

Summer 2024, 5 (2), 1-9
DOR:

Received: 13 Apr 2024
Accepted: 1 Jun 2024

مقاله پژوهشی

Leveraging Machine Learning for Optimal Trade Entry Point Identification in the Cryptocurrency Market

Abulfazl Yavari^{1*}, Hasan Aama², Mohammad Reza Hashemi³

1. Assistant Professor, Faculty of Computer Engineering and IT, Payam-e Noor University, Tehran, Iran.

*Corresponding Author, A.Yavari@pnu.ac.ir

2. Assistant Professor, Faculty of Management Economics and Accounting, Payam-e Noor University, Tehran, Iran.

3. Assistant Professor, Faculty of Computer Engineering, Skill National University, Tehran, Iran.

Abstract

Introduction: In the domain of financial forecasting, machine learning (ML) models have garnered significant attention in recent years. One prominent application lies in the cryptocurrency market, where intelligent trading bots facilitate a substantial portion of daily transactions.

Method: This paper investigates the efficacy of ML-based methods for identifying optimal trade entry points. Specifically, we employ the Relative Strength Index (RSI) and Simple Moving Average (SMA) indicators to extract a set of trend and crossover features. Subsequently, these features are utilized to train multilayer neural network, support vector machine, and nearest neighbor learning models. The performance of each model is then evaluated using digital currency market data encompassing the first seven months of 2023 for a variety of cryptocurrencies.

Results: Our findings demonstrate that, firstly, the extracted features exhibit promising efficacy. Secondly, the nearest neighbor model achieved the highest profitability during the evaluation period compared to the other investigated models.

Discussion: In the research conducted in this field, technical indicators are often used directly in market forecasting but in the proposed method of this article, instead of directly using the values of the indicators as the input of the classification methods, trend behaviors and their intersections have been used. In the continuation of this research, it is possible to determine the best exit points from the transaction with the help of machine learning and the use of volume indicators in the learning process.

Keywords: Cryptocurrency market, market forecasting, artificial neural network, support vector machine, nearest neighbor, technical analysis.



شناسایی نقطه ورود بهینه معاملات در بازار ارزهای دیجیتال با استفاده از یادگیری ماشین

دوره پنجم، تابستان ۱۴۰۳
شماره دوم، صص: ۹-۱

تاریخ دریافت: ۱۴۰۳/۰۱/۲۵
تاریخ پذیرش: ۱۴۰۳/۰۳/۱۲

ابوالفضل یآوری^{۱*}، حسن اعمی^۲، محمدرضا هاشمی^۳

- ۱- استادیار، گروه مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه پیام نور، تهران، ایران. (نویسنده مسئول) A.Yavari@pnu.ac.ir
- ۲- استادیار، گروه مدیریت اقتصاد و حسابداری، دانشگاه پیام نور، تهران، ایران. Hasanaama@pnu.ac.ir
- ۳- گروه مهندسی کامپیوتر، دانشگاه ملی مهارت، تهران، ایران. Smr.hashemi@shahroodut.ac.ir

چکیده: در سال‌های اخیر استفاده از مدل‌های یادگیری ماشین در حوزه‌های مختلفی مورد استفاده قرار گرفته‌است. از جمله این حوزه‌ها می‌توان به بازار رمزارزها اشاره کرد که بخش مهمی از معاملات روزانه در آن توسط ربات‌های معامله‌گر هوشمند انجام می‌شود. هدف اصلی این مقاله، یافتن بهترین نقطه ورود به یک معامله با کمک روش‌های یادگیری ماشینی است. در این مقاله از اندیکاتورهای شاخص قدرت نسبی (RSI) و میانگین متحرک ساده (SMA) برای استخراج چندین ویژگی روندی و تلاقی استفاده شده‌است. سپس با استفاده از این ویژگی‌ها، مدل‌های یادگیری شبکه عصبی چندلایه، ماشین بردار پشتیبان و نزدیکترین هم‌سایه آموزش داده می‌شوند. در نهایت، عملکرد هر یک از مدل‌ها بر روی داده‌های بازار ارزهای دیجیتال در بازه هفت ماه نخست سال ۲۰۲۳ برای چندین ارز دیجیتال ارزیابی شده‌است. نتایج نشان می‌دهند که اولاً ویژگی‌های استخراج شده از کارایی مناسبی برخوردارند و ثانیاً مدل نزدیکترین هم‌سایه، نسبت به مدل‌های دیگر، بیشترین سود را در این بازه زمانی کسب کرده‌است.

واژه‌های کلیدی: بازار رمزارزها، پیش‌بینی بازار، شبکه عصبی مصنوعی، ماشین بردار پشتیبان، نزدیکترین هم‌سایه، تحلیل تکنیکال.

۱. مقدمه

رمزارز^۱ شکلی از پول است که به صورت دیجیتالی یا مجازی ایجاد می‌شود و برای مبادله می‌توان از آن استفاده کرد. رمزارزها تمام ویژگی‌های پول‌های رایج را به جز ماهیت فیزیکی دارا هستند و از تکنولوژی رمزنگاری برای ایمن‌سازی و تأیید تراکنش‌ها استفاده می‌کنند. می‌توان آن‌ها را به سادگی مثل تراکنش‌های بانکی و با محدودیت‌های بسیار کمتر انتقال داد، با ارزهای دیگر مبادله کرد و خرید آنلاین انجام داد. اولین ارز دیجیتال بیت‌کوین بود که در سال ۲۰۰۸ توسط یک فرد ناشناس به جهان معرفی شد. در سال‌های اخیر، بازار رمزارزها رشد گسترده‌ای یافته است و ضریب نفوذ بالایی را بین افراد مختلف جامعه تجربه کرده است. علاوه بر این صندوق‌های تأمین و شرکت‌های بزرگ متعددی دارای‌های مرتبط با ارزهای دیجیتال را در سبد سرمایه‌گذاری و استراتژی‌های معاملاتی خود گنجانده‌اند.

دسترسی راحت به داده‌های معاملاتی همچون قیمت و حجم معاملات در دوره‌های زمانی^۲ مختلف، پژوهشگران زیادی را علاقمند به کار در این زمینه کرده است. در واقع، انگیزه اصلی می‌تواند یافتن بهترین موقعیت‌های خرید و فروش و کسب سود مداوم از بازار باشد. به عبارت دیگر، پیش‌بینی دقیق روند حرکتی آینده بازار از مهمترین اهداف پژوهش‌ها در این زمینه است. اما آیا به‌راستی بازار قابل پیش‌بینی است؟ در مورد قابل پیش‌بینی بودن بازار سهام، نظریه‌های متعددی وجود دارد. فاما در سال ۱۹۷۰، نظریه بازار کارآمد^۳ را مطرح کرد [۱]. طبق این نظریه، قیمت بازار از یک مدل راهپیمایی تصادفی^۴ پیروی می‌کند. به عبارت دیگر، تغییرات آتی قیمت بازار را نمی‌توان با استفاده از اطلاعات موجود، پیش‌بینی نمود. وجود ناهنجاری‌های متعددی در بازار سرمایه مانند واکنش پذیری ضعیف یا گاه بیش از حد، وجود جهش‌های کوتاه‌مدت و معکوس شدن بلندمدت بازار و همچنین نوسانات شدید قیمتی، نظریه بازار کارآمد را تأیید می‌کند. در پاسخ به این ناهنجاری‌ها، فرضیه بازار تطبیقی^۵ مطرح شد که روانشناسی انسان و نظریه مالی رفتاری را به کار می‌گیرد. اگرچه ناهنجاری‌ها در بازارهای مالی بوده و خواهند بود، اما نظریه داو را نمی‌توان نادیده گرفت. داو معتقد بود که کلیه بازارهای مالی از مجموعه قوانین و الگوهای تکرار شونده پیروی می‌کنند [۲]. به عبارت دیگر، تاریخ تکرار خواهد شد و این باعث می‌شود تا اطلاعات تاریخی بازار همواره مورد توجه معامله‌گران قرار گیرد.

به طور کلی دو رویکرد تحلیلی در پیش‌بینی قیمت‌ها مورد استفاده قرار می‌گیرد: تحلیل بنیادی و تحلیل تکنیکال. تحلیل بنیادی بر اطلاعات بنیادی شرکت‌ها مانند درآمد، هزینه‌ها، طرح‌های توسعه و موقعیت در بازار اشاره دارد. اما تحلیل تکنیکال تنها به مطالعه داده‌های تاریخی قیمت و حجم سهام برای پیش‌بینی حرکات قیمتی استوار است.

از طرفی روش‌های پیش‌بینی روند حرکتی آینده بازار را می‌توان به دو دسته روش‌های آماری و روش‌های مبتنی بر یادگیری ماشین

تقسیم کرد. اکثر مطالعات قدیمی‌تر از روش‌های آماری سری زمانی مبتنی بر داده‌های تاریخی برای پیش‌بینی قیمت استفاده کرده‌اند. در این میان، مدل ناهمگونی شرطی خودرگرسیون^۶، مدل میانگین متحرک رگرسیون خودکار^۷، مدل میانگین متحرک یکپارچه رگرسیون خودکار^۸، مدل میانگین متحرک، فیلتر کالمن و هموارسازی نمایی از محبوبترین تکنیک‌های آماری به حساب می‌آیند.

بعدها با معرفی هوش مصنوعی، مدل‌های یادگیری ماشین در مطالعات پیش‌بینی بازارها بیشتر مورد توجه قرار گرفتند. زیرا برخلاف روش‌های سری زمانی سنتی، این تکنیک‌ها می‌توانند داده‌های غیرخطی، آشفته، نویزی و پیچیده بازار را مدیریت کنند و با دقت و کارایی بیشتری به پیش‌بینی بپردازند.

در این مقاله، یک روش مبتنی بر تحلیل تکنیکال با استفاده از مدل‌های یادگیری ماشینی به منظور تعیین بهترین موقعیت‌های خرید در بازار ارزهای دیجیتال پیشنهاد شده است. در واقع ابتدا بر اساس اندیکاتورهای RSI و SMA یک سری ویژگی‌های جدید استخراج می‌شوند و سپس از مدل‌های یادگیری ماشینی نزدیکترین همسایه، ماشین بردار پشتیبان و شبکه عصبی مصنوعی برای یادگیری موقعیت خرید مناسب استفاده می‌شود. در نهایت مدل‌های آموزش دیده، بر روی داده‌های واقعی در بازه زمانی هفت ماه نخست ۲۰۲۳ ارزیابی شده‌اند. نتایج حاصل نشان می‌دهد که ویژگی‌های استخراج شده، جهت گرفتن بیشترین سود، کارایی کافی را دارند و مدل نزدیکترین همسایه بهترین عملکرد را دارا می‌باشد.

اولین نوآوری این مقاله روش برچسب‌گذاری داده‌های اولیه است. در واقع متناسب با میزان نوسانی بودن رمزارز می‌توان بر مبنای اندازه سود مورد انتظار در چند دوره زمانی بعدی، داده‌ها را برچسب‌گذاری نمود. دومین نوآوری این است که به جای استفاده مستقیم از اندیکاتورهای شناخته شده، رفتارهای روندی و تلاقی آن‌ها با یکدیگر، به عنوان ورودی رده‌بندها استفاده می‌شود. به عبارت دیگر به جای داده‌ها، استراتژی‌های معاملاتی به الگوریتم‌های رده‌بندی داده می‌شود. در ادامه ساختار مقاله بدین شرح است: در بخش ۲، تاریخچه‌ای مختصر در مورد پژوهش‌ها در زمینه معامله‌گری در بازارهای سهام آورده شده است. در بخش ۳ روش پیشنهادی به تفصیل شرح داده می‌شود. آزمایش‌ها و نتایج ارزیابی در بخش ۴ آمده است. در بخش ۵ نتیجه‌گیری و کارهای پیشنهادی بعدی آورده شده است.

۲. پیشینه تحقیق

هرچند استفاده از یادگیری ماشین برای پیش‌بینی بازار سهام سابقه طولانی دارد و پژوهش‌های زیادی درباره آن موجود است، اما تلاش‌های کمی برای تطبیق سیستم‌های معاملاتی فعلی با بازار ارزهای دیجیتال شده است [۳]. در برخی پژوهش‌ها، عوامل مؤثر بیرونی بر بازار ارز دیجیتال را بررسی کرده‌اند. در [۴] نشان دادند که بازار سهام ایالات متحده و شاخص بورس جهانی هیچ تأثیری بر حرکت بیت‌کوین به عنوان معتبرترین ارز دیجیتال ندارد. لیو و همکاران در [۵] به این

نتیجه رسیدند که عوامل کلان اقتصادی که به طور کلی بر پویایی بازارهای ارز، سهام و کالا مؤثر است، تاثیر قابل توجهی بر پویایی بازار ارزهای دیجیتال ندارند. بدین ترتیب به نظرمی رسد که جهت پیش بینی در بازار رمزارزها بیشتر باید به عوامل درونی این بازار توجه داشت. در [6-8] نشان دادند که می توان با داشتن یک استراتژی معاملاتی مبتنی بر تحلیل شبکه های اجتماعی، عملکردی بهتر نسبت به استراتژی خرید و نگهداری کسب نمود. نقش حجم معاملات در پیش بینی بازار سهام در [9] مورد بررسی قرار گرفت و نشان دادند که حجم در پیش بینی بازدهی ارزهای دیجیتال مفید است، اما در پیش بینی نوسانات قیمت ها چندان اهمیتی ندارد. در [10] دو مدل رگرسیون یادگیری ماشین پیشرفته با یک شبکه عصبی مصنوعی کاملاً متصل و یک شبکه حافظه کوتاه مدت^۹ برای پیش بینی قیمت ۶ ارز دیجیتال اصلی ساختند. آن ها دریافتند که شبکه عصبی مصنوعی به طور کلی بهتر از شبکه حافظه کوتاه مدت عمل می کند. علاوه بر این آن ها نشان دادند که پیش بینی همزمان داده های سری زمانی چند ارز دیجیتال توانایی پیش بینی را در مقایسه با آموزش روی هر ارز دیجیتال به طور جداگانه بهبود می بخشد.

روش های یادگیری ماشین متعددی به منظور پیش بینی رویدادها وجود دارد [۱۱،۱۲]. کوکر و همکاران [۱۳] مدلی را با استفاده از یادگیری تقویتی برای معاملات فعال ۵ ارز دیجیتال اصلی معرفی کردند و نشان دادند که نسبت به استراتژی خرید و نگهداری بازدهی بهتری دارد. در [۱۴] استفاده از روش های یادگیری ماشین را در مقایسه با تکنیک های پیش بینی سری زمانی در مورد پیش بینی قیمت روز بعد چند ارز دیجیتال بررسی کردند. هر چند سیگنال های خرید و فروش بیشتری در مدل های پیش بینی سری زمانی ایجاد شدند، اما بازدهی معاملات در مدل های یادگیری ماشین بیشتر بود.

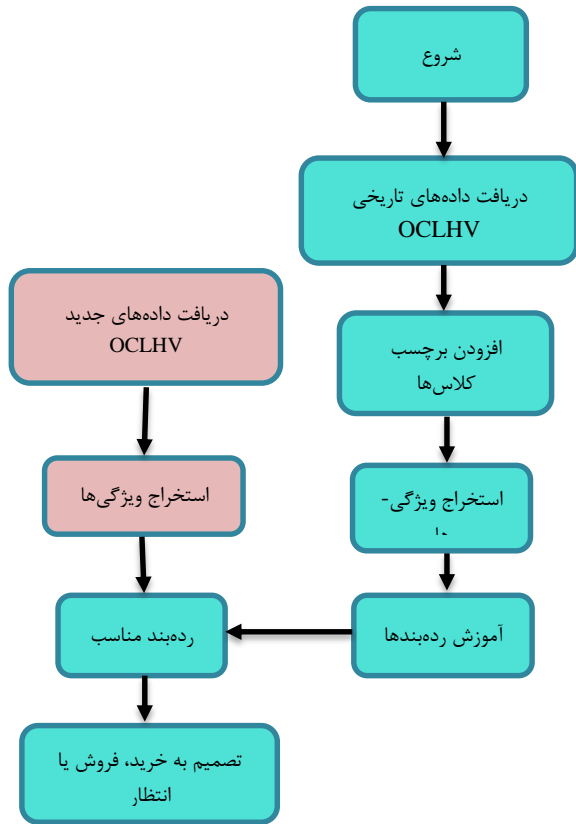
در [۱۵] با استفاده از چندین الگوریتم رده بندی، به پیش بینی بازار در دوره های زمانی روزانه و دقیقه ای پرداختند. آن ها از قیمت های گذشته بازار و اندیکاتورهای تکنیکالی به عنوان ورودی رده بندی های مختلف استفاده نمودند و توانستند دقت پیش بینی ۶۵ درصد را به دست آورند.

غالب این مطالعات نشان می دهند که داشتن یک استراتژی مبتنی بر یادگیری ماشین منجر به بازدهی بهتری نسبت به استراتژی خرید و نگهداری می شود. اما تنها از ویژگی های شناخته شده ای همچون اندیکاتورهای تکنیکالی و داده های قیمت و حجم استفاده نموده اند. در حالی که در این مقاله به جای استفاده مستقیم از مقادیر اندیکاتورها، رفتارهای روندی و تلاقی آن ها مورد استفاده قرار گرفته است.

۳. روش پیشنهادی

در این بخش روش پیشنهادی به منظور یافتن بهترین نقطه خرید آورده شده است. به طور کلی هدف استفاده از یادگیری ماشین در کاربردهای مختلف، کشف دانش نهفته در بین داده ها است. یادگیری با نظارت پراستفاده ترین تکنیک یادگیری در پیش بینی بازارهای مالی

است [۱۶]. از این رو در این پژوهش نیز از آن استفاده شده است. ساختار کلی روش پیشنهادی در شکل ۱ آمده است.



شکل ۱: ساختار کلی روش پیشنهادی

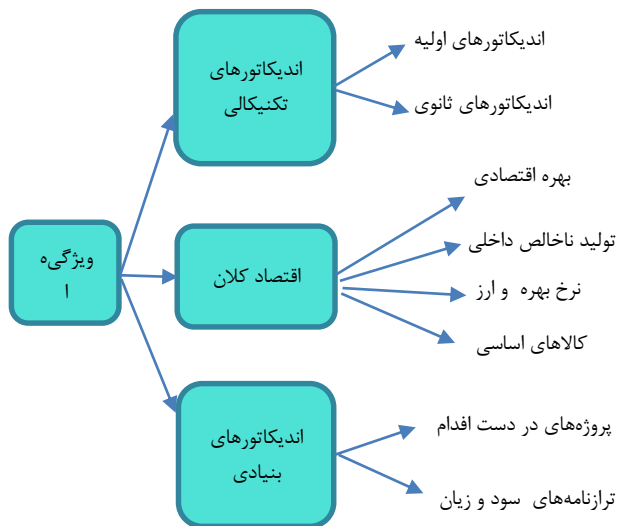
فرایند کلی با کسب داده های بازار که معمولاً قیمت باز و بسته شدن، بیشترین و کمترین قیمت و حجم^۱ در یک دوره زمانی می باشد، آغاز می شود. روش کسب داده و ویژگی های اولیه در بخش ۴ آورده شد است. در گام دوم برجسب مناسب کلاس ها به داده ها اضافه می شود. برجسب ها شامل "خرید" و "انتظار" می باشند. سپس استخراج ویژگی های جدید برای تصمیم گیری انجام می شود. گام چهارم به آموزش مدل های یادگیری ماشین اختصاص دارد. نهایتاً توانایی مدل ها در مواجهه با داده های جدید بازار مورد ارزیابی قرار می گیرند. در ادامه نحوه استخراج ویژگی و برجسب گذاری داده ها و تنظیمات مدل های رده بندی با جزئیات بیشتر آورده شده است.

۱.۳. استخراج ویژگی های جدید

در پژوهش های مختلفی که بین سال های ۲۰۰۸ تا ۲۰۲۱ در مورد بازارهای سهام انجام شده است، تعداد ۲۱۷۳ ویژگی منحصر به فرد در فرایندهای یادگیری ماشین مورد استفاده قرار گرفته اند [۱۷]. این ویژگی ها به طور کلی به ۳ گروه و چندین زیر گروه تقسیم می شوند (شکل ۲).

گروه اول، اندیکاتورهای تکنیکالی می باشند که پر کاربردترین ویژگی های مورد استفاده در پژوهش های پیش بینی بازار سرمایه

هستند. این ویژگی‌ها به دو زیر گروه اندیکاتورهای اولیه شامل OCLHV^۱ و اندیکاتورهای ثانویه شامل تمامی اندیکاتورهای شناخته شده در بازار سرمایه مانند انواع میانگین‌های متحرک، RSI و صدها اندیکاتور شناخته شده دیگر تقسیم می‌شوند.



شکل ۲: انواع ویژگی‌های مورد استفاده در پژوهش‌ها

گروه دوم ویژگی‌ها در شکل ۲ داده‌های اقتصاد کلان را در برمی‌گیرند. برخی از زیرگروه‌های اقتصاد کلان شامل بهره اقتصادی، تولید ناخالص داخلی، نرخ بهره، قیمت ارز و کالاهای اساسی می‌باشند. گروه سوم، شامل ویژگی‌های بنیادی همچون پروژه‌های در دست اقدام، و ترازنامه‌های سود و زیان می‌باشند.

در این مقاله از اندیکاتورهای RSI و SMA برای استخراج یک سری ویژگی جدید استفاده شده است. اندیکاتور RSI نشان‌دهنده قدرت بازار و قدرت خریداران و فروشندگان نسبت به هم است. این اندیکاتور همواره بین صفر تا ۱۰۰ در نوسان است و در خانواده اسیلیاتورها قرار دارد. نحوه محاسبه آن در رابطه (۱) و رابطه (۲) آورده شده است.

$$RS(n) = \frac{MG(n)}{ML(n)} \quad (1)$$

$$RSI = 100 - \left[\frac{100}{1 - RS} \right] \quad (2)$$

در رابطه (۱)، $MG(n)$ میانگین میزان سود در دوره زمانی به طول n است. در این مقاله از چهار دوره زمانی متداول شامل ۵، ۹، ۱۴ و ۲۱ جهت استخراج ویژگی استفاده شده است.

اندیکاتور SMA ساده‌ترین اندیکاتور در خانواده میانگین‌های متحرک محسوب می‌شود. برای محاسبه آن از رابطه (۳) می‌توان استفاده کرد.

$$SMA(n) = \frac{\sum_{i=1}^n C}{n} \quad (3)$$

رابطه (۳) یک میانگین‌گیری ساده را بر روی قیمت‌های بسته شدن در هر کندل قیمتی در یک دوره زمانی به طول n نشان می‌دهد. در این

مقاله از دوره‌های زمانی به طول ۹، ۱۴، ۲۱، ۵۰ و ۱۰۰ استفاده شده است.

دو اندیکاتور فوق را چنانچه از نظر روندی و تلاقی بررسی کنیم، چهار دسته ویژگی به دست می‌آیند. ویژگی‌های روندی SMA نشان می‌دهند که SMAهای مختلف در دوره‌های زمانی ۹، ۱۴، ۲۱، ۵۰، ۱۰۰ در طول یک پنجره زمانی دارای چه روندی بوده‌اند. یعنی مثلاً مشخص شود که در پنجره زمانی ۱۲ کندلی، روند SMA(9) افزایشی، کاهشی یا بدون تغییر بوده است. ویژگی‌های تلاقی SMA نیز نشان می‌دهند که SMA(9)، SMA(14) را در طول یک پنجره زمانی رو به بالا قطع کرده است یا رو به پایین یا بدون تلاقی بوده است. این تلاقی برای SMA(14) با SAM(21)، SMA(21) با SMA(50) و SMA(50) با SMA(100) نیز بررسی می‌شوند. بنابراین ۹ ویژگی روندی و تلاقی برای SMA تشکیل می‌شود که وقوع هر کدام از این موارد برای یک معامله‌گر خبره در بازارهای سرمایه با معنا است. به عنوان مثال چنانچه SMA(50)، SMA(100) را رو به بالا قطع کند، می‌تواند نشانه رشد قیمتی در آینده باشد.

ویژگی‌های روندی RSI نشان می‌دهند که RSIهای مختلف در دوره‌های زمانی ۵، ۹، ۱۴ و ۲۱ در طول یک پنجره زمانی، دارای چه روندی هستند. و ویژگی‌های تلاقی RSI نیز نشان می‌دهند که RSI(5)، RSI(9) را در طول پنجره زمانی رو به بالا قطع کرده است یا رو به پایین یا بدون تلاقی بوده است. این محاسبات برای تلاقی RSI(9) با RSI(14) و RSI(14) با RSI(21) نیز صورت می‌پذیرد. بنابراین ۷ ویژگی روندی و تلاقی برای RSI تشکیل می‌شود. نهایتاً با استفاده از SMA و RSI، ۱۶ ویژگی روندی و تلاقی جدید ایجاد شده است که در فرایند آموزش مدل‌های یادگیری ماشین مورد استفاده قرار می‌گیرند.

۲.۳. برچسب‌گذاری داده‌ها برای آموزش مدل‌های رده‌بند


در ابتدا نیاز است تا داده‌های دریافتی برچسب‌گذاری شوند. روند برچسب‌گذاری داده‌ها یکی از نوآوری‌های این پژوهش است. برای برچسب‌گذاری ابتدا باید مقدار دو پارامتر مشخص شوند. پارامتر نخست میزان درصد سود مورد انتظار (EP) و پارامتر دوم، طول پنجره زمانی است که معامله‌گر می‌خواهد به سود مورد انتظار دست یابد (WL). به عنوان مثال چنانچه $EP=3\%$ ، $WL=24$ و دوره زمانی نیز ۶۰ دقیقه باشد، بدین معنی است که داده‌ها به نحوی برچسب‌گذاری شوند تا بهترین زمان‌های خرید برای کسب سه درصد سود در ۲۴ ساعت را نشان دهند.

اگر چنین شرایطی رخ دهد، برچسب "خرید"، برای زمان ابتدای پنجره لحاظ خواهد شد. شکل ۳ این شرایط را نشان می‌دهد. اما اگر در طول یک پنجره زمانی، چنین رشد مورد انتظاری حاصل نشود، برچسب "انتظار" به معنای عدم خرید ثبت می‌شود (شکل ۴).


با برچسب‌گذاری و استخراج ویژگی‌ها، همه چیز برای آموزش مدل‌های یادگیری مهیا است. در این مقاله از سه مدل شبکه عصبی

مصنوعی، ماشین بردار پشتیبان و k-نزدیکترین همسایه استفاده شده است. تنظیمات هر مدل در جدول ۱ آورده شده است.

کسب سود مورد انتظار



شکل ۳: شرایط ثبت برچسب خرید در مجموعه داده‌ها



شکل ۴: شرایط ثبت برچسب انتظار در مجموعه داده‌ها

۴. آزمایش‌ها

در این بخش نحوه دریافت داده‌ها و خصوصیات آن‌ها، آزمایش‌های مختلف جهت ارزیابی مدل‌های رده‌بندی و نهایتاً مقایسه آن‌ها از نظر سوددهی با استراتژی خرید و نگهداری آورده شده است.

۴ / ۱. دریافت داده‌ها

ابتدایی‌ترین داده‌های معاملاتی که در مورد یک نماد در هر بازاری از جمله بازار ارزهای دیجیتال قابل دریافت است، OCLHV می‌باشند. این

داده‌ها مشخص می‌کنند که در یک دوره زمانی خاص مثلاً یک ساعته، قیمت اولین خرید (O)، قیمت آخرین خرید (C)، کمترین قیمت (L)، بیشترین قیمت (H) و کل حجم معامله شده (V) چقدر بوده است. داده‌های مربوطه در این مقاله از طریق API های موجود در سایت صرافی نو بیتکس^{۱۱} و با زبان برنامه‌نویسی پایتون دانلود شده‌اند. به منظور دانلود داده‌ها باید نام رمزارز، تایم فریم مورد نظر، تاریخ شروع و تاریخ پایان برای API مشخص باشد. به منظور برچسب‌گذاری و آموزش مدل‌های رده‌بندی، داده‌های بازار از تاریخ ۲۰۲۱/۱/۱ تا ۲۰۲۲/۱۲/۳۰ در دوره زمانی یک ساعته برای نمادهای بیت‌کوین، اتریوم، ریپل، ترون و تتر دانلود شده‌اند. ۵ ردیف از نمونه داده‌های اولیه برای نماد بیت‌کوین در جدول ۲ آورده شده است.

پس از دانلود داده‌های اولیه، برچسب‌گذاری داده‌ها طبق روشی که شرح آن در بخش ۲،۳ آمد، انجام می‌شود. ۵ ردیف داده برچسب‌گذاری شده برای بیت‌کوین در جدول ۳ آورده شده است.

مرحله بعدی استخراج ویژگی‌های روندی و تلاقی است که مطابق با روش شرح داده شده در بخش ۱،۳ بر اساس اندیکاتورهای RSI و SMA و با استفاده از کتابخانه pandas_ta در پایتون محاسبه می‌شوند. (جدول ۴)

اکنون ویژگی‌ها و برچسب کلاس‌ها، آماده است و با تقسیم‌بندی داده‌ها به مجموعه آموزشی و آزمون، مدل‌های رده‌بندی مورد نظر آموزش داده می‌شوند. دقت هر مدل در جدول ۵ آورده شده است.

لازم به ذکر است که، طول پنجره زمانی و سود مورد انتظار نمی‌تواند برای همه رمزارزها یکسان باشد. مثلاً اگر برای بیت‌کوین، طول پنجره ۱۲ و درصد رشد مورد انتظار ۰.۳٪ تنظیم شود، مشکل عدم توازن داده پیش خواهد آمد و تعداد برچسب‌های "خرید" در مقایسه با تعداد برچسب "انتظار" بسیار اندک خواهد بود. زیرا اصولاً رمزارز بیت‌کوین آنچنان نوسان زیادی ندارد که بارها و بارها در طول ۱۲ ساعت سه درصد رشد قیمتی را تجربه کند. بنابراین باید با یک روش آزمون و خطا، طول پنجره و درصد رشد مناسب را تعیین کرد طوری که بین ۴۰ تا ۶۰ درصد داده‌ها، برچسب خرید داشته باشند.

جدول ۱: پارامترهای مدل‌های یادگیری

مقادیر	پارامترها	نام مدل
Uniform 5	Weight K	نزدیکترین همسایه
Ball_tree	Algorithm	
(3,5)	Hidden Layer Size	
Tanh	Activation Function	شبکه عصبی چندلایه
lbfgs	Solver	
constant, 2e-5	Learning Rate	
Poly	Kernel	ماشین بردار پشتیبان
4	Degree	
1	C	

جدول ۲: پنج ردیف از داده‌های OCLHV برای بیت کوین

Date	Open	high	low	Close	Volume
2021-01-01 00:30:00	768700000	773995986	765501000	773500000	3.21494246
2021-01-01 01:30:00	773921000	774999900	770788301	773314200	4.768125762
2021-01-01 02:30:00	773314200	775000000	770000000	773998999	1.382566634
2021-01-01 03:30:00	773998999	773998999	770000000	770599001	2.713378
2021-01-01 04:30:00	770598002	771499000	767550000	770998000	1.895207556

جدول ۳: پنج ردیف از داده‌های برجسب‌گذاری شده برای بیت کوین

Date	Open	high	low	Close	Volume	Label
2021-01-01 00:30:00	768700000	773995986	765501000	773500000	3.21494246	W
2021-01-01 01:30:00	773921000	774999900	770788301	773314200	4.768125762	W
2021-01-01 02:30:00	773314200	775000000	770000000	773998999	1.382566634	W
2021-01-01 03:30:00	773998999	773998999	770000000	770599001	2.713378	B
2021-01-01 04:30:00	770598002	771499000	767550000	770998000	1.895207556	B

جدول ۴: پنج ردیف از ویژگی‌های استخراج شده برای بیت کوین

ویژگی استخراج شده	2021-01-01 00:30:00	2021-01-01 01:30:00	2021-01-01 02:30:00	2021-01-01 03:30:00	2021-01-01 04:30:00
SMA_9_Trend	Down	Down	Up	Up	Down
SMA_14_Trend	Down	Down	Down	Up	Down
SMA_21_Trend	Down	Down	Down	Down	Down
SMA_50_Trend	Up	Down	Down	Down	Up
SMA_100_Trend	Down	Down	Up	Down	Down
SMA_9_cross_14	No	No	Up	Down	Down
_cross_21^SMA_	Up	No	Up	No	Up
_cross_50^SMA_	No	No	No	Up	Up
_cross_100^SMA_	No	No	No	No	No
RSI_5_Trend	Down	Down	Down	Down	Down
RSI_9_Trend	Down	Down	Down	Down	Down
RSI_14_Trend	Up	Up	Up	Up	Up
RSI_21_Trend	Up	Up	Up	Up	Up
RSI_5_cross_9	Down	Down	Down	Down	Down
_cross_14^RSI_	Down	Down	Down	Down	Down
_cross_21^RSI_	Up	Up	Up	Up	Up
Label	w	w	w	B	B

جدول ۵: دقت مدل‌های رده‌بندی

	نزدیکترین همسایه	ماشین بردار پشتیبان	شبکه عصبی
دقت رده بندی	62%	51%	56%

نگهداری داشته‌اند که می‌تواند نشان‌دهنده انتخاب مناسب

ویژگی‌های استخراج شده باشد.

۲.۴. ارزیابی

پس از آموزش مدل‌های یادگیری، بر روی داده‌های جدید شامل هفت ماه نخست سال ۲۰۲۳، یک تست انجام می‌شود. عملکرد مدل‌ها با یکدیگر و با استراتژی خرید و نگهداری مقایسه شده است. منظور از استراتژی خرید و نگهداری این است که اگر رمزارز مورد نظر در ۲۰۲۳/۱/۱ خریداری شود و تا ۲۰۲۳/۰۷/۳۱ نگهداری گردد چه میزان سود یا ضرر کسب شده است. نتایج در جدول ۶ آورده شده است.

با توجه به جدول ۶، روش نزدیکترین همسایه بهترین عملکرد را بین تمامی روش‌های دیگر داشته است. علاوه بر این، تمامی مدل‌های یادگیری عملکرد بهتری نسبت به استراتژی خرید و

جدول ۶: میزان درصد سود یا زیان کسب‌شده برای ۵ رمزارز مختلف

خرید و نگهداری	شبکه عصبی	ماشین بردار پشتیبان	نزدیکترین همسایه
116%	148%	131%	186%
88%	109%	102%	146%
75%	108%	95%	128%
151%	133%	161%	156%
23%	42%	31%	76%

References

- [1] E. Fama. "Efficient capital markets: A review of the theory". *The Journal of Finance*, 25, 383–417, 1970
- [2] J. Almeida, T. Cruz, "A systematic literature review of investor behavior in the cryptocurrency markets", *Journal of Behavioral and Experimental Finance*, Volume 37, 2023
- [3] V. Derbentsev, V. Babenko, K. Khrustalev, H. Obruch and S. Khrustalova, "Comparative performance of machine learning ensemble algorithms for forecasting cryptocurrency prices". *International Journal of Engineering*, 34, 140–148, 2021
- [4] C. Conrad, A. Custovic and E. Ghysels, "Long-and short-term cryptocurrency volatility components: A GARCH-MIDAS analysis". *Journal of Risk and Financial Management*, 11(2), 23, 2018
- [5] Y. Liu and A. Tsyvinski, "Risks and returns of cryptocurrency". *The Review of Financial Studies*, 34(6), 2689–2727, 2021
- [6] R. C. Phillips and D. Gorse, "Predicting cryptocurrency price bubbles using social media data and epidemic modelling". In 2017 IEEE Symposium Series on Computational Intelligence (SSCI) (pp. 1-7). IEEE, 2017
- [7] F. Valencia, A. Gomez-Espinosa and B. Valdes-Aguirre, "Price movement prediction of cryptocurrencies using sentiment analysis and machine learning". *Entropy*, 21(6), 589, 2019
- [8] A. Yavari, H. Hassanpour, B. Rahimpour and M. Mahdavi, "Event prediction in social network through Twitter messages analysis. *Social Network Analysis and Mining*". 12. 10.1007/s13278-022-00911-x. 2022
- [9] E. Bouri, C. K. Lau, B. Lucey and D. Roubaud, "Trading volume and the predictability of return and volatility in the cryptocurrency market". *Finance Research Letters*, 29, 340–346, 2019
- [10] W. Zhengyang, L. Xingzhou, R. Jinjin and K. Jiaqing, "Prediction of cryptocurrency price dynamics with multiple machine learning techniques". In *Proceedings of the 2019 4th International Conference on Machine Learning Technologies* (pp. 15–19), 2019
- [11] Hajighorbani, Hashemi, Broumandnia, Faridpour, "a review of some semi-supervised learning methods", *Journal of Knowledge-Based Engineering and Information*, 2(4), 2013
- [12] S. Ansari-pour, T. J. Gandomani, "Comparison of the classification methods in software development effort estimation", *Intelligent Multimedia Processing and Communication Systems (IMPCS)*, 3(2), 11-18, 2022
- [13] T. E. Koker and D. Koutmos, "Cryptocurrency trading using machine learning". *Journal of Risk and Financial Management*, 13(8), 178, 2020
- [14] G. Attanasio, L. Cagliero, P. Garza and E. Baralis, "Quantitative cryptocurrency trading: Exploring the use of machine learning techniques". In *In Proceedings of the 5th*

لازم به ذکر است که چون در صرافی‌های ایران، امکان ایجاد معاملات در جهت فروش فراهم نیست، فروش هر معامله باز شده بر اساس تنظیم حد ضرر ۳ درصد و حد سود ۴ درصد انجام شده است. با رسیدن به حد سود مورد نظر، مجدد مقادیر حد سود و حد ضرر به روزرسانی می‌شوند تا زمانی که حد ضرر فعال شود و فروش رمزارز انجام گیرد. در محاسبات درصد سود نهایی جدول ۶، ۰٫۳ درصد کارمزدهای انجام معامله در صرافی نیز لحاظ شده است.

۵. نتیجه‌گیری و کارهای بعدی

هدف از این پژوهش، یافتن بهترین نقاط ورود به یک معامله ارز دیجیتال به کمک مدل‌های یادگیری ماشین است. در پژوهش‌های انجام شده در این حوزه، غالباً از اندیکاتورهای تکنیکالی به طور مستقیم در پیش‌بینی بازار استفاده می‌شود. اما در روش پیشنهادی این مقاله، به جای استفاده مستقیم از مقادیر اندیکاتورها به عنوان ورودی روش‌های رده‌بندی، از رفتارهای روندی و تلاقی آن‌ها استفاده شده است. در واقع روندهای افزایشی یا کاهشی و نحوه تلاقی این اندیکاتورها، برای برخی معامله‌گران در این حوزه به عنوان سیگنال‌های ورود و خروج از معامله تعبیر می‌شوند. بنابراین می‌توان گفت که استراتژی‌های معاملاتی به عنوان ورودی رده‌بندی در نظر گرفته شده است.

علاوه بر این در این مقاله روشی برای برچسب‌گذاری داده‌های اولیه پیشنهاد شده است که به واسطه آن می‌توان بهترین نقاط ورودی از نظر میزان سود مورد انتظار را به طور مناسب برچسب‌گذاری نمود. نتایج حاصل بر روی داده‌های هفت ماه نخست سال ۲۰۲۳ نشان می‌دهند که ویژگی‌های استخراجی کارایی لازم برای تشخیص بهترین نقاط ورود را داشته‌اند و روش نزدیکترین همسایه بیشترین سوددهی در این بازه زمانی را کسب کرده است. در ادامه این پژوهش، تعیین بهترین نقاط خروج از معامله با کمک یادگیری ماشین و استفاده از اندیکاتورهای حجمی در فرایند یادگیری، قابل بررسی است.

- Workshop on Data Science for Macro-Modeling with Financial and Economic Datasets* (pp. 1–6). 2019.
- [15] E. Akyildirim, A. Goncu and A. Sensoy, “Prediction of cryptocurrency returns using machine learning”. *Annals of Operations Research*, 297(1), 3–36, 2021
- [16] Z. Dongna, H. Xihui, L. Chi Keung and X. Bing, “Implications of cryptocurrency energy usage on climate change”, *Technological Forecasting and Social Change*, Volume 187, 2023,
- [17] M. Kumbure, C. Lohrmann, P. Luukka and J. Porras, “Machine learning techniques and data for stock market forecasting: A literature review”, *Expert Systems with Applications*, Volume 197, 2022

پی‌نوشت

- 1- Cryptocurrency
- 2- Time Frame
- 3- Efficient Market Hypothesis
- 4- Random Walk
- 5- Adaptive Market Hypothesis
- 6- Auto-Regressive Conditional Heteroscedasticity
- 7- Auto-Regressive Moving Average
- 8- Auto-Regressive Integrated Moving Average
- 9- Long-Short-Term-Memory
- 10- Open-Close-Low-High-Volume (OCLHV)
- 11- <https://api.nobitex.ir/>