

مروری بر ارائه یک مدل تصمیم یار مبتنی بر یادگیری عمیق برای حداکثر سازی سود ارزشهای دیجیتال

مجید سعیدی زاده
ناائینی *

گروه مهندسی کامپیوتر، دانشکده فنی و مهندسی، مؤسسه آموزش عالی آپادانا،
شیراز، ایران

چکیده

تحقیق در پیش بینی قیمت ارزشهای دیجیتال به طور فعال انجام شده است، زیرا ارزشهای دیجیتال توجه زیادی را به خود جلب کرده اند. اخیراً، محققان سعی کرده اند عملکرد روش های پیش بینی قیمت را با استفاده از مدل های مبتنی بر یادگیری عمیق بهبود بخشند. با این حال، اکثر مطالعات بر پیش بینی قیمت ارزشهای دیجیتال برای روز بعد تمرکز کرده اند. بنابراین، مشتریان با ضرورت تصمیم گیری سریع در مورد اقداماتی که از حداکثر سود آنها پشتیبانی می کنند، مانند "فروش"، "خرید" و "انتظار"، ناراحت می شوند. علاوه بر این، مطالعات بسیار کمی از استفاده از مدل های یادگیری عمیق برای ارائه توصیه های برای این اقدامات استفاده کرده اند و عملکرد چنین مدل هایی همچنان پایین است. بنابراین، برای حل این مشکلات، ما یک مدل یادگیری عمیق و سه ویژگی ورودی پیشنهاد می کنیم سود فروش، سود خرید و حداکثر سود از طریق این مفاهیم، به مشتریان معیارهایی ارائه می شود که بر اساس آن کدام اقدام در زمان فعلی سودمندتر خواهد بود. این معیارها می توانند به عنوان شاخص های تصمیم گیری برای تسهیل حداکثر سود استفاده شوند. برای تأیید اثربخشی روش پیشنهادی، از داده های روزانه قیمت شش ارز دیجیتال نماینده برای انجام یک آزمایش استفاده شد. نتایج تأیید می کند که مدل پیشنهادی حدود ۱۳٪ تا ۲۱٪ بهبود نسبت به روش های موجود داشته است و از نظر آماری معنی دار است.

کلیدواژه ها: ارز دیجیتال، بیت کوین، پیش بینی قیمت، یادگیری عمیق، ویژگی ورودی، تصمیم گیری، سود

مقدمه

از زمانی که ساتوشی ناکاموتو در سال ۲۰۰۸ ارز دیجیتال بیت کوین را معرفی کرد، ارزهای دیجیتال دیگری مانند اتریوم نیز ظهور کرده‌اند (Eyal, 2017). در حال حاضر، ارزهای دیجیتال همچنان بر بازارهای مالی جهانی تأثیر می‌گذارند و در زندگی روزمره نسبتاً رایج شده‌اند. ارزهای دیجیتال نسبت به سهام، به سرمایه‌گذاری‌های گمانه‌زنی محبوب تبدیل شده‌اند. علاوه بر این، فناوری بلاک چین به دلیل جلوگیری از جعل و تحریف از طریق دفترهای کل غیرمتمرکز، توجه قابل توجهی را به خود جلب کرده است. (Marke, 2018). علاوه بر این، بازار ارزهای دیجیتال می‌تواند با فناوری‌های جدید مختلف مانند متاورس ادغام شود که اخیراً توجه را به خود جلب کرده‌اند. از این رو، این ارتباطات ارزش ارزهای دیجیتال و پتانسیل آن‌ها برای پذیرش گسترده‌تر را افزایش داده است (Dowling, 2022). سرمایه‌گذاران بازار معاملات را برای پیش‌بینی قیمت ارزهای دیجیتال تحلیل می‌کنند. با این حال، ارز دیجیتال نسبت به سهام سنتی تاریخچه کوتاهی دارد، بنابراین تحقیقات در مورد تکنیک‌های تحلیل و پیش‌بینی قیمت ارزهای دیجیتال تاکنون در مراحل اولیه خود باقی مانده است (Hu et al., 2021). آثار نماینده شامل تحلیل‌های مختلف داده‌های آموزشی از دیدگاه‌های مختلف با استفاده از یادگیری عمیق و همچنین تحقیقات در مورد پیش‌بینی قیمت ارزهای دیجیتال با استفاده از مدل‌های حافظه طولانی کوتاه مدت و واحد بازگشتی گیت دار است که عملکرد بسیار خوبی در داده‌های سری زمانی نشان داده‌اند که مشکلات نرخ یادگیری کند و "گرادیان محو" مدل‌های شبکه عصبی بازگشتی را حل کرده‌اند. (Khedr et al., 2021) اخیراً قیمت ارزهای دیجیتال به شدت نوسان پیدا کرده است، تا جایی که پیش‌بینی قیمت‌ها در طول زمان غیرممکن یا غیرعملی شده است. به همین دلیل، ممکن است قیمت ارزهای دیجیتال دارای ویژگی‌های افزایش نوسان و نوسانات در نظر گرفته شوند. (Hoseinzade & Haratizadeh, 2019) در چند سال گذشته، ایده‌های مختلفی برای حل این مشکلات پیشنهاد شده است و آن‌ها اثربخشی خود را در پیش‌بینی‌های واقعی نشان داده‌اند. این مطالعات از مدل‌های ترکیبی، تحلیل احساسات برای بازتاب حالات روانشناختی انسان و تجزیه فرکانس برای به حداقل رساندن نوسان و نوسان استفاده کرده‌اند (Livieris et al., 2021). با این حال، این مطالعات شامل برخی محدودیت‌ها هستند. پیش‌بینی‌های دقیق ممکن است برای ارزهای دیجیتال مهم باشد، اما باید به چشم‌انداز حداکثر سود نهایی نیز از نظر موقعیت‌هایی که شامل نوسان و نوسانات شدید هستند، توجه کرد (Salimitari et al., 2017). برای حداکثر کردن سود، ارائه ابزارهای تصمیم‌گیری به مشتریان، مانند اینکه در چه نقاط خاصی باید دارایی‌های ارز دیجیتال را بفروشند، بخرند یا نگه دارند.

ما ویژگی‌های سود خرید را به عنوان سود قابل دستیابی با فروش یک ارز دیجیتال در زمان معین، سود فروش را به عنوان سود قابل دستیابی با خرید یک ارز دیجیتال در زمان معین و سود حداکثر را که حداکثر سود قابل دستیابی در زمان معین است، تعریف کردیم. در این مطالعه در مجموع از شش ارز دیجیتال نماینده از جمله بیت کوین، کاردانو، دش، اتریوم، لایت کوین و مونرو استفاده شد. (Vranken, 2017) برای مقایسه آزمایشگاهی عینی، دقت و امتیاز F1 به عنوان معیارهای ارزیابی استفاده شد. از طریق این مدل پیشنهادی، به مشتریان معیارهایی ارائه می‌شود تا تعیین کنند که آیا از فروش، خرید یا نگهداری ("انتظار") دارایی‌های ارز دیجیتال سود خواهند برد یا خیر.

پیشینه پژوهش

در این بخش، مطالعات قبلی در مورد مدل‌های یادگیری عمیق طراحی شده برای پیش‌بینی قیمت‌های آینده ارزهای دیجیتال و مدل‌هایی که یک اقدام را برای حمایت از حداکثر سود توصیه می‌کنند، معرفی می‌کنیم. پیش‌بینی قیمت

ارز دیجیتال یک حوزه بسیار دشوار و چالش برانگیز در تحقیق داده‌های سری زمانی است. ویژگی‌های نوسان بالا و نوسانات قیمت، مشکل پیش‌بینی قیمت را افزایش می‌دهند. مطالعات متعددی برای حل این مشکلات پیشنهاد شده است (Patel et al., 2020).

مدل ترکیبی

مدل‌های ترکیبی با ترکیب دو یا چند مدل پیش‌بینی مختلف، طراحی شده‌اند تا قیمت‌ها را پیش‌بینی کنند. به دلیل مزایای ترکیبی آن‌ها در جبران نقاط ضعف هر مدل، این مدل‌ها در زمینه‌های مختلف کاربرد فراوانی دارند. یک مدل ترکیبی را پیشنهاد کردند که یک شبکه عصبی کانولوشنی و یک معماری حافظه طولانی کوتاه مدت را با هم ترکیب می‌کند. این مدل عملکرد بالایی در داده‌های سری زمانی نشان داده است. آن‌ها از ۱۳۹۹ روز داده قیمت بیت‌کوین، اتریوم و ریپل از ۱ ژانویه ۲۰۱۷ تا ۳۱ اکتبر ۲۰۲۰ استفاده کردند. علاوه بر این، آن‌ها روشی را برای پیش‌بینی قیمت‌ها با استفاده از ویژگی‌ها و خصوصیات داده‌ها از لایه ادغام، شبکه عصبی کانولوشنی به عنوان ورودی یک لایه حافظه کوتاه بلند مدت پیشنهاد کردند. این روش نشان داده شد که نه تنها ارزان‌تر است، بلکه عملکرد پیش‌بینی بالاتری نسبت به مدل‌های سری زمانی موجود دارد (Livieris et al., 2021).

تحلیل احساسات

تحلیل احساسات روشی برای بررسی میزان تأثیر حالت روانشناختی مشتریان بر نتایج آینده است. داده‌های مربوط به حالت‌های روانشناختی می‌توانند از طریق تویتر، جوامع آنلاین و عناوین اخبار استخراج شوند. مدلی را پیشنهاد کردند که از توییت‌ها به عنوان ویژگی‌های ورودی استفاده می‌کند. آن‌ها از داده‌های بیت‌کوین، اتریوم، لایت‌کوین و ریپل برای ۱۴۴۰ ساعت از ۱۶ فوریه ۲۰۱۸ تا ۲۱ آوریل ۲۰۱۸ استفاده کردند. آن‌ها هر ساعت توییت‌های تویتر را جمع‌آوری کرده و تعیین کردند که کدام ارز دیجیتال با بیشترین توییت‌های مثبت یا منفی مرتبط است. سپس، آن‌ها روشی را با استفاده از نتایج به عنوان ویژگی‌های ورودی برای پیش‌بینی اینکه قیمت این ارزها بالا یا پایین خواهد رفت، پیشنهاد کردند. این روش پیش‌بینی‌کننده‌تر از زمانی است که توییت‌های تویتر استفاده نشده بود (Valencia et al., 2019). نیز به طور مشابه مدلی را پیشنهاد کردند که از توییت‌ها در تویتر به عنوان ویژگی‌های ورودی استفاده می‌کند. آن‌ها از پنج سال داده‌های سهام اپل، سیتی‌گروپ، گوگل و مایکروسافت از ۲۰۱۲ تا ۲۰۱۶ استفاده کردند. برخلاف مطالعات قبلی، روش پیشنهادی آن‌ها علاوه بر توییت‌های مثبت و منفی، توییت‌های خنثی را نیز به عنوان خروجی جدید پیش‌بینی کرد. این روش عملکرد پیش‌بینی بالاتری نسبت به زمانی که فقط توییت‌های مثبت و منفی استفاده می‌شد، نشان داد (Maqsood et al., 2020). مدلی را پیشنهاد کردند که از عناوین اخبار، داده‌های گوگل ترندز و توییت‌ها در تویتر به عنوان ویژگی‌های ورودی استفاده می‌کند. آن‌ها همچنین حافظه طولانی کوتاه مدت چند متغیره و چند فرکانسی را پیشنهاد کردند. اطلاعات را از داده‌های سری زمانی استخراج می‌کند. آن‌ها از ۴۳۳۳ روز داده سهام اپل از ۱ ژانویه ۲۰۰۹ تا ۱۱ نوامبر ۲۰۲۰ استفاده کردند. این روش عملکرد پیش‌بینی بالاتری نسبت به زمانی که فقط از توییت‌ها استفاده می‌شد، نشان داد (Aasi et al., 2021). یک مدل ترکیبی مبتنی بر مدل‌های حافظه طولانی کوتاه مدت و واحد بازگشتی گیت دار را پیشنهاد کردند که عملکرد بالایی در داده‌های سری زمانی نشان داد. آن‌ها از ۱۲۷۹ روز داده قیمت لایت‌کوین از ۲۴ آگوست ۲۰۱۶ تا ۲۳ فوریه ۲۰۲۰ و ۱۸۵۱ روز داده مونرو از ۳۰ ژانویه ۲۰۱۵ تا ۲۳ فوریه ۲۰۲۰ استفاده کردند. آن‌ها روشی را برای پیش‌بینی قیمت‌ها با ترکیب قیمت‌های پیش‌بینی شده در دو مدل با استفاده از همان داده‌ها پیشنهاد کردند. این روش عملکرد پیش‌بینی بالاتری نسبت به مدل حافظه طولانی کوتاه مدت موجود نشان داد (Patel et al., 2020). یک مدل ترکیبی مبتنی بر مدل حافظه طولانی کوتاه مدت و مدل خود رگرسیون شرطی هتروسکداستی عمومی را پیشنهاد کردند. مدل برای تحلیل داده‌های سری

زمانی استفاده می شود که تصور می شود خطای واریانس آن به صورت سری خود همبسته است. آن ها از ۶۱۷۹ روز داده قیمت S&P 500 از ۱ ژانویه ۲۰۰۴ تا ۳۰ نوامبر ۲۰۲۰ استفاده کردند. آن ها روشی را برای پیش بینی قیمت ها با ترکیب قیمت های پیش بینی شده در دو مدل با استفاده از همان داده ها پیشنهاد کردند. این روش عملکرد پیش بینی بالاتری نسبت به مدل حافظه طولانی کوتاه مدت موجود نشان داد (Koo & Kim, 2022).

تجزیه فرکانسی

این الگوریتم ها نوسانات داده ها و بزرگی نوسانات را کاهش می دهند، که منجر به عملکرد پیش بینی بالاتر می شود. در یک مقاله پیش پردازش داده های مربوط به قیمت را انجام دادند که با استفاده از الگوریتم تجزیه مد تجزیه نوسانات و نوسان پذیری را کاهش داد. این الگوریتم اطلاعات را از اجزای فرکانس بالا تا پایین داده های نمودار استخراج می کند. آن ها از داده های قیمت بازار سهام چین که در طول پنج سال، از ۲۰۱۵ تا ۲۰۱۹ ثبت شده بود، استفاده کردند. این روش ثابت کرد که افزودن اجزای فرکانسی به ویژگی های ورودی موجود، قیمت های سهام و عملکرد پیش بینی بالاتری را نشان می دهد (Xuan et al., 2020).

پیشنهاد اقدام

روشی برای توصیه اقداماتی است که از افزایش سود پشتیبانی می کنند. با این حال، در مقایسه با مطالعات پیش بینی قیمت، روش های نسبتاً کمی توسعه یافته اند و عملکرد توصیه آن ها پایین است. با مدل های پیشنهاد اقدام برای دو کلاس، از جمله "فروش" و "خرید" آزمایش کردند. آن ها با چهار مدل، از جمله حافظه طولانی کوتاه مدت، یک پرسپترون چند لایه، یک جنگل تصادفی و یک مدل شبه تصادفی آزمایش کردند. آن ها از داده های سهام برزیل از ۲۰۰۸ تا ۲۰۱۵ استفاده کردند. در این آزمایش، آن ها نشان دادند که حافظه طولانی کوتاه مدت بالاترین عملکرد توصیه و دقت متوسط ۰/۵۵۹۰ را نشان داد (Nelson et al., 2017). با مدل های پیشنهاد اقدام برای دو کلاس، از جمله "فروش" و "خرید" آزمایش کردند. آن ها با هفت مدل، از جمله حافظه کوتاه بلند مدت، جنگل تصادفی، پرسپترون چند لایه، ماشین بردار پشتیبان، رگرسیون لجستیک، درخت تصمیم و K-نزدیکترین همسایه آزمایش کردند. آن ها از داده های سهام تایلند از ۲۰۱۵ تا ۲۰۱۷ استفاده کردند. آن ها همچنین از داده های بازار به استثنای حجم معاملات به عنوان ویژگی های ورودی استفاده کردند. آن ها نشان دادند که حافظه کوتاه بلند مدت در مقایسه با سایر مدل ها، بالاترین عملکرد را نشان داد (Sanboon et al., 2019).

روش

مطالعات بسیار کمی استفاده از مدل های یادگیری عمیق را برای توصیه این اقدامات بررسی کرده اند و عملکرد چنین مدل هایی همچنان پایین است. در این مقاله، ما ویژگی های ورودی جدید و یک مدل یادگیری عمیق برای حل این مشکلات پیشنهاد می کنیم. خروجی روش پیشنهادی ما بر اساس داده های قیمت ارز دیجیتال محاسبه می شود. ابتدا، ما ویژگی های ورودی جدید مانند سود فروش، سود خرید و حداکثر سود را از طریق داده های جمع آوری شده و معادله پیشنهادی برای آموزش مدل یادگیری عمیق محاسبه می کنیم.

گروه های طبقه بندی محدود به متداول ترین توابع هستند: "فروش"، "خرید" و "انتظار". ما گروه ها را بر اساس سود فروش، سود خرید و حداکثر سود محاسبه شده و معیارهای پیشنهادی خود طبقه بندی می کنیم. این کلاس ها سپس به خروجی نهایی در مدل یادگیری عمیق تبدیل می شوند. سپس، مدل یادگیری عمیق را از طریق داده های جمع آوری شده، ویژگی های ورودی پیشنهادی و کلاس های پیشنهادی آموزش و آزمایش کردیم.

تعریف ویژگی

در این بخش، سه ویژگی ورودی پیشنهادی را شرح می دهیم: سود فروش، سود خرید و حداکثر سود. برای درک آسان، آن ها را بر اساس نمودارهای قیمت، معادلات و قیمت های واقعی شرح داده ایم.

سود فروش

سود فروش، سود قابل دستیابی هنگام فروش مقدار مشخصی از ارز دیجیتال را نشان می دهد. طبق مطالعه ای، مشتریانی که سهام را معامله می کنند، تمایل دارند اگر قیمت پیش بینی شود در درازمدت همچنان کاهش خواهد یافت، سهام خود را بفروشند (Ji et al., 2008). بر اساس نتایج این مطالعه، ما معادله (۱) را پیشنهاد می کنیم. نتیجه این معادله به عنوان سود فروش تعریف می شود.

معادله (۱): محاسبه سود فروش

فرض می کنیم مشتری امروز M واحد ارز دیجیتال را می فروشد، زمانی که قیمت فردا نسبت به امروز کاهش می یابد. زیرا ما زمانی می فروشیم که قیمت بالا است، سیستم با ضرب اختلاف قیمت در M واحد ارز دیجیتال فروخته شده، سود می کند.

سود خرید

ویژگی سود فروش به عنوان سودی که هنگام خرید مقدار مشخصی از ارز دیجیتال قابل دستیابی است، تعریف می شود. طبق مطالعه ای، مشتریانی که سهام را معامله می کردند، تمایل داشتند سهام خود را بفروشند اگر پیش بینی می شد که قیمت در درازمدت همچنان افزایش خواهد یافت. بر اساس نتایج این مطالعه، ما معادله (۲) را ارائه می کنیم. نتیجه این معادله به عنوان سود خرید تعریف می شود.

معادله (۲): محاسبه سود خرید

فرض می کنیم N واحد ارز دیجیتال را خریداری کنیم، زمانی که قیمت فردا نسبت به امروز افزایش می یابد. زیرا ما واحدهای ارز دیجیتال را زمانی خریداری می کنیم که قیمت پایین است، ما با ضرب اختلاف قیمت در N مقدار ارز دیجیتال خریداری شده، سود می کنیم.

حداکثر سود

ویژگی حداکثر سود نشان دهنده حداکثر سودی است که می تواند بین سود فروش و سود خرید به دست آید. مشتریانی که سهام را معامله می کنند، تمایل دارند پس از مقایسه سودهای کسب شده هنگام خرید سهام با سودهای کسب شده از فروش، اقدامات خاصی انجام دهند. اگر سود فروش بزرگتر از سود خرید باشد، حداکثر سود همان مقدار سود فروش را اختصاص داده می شود.

تعریف کلاس


از سه کلاس برای انجام طبقه بندی استفاده می شود، از جمله "فروش"، "خرید" و "انتظار". کلاس ها بر اساس سود فروش، سود خرید و حداکثر سود تعریف شده اند. در مورد کلاس "انتظار"، برخی از مشتریان زمانی عمل می کنند که بتوانند بیش از یک آستانه سود مشخص کسب کنند، و اگر نه، می توانند یک روز دیگر صبر کنند.

یافته‌ها

طراحی آزمایشی شامل سه زیربخش است: "جمع‌آوری داده‌ها"، "معماری مدل" و "ارزیابی". ابتدا، در بخش "جمع‌آوری داده‌ها"، ما یک شرح مختصر از داده‌های جمع‌آوری شده برای آزمایش را ارائه می‌دهیم. سپس، در بخش "معماری مدل"، ما ویژگی‌های ورودی، یک مدل یادگیری عمیق مبتنی بر Tensorflow 2.0، هایپارامترها و خروجی نهایی استفاده شده در آزمایش را شرح می‌دهیم. در نهایت، در بخش "ارزیابی"، ما معیارهای ارزیابی استفاده شده در آزمایش را با معادلات و مثال‌ها شرح می‌دهیم.


جمع‌آوری داده‌ها

رمز ارزهای مورد بررسی در این مطالعه عمدتاً شامل بیت کوین و اتریوم هستند. علاوه بر این، بر اساس داده‌های موجود از ژانویه ۲۰۱۸، با افزایش محبوبیت ارزهای دیجیتال، ما مجموعاً شش ارز دیجیتال دیگر را نیز در نظر گرفتیم، از جمله کاردانو، دش، لایت کوین و مونرو که از نظر امنیت، مقیاس‌پذیری و سرعت دارای مزیت‌هایی هستند. همچنین، ویژگی‌های ورودی استفاده شده در آزمایش شامل میانگین قیمت (P)، قیمت اولیه (O)، بالاترین قیمت (H)، پایین‌ترین قیمت (L) و حجم معاملات (V) بود. بنابراین، ۱۳۳۹ روز داده از ۱ ژانویه ۲۰۱۸ تا ۳۱ آگوست ۲۰۲۱ استفاده شد؛ همه ارزهای دیجیتال استفاده شده در آزمایش پس از یک تاریخ خاص افزایش نوسان را نشان دادند. برای ارزیابی عملکرد توصیه در این مورد، ۷۰٪ از داده‌ها (۹۳۷ روز) برای انجام آموزش و ۳۰٪ باقی مانده (۴۰۲ روز) به عنوان داده‌های آزمایشی استفاده شد. سمت چپ داده‌های آموزشی را نشان می‌دهد و سمت راست داده‌های آزمایشی را بر اساس خط عمودی قرمز نشان می‌دهد.



معماری مدل

یک مدل یادگیری عمیق مبتنی بر Tensorflow با پایتون و ژوپیتِر نوت بوک برای پیاده سازی رویکرد پیشنهادی استفاده کردیم. برای تأیید نتایج آزمایشی، آزمایش با استفاده از همان مدل یادگیری عمیق انجام شد. معماری مدل نشان داده شده است. در مورد هایپر پارامترها، مقدار به گونه ای تنظیم شد که عملکرد بهینه را با مصرف حداقل زمان نشان دهد. مقادیر دقیق را می توان در جدول ۱ یافت (Hutter et al., 2014).



جدول ۱

مقادیر هایپر پارامترهای مورد استفاده در مدل یادگیری عمیق

هایپر پارامتر	لایه حافظه طولانی کوتاه مدت	لایه متراکم
تعداد واحد	۴۸	3
تابع فعالساز	ReLU	softmax
بهینه ساز	Adam	Adam
تابع خسارت	Categorical-crossentropy	Categorical-crossentropy
نرخ یادگیری	0/001	0/001
اندازه دسته	64	64
دوره	100	100

ارزیابی

در این بخش، معیارهای ارزیابی استفاده شده در آزمایش را شرح می دهیم. از آنجایی که مدل مورد استفاده در آزمایش یک مدل توصیه بود، دقت و امتیاز F1 به عنوان دو ارزیابی مناسب استفاده شدند (Rezaei et al., 2021). یک ارزیابی منظم تر با استفاده از دقت، امتیاز F1 انجام شده است.

دقت

دقت را می توان همانطور که در معادله (۳) نشان داده شده است، محاسبه کرد. این معادله یک مقدار محاسبه شده با تقسیم تعداد نمونه های دقیقاً پیش بینی شده بر تعداد کل نمونه ها است و دقت پیش بینی کلی را نشان می دهد. دارای مقداری بین ۰ و ۱ است. این نشان دهنده عملکرد پیش بینی بالاتر با افزایش مقدار است (Zhu et al., 2010).

$$\text{دقت} = \frac{TP + TN}{TP + TN + FP + FN}$$

معادله (۳): محاسبه دقت

صحت

صحت را می توان همانطور که در معادله (۴) نشان داده شده است، محاسبه کرد. این معادله نسبت زمانی را نشان می دهد که مقدار واقعی نیز یک کلاس "مثبت" است، زمانی که مدل پیش بینی کننده پیش بینی می شود که یک کلاس "مثبت" باشد. این همان مقدار دقت بین ۰ و ۱ را می گیرد. این به معنای عملکرد پیش بینی بالاتر با افزایش مقدار است (Park et al., 2020).

$$\text{صحت} = \frac{TP}{TP + FP}$$

معادله (۴): محاسبه صحت

فراخوانی

فراخوانی را می توان همانطور که در رابطه (۵) نشان داده شده است محاسبه کرد. این معادله نسبتی را نشان می دهد که در آن مقدار پیش بینی شده نیز یک کلاس مثبت است زمانی که مقدار واقعی یک کلاس مثبت داده می شود. این همان محدوده از مقادیر را به عنوان دقت، بین ۰ و ۱ می گیرد. این نشان دهنده عملکرد پیش بینی بالاتر با افزایش مقدار است.

$$\text{فراخوانی} = \frac{TP}{TP + FN}$$

معادله (۵): محاسبه فراخوانی

امتیاز F1

امتیاز F1 را می توان همانطور که در رابطه (۶) نشان داده شده محاسبه کرد. صحت و فراخوانی می تواند به طور موثر در هنگام عدم تعادل توزیع کلاس استفاده شود. امتیاز F1 معادله ای است که هم دقت و هم فراخوانی را در نظر می گیرد. این مقدار برابر با دقت بین ۰ و ۱ است. این به معنای عملکرد پیش بینی بالاتر با افزایش مقدار است. به طور کلی، زمانی که هم دقت و هم فراخوانی بالا بود، امتیاز F1 نیز بالا بود (Huang et al., 2015).

$$\text{امتیاز F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

معادله (۶): محاسبه امتیاز F1

نتایج تجربی

برای تأیید مدل پیشنهادی، ۴۰۲ روز داده از ۲۵ ژوئیه ۲۰۲۰ تا ۳۱ آگوست ۲۰۲۱، که تاریخ افزایش نوسان و نوسان قیمت در میان ۱۳۳۹ روز داده از ۱ ژانویه ۲۰۱۸ تا ۳۱ آگوست ۲۰۲۱ است، به عنوان داده های آزمایشی استفاده شد. ما "مثبت" را به عنوان کلاس "انتظار" و "منفی" را به عنوان کلاس "فروش" و "خرید" تنظیم کردیم. هنگامی که کلاس واقعی و کلاس توصیه شده یکسان بودند و کلاس "انتظار" بود، نتیجه TP بود. برعکس، هنگامی که کلاس واقعی و کلاس توصیه شده یکسان بودند و کلاس "فروش" یا "خرید" بود، نتیجه TN در نظر گرفته شد. هنگامی که کلاس واقعی و کلاس توصیه شده متفاوت بودند و کلاس "انتظار" بود، نتیجه FP در نظر گرفته شد. برعکس، هنگامی که کلاس واقعی و کلاس توصیه شده متفاوت بودند و کلاس "فروش" یا "خرید" بود، نتیجه FN شد. جدول ۲ دقت

و امتیاز F1 مدل‌های موجود و پیشنهادی را برای هر ارز دیجیتال نشان می‌دهد. در مقایسه با مدل‌های موجود، می‌توان مشاهده کرد که هم دقت و هم امتیاز F1 از حدود ۱۳٪ تا ۲۱٪ بهبود یافته است.

جدول ۲

مقدار دقت و امتیاز F1 برای هر ارز دیجیتال

رمز ارز	روش پیشنهادی					
	سنبون و همکارا			نلسون و همکارا		
	امتیاز F1	دقت	امتیاز F1	دقت	امتیاز F1	دقت
بیت کوین	۰/۸۵۸۱	۰/۸۶۰۶	۰/۶۶۹۱	۰/۶۸۶۵	۰/۷۰۱۳	۰/۷۰۹۰
کاردانو	۰/۸۲۸۵	۰/۸۳۳۳	۰/۶۶۰۶	۰/۶۷۱۶	۰/۷۰۰۷	۰/۷۱۱۴
دش	۰/۸۲۸۶	۰/۸۴۸۲	۰/۶۷۸۷	۰/۶۹۱۵	۰/۷۲۲۸	۰/۷۲۸۸
اتریوم	۰/۷۳۷۱	۰/۷۸۶۰	۰/۶۲۳۳	۰/۶۶۶۷	۰/۶۴۰۵	۰/۶۹۱۵
لایت کوین	۰/۸۳۴۸	۰/۸۴۳۳	۰/۶۹۷۰	۰/۷۱۳۹	۰/۷۱۹۹	۰/۷۳۶۳
مونرو	۰/۸۴۰۴	۰/۸۵۳۲	۰/۶۷۸۵	۰/۷۰۶۵	۰/۷۲۶۷	۰/۷۳۳۸

برای همه ارزشهای دیجیتال، سطر اول به دقت برای کلاس "انتظار"، سطر دوم به دقت برای کلاس "فروش" و سطر سوم به دقت برای کلاس "خرید" اشاره دارد. ممکن است مشاهده شود که دقت برای کلاس "انتظار" در همه ارزشهای دیجیتال بالا بوده است و دقت برای دو مورد دیگر پایین بوده است. به ویژه، اتریوم عملکرد پایین تری نسبت به سایر ارزشهای دیجیتال نشان داد. ما توزیع کلاس را برای هر ارز دیجیتال تأیید کردیم تا دلایل این نتیجه را شناسایی کنیم و نتیجه در جدول ۳ نشان داده شده است.

جدول ۳

توزیع کلاس برای هر ارز دیجیتال

کلاس	رمز ارز					
	مونرو	لایت کوین	اتریوم	دش	کاردانو	بیت کوین
انتظار	۶۸۵	۶۷۳	۸۲۲	۶۷۰	۶۴۸	۶۳۶
فروش	۲۴۸	۲۷۵	۱۹۴	۲۷۵	۲۸۵	۳۰۷
خرید	۴۰۶	۳۹۱	۳۲۳	۳۹۴	۴۰۶	۳۹۶

جدول ۳ توزیع کلاس هر ارز دیجیتال را ارائه می‌دهد. نشان می‌دهد که کدام ارز دیجیتال دارای بیشترین تعداد کلاس‌های خاص است. و هم‌چنین نشان می‌دهد که کدام ارز دیجیتال دارای کمترین تعداد کلاس‌های خاص است. اول از همه، ممکن است مشاهده شود که همه ارزهای دیجیتال دارای بسیاری از کلاس‌ها به ترتیب "انتظار" - "خرید" - "فروش" هستند. ممکن است یک پدیده مشاهده شود که در آن دقت برای هر کلاس نیز دارای یک مقدار بالاتر یا مقدار به ترتیب "انتظار" - "خرید" - "فروش" است. علاوه بر این، در مورد اتریوم، ممکن است مشاهده شود که دقت برای کلاس‌های "خرید" و "فروش" پایین‌تر از سایر ارزهای دیجیتال بوده است. با حذف اتریوم، پنج ارز دیجیتال بین ۶۰۰ و ۷۰۰ نمونه "انتظار" از ۱۳۳۹ داده نشان دادند. با این حال، اتریوم بیش از ۸۰۰ کلاس "انتظار" داشت. بنابراین، تعداد نمونه‌های یادگیری کلاس‌های "خرید" و "فروش" کاهش یافت، که باعث عملکرد پایین مدل برای این کلاس‌ها شد. انتظار می‌رود که این مشکل حل شود اگر نسبت مساوی بین کلاس‌ها ایجاد شود، مانند افزایش مقدار داده‌های یادگیری.

جدول ۴ تعداد واقعی نتایج پیش‌بینی دقیق برای هر ارز دیجیتال را نشان می‌دهد. روش موجود (Nelson et al., 2017) بین ۲۷۸ تا ۲۹۶ مورد از مجموع ۴۰۲ داده را به درستی پیش‌بینی کرد و روش موجود (Sanboon et al., 2019) بین ۲۶۸ تا ۲۸۷ مورد از مجموع ۴۰۲ داده را به درستی پیش‌بینی کرد. روش پیشنهادی به طور کلی عملکرد پیش‌بینی بالاتری را نشان داد. روش پیشنهادی بین ۳۱۶ تا ۳۴۶ مورد از مجموع ۴۰۲ داده را به درستی پیش‌بینی کرد.

جدول ۴

تعداد واقعی نتایج پیش‌بینی دقیق برای هر ارز دیجیتال

روش پیشنهادی	سنبون و همکارا	نلسون و همکارا	رمز ارز
۳۴۶	۲۷۶	۲۸۵	بیت کوین
۳۳۵	۲۷۰	۲۸۶	کاردانو
۳۴۱	۲۷۸	۲۹۳	دش
۳۱۶	۲۶۸	۲۷۸	اتریوم
۳۳۹	۲۷۸	۲۹۶	لایت کوین
۳۴۳	۲۸۴	۲۹۵	مونرو

نتیجه گیری

در این مطالعه، یک مدل مبتنی بر یادگیری عمیق را پیشنهاد کردیم که برای توصیه اقداماتی طراحی شده است تا از حداکثر سود کوتاه مدت مشتریان ارز دیجیتال که تقریباً به روش معامله گران روزمره سنتی عمل می کنند، پشتیبانی کند. ما داده هایی را در مورد مجموعاً شش ارز دیجیتال نماینده جمع آوری دقت و امتیاز F1 به عنوان معیارهای ارزیابی برای آزمایش و تأیید عینی استفاده شدند. در مقایسه با روش های موجود که فقط از مدل حافظه طولانی کوتاه مدت استفاده می کردند، دقت و امتیاز F1 مدل پیشنهادی حدود ۱۳٪ تا ۲۱٪ افزایش یافت. در میان ارزهای دیجیتال استفاده شده در آزمایش، اتریوم عملکرد پایین تری را از نظر امتیاز F1 نسبت به پنج ارز دیجیتال دیگر نشان داد زیرا فرصت کمتری برای یادگیری کلاس های "فروش" و "خرید" وجود داشت و نتایج تحلیل نشان داد که این مشکل باعث عملکرد پایین این کلاس ها شد.

اگرچه روش پیشنهادی عملکرد بالاتری نسبت به روش موجود نشان داد، اما فقط بر حداکثر سودی که می توانست در یک روز واحد کسب شود، تمرکز داشت با این حال، دقت پیش بینی فاصله ای بسیار پایین است و اکثر مطالعات در مورد پیش بینی فاصله ای بسیار ناکافی باقی می ماند. به عنوان مثال، اکثر روش های موجود فقط قیمت را برای روز بعد پیش بینی می کنند (Lops et al., 2020). بنابراین، ما قصد داریم مطالعه ای را برای بهبود عملکرد روش های پیش بینی فاصله ای انجام دهیم که قیمت ها را در آینده دورتر، مانند سه یا هفت روز یا یک ماه، پیش بینی می کنند.

منابع

- Aasi, B., Imtiaz, S. A., Qadeer, H. A., Singarajah, M., & Kashef, R. (2021). Stock price prediction using a multivariate multistep LSTM: a sentiment and public engagement analysis model. 2021 IEEE International IOT, Electronics and Mechatronics Conference) IEMTRONICS , (Dowling, M. (2022). Is non-fungible token pricing driven by cryptocurrencies? *Finance Research Letters*, 44, 102097 .
- Eyal, I. (2017). Blockchain Technology: Transforming Libertarian Cryptocurrency Dreams to Finance and Banking Realities. *Computer*, 50(9), 38-49. <https://doi.org/10.1109/MC.2017.3571042>
- Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, 129, 273-285 .
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. *Applied System Innovation*, 4(1), 9 .
- Huang, H., Xu, H., Wang, X., & Silamu, W. (2015). Maximum F1-score discriminative training criterion for automatic mispronunciation detection. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 23(4), 787-797 .
- Hutter, F., Hoos, H., & Leyton-Brown, K. (2014). An efficient approach for assessing hyperparameter importance. *International conference on machine learning* ,
- Ji, L. J., Zhang, Z., & Guo, T. (2008). To buy or to sell: Cultural differences in stock market decisions based on price trends. *Journal of Behavioral Decision Making*, 21(4), 399-413 .
- Khedr, A. M., Arif, I., El-Bannany, M., Alhashmi, S. M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 3-34 .
- Koo, E., & Kim, G. (2022). A hybrid prediction model integrating garch models with a distribution manipulation strategy based on lstm networks for stock market volatility. *IEEE Access*, 10, 34743-34754 .
- Livieris, I. E., Kiriakidou, N., Stavroyiannis, S., & Pintelas, P. (2021). An advanced CNN-LSTM model for cryptocurrency forecasting. *Electronics*, 10(3), 287 .

- Lops, Y., Choi, Y., Eslami, E., & Sayeed, A. (2020). Real-time 7-day forecast of pollen counts using a deep convolutional neural network. *Neural Computing and Applications*, 32, 11827-11836 .
- Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., Selim, M. M., & Muhammad, K. (2020). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*, 50, 432-451 .
- Marke, A. (2018). *(Transforming climate finance and green investment with blockchains*. Academic Press .
- Nelson, D. M., Pereira, A. C., & De Oliveira, R. A. (2017). Stock market's price movement prediction with LSTM neural networks. 2017 International joint conference on neural networks (IJCNN) ,
- Park, S.-W., Huh, J.-H., & Kim, J.-C. (2020). BEGAN v3: avoiding mode collapse in GANs using variational inference. *Electronics*, 9(4), 688 .
- Patel, M. M., Tanwar, S., Gupta, R., & Kumar, N. (2020). A deep learning-based cryptocurrency price prediction scheme for financial institutions. *Journal of information security and applications*, 55, 102583 .
- Rezaei, H., Faaljou, H., & Mansourfar, G. (2021). Stock price prediction using deep learning and frequency decomposition. *Expert Systems with Applications*, 169, 114332 .
- Salimitari, M., Chatterjee, M., Yuksel, M., & Pasiliao, E. (2017). Profit maximization for bitcoin pool mining: A prospect theoretic approach. 2017 IEEE 3rd international conference on collaboration and internet computing (CIC) ,
- Sanboon, T., Keatruangkamala, K., & Jaiyen, S. (2019). A deep learning model for predicting buy and sell recommendations in stock exchange of thailand using long short-term memory. 2019 IEEE 4th International Conference on Computer and Communication Systems (ICCCS) ,
- Valencia, F., Gómez-Espinosa, A., & Valdés-Aguirre, B. (2019). Price movement prediction of cryptocurrencies using sentiment analysis and machine learning. *entropy*, 21(6), 589 .
- Vranken, H. (2017). Sustainability of bitcoin and blockchains. *Current opinion in environmental sustainability*, 28, 1-9 .
- Xuan, Y., Yu, Y., & Wu, K. (2020). Prediction of short-term stock prices based on EMD-LSTM-CSI neural network method. 2020 5th IEEE international conference on big data analytics (ICBDA) ,(
- Zhu, W., Zeng, N., & Wang, N. (2010). Sensitivity, specificity, accuracy, associated confidence interval and ROC analysis with practical SAS implementations. *NESUG proceedings: health care and life sciences, Baltimore, Maryland*, 19, 67 .