فصلنامه مهندسی مالی و مدیریت اوراق بهادار
شماره پنجاه و سه / زمستان ۱۴۰۱
نوع مقاله : علمی پژوهشی
صفحات : ۵۳-۳۴

ارائه مدل پیش‌بینی‌گر جهت بازار در معاملات آتی سکه طلای بورس کالای ایران با استفاده از الگوریتم حافظه طولانی کوتاه مدت (LSTM)

سهیل ذوقی[۱]
رضا راعی[۲]
سعید فلاح پور[۳]

تاریخ دریافت مقاله : ۱۴۰۰/۱۰/۰۷ تاریخ پذیرش مقاله : ۱۴۰۰/۱۱/۳۰

چکیده

در سال‌های اخیر شبکه‌های عصبی یادگیری عمیق به عنوان ابزاری قدرتمند جهت حل مسائل پیچیده شناخته شده‌اند. یادگیری عمیق یک زیرشاخه از هوش مصنوعی است که در آن بر مبنای مجموعه‌ای از الگوریتم‌ها، مسائل پیچیده دارای پارامترها و ورودی‌های بسیار زیاد، مدل می‌شوند. در این پژوهش به ارائه چاچوب جدیدی از یادگیری عمیق پرداخته می‌شود که در آن با استفاده از تبدیل موجک، خودرمزنگار انباشته و حافظه طولانی کوتاه مدت یا LSTM به پیش‌بینی جهت بازار در قراردادهای آتی سکه طلای بورس کالای ایران می‌پردازیم. در روش پیشنهادی ابتدا با استفاده از تبدیل موجک نویز داده‌های ورودی گرفته می‌شود. سپس با استفاده از خودرمزنگار انباشته شاخص‌های تاثیرگذار بر جهت بازار شناسایی شده و در نهایت این شاخص‌ها به عنوان ورودی به معماری LSTM داده می‌شود تا جهت بازار پیش‌بینی شود. از نوآوری‌های پژوهش حاضر می‌توان به ارائه چند شاخص تکنیکال جدید به منظور افزایش دقت مدل پیشنهادی و همین‌طور تنظیم پارامترهای الگوریتم‌های به کار رفته از جمله LSTM برای مسئله مورد مطالعه و ارائه استراتژی معاملاتی به جهت دستیابی به سوددهی مناسب شاره نمود. بررسی‌ها نشان می‌دهند که روش پیشنهادی از سایر روش‌ها پیشی می‌گیرد و به دقت و بازدهی بالاتری دست می‌یابد.

کلمات کلیدی

بازارطلا، شاخص‌های‌تکنیکال، پیش‌بینی جهت‌بازار، پیش‌بینی سری‌زمانی، حافظه‌طولانی‌کوتاه-مدت

۱-گروه مالی و بیمه، دانشکده مدیریت، دانشگاه تهران، تهران، ایران. (نویسنده مسئول) soheil_zoghi@ut.ac.ir
۲-گروه مالی و بیمه، دانشکده مدیریت، دانشگاه تهران، تهران، ایران. raei@ut.ac.ir
۳-گروه مالی و بیمه، دانشکده مدیریت، دانشگاه تهران، تهران، ایران. falahpor@ut.ac.ir

مقدمه

تحقیق در مورد پیش‌بینی پذیری بازارهای سهام سابقه طولانی در اقتصاد مالی دارد. در حالی که نظرات در مورد کارایی بازارها متفاوت است، بسیاری از مطالعات تجربی که به طور گسترده پذیرفته شده‌اند، نشان می‌دهد که بازارهای مالی تا حدی قابل پیش‌بینی هستند. با وجود این که پیش‌بینی بازده دارایی‌های مالی یکی از متداول‌ترین مباحث مالی است؛ اما در عمل، پیش‌بینی دقیق بازده در بازارهای مالی غیرممکن است و در اکثر پژوهش‌ها، محققان به پیش‌بینی جهت بازار پرداخته‌اند. همچنین، شناسایی شاخص‌هایی که هدایت‌کننده قیمت‌ها هستند بسیار بااهمیت است [1]. هوش محاسباتی[1] در امور مالی، موضوعی بسیار محبوب در علم و صنعت است و در چند دهه گذشته مطالعات متعددی در رابطه با آن منتشر شده است. یادگیری ماشین[2] و به طور خاص یادگیری عمیق[3]، به دلیل عملکرد بهتر نسبت به مدل‌های کلاسیک مورد توجه قرار گرفته است. ورود یادگیری ماشین به حوزه مالی سابقه‌ای ۴۰ ساله دارد [2]. بررسی داده‌های سری زمانی، در حوزه یادگیری عمیق، یک موضوع جا افتاده است. داده‌های مالی نیز از جنس سری زمانی هستند و می‌توان از بسیاری از الگوریتم‌های یادگیری عمیق که برای داده‌های سری زمانی توسعه داده شدند، در این مبحث استفاده نمود. با توجه به این که یادگیری عمیق برای مدل‌هایی که داده‌های پیچیده با تعداد بالا داشته باشند نتایج بهتری ارائه می‌دهد، استفاده از آن در بازارهای مالی قابل دفاع است [5]–[3]. نمونه‌هایی از شبکه‌های عصبی که در حوزه مالی استفاده می‌شوند عبارت‌اند از: خود رمزنگار[4](AE)، شبکه عصبی کانولوشنی[5](CNN) و شبکه عصبی بازگشتی[6](RNN).

به طور کلی می‌توان گفت بازده آتی دارایی‌ها می‌تواند از بازده‌های تاریخی آن‌ها استخراج شود [6]. نوسان قیمت طلا، همیشه ریسک سرمایه‌گذاری را افزایش می‌دهد. بدین منظور که تغییرات کوچک بالقوه در قیمت طلا، ممکن است سود و زیان زیادی را نتیجه دهد. بنابراین پیش‌بینی رفتار قیمت طلا می‌تواند سرمایه‌گذاران مالی و بانک‌های مرکزی را در اتخاذ تصمیم مناسب و کاهش ریسک‌های بالقوه پشتیبانی کند. با این حال این پیش‌بینی به خاطر طبیعت رفتاری قیمت طلا چالش‌های خود را به همراه دارد [2]. هدف این تحقیق پاسخ به این پرسش است که آیا می‌توان با استفاده از یادگیری عمیق جهت قیمت‌ها در بازار قراردادهای آتی سکه و بازار طلای جهانی را پیش‌بینی کرد؟ تحقیق‌ها در حوزه قیمت طلا و پیش‌بینی جهت حرکت بازار، برای دهه‌ها مطالعه شده است و روش‌های متعددی از روش‌های کلاسیک و شناخته شده‌ای همچون میانگین متحرک خودهمبسته‌ی یکپارچه۷ (به اختصار ARIMA) [7] تا روش‌های مدرن و پیچیده‌تر بر اساس یادگیری عمیق برای این کار ایجاد شده‌اند. با این وجود

مدل‌های آماری تحت برخی فرضیات همچون همبستگی خطی[۸] بین داده‌ها عمل می‌کنند. در حالی که مدل‌های یادگیری ماشین قادر به شناسایی چنین فرضیاتی نیستند. بنابراین هیچ ضمانتی برای پیش‌بینی قابل اطمینان وجود ندارد. این مشکلات با ورود یادگیری عمیق با موفقیت پشت سر گذاشته شدند. با وجود این که پژوهش‌های انجام شده در این حوزه هنوز با محدودیت‌هایی مواجه هستند، با افزایش در دسترس بودن داده‌های تجاری با فرکانس بالا و عملکرد نسبتاً ضعیف سایر مدل‌های موجود، مطالعات جامعی انجام شده‌اند که به طور عینی مناسب بودن یادگیری عمیق را برای پیش‌بینی و تجزیه و تحلیل بازار سهام بررسی می‌کنند و نشان می‌دهند که فرصت‌های بسیاری برای استفاده از این تکنولوژی نوین در بازارهای مالی وجود دارد [8] ,[1]. شایان ذکر است که عمده مقالات مورد توجه در سالیان گذشته از معماری حافظه طولانی کوتاه مدت[۹] (به اختصار LSTM) بهره می‌جویند و ما نیز به همین علت در این بخش بر روی این معماری متمرکز شده‌ایم تا با بررسی کاستی‌های موجود در مطالعات پیشین، گامی برای بهبود آن‌ها برداشته و روشی نوین به همراه معرفی شاخص‌های جدید موثر ارایه نماییم. پژوهش‌های پیشین نشان می‌دهند که با معرفی شبکه LSTM این پیش‌بینی‌ها به طور چشمگیری صحیح‌تر و قابل اطمینان‌تر شدند چرا که ذات شبکه LSTM استخراج و جمع آوری ویژگی‌های داده‌ها در طول زمان است و همین خاصیت آن را به محبوب‌ترین شبکه در حوزه مالی بدل کرده است [10] ,[9] ,[2]. به همین علت در این پژوهش نیز از این شبکه‌ها بهره گرفته می‌شود. در بازارهای مالی علاوه بر استفاده از مدل LSTM، شبکه‌های متنوع دیگری از جمله شبکه‌های خودرمزنگار به منظور بهینه نمودن داده‌های ورودی و عملکرد مدل مورد بهره‌برداری قرار می‌گیرند [11].

در این بخش به بررسی چندی از پژوهش‌های مشابه می‌پردازیم: لاوانیس و همکارانش در مقاله [5] سعی در توسعه در ترکیب دو مدل CNN و LSTM داشتند. در بخش ابتدایی CNN ویژگی‌های مهم را استخراج و در بخش دوم LSTM تحلیل زمانی بر روی ویژگی‌ها را انجام می‌دهد. زنهونگ و همکاران [12] رویکردی برعکس مقاله فوق داشتند و ابتدا داده‌ها را با LSTM پردازش کردند و خروجی را به واحد CNN سپردند. ایده مهم دیگر این مقاله، استفاده از مکانیزم توجه[۱۰][13] بود که یک روش قدرتمند برای معطوف کردند توجه شبکه به ویژگی‌های مهم است. در مقاله[14] جی‌آلین و دوستان سعی کردند به کمک معماری خودرمزنگار، حذف نویز را انجام دهند و مفیدترین ویژگی‌ها استخراج کنند. سپس این ویژگی‌ها وارد واحدهای سریالی LSTM شده و پیش‌بینی‌ها را تولید می‌کند. دسته دیگری از مقالات سعی بر بهره‌گیری از مدل‌های بازگشتی بدون اتکا به سایر معماری‌ها داشته‌اند. به طور مثال ایده مقاله [15] به استفاده بهینه از ساختار LSTM اختصاص دارد. در این تحقیق سعی شده است از معماری

بهینه شده‌ای مشابه LSTM که GRU [16] نام دارد استفاده کنند. در مقاله [17] این مورد بررسی شده است که لزوما همه‌ی ویژگی‌هایی که از داده خام به دست می‌آیند مفید نیستن و یک مرحله فیلترگذاری بر روی ویژگی‌ها لازم است. بدین منظور از روش‌های کاهش ابعاد استفاده شده است و سپس ویژگی‌های خالص به واحد LSTM برای پیش‌بینی نهایی وارد می‌شوند. در مقاله [18] یانگ‌لی و همکاران سعی کردند از مدل یادگیری گروهی استفاده کنند. این نوع یادگیری، به دلیل استفاده از قابلیت‌های مدل‌های موجود در گروه، معمولا عملکرد بهتری نسبت به استفاده از یک مدل دارد. همچنین با شیوع بیماری کرونا، توجه محققان به تاثیر این بحران بر اقتصاد جهانی معطوف شده است. به عنوان نمونه مهتاب محتشم‌خانی و همکاران در مقاله [19] مدلی را ارائه کردند تا بتواند در شرایط همه‌گیری کرونا بهترین پیش‌بینی را انجام دهد. مدل ابتدا بر اساس LSTM تحلیل زمانی را انجام می‌دهد سپس لایه‌های تماما متصل پیش‌بینی نهایی را انجام می‌دهند.

با وجود تمامی تحقیقات مختلفی در حوزه بررسی بازارهای مالی و با استفاده از روش‌های یادگیری عمیق انجام شده است، همچنان به نظر می‌آید مدلی جامع که به همراه یک استراتژی مناسب بتواند جهت بازارهای مبتنی بر طلا را به خوبی پیش‌بینی نماید و به سوددهی قابل توجهی برسد وجود ندارد. ضمناً با بررسی تحقیقات گذشته به نظر می‌آید که مدل‌های با قابلیت اطمینان بالا برای بازارهای داخلی ایران و با استفاده از تکنولوژی‌های نوین یادگیری عمیق کمتر موجود هستند و به طور خاص برای بازار بورس کالای ایران که از مهم‌ترین و پرسودترین بازارهای معاملاتی می‌باشد [20]، کمبود روش‌های هوشمندانه پیش‌بینی جهت قابل مشاهده است و به همین علت مقصود پژوهش حاضر پر نمودن شکاف پژوهشی ذکر شده می‌باشد.

با این تفاسیر که هدف از انجام این پژوهش پیش‌بینی جهت بازار با استفاده از معماری خودرمزنگار به منظور کاهش ابعاد داده‌های ورودی و سپس معماری LSTM خواهد بود. در این پژوهش از داده‌های به دست آمده از معاملات آتی سکه طلا در بازار بورس کالای ایران استفاده شده است که شامل داده‌هایی از ماه مه سال ۲۰۱۱ میلادی الی ماه مه سال ۲۰۱۸ می‌باشد و دربرگیرنده اطلاعات هر یک ربع ساعت از بازار است. در این مجموعه قیمت‌های آغازین، بالاترین، پایین‌ترین و قیمت پایانی به ریال ثبت شده‌اند و حجم معاملات و تعداد قراردادهای باز نیز به طور دقیق وجود دارند. از نوآوری‌های روش پیشنهادی می‌توان به ترکیب سه معماری مختلف با یکدیگر به منظور کاهش نویز، کاهش ابعاد و در نهایت پیش بینی دقیق جهت بازار و همینطور تنظیم پارامترها و ابرپارامترهای معماری‌های مورد استفاده اشاره نمود. علاوه بر این، استفاده از ۵ ویژگی اضافه شده توسط نویسندگان این اثر به منظور بررسی بازار می‌تواند در

سایر پژوهش‌های این زمینه نیز کارآمد باشد و تحلیل‌ها نشان می‌دهند که این ویژگی‌ها تاثیر به‌سزایی بر کیفیت پیش‌بینی‌های ارائه شده دارند. در ضمن بهره‌مندی از ترکیب تکنولوژی‌های مبتنی بر یادگیری عمیق در بازار بورس کالای ایران به این صورت بی‌سابقه بوده و جنبه دیگری از نوآوری تحقیقاتی این اثر به شمار می‌آید تا مدلی ارائه شود که منطبق با ویژگی‌های خاص بازار ذکر شده و به صورت بومی باشد. یافته‌های پژوهش اثبات می‌کنند که ترکیب الگوریتم‌های پیشنهادی به همراه اتخاذ استراتژی معاملاتی درست می‌تواند موجب سوددهی قابل‌توجهی در بازه مورد مطالعه شود و به این صورت تایید می‌شود که مجموعه الگوریتم‌های به کار گرفته شده می‌توانند با دقت مناسبی جهت بازار را پیش‌بینی نمایند.

روش‌شناسی تحقیق

در این پژوهش از تبدیل موجک[11] برای از بین بردن نویزهای داده‌های ورودی استفاده شده است. ویژگی اصلی تبدیل موجک در مقایسه با تبدیل فوریه این است که می‌تواند اجزای با فرکانس‌های متفاوت را به طور همزمان آنالیز کند. بنابراین کاربرد تبدیل موجک جهت بررسی داده‌های نامرتب مالی می‌تواند مناسب باشد [21]. در این جا از تابع هار[12] به عنوان تابع موجک پایه استفاده می‌شود، زیرا این تابع نه تنها سری‌های زمانی مالی را در حوزه زمان و فرکانس تجزیه می‌کند بلکه زمان پردازش را به طور چشمگیری کاهش می‌دهد. ضرایب تبدیل پیوسته موجک دارای اطلاعات اضافی بسیار زیادی می‌باشند، بنابراین منطقی است تا از این ضرایب جهت کاهش این اطلاعات اضافی نمونه‌برداری شود. تجزیه سری‌های زمانی به مجموعه‌های متعامد منجر به تبدیل موجک گسسته ((DW(t)) خواهند شد [22]. مالات [23] فیلتر کردن سری‌های زمانی با استفاده از یک جفت از فیلترهای بالاگذر و پایین‌گذر را جهت پیاده ساری تبدیل موجک گسسته پیشنهاد داد. در الگوریتم مالات دو نوع موجک، موجک پدر $\varphi(t)$ و موجک مادر $\psi(t)$ وجود دارد که موجک مادر توصیف کننده بخش‌های فرکانس بالا می‌باشد، درحالیکه موجک پدر توصیف کننده مولفه‌های فرکانس پایین یک سری زمانی می‌باشد. سری‌های زمانی مالی می‌تواند به وسیله یک سری از تصاویر موجک‌های پدر و مادر بازسازی شوند. در این تحقیق از یک موجک دو مرحله ای جهت انجام این پژوهش برای پیش پردازش داده‌های ورودی پیشنهاد می‌شود. به این صورت نویز داده‌های ورودی گرفته می‌شود و داده‌های پرت[13] و موارد استثنایی که می‌تواند یادگیری مدل را را با مشکل مواجه کند و توان تعمیم دهی[14] آن را بکاهند حذف می‌گردند [25] ,[24] ,[22].

در مرحله بعد از رمزنگارهای خودکار که یک تکنیک یادگیری بدون نظارت هستند استفاده می‌کنیم که در آن از شبکه‌های عصبی برای یادگیری بازنمایی داده‌ها بهره گرفته می‌شود. به این منظور یک معماری شبکه عصبی را طراحی خواهیم کرد به طوری که یک گلوگاه در شبکه تحمیل می‌کنیم که باعث

فشرده سازی داده‌های اولیه می‌گردد. در صورتی که ویژگی‌های ورودی هر کدام مستقل از یکدیگر باشند، این فشرده سازی کار بسیار دشواری خواهد بود. اما اگر نوعی ساختار در داده‌ها وجود داشته باشد (به عنوان مثال، همبستگی بین ویژگی‌های ورودی)، این ساختار را می‌توان آموخت و در نتیجه هنگام وارد کردن ورودی از طریق گلوگاه شبکه، از آن استفاده کرد [26] ,[11]. خودرمزنگار تک لایه، یک شبکه عصبی سه لایه است که در شکل ۱ نشان داده شده است.

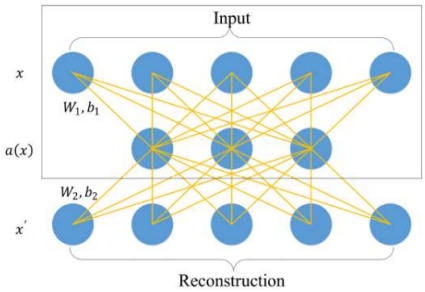

شکل ۱ – شمای کلی یک خودرمزنگار برای تبدیل داده‌های ورودی در ۵ بعد به خروجی در ۳ بعد

اما خودرمزنگار انباشته (SAE) از طریق تجمیع خودرمزنگارهای متوالی ساخته می‌شود. به طور کلی، لایه پنهان هر خودرمزنگار تک لایه به عنوان لایه ورودی خودرمزنگار بعدی در نظر گرفته می‌شود [27] . در این پژوهش از یک شبکه خود رمز نگار سه لایه استفاده شده است که داده‌های ورودی را از یک فضای ۲۱ بعدی دریافت می‌کند و در نهایت آنها را به فضایی با حداکثر ابعاد ۱۰ تایی نگاشت می‌نماید. به این صورت تعداد خصوصیات مربوط به هر سطر از داده‌ها کاهش می‌یابد و مدل یادگیرنده تنها ویژگی‌های مهم‌تر را به عنوان ورودی دریافت می‌کند .فرایند لایه به لایه کاهش ابعاد در طی سه لایه موجب می‌شود که مدل ابعاد داده‌ها را به صورت مرحله به مرحله بکاهد. تحقیقات نشان می‌دهند که این موضوع باعث افزایش دقت یادگیری خود رمز نگار می‌گردد و مدل‌های چند لایه عملکرد بهتری نسبت به خود رمزنگارهای تک لایه دارند [28] ,[27]. در نهایت پس از بررسی داده‌های خروجی خودرمزنگار، دریافت می‌شود که از بین ۱۰ ویژگی ممکن، مدل دو ویژگی را به صورت صفر در نظر گرفته و ۸ ویژگی دیگر را به عنوان نمایندگان داده‌های ورودی ایجاد نموده است.

شبکه‌های حافظه کوتاه بلندمدت [29] – که معمولاًLSTM نامیده می‌شوند – نوع خاصی از RNN هستند که قادر به یادگیری وابستگی‌های بلندمدت هستند. به خاطر سپردن اطلاعات برای مدت طولانی عملاً رفتار پیش فرض LSTM است و به همین علت در مواقعی که داده‌های سری زمانی داریم که توالی داده‌ها در آنها مهم است، معماری LSTM یکی از بهترین انتخاب‌ها برای انجام پیش‌بینی‌ها می‌باشد[30].

در این پژوهش به منظور در نظر گرفتن داده‌های گذشته با دقت بالا، از دو لایه مبتنی بر LSTM با تعداد ۵۰ نورون استفاده شده است. در واقع داده‌ها پس از خروج از خود رمزنگار، برای ورود به لایه‌های LSTM آماده سازی می‌شوند. این آماده سازی به این صورت انجام می‌شود که تعداد پنجره زمانی از گذشته به عنوان ورودی به لایه LSTM داده می‌شوند و در نهایت از مدل انتظار می‌رود که جهت بازار را در چند پنجره بعد پیش‌بینی نماید. در این‌جا هر پنجره زمانی را بازه‌های ۱۵ دقیقه ای از اطلاعات بازار در نظر میگیریم. ورودی‌ها پس از عبور از دولایهLSTM ، از دو لایه اصطلاحا Dense نیز عبور می‌کنند که هر کدام به ترتیب ۲۰ و ۱۰ نورون دارند. یک لایه Dense یا متراکم به لایه ای گفته می‌شود که کاملا به لایه قبلی خود متصل است، به این معنی که نورون‌های لایه به هر نورون لایه قبلی متصل هستند[32] ,[31] . در نهایت یک لایه متراکم با ۳ نورون در انتهای شبکه عصبی عمیق قرار دارد که با توجه به داده‌های ورودی طی شده از میان لایه‌های مختلف شبکه، پیش‌بینی می‌نماید که جهت بازار در پنجره‌های آینده نزولی خواهد بود یا صعودی. در واقع این سه نورون هرکدام محاسبه می‌کنند که احتمال اینکه داده‌های ورودی مربوط به یکی از سه کلاس خرید، فروش، و یا نگه داشتن سهم باشد چقدر است [33]. به طور خلاصه می‌توان گفت که مدل احتمال موفقیت آمیز بودن خرید سهم را از احتمال موفقیت سایر عملیات، یعنی فروش و یا عدم انجام معامله، بیشتر می‌داند.

داده‌های مورد استفاده در اثر حاضر داده‌های مربوط به معاملات آتی سکه از ابتدای سال ۱۳۹۰ هستند که از بورس کالای ایران دریافت گردیدند. همچنین داده‌های مربوط به بازار جهانی طلا از نرم افزار متاتریدر استخراج می‌شود. این داده‌ها شامل قیمت‌های آغازین، بالاترین، پایین ترین، پایانی، حجم معاملات و تعداد قراردادهای باز می‌باشد. سپس شاخص‌های تکنیکال متداول از جمله MA، RSI، MACD و ... محاسبه می‌شود. هچنین ۵ شاخص جدید که احتمال تاثیر آن‌ها بر جهت قیمت‌ها در بازار آتی زیاد می‌باشد، معرفی شده و پس از محاسبه به عنوان ورودی مدل در نظر گرفته می‌شود. در ادامه به تفصیل، به شرح دو مجموعه داده مورد نظر خواهیم پرداخت:

مجموعه داده‌های اول مشتمل بر معاملات آتی سکه از بورس کالای ایران دریافت گردیده است. داده‌های این مجموعه از ماه مه سال ۲۰۱۱ میلادی شروع شده و تا ماه مه سال ۲۰۱۸ ادامه یافته اند و مجموعه داده دوم مشتمل بر معاملات طلا در بازار جهانی است و از نرم افزار متاتریدر استخراج گردیده است. داده‌های این مجموعه از ماه مارچ سال ۲۰۰۹ میلادی شروع شده و تا ماه سپتامبر سال ۲۰۲۱ ادامه یافته اند. شایان ذکر است که در مجموعه معاملات طلا در بازار جهانی، ۵ شاخصی که در مجموعه اول محاسبه و اضافه گردیده اند، لحاظ نشده اند. علاوه بر این اطلاعات اولیه، ۱۵ شاخص تکنیکال برای

هر سطر از داده‌ها محاسبه شده و به آن اضافه گردیده است. این داده‌ها شامل ۱۰ شاخص تکنیکال رایج در بورس به عناوین زیر می‌باشند [34]:

MACD، CCI، ATR، BOLL، EMA20، MA10، MA5، ROC، RSI و WVAD.

علاوه بر این‌ها، برای مجموعه اول پنج شاخص جدید دیگر نیز از داده‌ها استخراج گردیده و به هر سطر از آنها اضافه شده است. تحلیل‌ها نشان می‌دهند که این پنج شاخص جدید نمایانگر وضعیت بازار بوده و مدل پیشنهادی با استفاده از آنها عملکرد بهتری خواهد داشت. پنج شاخص جدید معرفی شده به شرح زیر هستند:

High to Low ratio: نمایانگر نسبت بیشترین به کمترین قیمت در هر بازه زمانی[۱۵] است. این شاخص می‌تواند میزان نوسانات بازار را به خوبی نشان دهد.

Seller to Buyer ratio: این شاخص نشان دهنده نسبت خریدار به فروشنده در هر لحظه است.

Last 2 Hours of yesterday to mean of yesterday ratio: این شاخص قیمت پایانی دو ساعت آخر روز گذشته را نسبت به میانگین کل دیروز محاسبه می‌نماید. علاوه بر در نظر گرفتن قیمت تسویه، این شاخص نشان می‌دهد که بازار روز گذشته با حالت صعودی بسته شده است یا نزولی.

Close to Open of day ratio: نسبت قیمت پایانی به آغازین هر روز. این شاخص میزان قدرت خریدار نسبت به فروشنده را نشان می‌دهد.

Close of last day to Open of day ratio: آخرین شاخص بیان کننده نسبت قیمت پایانی روز گذشته قیمت آغازین روز حاضر است. اگر این نسبت نزدیک به یک باشد، نشان می‌دهد که در ساعات بسته بودن بازار اخبار و اطلاعات تاثیرگذاری منتشر نشده اند.

پرسش‌های پژوهشی

در این بخش تمرکز بر روی بیان مفروضات اتخاذ شده به منظور حل مسئله حاضر و همین‌طور بررسی پرسش‌های این تحقیق می‌باشد. پرسش‌های مربوط به پژوهش انجام شده در این مقاله در دو دسته پرسش‌های اصلی و فرعی مورد تحلیل قرار می‌گیرند. همان‌طور که پیشتر نیز ذکر شد، پرسش اصلی اثر حاضر این است که آیا با ترکیب الگوریتم‌های تبدیل موجک، خودرمزنگار انباشته، و حافظه طولانی کوتاه مدت می‌توان جهت بازار بورس کالا ایران برای آیتم سکه طلا را پیش‌بینی نمود یا خیر؟ همچنین پرسش‌های فرعی موجود برای چنین پژوهشی شامل نحوه انتخاب داده‌های ورودی، تعداد ابعاد تنظیم

شده به منظور کاهش ابعاد اولیه داده‌ها، استراتژی معاملاتی اتخاذ شده و نحوه انتخاب پارامترها و ابرپارامترهای الگوریتم‌های انتخابی می‌باشد.

همچنین فرضیات در نظر گرفته شده برای حل مسئله حاضر شامل این هستند که داده‌های تکنیکال می‌توانند در پیش‌بینی جهت حرکت بازار موثر واقع شوند. درضمن با در نظر گرفتن میزان نوسان‌های بازار سکه طلا، فرض می‌شود که داده‌های هر ۱۵ دقیقه از بازار می‌توانند برای پیش‌بینی آن مفید واقع شوند و کفایت کنند. علاوه بر پارامترهای ذکر شده، در این پژوهش سه پارامتر دیگر وجود دارند که نیازمند بررسی بیشتری هستند و مقدار ابتدایی آن‌ها از مفروضات اولیه در انجام تحقیق نخواهد بود و با استفاده از فرایند بهینه سازی به بهترین ترکیب از این پارامترها دست خواهیم یافت. این پارامترها شامل طول زمان بررسی بازار به منظور ارائه پیش‌بینی‌ها، طول بازه مورد پیش‌بینی و همینطور آستانه میزان سودی است که در صورت وقوع در هر معامله، می‌توان با توجه به هزینه کارمزد آن معامله را سودده نامید. در ادامه به شرح بررسی این سه پارامتر و نحوه بهینه سازی آنها برای دستیابی به بهترین حالت می‌پردازیم.

window_size

این پارامتر نشان گر تعداد پنجره‌های مورد بررسی در گذشته به منظور پیش‌بینی آینده است. می‌دانیم که مجموعه‌های داده مورد استفاده در پژوهش حاضر شامل رشته‌هایی است که هر کدام اطلاعات قیمت و شاخص‌ها را در هر ۱۵ دقیقه ثبت کرده اند و هر نمونه از مجموعه داده یک پنجره زمانی در نظر گرفته می‌شود. حال اینکه با استفاده از چند نمونه از داده‌های گذشته به پیش‌بینی آینده بپردازیم موردی است که باید تحت بررسی قرار گیرد. به همین منظور ۲ عدد مختلف را برای این پارامتر در نظر گرفته‌ایم. در این راستا، اعداد ۵ و ۲۰ به عنوان متغیرهای ممکن برای این پارامتر بررسی خواهد شد.

pred_window

حال با داشتن تعدادی از پنجره‌های زمانی گذشته، هدف این است که پیش‌بینی کنید در چند پنجره آینده جهت بازار به چه سمتی خواهد بود. این موضوع که مدل می‌تواند پیش‌بینی‌های دقیق‌تری برای آینده نزدیک‌تر داشته باشد و یا دورتر و اینکه در کدام یک از این حالت‌ها سوددهی بیشتری خواهد داشت، پارامتر دیگری است که باید مورد بررسی قرار بگیرد. در نتیجه دو متغیر ممکن برای این پارامتر را اعداد ۶ و ۹ در نظر می‌گیریم. به عنوان مثال عدد ۶ نشان می‌دهد که با توجه به پنجره‌های زمانی گذشته، می‌خواهیم پیش‌بینی نماییم که در ۶ پنجره آینده جهت بازار نزولی یا صعودی است.

return_percentage

درصد بازده سود یا زیان خالص یک سرمایه گذاری در یک دوره زمانی مشخص است که به صورت درصدی از هزینه اولیه سرمایه گذاری بیان می‌شود. در این پژوهش مناسب بودن شرایط بازار به منظور خرید و فروش سهم با در نظر گرفتن نرخ بازده محاسبه می‌شود. در واقع عوامل تاثیر گذار بر اینکه شرایط بازار به اندازه کافی مناسب هستند خرید یا فروش صورت بگیرد، نرخ بازده و تعداد پنجره‌های مورد پیش‌بینی هستند. مقادیر نسبتاً بزرگ برای حداقل نرخ بازده، باعث می‌شوند که معاملات کمتری صورت بگیرد و در بیشتر شرایط بازار به جای دستور خرید و فروش، به دست نگه داشتن و عدم معامله توصیه گردد. در نتیجه این پارامتر نیز نیازمند بهینه سازی می‌باشد و لازم است بررسی شود که کدام مقادیر آن موجب سوددهی حداکثری می‌شوند. به این منظور مقادیر ۰/۰۵، ۰/۱ و ۰/۲ برای بهینه سازی پارامتر مذکور انتخاب شده و مورد مطالعه قرار می‌گیرند. نتایج آزمون عملکرد مدل‌های یادگیرنده با در نظر گرفتن مقادیر مختلف برای این سه پارامتر در فصل بعد به تفصیل مورد تحلیل قرار خواهند گرفت.

یافته‌های پژوهش

در این بخش به بررسی نتایج پژوهش از جنبه‌های مختلف خواهیم پرداخت. در ابتدا دستاوردهای حاصل از بهینه سازی پارامترها در شده در بخش ۲ را بیان می‌کنیم و بهترین مجموعه به دست آمده از پارامترها را معرفی می‌نمایم. سپس با استفاده از این مجموعه مدل یادگیرنده نهایی را برای انجام پیش‌بینی جهت بازار بر روی پنجره‌های زمانی آینده ایجاد نموده و فرآیند توسعه و بهبود آن را شرح می‌دهیم. این فرایند شامل کاهش نویز با استفاده از تبدیل موجک، کاهش ابعاد داده‌ها با استفاده از خودرمزنگار، و انجام پیش‌بینی سری زمانی با بهره گیری از معماری LSTM می‌باشد. در نهایت به تحلیل عملکرد مدل بر روی مجموعه آزمون خواهیم پرداخت و میزان دقت و سوددهی مدل پیشنهادی در این مجموعه را مورد مطالعه قرار خواهیم داد.

پس از انجام پیش پردازش داده‌های ورودی با استفاده از تبدیل موجک و کاهش ابعاد داده‌ها از ۲۱ ویژگی به ۸ ویژگی مطابق توضیحاتی که در بخش ۲ صورت گرفت، به بهینه سازی سه پارامتر معرفی شده در بخش ۳ می‌پردازیم. به این منظور، به تعداد تمامی مجموعه‌های ممکن به دست آمده از ترکیب مقادیر مختلف این پارامتر ها، مجموعه‌های داده را ایجاد می‌نمایم. با توجه به اینکه سه متغیر مختلف برای پارامتر return_percentage، و دو متغیر برای هر یک از متغیرهای دیگر داریم، در کل ۱۲ مجموعه از ترکیب این مقادیر به دست خواهد آمد که تمامی آنها در نظر گرفته شده و مورد مطالعه قرار می‌گیرند.

جدول ۱ نشان دهنده تغییر تعداد داده‌های مربوط به هر یک از کلاس‌های خرید، فروش و عدم معامله است که با لغات Buy، Sell و Hold مشخص شده‌اند.

جدول ۱ – تراکم کلاس‌های خرید، فروش و عدم معامله در حالات مختلف سه پارامتر

pred_window	return_percentage	window_size	Sell	Hold	Buy
۶	۰/۰۵	۵	۱۹۵۳۶	۱۶۸۴۷	۱۹۲۹۸
۶	۰/۰۵	۲۰	۱۹۵۳۶	۱۶۸۴۷	۱۹۲۹۸
۶	/۱۰	۵	۱۴۱۱۳	۱۷۹۴۰	۱۳۶۲۸
۶	/۱۰	۲۰	۱۴۱۱۳	۱۷۹۴۰	۱۳۶۲۸
۶	/۲۰	۵	۸۶۹۸	۳۸۴۴۶	۸۵۳۷
۶	/۲۰	۲۰	۸۶۹۸	۳۸۴۴۶	۸۵۳۷
۹	۰/۰۵	۵	۲۱۳۶۲	۱۳۳۵۳	۲۰۹۶۶
۹	۰/۰۵	۲۰	۲۱۳۶۲	۱۳۳۵۳	۲۰۹۶۶
۹	/۱۰	۵	۱۶۴۳۸	۲۳۳۸۵	۱۵۸۵۸
۹	/۱۰	۲۰	۱۶۴۳۸	۲۳۳۸۵	۱۵۸۵۸
۹	/۲۰	۵	۱۱۱۴۲	۳۳۷۵۶	۱۰۷۸۳
۹	/۲۰	۲۰	۱۱۱۴۲	۳۳۷۵۶	۱۰۷۸۳

پس از ایجاد این مجموعه‌های داده، هر کدام از آنها به دو بخش داده‌های آموزش[۱۶] و آزمون[۱۷] تقسیم می‌شوند. این بخش کردن به این صورت انجام می‌شود که داده‌های سه ماه آخر هر سال میلادی به عنوان داده‌های آزمون و باقی نمونه‌های موجود در مجموعه در زمره داده‌های آموزش قرار می‌گیرند. علت انتخاب سه ماه آخر هر سال این است که توالی داده‌ها در آزمودن استراتژی‌های مالی حائز اهمیت است و امکان جداسازی داده‌ها به صورت تصادفی برای ایجاد مجموعه آزمون وجود ندارد [11].

پس از این مجموعه‌های آموزش و آزمون بر روی هر یک از ۱۲ حالت موجود در فرایند بهینه سازی، هر کدام از این مجموعه‌ها برای آموزش یک مدل مبتنی بر معماری LSTM جزئیات آن در بخش ۲ بیان شد، مورد استفاده قرار می‌گیرند. به منظور صرفه جویی در زمان در این پروسه، تمامی‌مدل‌ها برای ۱۰ دوره[۱۸] تحت آموزش قرار گرفتند. سپس هر کدام از مدل‌های به دست آمده با داده‌های آزمون مربوطه مورد بررسی قرار می‌گیرند که جزئیات این مجموعه‌ها در جدول ۱ درج شده است. پیش‌بینی‌های انجام شده توسز مدل، با مقادیر واقعی برای داده‌های متناظر مورد مقایسه قرار گرفته و میزان دقت هر یک از حالت‌ها بررسی شدند. شکل ۲ نشان دهنده میزان دقت پنج مورد از بهترین حالات به دست آمده در میان ۱۲ حالت موجود است. بیشترین میزان دقت و کمترین میزان هدر رفت مربوط به حالتی است که

در آن مقادیر پارامترها به ترتیب ۰,۱، ۶ و ۲۰ برای return_percentage، pred_window و window_size هستند. در نتیجه دریافت می‌شود که این مجموعه از پارامترها بهترین عملکرد را در شرایط یکسان نسبت به سایر مجموعه‌ها داشته و از این پس به عنوان مجموعه مبدا قرار گرفته و مدل پیشنهادی بر اساس آن توسعه می‌یابد.

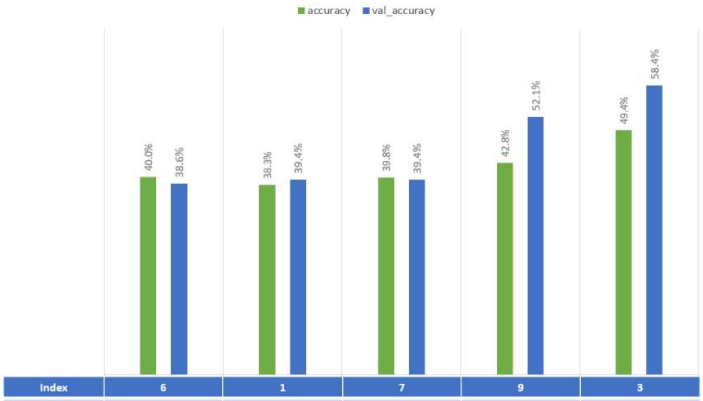

Index	6	1	7	9	3
pred_window	9	6	9	9	6
return_percentage	0.05	0.05	0.05	0.1	0.1
window_size	5	20	20	20	20

شکل ۲ – مقایسه دقت پنج حالت برتر به دست آمده از فرآیند بهینه‌سازی پارامترها

پس از تایید پارامترهای مورد بهینه سازی در مرحله قبل، بهترین مجموعه از پارامترهای انتخاب شده را به منظور آموزش مجدد مدل برای ۱۰۰ دوره و بر روی همان مجموعه‌های آموزش و آزمون قبلی آماده سازی می‌کنیم. ضمنا یک مکانیزم توقف زودهنگام[۱۹] به هنگام آموزش در نظر گرفته شده است که در صورت بیش برازش مدل و عدم بهبود آن در طی ده دوره متوالی، فرایند آموزش را متوقف سازد [35]. در اینجا برای اثبات توان بالای مدل در انجام پیش‌بینی‌های دقیق، نتایج به دست آمده از آن را بادو روش دیگر مبتنی بر یادگیری ماشین مقایسه می‌نماییم:

SVM Classifier: این روش یکی از قدرتمندترین روش‌های مبتنی بر یادگیری ماشین به منظور انجام دسته بندی بر روی داده‌ها است. در واقع متد دسته بندی با استفاده از ماشین بردار پشتیبان یا همان SVM [36] ,[3] به عنوان نماینده روش‌های یادگیری بدون استفاده از شبکه‌های عصبی می‌باشد. لازم به ذکر است که مجموعه‌های آموزش و آزمون برای این مدل دقیقاً مانند مدل اصلی مبتنی بر LSTM تقسیم شده‌اند.

Artificial Neural Network: این روش نیز نماینده روش‌های مبتنی بر شبکه‌های عصبی یادگیری

عمیق است که از معماری LSTM استفاده نمی‌کند. هرچند که این شبکه‌ها در بسیاری از مسائل نتایج شگرفی را به نمایش گذاشته‌اند، مکانیزمی برای به یاد سپاری اطلاعات مهم داده‌های سری زمانی در آنها وجود ندارد [31]. به همین علت، مقایسه این مدل با روش پیشنهادی می‌تواند تاثیر استفاده از معماری LSTM را به خوبی نشان دهد.

همانطور که در شکل ۳ مشاهده می‌شود، روش پیشنهادی با اختلاف معنی‌داری دقت پیش‌بینی‌ها را بهبود می‌بخشد. این آزمایش اثبات می‌کند که استفاده از معماری LSTM به صورت انباشته[۲۰] و با جزئیات اعلام شده در بخش ۲، می‌تواند به شکل قابل توجهی دقت روش‌های سنتی یادگیری ماشین و همین‌طور سایر روش‌های یادگیری عمیق را بهبود بخشد. در ضمن نتایج این آزمایش در کنار دستاوردهای بخش بهینه‌سازی پارامترها نشان می‌دهند که استفاده از معماری LSTM به تنهایی نمی‌تواند از سایر مدل‌ها پیشی بگیرد و فرایند بهینه‌سازی پارامترها و تنظیم ابرپارامترهای مدل پیشنهادی موجب افزایش دقت این معماری نسبت به سایر معماری‌ها گشته است. همین طور تحقیقات ثابت می‌کنند که بهبود حدودا ۸ درصدی میزان دقت پیش‌بینی امری سهل الوصول نیست و دستیابی به چنین دقتی با استفاده از داده‌های مربوط به تحلیل‌های تکنیکال، نتیجه ای مقبول و مطلوب است. ضمناً در این تصویر علاوه بر دقت، میزان بازده هر یک از مدل‌ها بر روی مجموعه آزمون نشان داده شده است و دیده می‌شود که روش پیشنهادی تقریبا ۱۰۰ درصد میزان بازده را بهبود می‌بخشد. با وجود اینکه دقت پیش‌بینی میان کلاس‌های موجود تنها ۸ درصد بهبود یافته است، رشد ۱۰۰ درصدی بازده نشانگر توانایی بالای مدل LSTM درتشخیص معاملات با سوددی زیاد است و اثبات می‌کند که روش پیشنهادی عموماً در صورت بروز اشتباه نیز منجر به زیان دهی سنگین نمی‌شود.

با تایید عملکرد مناسب مدل پیشنهادی در بخش گذشته، در این قسمت استراتژی‌های مختلف بهره گیری از آن را در خرید و فروش سکه در بازار بورس کالا بررسی خواهیم کرد. همچنین، عملکرد مدل مشابهی را که بر روی مجموعه داده‌های دوم، یعنی دادگان بازار طلای بین المللی، آموزش دیده است را با مدل اول مقایسه می‌نماییم و در نهایت میزان سودآوری هر دو مدل را به بحث می‌گذاریم. همانطور که در بخش ۲ دیده شد، داده‌های بازار طلای بین المللی شامل ۱۴ ویژگی برای هر سطر از داده‌ها هستند و تفاوتشان با مجموعه داده سکه در بورس کالا در پنج ویژگی تعریف شده برای آن مجموعه توسط این مقاله و همچنین حجم معاملات و قراردادهای باز است. در واقع بررسی‌های انجام شده در این بخش تاثیر آن ۵ ویژگی را بر دقت و میزان سود دهی مدل‌ها در بازارهای مالی داخلی و خارجی می‌سنجد.

برای انجام این مقایسه، هر سه مرحله ذکر شده در فصل ۲ را روی داده‌های بازار طلای بین المللی پیاده سازی می‌نماییم. در نهایت نتایج به دست آمده با استفاده از استراتژی‌های مختلف آزموده می‌شوند تا تفاوت میان داده‌های دو مجموعه داده و در نتیجه مدل‌های مبتنی بر آنها مشخص گردد. در این بخش دو استراتژی مختلف را برای سنجش میزان سوددهی دو مدل توسعه یافته از جمله مجموعه داده‌های موجود معرفی می‌نماییم. این استراتژی‌ها بر روی مجموعه‌های آزمون هر یک از مدل‌ها مورد سنجش قرار می‌گیرند:

استراتژی اول: در این استراتژی، به هنگامی که مدل در یک لحظه پیش‌بینی می‌نماید که با توجه به داده‌های ورودی، عملیات خرید یا فروش برای رسیدن به سود طی ۶ پنجره آینده عملیات مناسبی است، دستور انجام خرید و فروش بر اساس پیش‌بینی مدل انجام می‌شود. حال آنکه ممکن است در طی مدت ۶ پنجره آینده و با توجه به داده‌های ورودی به روز شده در هر لحظه، این پیش‌بینی با تغییراتی روبرو شود. مثلاً امکان دارد یک یا چند سیگنال از میان این ۶ سیگنال برخلاف سیگنال خرید، مناسب بودن فروش را پیش‌بینی کنند. در این حالت در طی استراتژی اول، مدل بدون توجه به سیگنال‌های آتی، سیگنال خرید اولیه را ادامه داده و تنها هنگامی که سفارش را می‌بندد که ۶ پنجره طی شده باشد.

استراتژی دوم: در این استراتژی، در موقعیتی که شرایط توضیح داده شده در حالت قبل پیش آید، مدل بلافاصله سفارش جاری را می‌بندد و سفارش جدیدی را باز می‌کند.

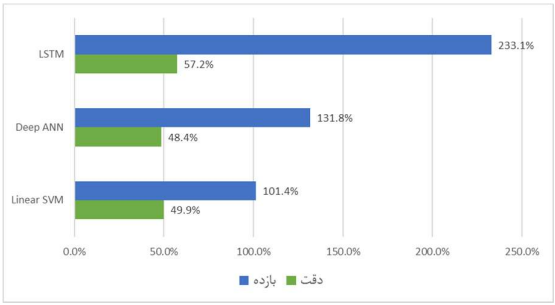

شکل ۳ - مقایسه میزان دقت و بازده روش پیشنهادی با سایر روش‌ها در مجموعه آزمون

نتایج بررسی این دو استراتژی در شکل ۴ به نمایش درآمده اند. این نتایج نشان می‌دهند که به طور کلی استراتژی اولیه عملکرد بهتری داشته و با استفاده از آن سوددهی بیشتری حاصل می‌شود. این موضوع می‌تواند به این دلیل باشد که در صورتی که مدل یک پیش‌بینی انجام می‌دهد، بهتر است به آن پیش‌بینی اعتماد شود و تا پایان شش پنجره سفارش باز بماند تا به حداکثر سود دهی برسد. همین‌طور به وضوح قابل مشاهده است که نتایج در بازار سکه بورس کالا به دلیل استفاده از ۵ ویژگی اضافه شده

توسط این پژوهش، بسیار قابل اتکاتر است و آزمودن استراتژی روی این بازار موجب سوددهی قابل توجهی شده است. حال آن که استراتژی‌های مشابه بر روی مدلی مشابه در بازار طلای جهانی تنها اندکی سودده بوده است. این موضوع، توانایی بالای مدل پیشنهادی در ارائه پیش‌بینی‌ها بر روی بازار داخلی را بیان می‌نماید.

نتیجه‌گیری و بحث

در این پژوهش به معرفی روشی برای پیش‌بینی جهت حرکت قیمت در بازارهای مالی با استفاده از روش‌های مبتنی بر یادگیری عمیق پرداختیم. به جهت انجام مطالعه موردی، این تحقیق در روی بازار سکه در بورس کالای ایران تمرکز دارد. با مشاهده نواقصی و کاستی‌هایی که در استفاده از داده‌های تکنیکال وجود دارد و کمبود دقت سایر روش‌هایی مبتنی بر این داده‌ها علی الخصوص در بازارهای داخلی، هدف این پژوهش ارائه مدلی دقیق به منظور بررسی بازار و پیش‌بینی جهت حرکت آن در بازه‌های زمانی آتی است. ضمناً روش پیشنهادی علاوه بر داده‌های تکنیکال از ۵ ویژگی دیگر که توسط پژوهشگران این

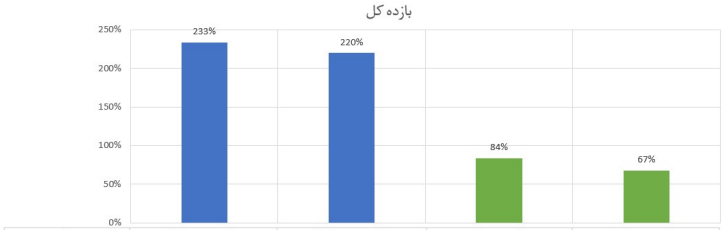

بازار	سکه بورس کالا	سکه بورس کالا	طلای جهانی	طلای جهانی
استراتژی	اول	دوم	اول	دوم
مدت	۲ سال	۲ سال	۳ سال	۳ سال
تعداد معاملات	۵۳۶	۵۵۰	۶۱۸	۶۴۶
معامله سود مثبت	۳۶۸	۳۷۵	۲۷۰	۲۵۵
معامله سود منفی	۱۵۱	۱۵۳	۳۶۳	۳۹۱
بازده کل	۲۳۳%	۲۲۰%	۸۴%	۶۷%

شکل ۴ – مقایسه سوددهی روش پیشنهادی در بازار سکه بورس کالای ایران و بازار طلای جهانی با دو استراتژی

مقاله اضافه شده است بهره می‌گیرد که از نوآوری‌های پژوهشی اثر حاضر به حساب می‌آید و در تحقیقات آینده نیز مورد استفاده خواهد بود. دادگان موجود در طی مراحلی برای انجام پیش‌بینی‌ها آماده شده و پس از کاهش نویز با استفاده از تبدیل موجک و کاهش ابعاد داده‌ها با بهره گیری از خود رمزنگار انباشته، به یک مدل یادگیری عمیق داده می‌شوند. این مدل که از معماری LSTM برای در نظر گرفتن بازه‌های زمانی گذشته و پیش‌بینی آینده استفاده می‌کند، با دریافت داده‌های ۲۰ پنجره زمانی گذشته (که هر کدام دربرگیرنده اطلاعات هر ۱۵ دقیقه از بازار هستند)، جهت بازار را طی ۶ پنجره آینده پیش‌بینی

می‌نماید و تشخیص می‌دهد که با توجه به شرایط موجود کدام یک از عملیات خرید، فروش و یا عدم انجام معامله می‌تواند بهترین گزینه باشد. بررسی‌های انجام شده بر روی مدل نشان می‌دهند که پیش‌بینی‌ها با استفاده از ۲۰ پنجره ورودی و ۶ پنجره در خروجی بهینه‌ترین حالت را شامل می‌شوند و در این حالات مدل به بیشینه میزان دقت دست می‌یابد. همچنین مقایسه با سایر روش‌های مبتنی بر یادگیری ماشین، یعنی روش‌های مطرح SVM و شبکه‌های عصبی عمیق با معماری Dense، اثبات می‌کند که استفاده از معماری LSTM در این مسئله به نحو قابل توجهی دقت را بهبود داده است. همینطور به منظور بررسی دقیق‌تر عمل کرده مدل پیشنهادی بر روی بازار، بازده آن نیز بر روی یک مجموعه آزمون با طول دو سال محاسبه شد و در بهینه‌ترین استراتژی به ۲۳۰ درصد سوددهی دست یافت. این موضوع اثبات می‌کند که روش پیشنهادی هم از دقت بالا و هم از میزان سوددهی قابل قبول برخوردار است و در انجام پیش‌بینی‌ها در بازار داخلی عملکرد قابل اتکایی دارد. در نتیجه از مزایای روش حاضر نسبت به روش‌های گذشته می‌توان به دقت و سوددهی بالای مدل پیشنهادی و عملکرد مناسب در بازه‌های زمانی کوتاه مدت اشاره نمود. علاوه بر این ارائه استراتژی معاملاتی متناسب با ویژگی‌های مدل پیشنهاد شده در این روش به عنوان مزیتی دیگر نسبت پژوهش‌های مشابه به حساب می‌آید و موجب کاربردی‌تر بودن مدل پیشنهادی در انجام معاملات واقعی خواهد شد. ضمناً در این تحقیق به مطالعه یکی از چالش‌برانگیزترین آیتم‌های معاملاتی یعنی طلا پرداخته شده است و حصول دقت مناسب در این معاملات از برتری‌های قابل ذکر نسبت پژوهش‌های مشابهی است که بر روی سایر معاملات صورت گرفته‌اند. مراحل بعدی این پژوهش می‌تواند شامل بررسی عملکرد روش پیشنهادی بر روی سایر بازارهای داخلی از جمله بازار بورس، و همینطور سایر کالاها در بازار بورس کالا باشد. در واقع به این علت که هر یک از بازارها ممکن است به خاطر ویژگی‌های خاص خود نیازمند تغییراتی برای بهینه سازی عملکرد مدل باشند. هرچند می‌توان با جمع آوری یک مجموعه داده جامع از داده‌های یک بازار مشخص، مانند بازار بورس کالای ایران، مدل جامعی را برای تمامی کالاها آموزش داد تا به یک سهم یا کالای خاص وابسته نباشد. به این صورت می‌توان میزان سوددهی را بالاتر برد و همین طور در مواقعی که شرایط یک بازار یا یک کالای مشخص برای انجام معامله نامناسب است، با فعالیت در سایر بازارها از زیان دادن پرهیز کنیم. هرچند از محدودیت‌های انجام این کار می‌توان به چالش‌های جمع آوری این میزان عظیم از داده و همین‌طور پردازش و آموزش مدل با استفاده از آنها اشاره کرد. علاوه بر نیازمندی به توان پردازشی بالا، ایجاد چنین مدلی ملزم به بهینه سازی سرعت عملکرد آن می‌باشد تا با بررسی تمامی دارایی‌ها در بازار و با ارسال سیگنال برای انجام معاملات در زمان مناسب بتواند به سوددهی مورد نظر دست یابد.

منابع

[۱۰] شریف‌فر امیر و همکاران. 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. ۱۴۰۰

[۲۰] سعیدی علی، علی‌محمدی شهریار. بررسی عوامل مؤثر بر تغییرات قیمت قراردادهای آتی در بورس کالای ایران. مهندسی مالی و مدیریت اوراق بهادار. ۱۳۹۳

[1] R. Iacomin, “Stock market prediction,” 2015 19th Int. Conf. Syst. Theory, Control Comput. ICSTCC 2015 - Jt. Conf. SINTES 19, SACCS 15, SIMSIS 19, pp. 200–205, 2015, doi: 10.1109/ICSTCC.2015.7321293.

[2] A. Arévalo, J. Niño, G. Hernández, and J. Sandoval, “High-Frequency Trading Strategy Based on Deep Neural Networks,” Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics), vol. 9773, p. V, 2016, doi: 10.1007/978-3-319-42297-8.

[3] K. J. Kim, “Financial time series forecasting using support vector machines,” Neurocomputing, vol. 55, no. 1–2, pp. 307–319, 2003, doi: 10.1016/S0925-2312(03)00372-2.

[4] G. P. Zhang and M. Qi, “Neural network forecasting for seasonal and trend time series,” Eur. J. Oper. Res., vol. 160, no. 2, pp. 501–514, 2005, doi: 10.1016/j.ejor.2003.08.037.

[5] I. E. Livieris, E. Pintelas, and P. Pintelas, “A CNN–LSTM model for gold price time-series forecasting,” Neural Comput. Appl., vol. 32, no. 23, pp. 17351–17360, 2020, doi: 10.1007/s00521-020-04867-x.

[6] X. Pang, Y. Zhou, P. Wang, W. Lin, and V. Chang, “An innovative neural network approach for stock market prediction,” J. Supercomput., vol. 76, no. 3, pp. 2098–2118, 2020, doi: 10.1007/s11227-017-2228-y.

[7] M. Hiransha, E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman, “NSE Stock Market Prediction Using Deep-Learning Models,” Procedia Comput. Sci., vol. 132, no. Iccids, pp. 1351–1362, 2018, doi: 10.1016/j.procs.2018.05.050.

[8] N. JEGADEESH and S. TITMAN, “Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency,” J. Finance, vol. 48, no. 1, pp. 65–91, 1993, doi: 10.1111/j.1540-6261.1993.tb04702.x.

[9] M. Faraz, H. Khaloozadeh, and M. Abbasi, “Stock Market Prediction-by-Prediction Based on Autoencoder Long Short-Term Memory Networks,” 2020 28th Iran. Conf. Electr. Eng. ICEE 2020, 2020, doi: 10.1109/ICEE50131.2020.9261055.

[11] E. Chong, C. Han, and F. C. Park, "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies," Expert Syst. Appl., vol. 83, pp. 187–205, 2017, doi: 10.1016/j.eswa.2017.04.030.

[12] Z. He, J. Zhou, H. N. Dai, and H. Wang, "Gold price forecast based on LSTM-CNN model," Proc. - IEEE 17th Int. Conf. Dependable, Auton. Secur. Comput. IEEE 17th Int. Conf. Pervasive Intell. Comput. IEEE 5th Int. Conf. Cloud Big Data Comput. 4th Cyber Sci., pp. 1046–1053, 2019, doi: 10.1109/DASC/PiCom/CBDCom/CyberSciTech.2019.00188.

[13] J. Han, M. Kamber, and J. Pei, "Data Mining: Concepts and Techniques," Data Min. Concepts Tech., 2012, doi: 10.1016/C2009-0-61819-5.

[14] J. Liu, F. Chao, Y.-C. Lin, and C.-M. Lin, "Stock Prices Prediction using Deep Learning Models," pp. 1–15, 2019, [Online]. Available: http://arxiv.org/abs/1909.12227.

[15] M. S. Islam and E. F. Hossain, "Exchange Currency Rate Prediction using a GRU-LSTM Hybrid Network," Sciencedirect, 2021.

[16] R. Dey and F. M. Salemt, "Gate-variants of Gated Recurrent Unit (GRU) neural networks," Midwest Symp. Circuits Syst., vol. 2017-Augus, no. 2, pp. 1597–1600, 2017, doi: 10.1109/MWSCAS.2017.8053243.

[17] J. Shen and M. O. Shafiq, "Short-term stock market price trend prediction using a comprehensive deep learning system," J. Big Data, vol. 7, no. 1, 2020, doi: 10.1186/s40537-020-00333-6.

[18] Y. Li and Y. Pan, "A novel ensemble deep learning model for stock prediction based on stock prices and news," Int. J. Data Sci. Anal., pp. 1–15, 2021, doi: 10.1007/s41060-021-00279-9.

[19] M. Mohtasham Khani, S. Vahidnia, and A. Abbasi, "A Deep Learning-Based Method for Forecasting Gold Price with Respect to Pandemics," SN Comput. Sci., vol. 2, no. 4, 2021, doi: 10.1007/s42979-021-00724-3.

[21] A. Graps, "An Introduction to Wavelets," IEEE Comput. Sci. Eng., vol. 2, no. 2, pp. 50–61, 1995, doi: 10.1109/99.388960.

[22] M. R. Chernick, "Wavelet Methods for Time Series Analysis," Technometrics, vol. 43, no. 4, pp. 491–491, 2001, doi: 10.1198/tech.2001.s49.

[23] S. Mallat and W. L. Hwang, "Singularity Detection and Processing with Wavelets," IEEE Trans. Inf. THEORY, vol. 38, no. 2, 1992, [Online]. Available: http://manufacturingscience.asmedigitalcollection.asme.org/article.aspx?articleid=1450778%0Ahttp://link.springer.com/10.1007/s00170-006-0523-5.

[24] H. G. Rodney Tan, A. C. Tan, P. Y. Khong, and V. H. Mok, "Best wavelet function identification system for ECG signal denoise applications," 2007 Int. Conf. Intell. Adv. Syst. ICIAS 2007, no. 1, pp. 631–634, 2007, doi: 10.1109/ICIAS.2007.4658464.

[25] Y. H. Peng, "De-noising by modified soft-thresholding," IEEE Asia-Pacific Conf. Circuits Syst. - Proc., vol. 41, no. 3, pp. 760–762, 2000, doi: 10.1109/apccas.2000.913631.

[26] P. Vincent, H. Larochelle, Y. Bengio, and P.-A. Manzagol, "Extracting and composing robust features with denoising autoencoders," 2008, doi: 10.1016/j.neucom.2018.05.040.

[27] G. Liu, H. Bao, and B. Han, "A Stacked Autoencoder-Based Deep Neural Network for Achieving Gearbox Fault Diagnosis," Math. Probl. Eng., vol. 2018, 2018, doi: 10.1155/2018/5105709.

[28] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio, "Deep learning," Nature, vol. 1, no. 2, 2016.

[29] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Comput., vol. 9, pp. 1735–1780, 1997, doi: 10.17582/journal.pjz/2018.50.6.2199.2207.

[30] R. DiPietro and G. D. Hager, Deep learning: RNNs and LSTM. Elsevier Inc., 2019.

[31] J. Schmidhuber, "Deep Learning in neural networks: An overview," Neural Networks, vol. 61, pp. 85–117, 2015, doi: 10.1016/j.neunet.2014.09.003.

[32] Y. Bengio, "Learning Deep Architectures for AI," Found. Trends® Mach. Learn., vol. 2, no. 1, pp. 1–127, 2009, [Online]. Available: http://www.nowpublishers.com/product.aspx?product=MAL&doi=2200000006.

[33] N. Ketkar, Deep Learning with Python. 2017.

[34] D. Mo and Y. Chen, "Projecting Financial Technical Indicators into Networks as a Tool to Build a Portfolio," IEEE Access, vol. 9, pp. 39973–39984, 2021, doi: 10.1109/ACCESS.2021.3064924.

[35] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.

[36] L. Liu, E. A. Silva, C. Wu, and H. Wang, "A machine learning-based method for the large-scale evaluation of the qualities of the urban environment," Comput. Environ. Urban Syst., vol. 65, pp. 113–125, 2017, doi: 10.1016/j.compenvurbsys.2017.06.003.

یادداشت‌ها :

1 Computational intelligence
2 Machin learning
3 Deep learning
4 Auto Encoder
5 Convolutional Neural Network
6 Recurrent Neural Network
7 Autoregressive integrated moving average
8 Linear correlation
9 Long-Short term memory
10 Attention mechanism
11 Wavelet transforms
12 Haar
13 Outliers
14 Generalization
15 Time Frame
16 Training set
17 Test set
18 Epoch
19 Early stopping
20 Stacked