vector machines: the case of Casablanca

- stock exchange”. *Procedia Computer Science*, 127: 161-169.
- 24) Palangi, H., Ward, R., Drng, L. (2016). “Distirbuted compressive sensing: a DL approach,” *IEEE Transactions on Signal Processing*, 64(17), 4504-4518.
- 25) Sezer, O. B., Ozbayoglu, A. M. (2018). “Algorithmic financial trading with deep convolutional neuralnetworks: Time series to image conversion approach”. *Applied Soft Computing Journal*, 70: 525-538.
- 26) Sezer, O. B., Gudelek, M. U., Ozbayoglu, A. M. (2020). “Financial time series forecasting with deep learning, A systematic literature review: 2005–2019.” *Applied Soft Computing*, 90: 1-63.
- 27) Ul Haq, A., Zeb, A., Lei, Z., Zhang, D. (2021). “Forecasting daily stock trend using multi-filter feature selection and deep learning”. *Expert Systems With Applications*, 168(3), 114444.
- 28) Yadav, A., Jha, C. K., Sharan, A. (2020). “Optimizing LSTM for time series prediction in Indian stock market”. *Procedia Computer Science*, 167: 2091–2100, *International Conference on Computational Intelligence and Data Science*.
- 29) Yuxu, L., Li, Y. (2019). “Research on Shanghai and shenzhen 300 index forecast model based on LSTM neural network,” *Mathematical Practice and Knowledge*, 49(7). 309–315.
- 30) Zhong, X., Enke, D. (2017). “Forecasting daily stock market return using dimensionality reduction.” *Expert Systems with Applications*, 67: 126-139.

-
- ۱ Sezer et al.
 - ۲ Hiransha et al.
 - ۳ Short Term Memory Neural Network
 - ۴ Minimum Redundancy Maximum Relevance
 - 5 Zhong & Enke
 - 6 Lee
 - 7 Sezer & Ozbayoglu
 - ۸ Convolutional Neural Networks
 - 9 Recurrent Neural Network
 - 10 Ding et al.
 - 11 Hinton et al.
 - 12 Deep Belief Network
 - ۱۳ Jie & Zheng
 - ۱۴ Palangi et al.
 - ۱۵ Bhandari et al.
 - ۱۶ Yadav, Jha & Sharan
 - ۱۷ Fischer & Krauss
 - 18 Karmiani et al.
 - ۱۹ Lee & Yoo
 - ۲۰ Chen & Xu
 - 21 Yuxu & Li
 - ۲۲ Mutual Information Difference
 - ۲۳ Mean Absolute Error
 - ۲۴ Mean Square Error
 - ۲۵ Mean Percentage Error
 - ۲۶ Multi-Layer Perceptron
 - ۲۷ Radial Basis Function
 - 28 Support Vector Regression
 - ۲۹ Decision Tree
 - ۳۰ Random Forest
 - 31 Multi-Linear Regression
 - ۳۲ Deep Neural Network
 - ۳۳ Initial Selected Features_ Mutual Information Difference
 - 34 Gunduz & Cataltepe