

Designing an Automated Trading System Using Convolutional Neural Network

Amir Hossein Yaftian*, Mohammad Ali Rastegar**

Abstract

In recent years, many articles and researches have been published on the use of machine learning methods and algorithmic trading in financial markets in order to earn returns. The aim of this study is to create an automated trading system using image processing by convolutional neural network. For this purpose, initially, after receiving the data required for the selected stocks, 28 technical analysis indicators were selected and the values of each were calculated separately for each stock. Then the time series of these indicators were converted to 2D images, and as a result, for each data on the time series of the stock price, a 2D image with dimensions of 28 x 28 was created. After labeling each image with one of the buy, sell, or hold labels, these images entered the convolutional neural network. Also, to evaluate the return and risk of the proposed system, a method for buying and selling based on the results of the model in the past has been introduced. The results show that in 80% of cases, this method is more effective than the buy and hold strategy. It also always performs better in terms of standard deviation risk and maximum drawdown. Also, the results show the high impact of trading commission on the Tehran Stock Exchange on the return of the model. In such a way that the model loses many times the profit earned for the payment of the commission.

Keywords: Algorithmic trading; Technical analysis; Deep learning; Convolutional neural networks.

Received: 2020.July.25, Accepted: 2020.December.09.

* MA Candidate in Industrial Engineering, Tarbiat Modares University, Tehran, Iran.

** Assistant Prof, Department of Industrial & Systems Engineering, Tarbiat Modares University, Tehran, Iran. (Corresponding Author). Email: ma_rastegar@modares.ac.ir

طراحی یک سیستم معاملاتی خودکار با استفاده از شبکه عصبی پیشی

امیر حسین یافتیان*، محمد علی رستگار**

چکیده

در سال‌های اخیر مقالات و پژوهش‌های زیادی در زمینه‌ی استفاده از روش‌های یادگیری ماشین و معاملات الگوریتمی در بازارهای مالی به منظور کسب بازدهی منتشر شده است. هدف این پژوهش ایجاد یک سیستم معاملاتی خودکار با استفاده از پردازش تصویر به وسیله‌ی شبکه عصبی پیشی است. بدین منظور، در ابتدا پس از دریافت داده‌های مورد نیاز برای سهام منتخب، ۲۸ اندیکاتور تحلیل تکنیکال انتخاب و مقادیر هر کدام به صورت جداگانه برای هر سهم محاسبه شد. سپس سری‌های زمانی این اندیکاتورها به تصاویر ۲ بعدی تبدیل شده و در نتیجه برای هر داده روی سری زمانی قیمت سهم، یک تصویر دو بعدی با ابعاد ۲۸×۲۸ ساخته شد. پس از برچسب‌گذاری هر تصویر با یکی از برچسب‌های خرید، فروش و نگهداری، این تصاویر به شبکه عصبی پیشی وارد شدند. همچنین برای برر سی بازدهی و ریسک سیستم ارائه شده، یک روش برای خرید و فروش بر اساس نتایج مدل در زمان گذشته معرفی شده است. نتایج پژوهش نشان می‌دهد که در ۸۰٪ موارد، این روش بازدهی بیشتری نسبت به استراتژی مرسوم خرید و نگهداری کسب کرده است. همچنین همواره از نظر معیارهای ریسک انحراف معیار و بیشترین افت بهتر عمل می‌کند. همچنین، نتایج نشان‌دهنده‌ی تأثیر زیاد کارمزد معاملات بورس اوراق بهادار تهران بر روی بازدهی مدل است. به گونه‌ای که مدل چند برابر سود کسب شده را برای پرداخت کارمزد از دست می‌دهد.

کلیدواژه‌ها: معاملات الگوریتمی؛ تحلیل تکنیکال؛ یادگیری عمیق؛ شبکه عصبی
پیشی.

تاریخ دریافت مقاله: ۱۳۹۹/۰۵/۰۴، تاریخ پذیرش مقاله: ۱۳۹۹/۰۹/۱۹.

* دانشجوی کارشناسی ارشد مهندسی صنایع، دانشگاه تربیت مدرس، تهران، ایران.

** استادیار دانشکده مهندسی صنایع و سیستم‌ها، دانشگاه تربیت مدرس، تهران، ایران (نویسنده مسئول).

E-Mail: ma_rastegar@modares.ac.ir

۱. مقدمه

پیش‌بینی بازار سهام بر اساس مدل‌های گوناگون محاسباتی، همواره بخشی از سیستم‌های معاملاتی سهام در چند دهه گذشته بوده است. در این سال‌ها، بازارهای مالی گوناگون مانند بازار سهام، بازار مشتقات مالی، بازارهای اهرمی و ... ابزارهای مالی متنوعی را در اختیار سرمایه‌گذاران و معامله‌گران قرار داده‌اند. در نتیجه، در جهان و در بازارهای مالی مختلف، به سیستم‌های معاملاتی مبتنی بر مدل‌های تصمیم‌گیری هوشمند توجه بیشتری شده است. هم‌اکنون حجم زیادی از معاملات در بازارهای، توسط سیستم‌های معاملاتی الگوریتمی و به صورت خودکار اجرا می‌شوند. رشد حضور سیستم‌های معاملات الگوریتمی و نیاز به سیستم‌ها و الگوریتم‌های جدید با عملکردهای گوناگون، تقاضای نهادهای مختلف برای امکان‌سنجی، طراحی و توسعه سیستم‌های معاملاتی خودکار را در کشورهای گوناگون و اخیراً ایران افزایش داده است. مزیت اصلی این نوع سیستم‌ها برای سرمایه‌گذاران، افزایش سرعت و دقت تحلیل اطلاعات و تصمیم‌گیری بدون دخالت دادن احساسات است. تا کنون از تکنیک‌های گوناگونی همچون تحلیل تکنیکال و تحلیل سری‌های زمانی برای ساخت این سیستم‌ها استفاده شده است. روش‌های گوناگون تحلیل داده‌های سری زمانی همچون تحلیل‌های آماری و ریاضی، پردازش سیگنال، استخراج ویژگی، شناخت الگو و یادگیری ماشینی در سال‌های اخیر مورد توجه محققین این حوزه بوده‌اند [۸].

اما در سال‌های اخیر، یادگیری عمیق، مبتنی بر مدل‌های پیش‌بینی و طبقه‌بندی بسیار گسترده شده و در موارد مختلفی که به کار گرفته شده، بهترین عملکرد را داشته است؛ به طوری که بر روش‌های سنتی هوش محاسباتی مانند ماشین بردار پشتیبان غلبه کرده است. با وجود پردازش تصویر و بینایی ماشین در برنامه‌های کاربردی مختلف، مدل‌های یادگیری عمیق تقریباً بر دیگر تکنیک‌ها غلبه کرده‌اند. تا کنون، شبکه‌های عصبی پیچشی^۱ که به اختصار CNN هم نامیده می‌شوند، یکی از بهترین مدل‌های یادگیری عمیق بوده‌اند، اما اکثراً برای رفع چالش‌های پردازش تصویر و بینایی ماشین پیاده‌سازی شده‌اند [۳].

مدل‌های CNN که اولین بار در سال ۲۰۱۲ و پس از عملکرد موفقیت‌آمیز مدل AlexNet روی داده‌های ImageNet مورد توجه قرار گرفتند، در سال‌های اخیر رشد چشمگیری داشتند و با پیاده‌سازی مدل‌های جدیدتر، خطای آن‌ها همواره رو به کاهش بوده است. به گونه‌ای که از دقت حدود ۵۵٪ در مدل AlexNet، به دقت حدود ۸۰٪ در ورژن‌های جدید مدل‌های Inception و ResNet رسیده‌ایم. امروزه، تقریباً همه محققان بینایی ماشین، CNN را در زمره مسائل طبقه‌بندی تصویر قرار می‌دهند. با وجودی که مدل‌های یادگیری عمیق، به ویژه CNN‌های عمیق، از رایج‌ترین روش‌های انتخابی محققین در سال‌های اخیر بوده است، تنها تعداد محدودی از این شبکه‌های عصبی عمیق برای مسائل مالی پیاده‌سازی شده است [۳].

^۱ Convolutional Neural Network

در این پژوهش از شبکه عصبی پیچشی استفاده شده است. از نکات جدید بودن این پژوهش می‌توان به مواردی همچون تبدیل سری‌های زمانی مالی یک-بعدی رایج در پژوهش‌های قبلی به داده‌های شبه تصویر دو-بعدی و استفاده از این تصاویر به عنوان ورودی مدل برای پیش‌بینی موقعیت‌های بازار و همچنین نبود محدودیت در انتخاب تندها تعداد پارامتر محدود برای اندیکاتورهای تکنیکال به دلیل ورود چندین اندیکاتور تکنیکال با پارامترهای متفاوت در قالب یک تصویر اشاره کرد. به منظور پاسخ به کلیدی‌ترین پرسش این تحقیق یعنی "آیا استفاده از مدل شبکه عصبی پیچشی می‌تواند به کسب بازدهی بیشتر در بازارهای مالی کمک کند؟"، یک سیستم معاملات خودکار طراحی شده که تمامی بخش‌های دریافت داده، تحلیل داده، مشخص کردن نقاط ورود و خروج، تشکیل سبد سرمایه‌گذاری و شبیه‌سازی اجرای معاملات را در بر می‌گیرد. همچنین در این تحقیق برای ساده‌سازی محاسبات و الگوریتم‌ها و همچنین استفاده از برخی مفاهیم و ابزارها، موارد زیر به عنوان پیش‌فرض در نظر گرفته شده‌اند:

— امکان اتخاذ موقعیت خرید و فروش بدون توجه به وجود صف در بازار سهام ایران

— وجود اطلاعات کافی در داده‌های تاریخی قیمت سهام برای پیش‌بینی آن

در ادامه، در بخش دوم به مبانی نظری و پیشینه تحقیق در حوزه معاملات الگوریتمی و کاربرد یادگیری عمیق می‌پردازیم. در بخش سوم به نام چارچوب نظری، به معرفی مدل و روش ارزیابی نتایج پرداخته و در بخش چهارم یعنی روش‌شناسی تحقیق، داده‌های مورد استفاده، مدل پیشنهادی و سایر جزئیات سیستم معاملات خودکار معرفی خواهند شد. در نهایت در بخش پنجم نتایج و داده‌ها مورد تجزیه و تحلیل قرار خواهند گرفت و در بخش ششم نیز این نتایج مورد بحث قرار خواهند گرفت. این پژوهش در فصل آخر با ارائه پیشنهادها آتی به اتمام می‌رسد.

۲. مبانی نظری و پیشینه پژوهش

تعریف ساده معاملات الگوریتمی را می‌توان به این صورت بیان کرد: "معاملاتی که از طریق رایانه انجام می‌شوند و از طریق الگوریتم‌هایی دستور انجام معاملات را می‌دهند و بر انجام درست معاملات نظارت می‌کنند". در تحقیقات مختلف به تأثیرات معاملات الگوریتمی بر بازار اشاره شده است. بر طبق آماری که در پژوهش کارتی (۲۰۱۳) ارائه شده است، حدود ۷۰٪ از حجم معاملات در بازارهای سهام کشور ایالات متحده آمریکا از طریق معاملات الگوریتمی و معاملات پر سود انجام می‌شود [۴]. این موضوع باعث تغییراتی بزرگ در زیرساخت‌های بازار شده است. به طور مشخص همزمان با افزایش حجم این نوع معاملات از حجم کل معاملات در بازارهای مالی، میزان تقاضا برای پژوهش و بررسی‌های مختلف در این حوزه افزایش یافته است. تحلیل تکنیکال اولین بار توسط چارلز داو ابداع شد. در سال ۱۸۹۷، چارلز داو شاخص دو بازار را برای اولین بار ایجاد کرد. میانگین صنعت که شامل دوازده سهام مرغوب و برتر بود و میانگین

راه‌آهن که بیست شرکت اقتصادی خطوط راه‌آهن را در خود داشت. اکنون این شاخص‌ها را میانگین صنعتی داوجونز و میانگین حمل و نقل داوجونز می‌نامند. تئوری داو از یکسری گفتارها و مقالات منتشر شده چالز داو در مجله وال استریت بین سال‌های ۱۹۰۰ و ۱۹۰۲ به دست آمده است. به نظر پژوهشگران و اقتصاددانان، تحلیل تکنیکال می‌تواند از طریق تلاش برای پیش‌بینی قیمت‌ها، به مطالعه رفتار بازار نیز کمک کند. پژوهشگران تحقیقات زیادی در مورد سودده بودن و کارایی شاخص‌های مورد استفاده در تحلیل تکنیکال انجام داده‌اند [۲۳، ۱۹]. به طور مثال، پاکباز، داوری و بلگوریان (۱۳۹۶) قدرت پیش‌بینی محتوای اطلاعاتی اعلان سود حسابداری توسط سیگنال‌های تحلیل تکنیکال در بورس اوراق بهادار تهران را مورد بررسی قرار دادند. آن‌ها از معیارهای میانگین متحرک و اندیکاتور حجم معاملات به عنوان استراتژی معامله برای ۵۰ شرکت فعال تر بورس اوراق بهادار تهران بین سال‌های ۱۳۹۰ تا ۱۳۹۴ استفاده کردند. نتایج پژوهش حاکی از آن است که معیارهای معاملاتی انتخاب شده در تحلیل تکنیکال می‌تواند بازده تعدیل شده بر اساس هزینه معاملات و بازده غیرعادی مثبت ایجاد کند [۱۷].

علاوه بر استفاده از تحلیل تکنیکال، تکنیک‌های تحلیل سری‌های زمانی از دیگر رشته‌ها نیز در علوم مالی و مخصوصاً مطالعه قیمت سهام به طور گسترده مورد استفاده قرار گرفته‌اند. پیش‌بینی سری زمانی در زمینه‌های مختلفی همچون پیش‌بینی سرعت باد، پیش‌بینی قیمت سهام، پیش‌بینی تقاضای برق، پیش‌بینی غلظت گرده در هوا، پیش‌بینی تشخیص فعالیت‌های انسانی، پیش‌بینی رفتار کاربر در اینترنت اشیاء و موارد بسیار دیگری به کار رفته است. روش‌های گوناگونی برای تحلیل داده‌های سری زمانی مطرح شده است. گانز و همکاران (۲۰۱۵) این روش‌ها را در دسته‌های تحلیل‌های آماری و ریاضی، پردازش سیگنال، استخراج ویژگی و شناخت الگو و یادگیری ماشینی قرار دادند [۸].

اخیراً روش‌های یادگیری ماشینی برای تحلیل و پیش‌بینی داده‌های سری زمانی به کار مورد توجه واقع شده‌اند. برخی از روش‌های یادگیری ماشینی که برای تحلیل داده‌های سری زمانی به کار رفته‌اند، عبارتند از: الگوریتم‌های خوشه‌بندی که در پژوهش داس و همکاران (۱۹۹۸) از آن استفاده شده، مدل‌های مارکوف پنهان^۱ که رامونی، سباستین و کوهن (۲۰۰۲) در پژوهش خود از آن استفاده کردند، ماشین بردار پشتیبان^۲ در پژوهش احمد، آتیا و گایار (۲۰۱۰)، شبکه‌های عصبی مصنوعی^۳ در پژوهش کالایتر اکیز و همکاران (۲۰۰۲) و در نهایت نقشه خودمراقبتی^۴ که در پژوهش کو و همکاران (۲۰۰۴) استفاده شده است [۹، ۱۸، ۱، ۱۲، ۱۶]. همچنین در بسیاری از پژوهش‌ها، روش‌های ترکیبی نتایج بهتری را نسبت به استفاده تنها از یک تکنیک خاص نشان داده‌اند.

^۱ Hidden Markov Model

^۲ Support Vector Machine (SVM)

^۳ Artificial Neural Network (ANN)

^۴ Self-Organizing Map (SOM)

بسیاری از این روش‌های ترکیبی با ترکیب روش‌های مبتنی بر تحلیل تکنیکال و تحلیل سری‌های زمانی و اخیراً یادگیری ماشینی، به نتایج بسیار خوبی دست یافته‌اند [۲۲]. باجلان، فلاح‌پور و دانا (۱۳۹۶) مدلی برای پیش‌بینی روند قیمت سهام بر پایه‌ی ماشین بردار پشتیبان وزن‌دهی شده توسط حجم‌های روزانه معاملات، همراه با روش انتخاب ویژگی هیبرید F-SSFS ارائه کردند. آن‌ها از شاخص‌های تحلیل تکنیکال و شاخص‌های آماری که برای ۱۰ سهم محاسبه شدند، به عنوان مجموعه ویژگی‌های اولیه ورودی ماشین بردار پشتیبان تعدیل یافته استفاده کردند. نتایج این پژوهش نشان داد که عملکرد ماشین بردار پشتیبان وزن‌دهی شده، در مورد مسئله پیش‌بینی روند قیمت سهام، به میزان قابل توجهی بهتر از ماشین بردار پشتیبان ساده است [۲].

اسماعیلی، عباسی و فلاح (۱۳۹۷) مدل‌های طبقه‌بندی مختلف را برای یافتن مدلی که از کارایی و دقت بالایی در پیش‌بینی عملکرد کوتاه‌مدت IPO برخوردار باشد مورد ارزیابی قرار دادند. آن‌ها ۶۰ مورد IPO عرضه شده در بورس اوراق بهادار تهران را طی دوره ۹۴-۱۳۸۴ را مورد بررسی قرار دادند. نتایج نشان دادند که مدل نزدیکترین همسایگی و ماشین بردار پشتیبان از دقت و کارایی بالایی در پیش‌بینی عملکرد کوتاه‌مدت IPO برخوردار هستند [۷].

کاربرد یادگیری عمیق در مالی. یادگیری عمیق به عنوان زیرشاخه‌ای از یادگیری ماشین شناخته می‌شود. یادگیری عمیق از لایه‌های متعدد تبدیلات خطی به منظور پردازش سیگنال‌های حسی مثل صوت و تصویر استفاده می‌کند. این روش با تقسیم مفاهیم پیچیده به تعدادی مفاهیم ساده‌تر و تکرار این کار، به مفاهیم پایه‌ای می‌رسد که ماشین قادر به تصمیم‌گیری درباره آن‌ها است. به این صورت، دیگر نیازی به وجود نظارت کامل انسان برای مشخص کردن جزئیات اطلاعات مورد نیاز ماشین در هر لحظه نیست. مهمترین مسئله‌ای که در یادگیری عمیق اهمیت دارد، روش ارائه‌ی اطلاعات به ماشین است. ارائه اطلاعات به ماشین باید به صورتی باشد که ماشین بتواند در کوتاه‌ترین زمان ممکن، اطلاعات مورد نیازی را باید با استناد به آن‌ها تصمیم بگیرد، دریافت کند.

انواع مختلفی از مدل‌های یادگیری عمیق مانند شبکه عصبی پیچشی، شبکه عصبی مجدد^۱، شبکه‌های باورهای عمیق^۲، ماشین‌های بولتزمن محدود^۳ و شبکه‌های با حافظه طولانی-کوتاه مدت^۴ وجود دارد. مدل‌های یادگیری عمیق اشاره شده برای اهداف مختلف مورد استفاده قرار می‌گیرند. در تحقیق‌های پیشین، CNN، DBN و RBM بیشتر برای طبقه‌بندی و به کار با

^۱ Recurrent Neural Network (RNN)

^۲ Deep Belief Network (DBN)

^۳ Restricted Boltzmann Machine (RBM)

^۴ Long Short-Term Memory (LSTM)

تصاویر استفاده می‌شوند. RNNها و LSTMها برای تجزیه و تحلیل داده‌های متوالی، پردازش زبان طبیعی، تشخیص گفتار و تجزیه و تحلیل داده‌های سری‌زمانی استفاده می‌شوند. علاوه بر این، CNNها عمدتاً در پردازش تصویر و ویدئو، طبقه‌بندی و شناسایی استفاده می‌شوند [۱۵]، [۱۱]. اما در پردازش زبان طبیعی و طبقه‌بندی حروف نیز استفاده می‌شوند [۱۴، ۱۰].

طبق بررسی‌های کانزایی، پاکه و کالرسیلو (۲۰۱۶)، تا کنون، CNNها یکی از بهترین مدل‌های یادگیری عمیق بوده‌اند، اما اکثراً برای رفع چالش‌های پردازش تصویر و بینایی ماشین پیاده‌سازی شده‌اند [۳]. با پیاده‌سازی موفقیت‌آمیز مدل‌های CNN، خطای این مدل‌ها در طول سال‌ها رو به کاهش بوده است. AlexNet یکی از اولین مدل‌های ارائه شده در این حوزه است که به نرخ موفقیت ۵۰-۵۵٪ دست یافت. اما اخیراً مدل‌های دیگری همچون ورژن‌های مختلف الگوریتم‌های Inception و ResNet به نرخ موفقیت تقریباً ۷۵-۸۰٪ دست یافته‌اند. امروزه، تقریباً همه محققان بینایی ماشین، CNN را در زمره مسائل طبقه‌بندی تصویر قرار می‌دهند.

دنگ و همکاران (۲۰۱۶) یک روش یادگیری عمیق برای استخراج متون اخبار، روزنامه‌ها و اطلاعات از اینترنت جهت پیش‌بینی رویدادهای تأثیرگذار بر بازار سهام پیشنهاد دادند. آن‌ها همچنین از یک شبکه تنسور عصبی^۱ و CNN عمیق برای مدل‌سازی تأثیرات کوتاه‌مدت و بلندمدت شرایط بر تغییرات قیمت سهام استفاده کردند. آن‌ها برای آزمایش مدل‌هایشان از داده‌های تاریخی سهام‌های S&P500 استفاده کردند [۶].

در تحقیقی دیگر، گودلک و همکاران (۲۰۱۷) از ۲۸ شاخص تحلیل تکنیکال به منظور ساخت تصاویر برای هر روز از سری‌زمانی داده‌های قیمت ۱۷ صندوق سرمایه‌گذاری شاخصی استفاده کردند. سپس این تصاویر را یک بار با برچسب‌های خرید و فروش، برچسب‌گذاری کردند و یک بار دیگر با برچسب خرید، فروش و نگهداری. در ادامه این تصاویر را به CNN وارد کردند تا برچسب‌های داده‌های آزمون را پیش‌بینی کند. آن‌ها داده‌های آزمون را از سال ۲۰۰۰ تا ۲۰۱۴ در نظر گرفتند و نتایج روی داده‌های تست از سال ۲۰۱۵ تا ۲۰۱۷ سوددهی این روش را نسبت به روش خرید و نگهداری نشان داد [۹].

سزار و اوزبایوقلو (۲۰۱۸) نیز در تحقیق خود از ۱۵ شاخص تحلیل تکنیکال و داده‌های قیمت سهام‌های داو جونز و تعدادی صندوق سرمایه‌گذاری شاخصی برای ساخت تصاویر استفاده کردند. آن‌ها نیز داده‌ها را با سه برچسب خرید و فروش و نگهداری برچسب‌گذاری کردند و تصاویر را به شبکه CNN وارد کردند. همانند تحقیق گودلک و همکاران (۲۰۱۷)، نتایج این تحقیق هم در بسیاری از موارد نسبت به روش‌های دیگر بازدهی بیشتری داشته است [۲۰].

ون و یوان (۲۰۱۸) در پژوهش خود از یک شبکه ترکیبی CNN-LSTM برای تحلیل داده‌ها استفاده کردند. آن‌ها از داده‌های قیمت سهام، شاخص‌های تحلیل تکنیکال، اطلاعات تحلیل

^۱ Neural Tensor Network

بنیادی و پارامترهای اقتصادی و قیمت‌های جهانی به عنوان ورودی شبکه استفاده کردند. نتایج نشان داده که شبکه ارائه شده توسط آن‌ها از نظر پارامترهایی چون F1-Score نسبت به شبکه‌های LSTM و CNN به صورت جداگانه عملکرد بهتری داشته است [۲۴].

در تحقیقی دیگر نیز، کیم و کیم (۲۰۱۹) از یک مدل ترکیبی LSTM-CNN برای پیش‌بینی قیمت سهام‌های S&P500 استفاده کردند. نتایج نشان داد که مدل ارائه شده توسط آن‌ها، از لحاظ روش‌های مختلف اندازه‌گیری خطا، نسبت به شبکه‌های LSTM و CNN به صورت جداگانه خطای کمتری داشته و توانسته پیش‌بینی بهتری ارائه کند [۱۳].

سزار و اوزبایوولو (۲۰۱۹) نیز در تحقیقی دیگر با استفاده از رویکردی متفاوت برای ایجاد تصاویر نسبت به پژوهش قبلی‌شان، قصد پیش‌بینی برچسب‌های خرید، فروش و دست‌نگه‌داشتن را داشتند. سپس این تصاویر و برچسب‌ها را به مدل CNN وارد کردند. در نهایت نتیجه گرفتند که روش آن‌ها توانسته نسبت به روش خرید و نگهداری بازدهی بیشتری کسب کند و موفق‌تر عمل کرده است [۲۱].

در این پژوهش از شبکه عصبی پیچشی به عنوان مدل پیش‌بینی استفاده شده است. همچنین برای ارزیابی عملکرد مدل نیز از ماتریس درهم‌ریختگی استفاده شده است.

شبکه عصبی پیچشی. از شبکه‌های عصبی پیچشی همواره به عنوان یکی از مهمترین روش‌های یادگیری عمیق نام برده می‌شود. در این شبکه‌ها چندین لایه با روشی خاص آموزش می‌بینند. شبکه‌های عصبی پیچشی و شبکه‌های عصبی مصنوعی تا حد بسیار زیادی شبیه هم هستند. این شبکه‌ها از تعداد زیادی نورون با وزن‌ها و بایاس‌های قابل یادگیری و قابل تنظیم تشکیل شده‌اند. هر نورون وظیفه دارد تا پس از دریافت تعدادی ورودی، حاصل ضرب ورودی‌ها در وزن‌ها را محاسبه کند و در انتها از یک تابع فعال سازی غیرخطی استفاده کرده تا نتیجه‌ای را به عنوان خروجی ارائه دهد. کل شبکه در نهایت یک تابع امتیاز مشتق‌پذیر را به دست می‌دهد. در یک طرف این تابع پیکسل‌های خام تصاویر ورودی و در طرف دیگر، امتیازهای هر دسته قرار دارند. این نوع شبکه‌ها در لایه آخر یعنی همان لایه کاملاً متصل، هنوز یک تابع خطا دارند. همه‌ی نکاتی که در مورد شبکه‌های عصبی معمولی مطرح است، در اینجا هم صدق می‌کند.

به طور کلی، چهار لایه اصلی تشکیل‌دهنده یک شبکه CNN عبارتند از: لایه Convolution، لایه Pooling، لایه Dropout و لایه Fully Connected. هر لایه وظیفه متفاوت و مخصوص به خود را دارد. آموزش مدل در هر شبکه عصبی پیچشی همانند دیگر شبکه‌های عصبی از دو مرحله‌ی Feed Forward و Backpropagation تشکیل می‌شود. در مرحله اول یا همان Feed Forward، تصاویر ورودی به شبکه وارد می‌شود. این عمل در واقع ضرب نقطه‌ای بین داده‌های تصاویر ورودی و پارامترهای هر نورون است. در ادامه نیز اعمال

عملیات پیچشی روی هر لایه اعمال می شود و بعد از آن، خروجی شبکه حساب می شود. حال جهت تنظیم پارامترهای شبکه (آموزش شبکه)، میزان خطا با استفاده از نتیجه حاصل از خروجی شبکه محاسبه استفاده می شود. بدین منظور، را با استفاده از یک تابع خطا، خروجی شبکه را با پاسخ صحیح مقایسه می کنند و میزان خطا به دست می آید. حال در مرحله بعدی، مرحله Backpropagation با توجه به میزان خطای محاسبه شده آغاز می شود. در طی این مرحله، با توجه به قاعده Chain Rule، گرادینت هر پارامتر محاسبه می شود و سپس با توجه به تأثیری که هر پارامتر بر خطای ایجاد شده در شبکه دارد، تمامی پارامترها تغییر پیدا می کنند. در نهایت، پس از به روز شدن پارامترها مرحله بعدی Feed Forward آغاز می شود. پس از اینکه تعداد مناسبتی از این مراحل تکرار شدند، آموزش شبکه به پایان می رسد.

ماتریس درهم ریختگی. در مدل هایی که برای دسته بندی داده ها به کار می روند، نمی توان به راحتی دقت مدل را همانند مدل های رگرسیون محاسبه کرد. چرا که نتایج در اینجا گسسته هستند. از طرفی، لزوماً تعداد ورودی هایی که مدل درست دسته بندی کرده به عنوان معیار بررسی مدل کافی نیست. گاهی لازم است بدانیم چه مقدار از داده ها اشتباه دسته بندی شده اند. در چنین مواقعی، که دقت تشخیص یک دسته در مقایسه با دقت تشخیص کلی، اهمیت بیشتری دارد، مفهوم ماتریس درهم ریختگی به کمک ما می آید. ماتریس درهم ریختگی یک $N \times N$ است که N همان تعداد دسته های مورد نظر ما است. اگر N را ۲ فرض کنیم، ماتریس به شکل جدول ۱ در می آید:

جدول ۱. نمونه ماتریس درهم ریختگی 2×2

برچسب پیش بینی شده			
		مثبت	منفی
مقدار واقعی	مثبت	به درستی مثبت پیش بینی شده (TP)	به اشتباه منفی پیش بینی شده (FN)
	منفی	به اشتباه مثبت پیش بینی شده (FP)	به درستی منفی پیش بینی شده (TN)

ماتریس درهم ریختگی، نتایج حاصل از طبقه بندی را بر اساس اطلاعات واقعی موجود، نمایش می دهد. حال بر اساس این مقادیر می توان برای هر برچسب، معیارهای مختلف ارزیابی و اندازه گیری دقت را تعریف کرد. یکی از متداول ترین آن ها، معیار یادآوری^۱ است. معیار یادآوری به این معنی است که چه نسبتی از موارد در مرحله آزمون به درستی تشخیص داده شده اند. این پارامتر برای هر کدام از دسته ها به صورت زیر محاسبه می شود:

رابطه (۱)

^۱ Recall

$$\text{Recall} = \frac{TP}{TP + FN} \times 100 \quad \text{یا} \quad \text{Recall} = \frac{TN}{TN + FP}$$

معیار دیگری که پر کاربرد است، معیار درستی^۱ است. این معیار بیان می‌دارد که چه مقدار از داده‌هایی که در یک دسته قرار گرفته‌اند، در واقعیت هم متعلق به همان دسته هستند. در حقیقت این معیار بررسی می‌کند که چه میزان از داده‌ها اشتباه در دسته‌ی دیگری قرار گرفته‌اند. نحوه محاسبه آن به صورت زیر است:

$$\text{Precision} = \frac{TP}{TP + FP} \times 100 \quad \text{یا} \quad \text{Precision} = \frac{TN}{TN + FN} \quad \text{رابطه (۲)}$$

در نهایت، F1-Score به عنوان آخرین معیار پرکاربرد است که در این پژوهش از آن استفاده می‌شود. این معیار برای ارزیابی کلی عملکرد مدل مورد استفاده قرار می‌گیرد و از ترکیب دو معیار یادآوری و صحت حاصل می‌شود. این معیار به صورت زیر تعریف می‌شود:

$$\text{F1 - Score} = 2 \times \frac{\text{Recal} \times \text{Precision}}{\text{Recal} + \text{Precision}} \times 100 \quad \text{رابطه (۳)}$$

هر ۳ این معیارها بین ۰ و ۱ هستند. هر چه به ۱ نزدیکتر باشند، نشان دهنده دقت بیشتر مدل و هر چه به ۰ نزدیکتر باشند، نشان دهنده دقت پایین مدل هستند.

۳. روش شناسی پژوهش

۳.۱.۳. دریافت داده‌ها. همان‌طور که پیش‌تر اشاره شد، مدل ارائه‌شده در این پژوهش برای معامله در بازار سهام طراحی شده است. بدین منظور سهم‌های سفارس، فلوله، کروی، خودرو و شبهرن از سهام بورس اوراق بهادار تهران به عنوان نمونه‌هایی از کل بازار با توجه به سعی در ایجاد پراکندگی مناسب در صنعت، تعداد داده زیاد (روزهای معاملاتی) و عدم وجود گپ قیمتی و زمانی (به خاطر بسته بودن طولانی‌مدت) انتخاب شدند. پراکندگی در صنعت برای تعمیم مدل به کل بازار، تعداد زیاد داده به دلیل نیاز مدل‌های یادگیری عمیق به تعداد داده‌های زیاد و عدم وجود گپ قیمتی و زمانی هم به دلیل پیوستگی در داده‌ها در نظر گرفته شده‌اند. سپس داده‌های قیمت اولین معامله، بالاترین قیمت معامله در طول روز، پایین‌ترین قیمت معامله در طول روز، قیمت پایانی و حجم معاملات این سهم‌ها در چارچوب زمانی روزانه از تاریخ ۱۳۸۰/۰۱/۰۵ تا تاریخ ۱۳۹۸/۰۵/۳۰ از شرکت پردازش اطلاعات مالی نوآوران امین دریافت شدند.

^۱ Precision

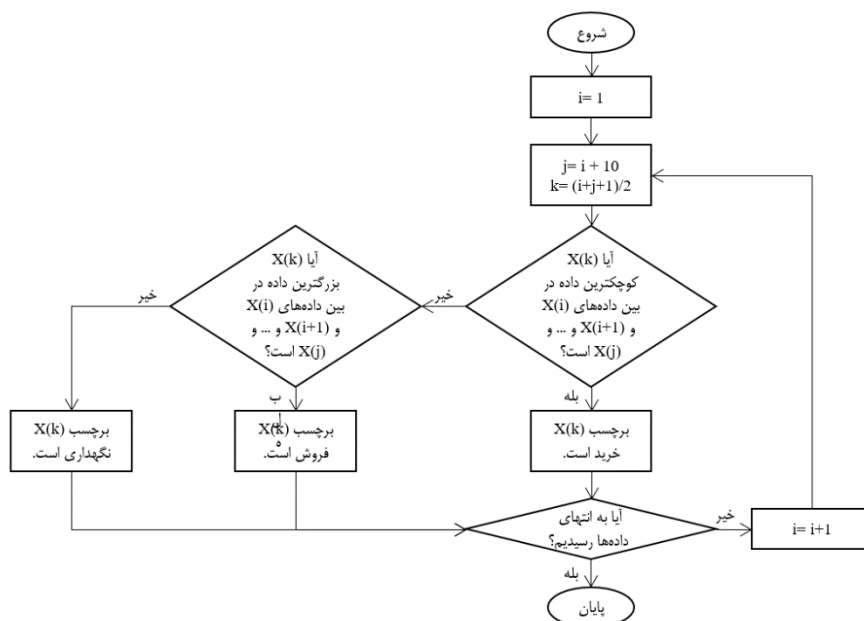
۲.۳. برچسب زدن روی داده ها. پس از دریافت داده ها، اولین قدم برچسب زدن روی داده ها است. مدل این پژوهش تعدادی تصویر با برچسب های مشخص دریافت می کند. سپس بعد از تعدادی تکرار، سعی می کند وزن های مدل را به گونه ای تنظیم کند تا مدل بتواند برچسب هر کدام از این تصاویر را به درستی پیش بینی کند. این یک مسئله نظارت شده و از نوع دسته بندی است. در این مدل ما سه نوع برچسب خرید، فروش و نگهداری (بدون اقدام) داریم.



نمودار ۱. نمایش برچسب های خرید (ضربدر)، فروش (فلش) و نگهداری (سایر نقاط) روی بخشی از نمودار سهم خودرو

برای انجام فرآیند برچسب زنی، از یک الگوریتم با پنجره زمانی متحرک با طول مشخص استفاده کردیم. این کار برای بررسی وضعیت نقطه وسط پنجره که آیا ماکزیمم نسبی یا مینیمم نسبی است یا نه انجام شد. به طور مثال اگر طول پنجره زمانی ۱۱ بود، بررسی شد که نقطه وسط نسبت به ۵ داده قبل تر و بعدتر خود، ماکزیمم (یا مینیمم) است یا نه. در صورتی که ماکزیمم (یا مینیمم) بود، این نقطه برچسب فروش (یا خرید) دریافت می کرد. اما اگر هیچ کدام نبود، برچسب نگهداری دریافت می کرد. این الگوریتم در زیر آورده شده است:

پروژه هوش مصنوعی و مطالعات فریبگی
پرتال جامع علوم انسانی



نمودار ۲. الگوریتم برچسب‌زنی روی داده‌ها

با طول پنجره ۱۱ به طور میانگین حدود ۵ درصد از داده‌ها برچسب خرید و حدود ۵ درصد دیگر برچسب فروش دریافت کردند. مابقی ۹۰ درصد داده‌ها برچسب نگهداری دریافت کردند. این وضعیت باعث عدم تعادل در داده‌ها شد. مدل به سادگی همه‌ی داده‌ها را نگهداری پیش‌بینی می‌کرد و دقت بالایی را کسب می‌کرد. در مورد این مشکل و حل آن جلوتر بحث شده است. نکته مهم در انتخاب بازه این بود که اگر بازه‌ی بلندتری انتخاب می‌شد، درصد داده‌های با برچسب خرید و فروش کمتر می‌شد و مشکل عدم تعادل در داده‌ها شدیدتر می‌شد. همچنین در صورتی که بازه‌ی کوتاه‌تری انتخاب می‌شد، فاصله بین نقطه خرید تا نقطه فروش بعدی کاهش می‌یافت. در صورتی که بازه انتخابی بیش از حد کوتاه می‌شد، این فاصله به حدی کاهش می‌یافت که در صورتی که مدل همه‌ی برچسب‌ها را هم به درستی پیش‌بینی کند، باز هم در معاملاتش نمی‌توانست کارمزد معامله را بپردازد و زیان می‌کرد. به همین خاطر با آزمون و خطای صورت گرفته فاصله ۱۱ انتخاب شد.

۳.۳. ساخت تصاویر. رویکردی که در این پژوهش از آن استفاده شده است، تبدیل داده‌های سری زمانی مالی به تصویر است. به منظور تبدیل این داده‌ها به تصویر، از اندیکاتورهای تحلیل تکنیکال استفاده کردیم. برای ساخت تصاویر، از اندیکاتورهای تحلیل تکنیکال زیر استفاده کردیم.

اندیکاتورهای زیر که در این پژوهش مورد استفاده قرار گرفته‌اند، با توجه به موارد استفاده آن‌ها در تحقیقات پیشین انتخاب شده‌اند. این اندیکاتورها عبارتند از:

شاخص قدرت نسبی^۱. یکی از مرسوم‌ترین شاخص‌های تحلیل تکنیکال است که توسط ولز وایلدر در سال ۱۹۷۸ ایجاد و ارائه شد. این شاخص برای اندازه‌گیری قدرت روند در شرایط نزولی و صعودی بازار کاربرد دارد. مقدار شاخص قدرت نسبی بین ۰ تا ۱۰۰ نوسان دارد. مقدار نزدیک به ۱۰۰ نشان‌دهنده این است که بازار می‌تواند روند صعودی شدیدی را تجربه کند. اما مقدار نزدیک به صفر نشان می‌دهد که روند بازار نزولی خواهد بود. دو سطح مهم این شاخص، ۳۰ و ۷۰ هستند که به ترتیب نشان‌دهنده سطوح فروش افراطی (بیش فروش) و خرید افراطی (بیش خرید) است.

$$RSI(t) = 100 - \frac{100}{1 + \frac{\text{Average Gain}(t)}{\text{Average Loss}(t)}} \quad \text{رابطه (۴)}$$

میانگین متحرک ساده^۲. میانگین متحرک ساده، میانگین قیمت در یک دوره زمانی گذشته که کاربر مشخص می‌کند را اندازه‌گیری می‌کند. به طور مثال میانگین متحرک ۵ روزه، میانگین قیمت در ۵ روز گذشته را نشان می‌دهد. هر بار که یک دوره زمانی جدید اضافه می‌شود، آخرین دوره زمانی از محاسبات بیرون گذاشته می‌شود. بدین صورت، مقدار میانگین متحرک هم به روز می‌شود. مثل هر شاخص دیگری، دوره زمانی انتخاب شده یکی از عناصر حیاتی است. هر چه دوره زمانی کوتاه‌تر باشد، میانگین متحرک به حرکات قیمت حساس‌تر است و بیشتر تغییر می‌کند؛ اما هرچه دوره زمانی بلندتر باشد میانگین متحرک ثابت‌تر است اما نسبت به نوسانات قیمت هم کمتر حساس است.

$$SMA(M, n) = \sum_{k=a+1}^{a+n} \frac{M(k)}{n} \quad \text{رابطه (۵)}$$

همگرایی-واگرایی میانگین متحرک^۳. تفاضل میان دو میانگین متحرک نمایی (میانگین متحرک نمایی بلندمدت منهای میانگین متحرک نمایی کوتاه‌مدت) است. رایج‌ترین نحوه تنظیم MACD یک میانگین متحرک نمایی ۲۶ دوره‌ای و یک میانگین متحرک نمایی ۱۲ دوره‌ای است. MACD زمانی مثبت است که میانگین ۱۲ دوره‌ای بالاتر از میانگین ۲۶ دوره‌ای باشد که

^۱ Relative Strength Index (RSI)

^۲ Simple Moving Average (SMA)

^۳ Moving Average Convergence Divergence (MACD)

این امر نشان می‌دهد نرخ تغییر میانگین متحرک کوتاه‌تر بیشتر از میانگین متحرک بلندتر بوده است و به معنای حرکت مثبت است. از طرف دیگر، MACD زمانی منفی است که میانگین ۱۲ دوره‌ای زیر میانگین ۲۶ دوره‌ای باشد که این امر نشان می‌دهد نرخ تغییر میانگین متحرک کوتاه‌تر کمتر از میانگین متحرک بلندتر بوده است و به معنای حرکت منفی است. این مقادیر روی هیستوگرام رسم می‌شوند.

$$\text{EMA}(M, t, \tau) = (M(t) - \text{EMA}(M, t - 1, \tau)) \times \frac{2}{\tau + 1} + \text{EMA}(M, t - 1, \tau) \quad \text{رابطه (۶)}$$

$$\text{MACD line}(t) = \text{EMA}(M, t, \tau_1) - \text{EMA}(M, t, \tau_2) \quad \text{رابطه (۷)}$$

$$\text{MACD histogram}(t) = \text{MACD line}(t) - \text{EMA}(\text{MACD line}, t, \tau_3) \quad \text{رابطه (۸)}$$

استوکستیک^۱. در دهه ۵۰ میلادی توسط جورج لین ایجاد شد. استوکستیک آخرین قیمت نهایی را نسبت به محدوده معاملات بازه زمانی انتخاب‌شده مقایسه می‌کند. مقدار اسیلاتور استوکستیک محدوده‌ای بین ۰ تا ۱۰۰ یا به عبارت دقیق‌تر بین ۰٪ تا ۱۰۰٪ است. وقتی مقدار اسیلاتور نزدیک به صفر باشد نشان‌دهنده این است که قیمت نهایی آخرین دوره نزدیک به کف محدوده نوسانات بازه زمانی انتخاب‌شده است. وقتی مقدار اسیلاتور نزدیک به یک باشد نشان‌دهنده این است که قیمت نهایی آخرین دوره نزدیک به سقف محدوده نوسانات بازه زمانی انتخاب‌شده است.

$$K = \frac{\text{Close}(t) - \min(\text{low}(t))}{\max(\text{high}(t)) - \min(\text{low}(t))} \times 100 \quad \text{رابطه (۹)}$$

$$D = \text{SMA}(K, 3) \quad \text{رابطه (۱۰)}$$

ویلیام آر^۲. این اندیکاتور توسط فردی به نام لری ویلیامز به وجود آمده است. بازه‌ای که در آن قرار دارد بین ۰ تا ۱۰۰- است. این اندیکاتور از نظر کارایی شباهت زیادی به استوکستیک دارد. تفاوت این دو اندیکاتور از نظر سطحی است که در آن نوسان می‌کنند.

$$R = \frac{\max(\text{high}) - \text{Close}}{\max(\text{high}) - \min(\text{low})} \times -100 \quad \text{رابطه (۱۱)}$$

^۱ Stochastic

^۲ Williams %R

نوسان‌نمای نهایی^۱ از این شاخص برای کاهش نوسانات و تراکنش‌های اشتباه استفاده می‌شود. مقدار آن در یک محدوده ۰ تا ۱۰۰ متغیر است و مرکز این محدوده هم مقدار ۵۰ است. مقدار زیر ۳۰ به عنوان منطقه اشباع خرید و مقدار بین ۷۰ تا ۱۰۰ نیز به عنوان منطقه اشباع در نظر گرفته می‌شود.

$$BP = \text{close}(t) - \min(\text{low}(t), \text{close}(t - 1)) \quad \text{رابطه (۱۲)}$$

$$TR = \max(\text{high}(t), \text{close}(t - 1)) - \min(\text{low}(t), \text{close}(t - 1)) \quad \text{رابطه (۱۳)}$$

$$UOS = 100 \times \frac{(\tau_3 \times \sum_{i=t-\tau_1}^i \frac{BP}{TR}) + (\tau_2 \times \sum_{i=t-\tau_2}^i \frac{BP}{TR}) + (\tau_1 \times \sum_{i=t-\tau_3}^i \frac{BP}{TR})}{\tau_1 + \tau_2 + \tau_3} \quad \text{رابطه (۱۴)}$$

شاخص جریان پول^۲ این شاخص یک شاخص لحظه‌ای است که در هر لحظه قدرت جریان ورودی و خروجی پول به سهم را اندازه می‌گیرد. شاخص جریان پول با شاخص قدرت نسبی ارتباط نزدیکی دارد. چنانچه قیمت امروز از قیمت دیروز کمتر باشد، جریان پول منفی در نظر گرفته می‌شود و اگر قیمت واقعی امروز از قیمت واقعی دیروز بیشتر باشد این امر جریان پول مثبت را نشان می‌دهد. جریان پول منفی مجموع پول‌های منفی و جریان پولی مثبت مجموع پول‌های مثبت در طول تعداد دوره‌های مشخص است. جریان معاملات مثبت و منفی به وسیله‌ی جمع‌بندی کلیه پول‌های ورودی به معاملات ۱۴ روزه یک سهم با تفکیک پول‌هایی که به سامانه خرید وارد شده و پول‌هایی که از طریق معاملات فروش خارج شده است به دست می‌آید.

$$\text{Typical Price}(t) = \frac{\text{high}(t) + \text{low}(t) + \text{close}(t)}{3} \quad \text{رابطه (۱۵)}$$

$$\text{Raw Money Flow} = \text{Typical Price}(t) \times \text{Volume}(t) \quad \text{رابطه (۱۶)}$$

$$\text{MFR}(i) = \frac{\sum_{i=t-\tau}^i \text{Positive Money Flow}}{\sum_{i=t-\tau}^i \text{Negative Money Flow}} \quad \text{رابطه (۱۷)}$$

$$\text{MFI}(i) = 100 - \frac{100}{1 + \text{MFR}(i)} \quad \text{رابطه (۱۸)}$$

^۱ Ultimate Oscillator (UO)

^۲ Money Flow Index (MFI)

جدول ۲. اندیکاتورهای تحلیل تکنیکال و پارامترهای آن‌ها برای ساخت تصاویر

تعداد	پارامترها	نام
۱	-	تانژانت هایپربولیک تفاضل دوم قیمت
۱	-	حجم معامله
۴	۳۰-۲۵-۲۰-۱۵	شاخص قدرت نسبی
۴	۳۰-۲۵-۲۰-۱۵	میانگین متحرک ساده
۳	۳۰،۱۶ - ۲۸،۱۴ - ۲۶،۱۲	همگرایی-واگرایی میانگین متحرک
۳	۱۱،۳۰،۱۶ - ۱۰،۲۸،۱۴ - ۹،۲۶،۱۲	ماشه ^۱ همگرایی-واگرایی میانگین متحرک
۳	۲۲-۱۸-۱۴	ویلیام %R
۳	۲۲-۱۸-۱۴	استوکستیک
۳	۹،۱۸،۳۶ - ۸،۱۶،۲۲ - ۷،۱۴،۲۸	نوسان‌نمای نهایی
۳	۲۲-۱۸-۱۴	شاخص جریان نقدینگی
۲۸		


پس از محاسبه مقادیر جدول بالا برای تمامی روزهای معاملاتی سهم مورد نظر، به جهت یکسان کردن مقیاس داده‌ها، هر کدام از این ۲۸ ویژگی (هر ویژگی یک سری زمانی از داده‌ها است) را جدای از بقیه، بین ۱- و ۱ نرمالایز کردیم. رابطه‌ای که به وسیله‌ی آن فرآیند نرمالایز صورت گرفت به صورت زیر است:

$$\text{Normalized } X(i) = \left(\frac{X(i) - \text{Min}(X)}{\text{Max}(X) - \text{Min}(X)} \times (\text{New Max} - \text{New Min}) \right) + \text{New Min} \quad \text{رابطه (۱۹)}$$

که در اینجا مقدار New Max برابر با ۱ و مقدار New Min برابر با ۱- است. در این روش همانند نموداری که در تصویر زیر مشخص است، توزیع داده‌ها تغییری نکرد، بلکه صرفاً مقادیر بیشینه و کمینه داده‌ها تغییر پیدا کرد و مابقی داده‌ها نیز به همان نسبت تغییر کردند.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

^۱ Trigger



نمودار ۳. نرمالیز کردن داده‌ها

به طور عملی تفاوت خاصی بین نرمالایز کردن داده‌ها بین -1 و 1 یا بین 0 و 1 وجود ندارد. اما در مدل‌های CNN نرمالایز بین -1 و 1 مرسوم‌تر است.

در ادامه، تصاویر را ساختیم. بدین منظور برای هر روز که سهم معامله شده، یک ماتریس 28×28 ایجاد کردیم. روز بیست و هشتم را در نظر گرفتیم. تمامی ویژگی مشخص شده در جدول (۲) را برای روز بیست و هشتم را در ستون اول این ماتریس قرار دادیم. حال یک روز به عقب، یعنی روز بیست و هفتم برگشتیم و مقادیر تمامی این 28 ویژگی را در ستون دوم ماتریس قرار دادیم. همین‌طور به عقب رفتیم تا این که در ستون بیست و هشتم ماتریس، مقادیر 28 ویژگی روز اول قرار گرفتند. در نهایت به یک ماتریس 28×28 رسیدیم. این ماتریس به عنوان تصویر در مراحل بعدی به مدل داده شد. این موارد در جدول (۳) به صورت مشخص نشان داده شد.

جدول ۳. ماتریس اجزای هر تصویر

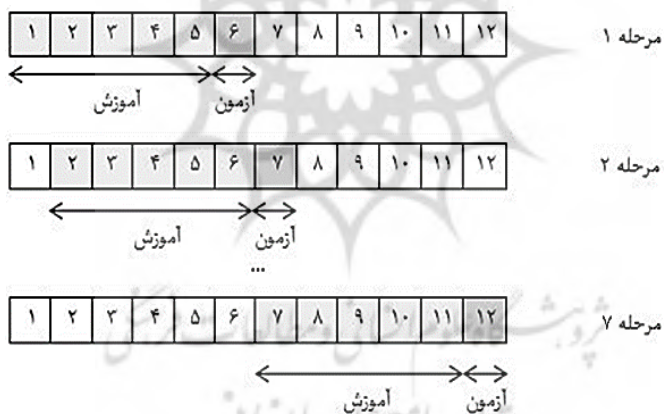
	t	t-1	t-2	...	t-26	t-27
Tanh(Diffrence2(Close)						
Volume						
RSI (15)						
RSI (20)						
RSI (25)						
RSI (30)						
SMA (15)						
SMA (20)						
SMA (25)						
SMA (30)						
MACD (26,12)						
MACD (28,14)						
MACD (30,16)						
MACD_trigger (9,26,12)						
MACD_trigger (10,28,14)						
MACD_trigger (11,30,16)						
William %R (14)						
William %R (18)						
William %R (20)						
Stochastic (14)						
Stochastic (18)						
Stochastic (20)						
UO (7,14,28)						

UO (8,16,22)
UO (9,18,36)
MFI (14)
MFI (18)

۴.۳. آماده‌سازی داده‌های آموزش و آزمون

رویکرد مورد نظر این پژوهش برای تقسیم داده‌ها به مجموعه‌های آموزش و آزمون از روش اعتبارسنجی متقابل^۱ اقتباس شده است. بدین منظور، ما داده‌ها را به صورت زیرمجموعه‌های ۲۵۰ تایی تقسیم کردیم. حال پنج دسته ۲۵۰ تایی اول را به عنوان مجموعه آموزش و یک دسته ۲۵۰ تایی بعد این‌ها را به عنوان مجموعه آزمون در نظر گرفتیم. در گام بعدی ۱ دسته به جلو آمدیم و دوباره همین کار را تکرار کردیم. به طور مثال داده‌های ایران خودرو را به ۱۲ زیرمجموعه ۲۵۰ تایی تقسیم کردیم. نمودار (۴) فرآیند مشخص کردن مجموعه آموزش و آزمون روی داده‌های ایران خودرو را به خوبی نشان می‌دهد.

برای کاهش اثرات ناشی از عمق کم بازار در سال‌های ابتدایی بازه مشخص شده تعدادی از داده‌های سال‌های ابتدایی را حذف کردیم. به گونه‌ای که برای هر نماد به ۳۰۰۰ داده رسیدیم. تعداد روزهای معاملاتی در ایران در حدود ۲۵۰ روز در سال در نظر گرفته شده است.




نمودار ۴. مجموعه‌های آموزش و آزمون

^۱ Cross Validation

نکته مهم دیگر که قبلاً اشاره شد، بحث عدم تعادل در داده‌هاست. تعداد برچسب‌های خرید و فروش ما نسبت به تعداد برچسب‌های نگهداری، بسیار کمتر است. برای افزایش این نسبت و از بین بردن عدم تعادل، ما داده‌هایی که برچسب خرید و فروش داشتند را ۱۰ بار کپی کردیم و دوباره در مجموعه داده‌ها قرار دادیم. سپس برای اینکه مدل ۱۰ بار هر کدام از این داده‌ها را به صورت تکراری پشت سر هم ببیند، این داده‌ها را درهم^۱ کردیم.

۵.۳. مدل و اجزای آن. برای ساخت مدل‌های شبکه عصبی پیچشی، همانند دیگر مدل‌های شبکه عصبی، رابطه خاصی وجود ندارد. بلکه با آزمون و خطا و نیاز پژوهشگر ایجاد می‌شوند. مدل ارائه شده در این پژوهش از مدل LeNet الگو گرفته است. این مدل به عنوان اولین مدل CNN با نتیجه قابل قبول روی مجموعه تصاویر MNIST شناخته شده است.

مطابق با نمودار(۳)، مدل ارائه شده در این پژوهش ۸ لایه دارد. در لایه ورودی، مدل تصاویری که قبلاً ایجاد کرده بودیم را می‌گیرد. هر کدام از این تصاویر $28 \times 28 = 784$ نورون دارند که این نورون‌ها از طریق فیلترهای هر لایه کانولوشن، به لایه بعدی متصل می‌شوند. لایه دوم که یک لایه کانولوشن است، ۳۲ فیلتر 3×3 دارد. هر چقدر سایز فیلتر کمتر باشد، جزئیات بیشتری از تصویر توسط لایه کانولوشن دریافت می‌شود. سایز 3×3 معمول‌ترین سایز برای فیلتر در مدل‌های CNN است. استفاده از سایز 3×3 کمک می‌کند که در هنگام پردازش، اطلاعات از نزدیکترین همسایگی‌های هر نورون مورد پردازش قرار بگیرد. در این صورت تغییرات ناگهانی در تصویر قابل شناسایی خواهد بود. با توجه به کوچک بودن سایز تصاویر، بهتر است از سایزهای بزرگتر استفاده نشود. همچنین برای اینکه ابعاد تصویر در لایه‌های دوم و سوم با لایه اول برابر باشد، ما از Stride 1 استفاده کردیم. بدین صورت که دور تا دور ماتریس تصویر را یک ردیف صفر گذاشتیم (ماتریس 28×28 به 30×30 تبدیل شد) و سپس فیلترها روی این تصاویر اعمال شدند.



نمودار ۵. مدل CNN ارائه شده

^۱ Shuffle

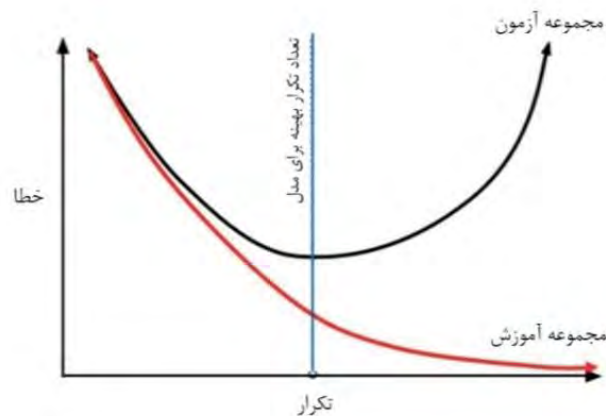
لایه سوم نیز یک لایه کانولوشن با $64 \times 3 \times 3$ فیلتر است. در لایه چهارم از Max Pooling با اندازه 2×2 استفاده کرده این تا با کاهش ابعاد داده‌ها، فقط اطلاعات مهم آن‌ها را ذخیره کرده و به لایه بعدی انتقال دهیم. لایه پنجم یک لایه Dropout با نرخ 0.25 است که باعث می‌شود ۲۵ درصد اتصالات به لایه کاملاً متصل در هر تکرار به طور تصادفی حذف شوند. این کار برای جلوگیری از بیش‌برازش مدل مفید است. لایه بعدی یک لایه کاملاً متصل است که در آن از تابع فعال‌سازی Relu استفاده شده است. همچنین بعد از لایه کاملاً متصل نیز یک لایه Dropout با نرخ 0.5 قرار دارد. در نهایت نیز لایه خروجی وجود دارد که در آن از تابع فعال‌سازی Softmax استفاده شده است و در آخر یکی از ۳ برچسب اولیه را پیش‌بینی می‌کند.

افزایش تعداد لایه‌ها موجب پیچیده‌تر شدن مدل می‌شود و مدل می‌تواند جزئیات بیشتری را بررسی کند، اما امکان دارد مدل دچار بیش‌برازش شود. به همین خاطر در این سال‌ها تلاش شده است تا با ایجاد ساختارهای جدید بر این مشکل بیش‌برازش غلبه شود تا بتوان از مزایای افزایش لایه‌ها استفاده کرد. به دلیل پیچیدگی‌های زیاد این ساختارها، در این پژوهش به همین مدل ساده و اولیه اکتفا شده است. در صورتی که امروزه مدل‌های بسیار پیچیده با بیش از ۵۰ لایه نیز ارائه شده‌اند. نکته دیگر در افزایش تعداد لایه‌های مدل، افزایش میزان پردازش مورد نیاز برای مدل است. در صورتی که سخت‌افزار مناسبی برای پردازش مدل‌های پیچیده در دسترس نباشد، اجرای مدل روزها و هفته‌ها به طول خواهد انجامید. در این پژوهش برای پیاده‌سازی مدل از زبان برنامه‌نویسی Python 3.6، برای آماده‌سازی داده‌ها از کتابخانه‌های Numpy و Pandas، برای مصورسازی داده‌ها از کتابخانه Matplotlib و برای محاسبه شاخص‌های تحلیل تکنیکال نیز از کتابخانه TALib استفاده شده است. همچنین برای پیاده‌سازی مدل از کتابخانه Keras استفاده شده است. Keras برای اجرای مدل یکسری تنظیمات را لازم دارد. این تنظیمات عبارتند از تابع بهینه‌سازی، تابع محاسبه خطا، تعداد تکرار اجرای مدل و اندازه دسته. می‌توان از تابع‌های بهینه‌سازی مختلفی استفاده کرد. در اینجا از تابع بهینه‌سازی Adam استفاده کردیم. همچنین برای محاسبه خطا نیز از تابع Categorical Cross Entropy که در مدل‌های CNN مرسوم است استفاده کردیم.

۴. تحلیل داده‌ها و یافته‌ها

در مورد تعداد تکرار، هیچ فرمولی وجود ندارد. تعداد تکرار کم، باعث عدم یادگیری مدل و تعداد تکرار زیاد، باعث بیش‌برازش مدل می‌شود. روش مرسوم برای پیدا کردن تعداد تکرار بهینه بدین صورت است که مدل را با تعداد تکرار زیادی اجرا می‌کنند. در هر تکرار مدل، مقدار خطای مجموعه داده آموزش و آزمون محاسبه می‌شود. تا وقتی که هم خطای داده‌های آموزش و هم خطای

داده‌های آزمون کاهش می‌دهد، تکرار اجرای مدل را ادامه می‌دهیم. هر جا که مشاهده کردیم خطای داده‌های آموزش کاهش پیدا کرده ولی خطای داده‌های آزمون افزایش پیدا کرده، نقطه بهینه برای تعداد تکرار اجرای مدل است. تصویر (۶) این روش را بهتر نشان می‌دهد.



نمودار ۶. روش پیدا کردن تعداد تکرار بهینه برای مدل

اما در این پژوهش این روش لزوماً روش بهینه‌ای نیست. باید توجه شود که هدف ما از ساخت این مدل، کاهش مقدار خطای روی داده‌های آزمون نیست. بلکه هدف ما کسب سود بیشتر است. بنابراین روش درست‌تر برای پیدا کردن تعداد بهینه تکرار در این پژوهش، محاسبه میزان سود مدل در یک تست در هر مرحله آموزش است. میزان سود (یا ارزش دارایی‌ها) را به جای خطا در نظر گرفتیم. تا وقتی که این میزان صعودی بود، به تکرار ادامه دادیم. نقطه‌ای که این مقدار کاهش می‌شد، تعداد مناسب برای تکرار مدل را نشان داد. هر چند به خاطر حجم زیاد محاسبات، در این پژوهش مقدار ارزش دارایی‌ها در هر تکرار را حساب نکردیم. بلکه فقط برای تعداد تکرارهای ۲۵، ۵۰، ۷۵ و ۱۰۰ محاسبه کردیم و نمایش دادیم تا حدود تکرار مناسب برای اجرای مدل مشخص شود.

برای پیدا کردن تعداد تکرار بهینه مدل، مدل را با تکرارهای ۲۵، ۵۰، ۷۵ و ۱۰۰ روی همه‌ی داده‌ها اجرا کردیم و هر بار، مقادیر Recall خرید و فروش و موجودی حساب بدون در نظر گرفتن کارمزد برای مجموعه داده آزمون هر کدام را محاسبه کردیم. تعداد تکراری بهینه‌تر است که بتواند در همه نمادها بیشترین Recall و موجودی حساب را کسب کند. نتایج در جدول (۴) آورده شده است.

جدول ۴. نتایج اجرای مدل با تکرارهای مختلف برای پیدا کردن تعداد تکرار بهینه

تعداد تکرار	معیارهای مقایسه	سفارس	فلوله	کروی	خودرو	شبه‌هین
۲۵	ارزش دارایی‌ها	۱۰۴۴/۱	۱۹۲۰/۴	۱۰۰۳/۶	۹۹۸/۹	۹۶۷/۲
	Recall خرید	۰/۰۸۱	۰/۲۰۱	۰/۰۹۰	۰/۰۴۱	۰/۱۱۱۱
	Recall فروش	۰/۲۰۳	۰/۲۰۷	۰/۱۳۸	۰/۰۷۸	۰/۰۶۱۲
۵۰	ارزش دارایی‌ها	۱۵۵۶/۸	۱۰۷۶/۹	۱۸۲۰/۶	۷۱۴۰	۴۵۳۱/۲
	Recall خرید	۰/۵۸۱	۰/۶۰۵	۰/۵۱۳	۰/۴۰۶	۰/۶۳۶۳
	Recall فروش	۰/۷۴۷	۰/۶۱۳	۰/۵۵۵	۰/۵۱۹	۰/۵۸۱۶
۷۵	ارزش دارایی‌ها	۵۳۴۵/۸	۶۲۰۸/۷	۷۶۰۴	۱۰۹۶۰	۱۱۴۲۵
	Recall خرید	۰/۸۷۷	۰/۸۷۵	۰/۷۴۷	۰/۸۱۲	۰/۹۲۹۲
	Recall فروش	۰/۹۲۲	۰/۹۸۱	۰/۸۴۲	۰/۹۲۱	۰/۹۳۸۷
۱۰۰	ارزش دارایی‌ها	۲۱۳۴	۳۳۷۸/۶	۲۶۲۹/۵	۸۸۵۸	۱۰۲۲۸
	Recall خرید	۰/۷۹۵	۰/۷۹۸	۰/۶۶۶	۰/۷۳۹	۰/۸۴۸۴
	Recall فروش	۰/۹۰۲	۰/۹۰۵	۰/۷۲۲	۰/۸۶۲	۰/۸۴۶۹

ملاحظه شد که بعد از ۷۵ تکرار، میزان موجودی حساب و Recall کاهش یافت، بنابراین ما ۷۵ تکرار را به عنوان تعداد تکرار بهینه در نظر گرفتیم. در قسمت‌های بعدی، مدل و نتایج را با این تعداد تکرار روی هر سهم بررسی می‌کنیم.

۱.۴ بررسی عملکرد محاسباتی مدل. به طور معمول برای بررسی عملکرد مدل در مدل‌های دسته‌بندی، از ماتریس درهم‌ریختگی استفاده می‌شود. پس از به دست آوردن ماتریس درهم‌ریختگی، معیارهای Precision، Recall و F1 Score بر اساس آن قابل محاسبه است. این مقادیر برای هر سهم با توجه به تعداد تکرار بهینه، در جدول (۵) آورده شده است.

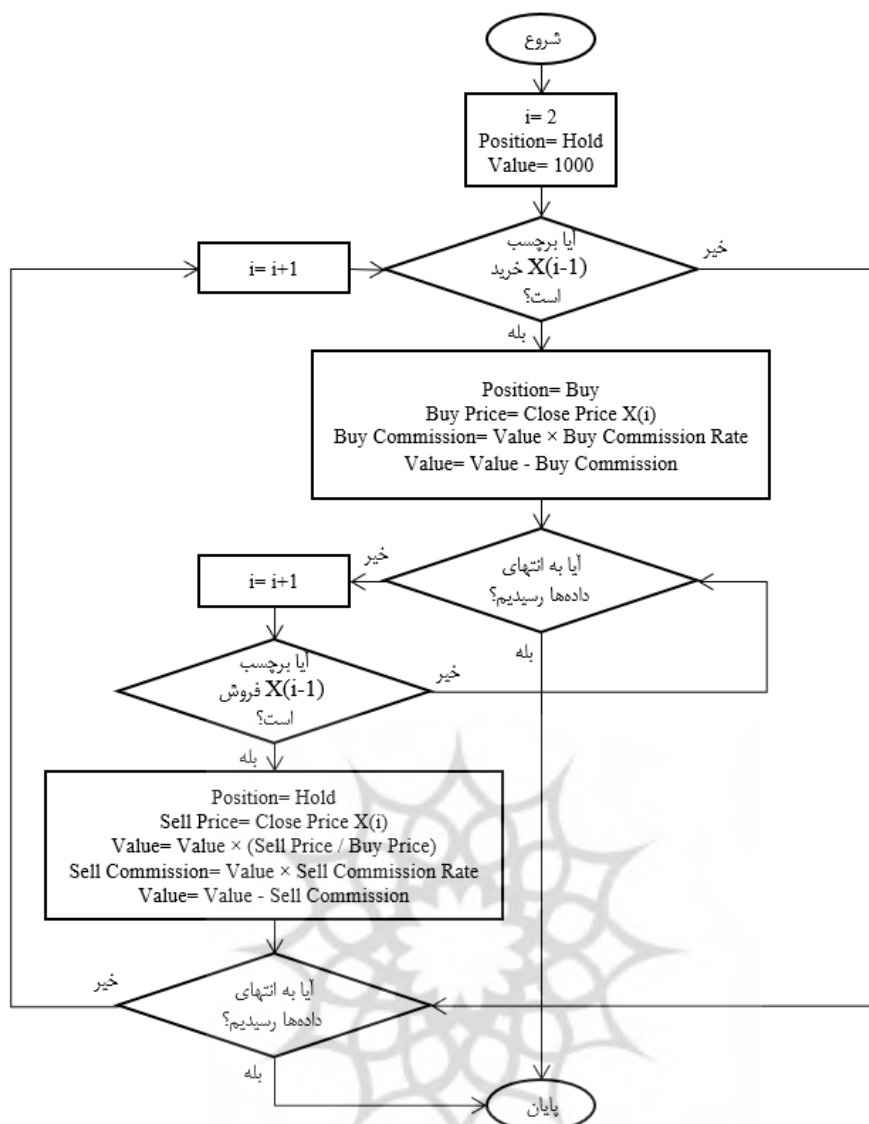
جدول ۵. ماتریس درهم‌ریختگی و معیارهای مربوطه برای سهام منتخب

		نگهداری	خرید	فروش	Recall	Precision	F1 Score
سفارس	نگهداری	۱۲۵۴	۱۲۷	۱۶۸	۰/۸۰۹۵	۰/۹۸۴۳	۰/۸۸۸۴
	خرید	۱۲	۸۶	۰	۰/۸۷۷۵	۰/۴۰۳۷	۰/۵۵۳۰
	فروش	۸	۰	۹۵	۰/۹۲۲۳	۰/۳۶۱۲	۰/۵۱۹۱
فلوله	نگهداری	۱۲۲۲	۱۴۲	۱۷۶	۰/۷۹۳۵	۰/۹۸۷۸	۰/۸۸۰۰
	خرید	۱۲	۹۱	۱	۰/۸۷۵	۰/۳۹۰۵	۰/۵۴۰۰
	فروش	۲	۰	۱۰۴	۰/۹۸۱۱	۰/۳۷۱۴	۰/۵۳۸۸
کروی	نگهداری	۱۲۵۳	۱۴۵	۱۳۳	۰/۸۱۸۴	۰/۹۶۵۳	۰/۸۸۵۸

	خرید	۲۶	۸۳	۲	۰/۷۴۷۷	۰/۳۶۴۰	-/۴۸۹۶
	فروش	۱۶	۱	۹۱	۰/۸۴۲۵	۰/۴۰۶۲	-/۵۴۸۱
خودرو	نگهداری	۱۲۶۹	۱۳۵	۱۴۸	۰/۸۱۷۶	۰/۹۲۱۵	-/۸۹۱۴
	خرید	۱۸	۷۸	۰	۰/۸۱۲۵	۰/۳۶۶۱	-/۵۰۴۸
	فروش	۸	۰	۹۴	۰/۹۲۱۵	۰/۳۸۸۴	-/۵۴۶۵
شپهرن	نگهداری	۱۱۸۹	۱۵۷	۲۰۷	۰/۷۶۵۶	۰/۹۲۹۲	-/۹۲۸۷
	خرید	۷	۹۲	۰	۰/۹۸۹۱	۰/۳۶۹۴	-/۳۰۷۶
	فروش	۶	۰	۹۲	۰/۸۶۳۱	۰/۵۲۸۷	-/۴۶۳۴

ملاحظه می‌شود که در همه سهم‌ها، مقدار Recall درصد بالایی را نشان می‌دهد ولی Precision بسیار پایین است. این امر می‌تواند به ۲ دلیل باشد. دلیل اول، بیش‌برازش شدن مدل است. در اثر افزایش تکرارها، مدل داده‌های دیگر را هم که برچسب نگهداری دارند، به عنوان نقاط خرید و فروش شناسایی کرده است. چرا که تعداد برچسب‌های خرید و فروش در مجموعه آزمون به اندازه ۱۰٪ تعداد برچسب‌ها در مجموعه آموزش است. دلیل دوم هم شباهت نقاطی است که برچسب نگهداری دارند ولی در کنار نقاطی هستند که برچسب‌های خرید و فروش دارند. مقدار اندیکاتورهای تحلیل تکنیکال در این نقاط تقریباً نزدیک نقاط با برچسب‌های خرید و فروش است و مدل این‌ها را به عنوان نقاط خرید و فروش دسته‌بندی کرده است. در بخش پیشنهادها برای حل این مشکل راهکارهایی ارائه شده است.

۲.۴. ارزیابی مالی مدل. علاوه بر ارزیابی عملکرد محاسباتی مدل با روش‌های مرسوم در یادگیری ماشینی که در بخش قبلی آورده شد، چون هدف سیستم معاملاتی ما کسب سود است، باید آن را از نظر مالی نیز بررسی کنیم. بدین منظور از ابتدای بازه آزمون، هر گاه که سیستم در هیچ معامله‌ای نبود و سیگنال خرید صادر شد (برای آن روز برچسب خرید پیش‌بینی شد)، همه‌ی موجودی وجه نقد را با قیمت پایانی روز بعد از آن سهم خریدیم. این سهم را تا زمانی نگه داشتیم که سیگنال فروش صادر شد. بعد از آن همه‌ی موجودی از آن سهم را با قیمت پایانی روز بعد فروختیم و تا زمانی که دوباره سیگنال خرید صادر شد، دست نگه داشتیم و نقد ماندیم. پس از اجرای ساز و کار معامله بر اساس سیگنال‌های صادر شده، معیارهایی برای هر سهم محاسبه شدند. مورد کارمزد معاملات سهام طبق قوانین بازار سرمایه ایران در بازه‌ی آزمون، برای معاملات خرید، ۰/۴۶۴٪ از ارزش معامله و برای معاملات فروش، ۰/۹۷۵٪ از ارزش معامله فروش است.



نمودار ۷. الگوریتم خرید و فروش

در جدول (۶) اطلاعاتی از عملکرد مالی مدل روی سهام سفارس ارائه شده است. ارزش دارایی‌ها برای ارزیابی عملکرد در ابتدای بازه آزمون، ۱۰۰۰ واحد در نظر گرفته شده است. میزان ارزش دارایی‌ها با خرید و فروش‌های مدل تغییر کرده است و بر اساس مقدار ارزش روزانه دارایی‌ها در طول زمان آزمون، سایر پارامترها محاسبه شدند. ارزش دارایی‌ها در هر روز برابر است با ارزش سهام در دست مدل و یا وجه نقد در دست مدل. در جدول زیر منظور از روزهای بیکاری، روزهایی

است که مدل وجه نقد داشته است. در محاسبه‌ی نسبت شارپ، بازده بدون ریسک سالانه ۲۰٪ فرض شده است.

جدول ۶: ارزیابی مالی مدل روی سهم سفارس

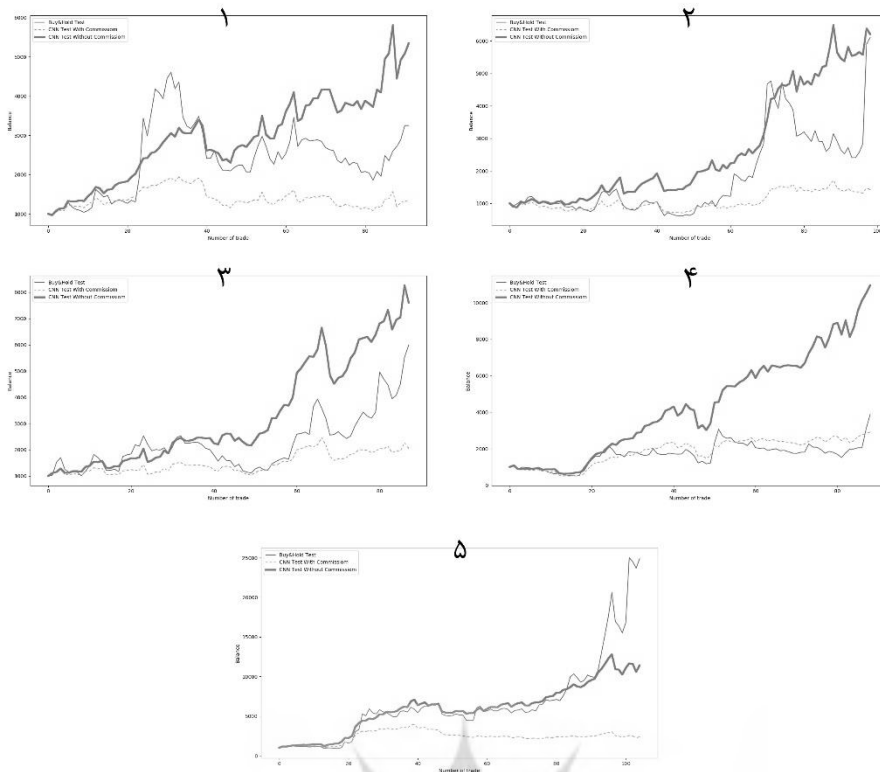
سفارس	بدون کارمزد	با کارمزد	خرید و نگهداری
ارزش دارایی‌ها در زمان شروع	۱۰۰۰	۱۰۰۰	۱۰۰۰
ارزش دارایی‌ها در زمان پایان	۵۳۴۵/۵۴	۱۳۵۷/۸۵	۳۲۰۸/۹۶
بازده کل	۴/۳۴۳۷	۰/۳۵۷۸	۲/۲۰۸۹
متوسط بازده سالانه	۰/۲۳۳۱	۰/۰۳۸۹	۰/۱۵۶۸
تعداد روزهای آزمون	۱۷۵۰	۱۷۵۰	۱۷۵۰
تعداد سال‌های آزمون	۸	۸	۸
تعداد معاملات	۹۱	۹۱	۱
بازده هر معامله	کمترین متوسط بیشترین	- ۰/۲۳۴۷ ۰/۰۲۱۱ ۰/۱۹۲۲	- ۰/۲۴۶۲ ۰/۰۰۵۸ ۰/۱۹۲۲
معاملات بسته شده	تعداد درصد	۶۰ ٪ ۶۵/۹۳	۴۶ ٪ ۵۰/۵۴
در سود	متوسط بازده تعداد درصد	۰/۰۵۶۸ ۳۱ ٪ ۳۴/۰۶	۰/۰۵۵۶ ۴۵ ٪ ۴۹/۴۵
در زیان	متوسط بازده	- ۰/۰۴۷۹	- ۰/۰۴۴۹
زمان	کل روزهای معاملات متوسط روزهای نگهداری هر سهم درصد روزهای معاملات به کل	۷۳۸ ۸/۱۰ ٪ ۴۲/۱۷	۷۳۸ ۸/۱۰ ٪ ۴۲/۱۷
	کل روزهای بیکاری متوسط روزهای بیکاری درصد روزهای بیکاری به کل	۱۰۱۲ ۱۰/۰۵ ٪ ۵۷/۸۲	۱۰۱۲ ۱۰/۰۵ ٪ ۵۷/۸۲
کارمزد	مقدار متوسط کارمزد هر معامله مقدار کل کارمزد پرداختی	۰ ۰	۲۰/۹۳ ۱۹۰۴/۹
ریسک	واریانس بازده انحراف معیار بازده نسبت شارپ بیشترین افت ^۱	۰/۰۰۵۰ ۰/۰۷۱۲ ۰/۱۰۶۶ ۰/۳۰۶۸	۰/۰۱۸۹ ۰/۰۷۰۲ - ۰/۰۴۸۵ ۰/۷۹۱۱

^۱ Maximum Drawdown

جدول (۶) برای تمامی سهم‌های منتخب محاسبه شده است. مهمترین مواردی که برای این سهم‌ها مورد نظر است و بر اساس آن نتیجه‌گیری خواهیم کرد به طور خلاصه در جدول (۷) آورده شده است.

جدول ۷. خلاصه نتایج ارزیابی مالی روی سهام منتخب

خرید و نگهداری	CNN با در نظر گرفتن کارمزد	CNN بدون در نظر گرفتن کارمزد		
۰/۱۵۶۸	۰/۰۳۸۹	۰/۲۳۳۱	سفارس	متوسط بازده سالانه
۰/۱۹۸۲	۰/۰۳۹۶	۰/۲۲۴۹	فلوله	
۰/۲۵۵۹	۰/۰۹۳۹	۰/۲۸۸۶	کروی	
۰/۱۶۲۱	۰/۱۲۶۱	۰/۳۰۴۷	خودرو	
۰/۴۲۷۴	۰/۱۰۱۴	۰/۳۱۰۸	شبه‌رن	
۰/۱۳۷۶	۰/۰۷۰۲	۰/۰۷۱۲	سفارس	انحراف معیار
۰/۱۷۷۵	۰/۰۷۶۸	۰/۰۷۸۰	فلوله	
۰/۱۴۵۰	۰/۰۸۲۱	۰/۰۸۳۴	کروی	
۰/۱۷۲۵	۰/۰۹۴۸	۰/۰۹۶۲	خودرو	
۰/۱۴۵۶	۰/۰۷۳۹	۰/۰۷۵۰	شبه‌رن	
- ۰/۰۴۸۵	- ۰/۷۲۴۵	۰/۱۰۶۶	سفارس	نسبت شارپ
- ۰/۰۰۱۸	- ۰/۹۱۹۱	۰/۱۱۱۰	فلوله	
۰/۱۳۴۲	- ۰/۹۵۰۱	۰/۴۷۲۷	کروی	
- ۰/۰۵۳۴	- ۰/۰۹۶۸	۰/۱۱۲۱	خودرو	
۰/۳۰۵۶	- ۰/۲۵۴۵	۰/۲۶۱۲	شبه‌رن	
۰/۶۵۲۸	۰/۷۹۱۱	۰/۳۰۶۸	سفارس	بیشترین افت
۰/۶۶۴۱	۰/۶۱۸۷	۰/۲۰۶۷	فلوله	
۰/۶۴۲۴	۰/۵۴۰۲	۰/۴۷۲۲	کروی	
۰/۶۶۶۶	۰/۶۰۹۱	۰/۴۷۱۱	خودرو	
۰/۳۸۳۷	۰/۸۴۰۷	۰/۲۴۹۴	شبه‌رن	
%۰	% ۵۷/۸۲	% ۵۷/۸۲	سفارس	درصد روزهای بیکاری
%۰	% ۵۷/۰۹	% ۵۷/۰۹	فلوله	
%۰	% ۵۶/۴۰	% ۵۶/۴۰	کروی	
%۰	% ۵۸/۲۲	% ۵۸/۲۲	خودرو	
%۰	% ۵۶/۵۱	% ۵۶/۵۱	شبه‌رن	



نمودار ۸. نمودار ارزش دارایی‌ها برحسب معاملات انجام شده. شماره‌های ۱ تا ۵ به ترتیب سهم‌های سفارس، فوله، کروی، خودرو و شبهرن هستند. CNN بدون در نظر گرفتن کارمزد به صورت خط ضخیم، CNN با در نظر گرفتن کارمزد به صورت خطچین و خرید و نگهداری به صورت خط ممتد نشان داده شده‌اند.

۵. بحث و نتیجه‌گیری

در هنگام پیدا کردن تعداد تکرار بهینه، مشاهده شد که با افزایش تکرار، مقدار Recall افزایش می‌یابد. مقدار Recall بیان می‌کند که چه درصدی از داده‌های واقعی، درست پیش‌بینی شده‌اند. هر چقدر این درصد بالاتر باشد، به این معنی است که مدل توانسته ویژگی‌های ورودی‌ها را بهتر تشخیص بدهد و آن‌ها را درست برچسب‌گذاری کند. اما وقتی به جدول (۴) نگاه کنیم، متوجه می‌شویم که این افزایش Recall به بهای کاهش Precision تمام شده است. Precision بیان می‌کند که از میان کل داده‌هایی که یک برچسب گرفته‌اند، چه درصدی از آن‌ها در واقعیت هم همان برچسب را دارند. در این جدول ما مشاهده می‌کنیم که میزان Precision بسیار کمتر از Recall است. این مسئله به دو دلیل می‌تواند رخ دهد. دلیل اول، بیش‌برازش شدن مدل است. در اثر افزایش تکرارها، مدل داده‌های دیگر را هم که برچسب نگهداری دارند، به عنوان نقاط خرید و فروش شناسایی کرده است. چرا که تعداد برچسب‌های خرید و فروش در مجموعه آزمون به اندازه ۱۰٪ تعداد برچسب‌ها در مجموعه آموزش است. دلیل دوم هم شباهت نقاطی است که

برچسب نگهداری دارند ولی در کنار نقاطی هستند که برچسب‌های خرید و فروش دارند. مقدار اندیکاتورهای تحلیل تکنیکال در این نقاط تقریباً نزدیک نقاط با برچسب‌های خرید و فروش است و مدل این‌ها را به عنوان نقاط خرید و فروش دسته‌بندی کرده است.

در ادامه، به ارزیابی مالی نتایج حاصل از بکتست مدل به وسیله ساز و کار تعریف شده برای خرید و فروش پرداختیم. با توجه به هزینه‌های بالای معاملات در ایران، ما در اینجا سه حالت را در نظر گرفتیم. اول، خرید و فروش بر اساس نتایج مدل بدون در نظر گرفتن هزینه‌های معاملاتی، دوم، خرید و فروش بر اساس نتایج مدل با در نظر گرفتن هزینه‌های معاملاتی و در نهایت هم خرید و نگهداری سهم در بازه زمانی بکتست. مشاهده می‌کنیم که در سهم‌های سفارس، فلوله، کروی و خودرو، روش CNN بدون کارمزد برتری دارد. مطابق آنچه مشاهده کردیم، وجود هزینه‌های کارمزد معاملات باعث شده که روش CNN با کارمزد در هر ۵ سهم از روش خرید و فروش بازدهی پایین‌تری داشته باشد. دلیل این موضوع در مقدار متوسط بازده هر معامله نهفته است. مقدار متوسط بازده هر معامله به طور مثال در سهم سفارس، $\frac{2}{3}\%$ است. با در نظر گرفتن کارمزد حدود $\frac{1}{4}\%$ ، بخش زیادی از این بازده صرف پرداخت هزینه‌های معاملات شده است. چنانچه می‌بینیم که بعد از ۸ سال، روش CNN با کارمزد روی سهم سفارس فقط $\frac{35}{7}\%$ و میزان $\frac{357}{85}$ واحد بازده کسب کرده است، حال آن‌که $\frac{1904}{9}$ واحد کارمزد پرداخت کرده است. اینکه چرا متوسط بازده هر معامله مقدار کمی است، به پنجره زمانی برای برچسب‌گذاری باز می‌گردد. ما بازه این پنجره را ۱۱ روز در نظر گرفتیم. در این صورت نقاط مینیمم (خرید) و ماکزیمم (فروش) در این بازه ۱۱ روزه با دیگر نقاط مقایسه و مشخص شدند. در صورتی که این پنجره زمانی را بزرگتر در نظر بگیریم، فاصله نقاط خرید و فروش از یکدیگر بیشتر شده و میانگین بازده هر معامله افزایش می‌یابد. اما این کار باعث می‌شود که تعداد نقاط با برچسب‌های خرید و فروش کاهش یابد و مشکل عدم تعادل داده‌ها را که با آن مواجه بودیم بدتر می‌کند.

از طرف دیگر در نتایج مشاهده می‌کنیم که در همه سهم‌ها، روش CNN بیش از 50% بازه زمانی آزمون را بیکار بوده است. یعنی در این زمان‌ها هیچ سهمی در پرتفو ندارد و نقد است. این مسئله نیز نشان می‌دهد که مدل از حداکثر منابع موجود به طور کامل استفاده نکرده است و شاید بهبودهایی در این زمینه بتواند بازدهی روش‌ها را افزایش دهد.

در مورد ریسک مدل نیز مشاهده می‌شود نسبت شارپ در روش CNN بدون کارمزد، در سهم‌های کروی و خودرو، عملکرد بهتری را نسبت به روش خرید و نگهداری نشان می‌دهد (میزان نرخ بهره سالانه بدون ریسک 20% فرض شده است). حال آنکه میزان بیشترین افت روش CNN بدون کارمزد در همه‌ی سهم‌ها، مقدار کمتری نسبت به روش خرید و نگهداری دارد و بهتر عمل کرده است.

به طور کلی می‌توان نتیجه‌گیری کرد که روش CNN بدون کارمزد ارائه شده در این پژوهش با روش خرید و نگهدار قابل مقایسه است و طبق بررسی‌های انجام شده در ۴ سهم از ۵ سهم مورد بررسی از نظر بازدهی بهتر عمل کرده است. اما با در نظر گرفتن کارمزد، نمی‌تواند به روش خرید و نگهداری غلبه کند. اما نکته قابل توجه، عدم استفاده مدل از همه‌ی منابع موجود است. در صورتی که روش یا روش‌هایی برای استفاده از تمام منابع موجود ارائه شود، این امکان وجود خواهد داشت که این روش‌ها حتی از روش خرید و نگهداری نیز بهتر عمل کنند.

۶. پیشنهادها و محدودیت‌ها

در مورد محدودیت‌ها، مهمترین موارد کارمزد معاملات و یکطرفه بودن بازار است. چنانچه در نتایج مشاهده کردیم، کارمزد معاملات سبب کاهش بسیار زیاد بازدهی مدل می‌شود. چنانچه در جدول (۵) هم می‌بینیم که مدل بیش از ارزش دارایی‌ها در زمان پایان، کارمزد پرداخته است. همچنین یکطرفه بودن بازار در ایران بدین معنا که معامله‌گر فقط می‌تواند از افزایش قیمت سهم منتفع شود نیز باعث شده که مدل بیش از نیمی از زمانش بیکار باشد و وجه نقد نگه دارد. در صورتی که بازار دوطرفه بود، یعنی معامله‌گر می‌توانست با اتخاذ موقعیت فروش از کاهش قیمت‌ها نیز منفعت کسب کند، این مدت زمان بیکاری به صفر می‌رسید و حتی می‌توانست باعث افزایش بازدهی مدل نیز بشود.

مورد بعدی در بحث محدودیت، عدم امکان استفاده از این مدل برای سهم‌های با داده‌های کم است که به تازگی عرضه اولیه شده‌اند. چنانچه قبلاً بیان شد، مدل‌های یادگیری عمیق نیاز به حجم زیادی داده دارند. در صورتی که سهم‌هایی که تازه عرضه اولیه شده‌اند، داده‌های قیمت زیادی برای استفاده در این مدل ندارند.

برای دستیابی به مهمترین هدف این پژوهش یعنی کسب بازدهی بیشتر، نیاز به بهبود عملکرد محاسباتی و مالی مدل داریم. با توجه این موضوع پیشنهادهاى زیر جهت انجام تحقیقات آتی به علاقه‌مندان توصیه می‌شود:

با توجه به اینکه میانگین بازده هر معامله با توجه به کارمزد، مقدار کمی است، بهتر است روشی بهتر برای برچسب‌گذاری روی داده‌ها ارائه شود تا این مشکل حل شود. یکی از راه‌ها، افزایش بازه پنجره زمانی است. البته این مورد باعث کاهش تعداد برچسب‌ها و افزایش مشکلات ناشی از عدم تعادل در داده‌ها می‌شود. روشی که می‌توان به کاربرد، استفاده از ناحیه خرید و ناحیه فروش به جای نقطه خرید و نقطه فروش است. با این فرض که مقادیر شاخص‌های تحلیل تکنیکال در صورت عدم تغییرات زیاد قیمت، تغییر چندانی نمی‌کنند، در صورتی که نقاط اطراف نقطه ماکزیمم نسبی (مینیمم نسبی) تغییرات قیمتی زیادی نداشته باشند، این نقاط نیز می‌توانند به عنوان نقاط فروش (خرید) برچسب بخورند. در اینجا می‌توان مقدار تغییرات قیمتی مجاز برای

اینکه یک نقطه در ناحیه خرید یا فروش قرار بگیرد را مقدار کمی (مانند ۱٪) نسبت به نقطه ماکزیمم نسبی یا مینییمم نسبی در نظر گرفت.

پیشنهاد دیگر، استفاده از داده‌هایی دیگر برای ساخت تصاویر است. می‌توان به جای شاخص‌های تحلیل تکنیکال ارائه‌شده، پارامترهای اقتصادی و یا بنیادی سهم را قرار داد. یا اینکه با در نظر گرفتن تعداد بیشتری شاخص تحلیل تکنیکال، تصویر بزرگ‌تری ایجاد کرد. توجه شود که بزرگ‌تر شدن تصویر به معنای نیاز به منابع پردازشی بیشتر و افزایش زمان لازم برای اجرای هر تکرار شبکه است.

همچنین می‌توان از مدل‌های پیچیده‌تر شبکه‌های عصبی پیچشی نیز استفاده کرد. مدل LeNet یک از مدل‌های بسیار ابتدایی بود که دقت پایینی هم داشت. اما اکنون مدل‌های بسیار جدید و پیچیده‌تری نیز در دسترس هستند که عملکرد بسیار بهتری نسبت به LeNet دارند. اما توجه شود که پیچیده‌تر شدن مدل نیز به معنای نیاز به منابع پردازشی بیشتر و افزایش زمان لازم برای اجرای هر تکرار شبکه است.

کار دیگری که می‌توان انجام داد، استفاده از روش‌هایی به عنوان روش کمکی برای سیگنال‌دهی است. ترکیب روش‌های دیگر، مانند روش‌های تحلیل تکنیکال، به روش ارائه شده در این پژوهش، می‌تواند به بهبود عملکرد آن کمک کند.

پیشنهاد دیگر، استفاده از یک سیستم خرید و فروش ترکیبی روی داده‌هاست. به این معنا که به جای اینکه مدل فقط روی یک دارایی خرید و فروش کند، روی سبدی از ترکیب دارایی‌های مختلف خرید و فروش کند. در این صورت میزان استفاده از منابع مدل نیز افزایش می‌یابد و مدل بهینه‌تر می‌شود.

در آخر نیز پیشنهاد می‌گردد این مدل در بازارهای دیگر نیز مورد بررسی قرار گیرد. با توجه به اینکه مقدار بیشینه افت در این مدل کمتر از روش خرید و نگهداری است، استفاده از اعتبار و اهرم‌های مالی می‌تواند به بازدهی بیشتر بیانجامد. همچنین بازارهای دو طرفه که می‌توان هم سمت خرید و هم سمت فروش قرار گرفت نیز باعث استفاده از سیگنال‌های فروش مدل می‌شود و عملاً دیگر زمان بیکاری نداریم. علاوه بر این به طور معمول کارمزد در بازارهای خارج از ایران بسیار پایین‌تر است و این نیز به بهبود بازدهی می‌انجامد.

منابع

1. Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6), 594-621.
2. Bajlan, S., Fllah Poor, S., & Dana, N. (2017). Predicting stock price trends using a modified support vector machine with hybrid feature selection, *Journal of Financial Management Perspective*, 17(1), 69-86. (In Persian)
3. Canziani, A., Paszke, A., & Culurciello, E. (2016). An analysis of deep neural network models for practical applications. *arXiv preprint arXiv:1605.07678*.
4. Cartea, A., & Jaimungal, S. (2013). Modelling asset prices for algorithmic and high-frequency trading. *Applied Mathematical Finance*, 20(6), 512-547.
5. Das, G., Lin, K. I., Mannila, H., Renganathan, G., & Smyth, P. (1998, August). Rule Discovery from Time Series. In *KDD* (Vol. 98, No. 1, pp. 16-22).
6. Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. (2016). Deep direct reinforcement learning for financial signal representation and trading. *IEEE transactions on neural networks and learning systems*, 28(3), 653-664.
7. Esmaeili, Z., Abbasi, E., Fallahshams, M. (2018). Prediction of initial public offering short-term performance using nearest neighbor and support vector machine models. *Journal of Financial Management Perspective*, 8(21), 9-27. (In Persian)
8. Ganz, F., Puschmann, D., Barnaghi, P., & Carrez, F. (2015). A practical evaluation of information processing and abstraction techniques for the internet of things. *IEEE Internet of Things journal*, 2(4), 340-354.
9. Gudelek, M. U., Boluk, S. A., & Ozbayoglu, A. M. (2017, November). A deep learning based stock trading model with 2-D CNN trend detection. In *2017 IEEE Symposium Series on Computational Intelligence (SSCI)* (pp. 1-8). IEEE.
10. Kalchbrenner, N., Grefenstette, E., & Blunsom, P. (2014). A convolutional neural network for modelling sentences. *arXiv preprint arXiv:1404.2188*.
11. Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., & Fei-Fei, L. (2014). Large-scale video classification with convolutional neural networks. In *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition* (pp. 1725-1732).
12. Kalaitzakis, K., Stavrakakis, G. S., & Anagnostakis, E. M. (2002). Short-term load forecasting based on artificial neural networks parallel implementation. *Electric Power Systems Research*, 63(3), 185-196.
13. Kim, T., & Kim, H. Y. (2019). Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. *PloS one*, 14(2), e0212320.
14. Kim, Y. (2014). Convolutional neural networks for sentence classification. *arXiv preprint arXiv:1408.5882*.
15. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems* (pp. 1097-1105).
16. Kuo, S. C., Li, S. T., Cheng, Y. C., & Ho, M. H. (2004, December). Knowledge discovery with SOM networks in financial investment strategy. In *Fourth International Conference on Hybrid Intelligent Systems (HIS'04)* (pp. 98-103). IEEE.
17. Pakbaz, M., Davari, M., & Balgourian, M. (2018). Investigating the predictive power of information content of accounting profit announcement by technical analysis signals. *Journal of Financial Management Perspective*, 20(4), 115-131. (In Persian)

18. Ramoni, M., Sebastiani, P., & Cohen, P. (2002). Bayesian clustering by dynamics. *Machine learning*, 47(1), 91-121.
19. Ratner, M., & Leal, R. P. (1999). Tests of technical trading strategies in the emerging equity markets of Latin America and Asia. *Journal of Banking & Finance*, 23(12), 1887-1905.
20. Sezer, O. B., & Ozbayoglu, A. M. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*, 70, 525-538.
21. Sezer, O. B., & Ozbayoglu, A. M. (2019). Financial trading model with stock bar chart image time series with deep convolutional neural networks. *arXiv preprint arXiv:1903.04610*.
22. Shen, F., Chao, J., & Zhao, J. (2015). Forecasting exchange rate using deep belief networks and conjugate gradient method. *Neurocomputing*, 167, 243-253.
23. Sweeney, R. J. (1988). Some new filter rule tests: Methods and results. *Journal of Financial and Quantitative Analysis*, 285-300.
24. Wen, Y., & Yuan, B. (2018, March). Use CNN-LSTM network to analyze secondary market data. In *Proceedings of the 2nd International Conference on Innovation in Artificial Intelligence*, pp. 54-58.

