



پژوهش‌های نوین در تصمیم‌گیری

دوره ۱۱، شماره ۱، فصل بهار، صص ۱۶۷-۱۴۷

نوع مقاله: پژوهشی

پیش‌بینی جهت حرکت قیمت بیت‌کوین پس از بیش‌واکنش

سرمایه‌گذاران با بهره‌گیری از مدل یادگیری عمیق

چندمتغیره

مرجان سادات فاطمی قمی^۱، عباس سقایی^{۲*}، مجید میرزایی قزآنی^۳

۱. دانشجوی دکتری، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۲. استاد، گروه مهندسی صنایع، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

۳. دانشیار، گروه مهندسی مالی، دانشکده مهندسی صنایع، دانشگاه صنعتی خواجه نصیر، تهران، ایران

تاریخ پذیرش: ۱۴۰۴/۱۲/۰۷

تاریخ بازنگری: ۱۴۰۴/۱۲/۰۱

تاریخ دریافت: ۱۴۰۴/۱۰/۱۵

چکیده

این پژوهش با هدف پیش‌بینی جهت حرکت قیمت بیت‌کوین پس از وقوع پدیده «بیش‌واکنش سرمایه‌گذاران» انجام شده است؛ پدیده‌ای که در ادبیات مالی رفتاری به‌عنوان یک ناهنجاری کلیدی شناخته می‌شود. با بهره‌گیری از رویکرد داده‌های چندوجهی، مجموعه‌ای از اطلاعات معاملاتی، شاخص‌های فنی، داده‌های درون‌زنجیره‌ای و شاخص‌های اجتماعی طی بازه اوت ۲۰۱۷ تا دسامبر ۲۰۲۳ تحلیل شد. پس از شناسایی ۳۰۳ روز بیش‌واکنش، فرآیند انتخاب ۱۱ ویژگی کلیدی از میان ۱۵۸ متغیر طی یک رویکرد سه‌مرحله‌ای شامل الگوریتم جنگل تصادفی، بررسی ماتریس همبستگی و محاسبه شاخص تورم واریانس (VIF) انجام شد تا ضمن اطمینان از نبود هم‌خطی چندگانه، مجموعه‌ای بهینه و معتبر برای ورود به مدل فراهم گردد. مدل پیشنهادی مبتنی بر شبکه عصبی حافظه بلند-کوتاه‌مدت (LSTM) چندمتغیره، با دقت ۶۷٪ جهت حرکت قیمت را پیش‌بینی کرد که به‌طور معناداری بالاتر از دقت مدل رگرسیون لجستیک (۵۳.۴٪) است. همچنین، روند کاهشی و باثبات تابع زیان آموزشی و آزمایشی، عدم بروز بیش‌برازش و توانایی مدل در یادگیری الگوهای واقعی را اثبات نمود. یافته‌ها حاکی از وجود ناکارایی‌های کوتاه‌مدت در بازار بیت‌کوین و قابلیت پیش‌بینی بازده‌های غیرعادی پس از بیش‌واکنش (در سطح اطمینان ۹۹٪) است. این چارچوب می‌تواند در طراحی استراتژی‌های معاملاتی و مدیریت ریسک هوشمند در بازارهای رمزارز به‌کار گرفته شود.

کلیدواژه‌ها: بازار بیت‌کوین، بیش‌واکنش سرمایه‌گذاران، پیش‌بینی قیمت، داده‌های چندوجهی، یادگیری عمیق.



۱- مقدمه و بیان مسئله

تحلیل پویایی بازارهای مالی همواره کانون توجه پژوهش‌های اقتصادی بوده است. فرضیه بازار کارای فاما (۱۹۶۵) مبنی بر انعکاس آنی اطلاعات در قیمت‌ها، مبنای نظری بسیاری از این مطالعات است؛ با این حال، شواهد تجربی متعدد با شناسایی «ناهنجاری‌های مالی» نظیر الگوهای تقویمی، حرکت تداومی و رفتارهای واکنشی معامله‌گران (بیش‌واکنش و کم‌واکنش)، کارایی کوتاه‌مدت بازارها را به چالش کشیده‌اند [۱]، [۲]. در این میان، ناهنجاری «بیش‌واکنش»^۱ که با انحراف شدید قیمت از ارزش ذاتی و بازگشت تدریجی آن به سطح تعادلی تعریف می‌شود [۳]، در بازارهای سنتی به اثبات رسیده است [۴]، [۵]. با ظهور بازار ارزهای دیجیتال و ویژگی‌های متمایز آن از جمله نوسان‌پذیری و عدم قطعیت بالا [۶]، [۷]، بررسی رفتارهای نابهنجار در این بازار نوظهور اهمیت دوچندانی یافته است [۸]. شواهد اولیه از وقوع شدید پدیده بیش‌واکنش در بازار رمزارزها، به‌ویژه بیت‌کوین خبر می‌دهند، اما ادبیات پژوهش در این حوزه همچنان محدود است. پژوهش حاضر با هدف پیش‌بینی جهت حرکت قیمت بیت‌کوین در روز پس از وقوع بیش‌واکنش طراحی شده است. گزینش بیت‌کوین به دلیل حجم معاملات بالا، نقدینگی، حساسیت رفتاری و وجود داده‌های تاریخی متقن صورت گرفته است. برخلاف رویکردهای آماری و تک‌متغیره سنتی، این مطالعه با اتکا به قابلیت‌های یادگیری عمیق چندمتغیره و به‌طور خاص شبکه عصبی حافظه بلند-کوتاه‌مدت (LSTM)، به دنبال تحلیل هم‌زمان عوامل فنی، رفتاری و ساختاری بازار است. مدل پیشنهادی بر پایه یک فضای ویژگی چندوجهی در چهار دسته کلیدی طراحی شده است: نخست، داده‌های تاریخی^۲ (شامل متغیرهای قیمتی، حجم و بازده‌های روزانه و درون‌روزی) که نمایانگر روند گذشته و احساسات بازار هستند [۹]؛ دوم، شاخص‌های فنی^۳ نظیر سطوح حمایت و مقاومت که نقش محوری در شناسایی نقاط بازگشت قیمت ایفا می‌کنند [۱۰]، [۱۱]؛ سوم، معیارهای درون‌زنجیره‌ای^۴ (مانند تعداد و ارزش تراکنش‌ها) که منعکس‌کننده فعالیت شبکه و مشارکت کاربران هستند [۱۰]؛ و چهارم،

^۱ Overreaction

^۲ Historical data

^۳ Technical indicator

^۴ On-chain metrics



شاخص‌های اجتماعی^۱ (برگرفته از گوگل‌تندز) که به‌عنوان سنج‌های برای پایش توجه عمومی و پیش‌بینی روندهای آتی به‌کار می‌روند [۱۲]. ماهیت غیرخطی و وابسته‌به‌زمان بازار رمزارزها استفاده از LSTM را که توانایی استخراج وابستگی‌های زمانی و الگوهای غیرخطی را دارد توجیه‌پذیر می‌سازد [۱۳]، در حالی‌که مدل‌های سنتی ممکن است در مواجهه با این پیچیدگی‌ها با محدودیت همراه باشند [۱۴]، [۱۵]. بر این اساس، مسئله اصلی پژوهش، پیش‌بینی جهت حرکت قیمت بیت‌کوین در روز پس از وقوع بیش‌واکنش با استفاده از داده‌های چندمنبعی و مدل LSTM است. نوآوری اصلی این پژوهش در توسعه یک چارچوب پیش‌بینی چندمنبعی مبتنی بر یادگیری عمیق برای مسئله‌ای رفتاری و زمان‌مند، یعنی پیش‌بینی جهت حرکت قیمت بیت‌کوین در روز پس از وقوع بیش‌واکنش، نهفته است. نوآوری مطالعه نه صرفاً در ترکیب ویژگی‌های مختلف و نه فقط در به‌کارگیری مدل LSTM است، بلکه در هم‌افزایی این دو مؤلفه در قالب یک چارچوب یکپارچه قرار دارد؛ چارچوبی که در آن، فضای ویژگی چندوجهی برای توصیف جامع وضعیت بازار در حوالی رویدادهای بیش‌واکنش طراحی می‌شود و سپس مدل LSTM برای استخراج وابستگی‌های زمانی و الگوهای غیرخطی مؤثر بر جهت حرکت قیمت به‌کار گرفته می‌شود. این مقاله در پنج بخش سازماندهی شده است: مقدمه، مبانی نظری و پیشینه پژوهش، روش‌شناسی، یافته‌های تجربی و نتیجه‌گیری.

۲- مبانی نظری و پیشینه پژوهش

پدیده بیش‌واکنش به‌مثابه انحراف قیمت از ارزش ذاتی در پاسخ به جریان اطلاعاتی، فرضیه بازار کارا را به چالش کشیده و ریشه در سوگیری‌های شناختی و رفتاری معامله‌گران دارد [۳]، [۴]. در بازار رمزارزها، فقدان نظارت نهادی در کنار حساسیت شدید به اخبار محیطی و سیگنال‌های چهره‌های تأثیرگذار، بستری مساعد برای تشدید و تکرار این نوسانات فراهم آورده است [۸]. کاپوراله و پلاستون^۲ (۲۰۱۹) نشان دادند که بازده روز بعد از بیش‌واکنش در چهار رمزارز اصلی به‌طور معناداری افزایش می‌یابد، هرچند این امر به یک استراتژی سودآور منجر نشد [۲]. در پژوهشی دیگر، کاپوراله و همکاران^۳ (۲۰۲۰) الگوهای تکرارشونده و قابل

^۱. Social sentiment Index

^۲. Caporale & Plastun

^۳. Caporale & Plastun



پیش‌بینی پس از بیش‌واکنش را در بیت‌کوین شناسایی کردند که ناقض کارایی بازار است [۱۶]. یافته‌های چوایاتراکول و ماسیا^۱ (۲۰۱۹) نیز وقوع بیش‌واکنش بیت‌کوین در دوره‌های ریزش شدید و رشد هفتگی را تأیید می‌کند [۱۷]. به‌طور مشابه، بورگاردز و چوداج^۲ (۲۰۲۰) نشان دادند که این پدیده در ۱۲ رمزارز مختلف رایج است [۵]. نتایج کوربت و کاتسیامپا^۳ (۲۰۲۰) حاکی از آن است که بازده‌های منفی پس از بیش‌واکنش، اصلاحات شدیدتر و سریع‌تری نسبت به بازده‌های مثبت دارند [۱۸]. پژوهش‌های دیگری از جمله مطالعات گیل‌آلانا آیکینز و رومرو^۴ (۲۰۲۰) و مارتینس^۵ (۲۰۲۰) نشان داده‌اند که الگوهای بیش‌واکنش در رمزارزهای مختلف مشابه نیست [۱۹]، [۲۰]. همچنین کلنر و مالتترینز^۶ (۲۰۲۱) بیان کردند که شدت بیش‌واکنش با ناکارایی کوتاه‌مدت بازار رابطه‌ای مستقیم دارد [۲۱]. در ادامه، شاب^۷ (۲۰۲۲) نشان داد که بیت‌کوین و اتریوم پس از بیش‌واکنش‌های منفی دارای حرکت برگشتی معنادار هستند [۲۲]. در نهایت، دیاس، چامبینو و دیاس، چامبینو و پالما^۸ (۲۰۲۳) با آزمون‌های ناپارامتریک، الگوهای همبستگی خودکار مثبت و منفی در بیش‌واکنش بازار رمزارزها را شناسایی کردند که می‌تواند نقش کاهنده در نوسان داشته باشد [۲۳]. مرور ادبیات نشان می‌دهد که علی‌رغم تأیید وقوع بیش‌واکنش در بازار رمزارزها، مطالعات پیشین عمدتاً بر توصیف این ناهنجاری متمرکز بوده‌اند و پیش‌بینی جهت قیمت پس از آن، به‌ویژه با رویکردهای چندمتغیره و یادگیری عمیق، کمتر مورد توجه قرار گرفته است؛ به‌طوری‌که تلاش‌های اولیه مانند مطالعه کاپوراله و پلاستون^۹ (۲۰۱۹) به دقتی در سطح تصادفی محدود مانده است [۲]. پژوهش حاضر با هدف پوشش این خلأ نظری و تجربی، یک چارچوب چندمتغیره مبتنی بر شبکه عصبی LSTM برای پیش‌بینی جهت حرکت قیمت بیت‌کوین پس از بیش‌واکنش توسعه می‌دهد. این رویکرد علاوه بر بهینه‌سازی عملیاتی تصمیمات معاملاتی در بازارهای پرنوسان، به توسعه مبانی نظری

^۱ Chevepatrakul & Mascia

^۲ Borgards & Czudaj

^۳ Corbet & Katsiampa

^۴ Gil-Alana, Aikins & Romero

^۵ Martins

^۶ Kellner & Maltritz

^۷ Schaub

^۸ Dias, Chambino & Palma

^۹ Caporale & Plastun



ناهنجاری‌های رفتاری در دارایی‌های دیجیتال کمک می‌کند. در این راستا، فرضیه‌های زیر مطرح می‌شوند: فرضیه ۱: وقوع بیش‌واکنش با شکل‌گیری نوسانات و بازده‌های غیرعادی در روز معاملاتی بعد همراه است. فرضیه ۲: مدل چندمتغیره مبتنی بر یادگیری عمیق LSTM دقت پیش‌بینی جهت حرکت قیمت پس از بیش‌واکنش را در مقایسه با مدل‌های سنتی به‌طور معناداری افزایش می‌دهد.

۳- روش‌شناسی پژوهش

۳-۱- داده‌ها و منابع استخراج

این پژوهش از داده‌های قیمتی (OHLC) جفت ارز BTC/USDT استخراج‌شده از رابط برنامه‌نویسی کاربردی^۱ صرافی بایننس^۲ در بازه زمانی آگوست ۲۰۱۷ تا دسامبر ۲۰۲۳ استفاده می‌کند. با اتکا به همبستگی بالای قیمت‌ها در بازارهای مختلف ارز دیجیتال [۲۴]، فرض بر این است که نتایج نسبت به انتخاب منبع داده‌ها از استقلال ساختاری برخوردارند. علاوه بر استخراج سطوح حمایت و مقاومت (روش محوری^۳)، داده‌های درون‌زنجیره‌ای از وبسایت *Blockchair* و شاخص‌های اجتماعی گوگل ترندز از طریق کتابخانه *PyTrends* جمع‌آوری شدند. جهت تضمین یکپارچگی داده‌ها، فرآیند پیش‌پردازش شامل حذف داده‌های پرت^۴ و مقادیر مفقود اعمال شد. به‌منظور رفع ناهمگنی مقیاس متغیرها (نظیر حجم معاملات و شاخص‌های اجتماعی)، از تکنیک نرمال‌سازی مکس-مین^۵ برای انتقال ویژگی‌ها به بازه [۰, ۱] استفاده گردید [۲۵]. برای ارائه نمایی کلی از مجموعه داده‌های گردآوری‌شده، جدول ۱ آمار توصیفی مربوط به بازده‌های روزانه را برای ۲۳۳۸ نمونه ارائه می‌دهد. این آمار، شامل میانگین، کمینه، بیشینه، انحراف معیار، چولگی و کشیدگی مقادیر در طول دوره زمانی مورد مطالعه است و نوسانات شدید قیمت پایانی بیت‌کوین را نشان می‌دهد. نسبت انحراف معیار به میانگین تقریباً ۰/۷۶ است که حاکی از تغییرپذیری بالا در داده‌ها بوده و نشان می‌دهد که میانگین نسبت به مرکز توزیع، دارای نوسان قابل توجهی است. چولگی مثبت

^۱ API

^۲ Binance

^۳ Pivot

^۴ Outliers

^۵ Max-Min

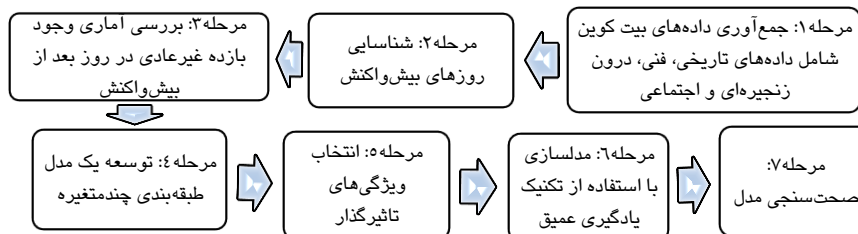


(۰/۸۹~) بیانگر آن است که توزیع قیمت‌های پایانی، تمایل به داشتن دُم بلند در سمت راست (مقادیر بالاتر) دارد. کشیدگی منفی نسبت به توزیع نرمال ($-۰/۲۷$) نشان می‌دهد که فراوانی مقادیر نزدیک به میانه، نسبتاً زیاد بوده و دُم پایینی توزیع، نسبت به توزیع نرمال فشرده‌تر است. به طور عملی، ترکیب چولگی مثبت و کشیدگی منفی می‌تواند نشان‌دهنده توزیعی با دُم بلند در سمت بالا و یک بدنه نسبتاً فشرده باشد. نهایتاً، بازه مقادیر از ۳,۱۸۹ تا ۶۷,۵۲۶ تتر گسترش دارد که این دامنه وسیع، خود تأکیدی بر نوسانات شدید قیمتی بیت‌کوین در این دوره است.

جدول ۱: خلاصه آماری قیمت بسته‌شدن روزانه بیت‌کوین (دوره: ۲۰۱۷-۲۰۲۳)

متغیر	تعداد مشاهدات	میانگین	مینیمم	ماکزیمم	انحراف معیار	چولگی	کشیدگی
قیمت پایانی	۲۳۳۸	۲۰۹۱۳	۳۱۸۹	۶۷۵۲۶	۱۵۹۱۲	۰/۸۹	-۰/۲۷

در ادامه، شکل ۱ فرآیند پژوهش را به تفصیل نشان می‌دهد. این فرآیند شامل جمع‌آوری و پاک‌سازی داده‌ها، شناسایی رخدادهای بیش‌واکنش، بررسی بازده‌های غیرعادی روز بعد، توسعه مدل طبقه‌بندی چندمتغیره برای پیش‌بینی روند قیمت، به‌کارگیری روش یادگیری عمیق و در نهایت اعتبارسنجی مدل است.



شکل ۱. فرآیند پژوهش

۲-۳- تعریف و شناسایی بیش‌واکنش

در ادبیات مالی، تعریف مشترک و مورد توافقی برای تشخیص «بیش‌واکنش» وجود ندارد و روش‌های متعددی در مطالعات پیشین به کار گرفته شده است [۳]. در این مقاله، بیش‌واکنش به عنوان حرکت قیمتی بزرگی تعریف می‌گردد که بازده آن، یک انحراف معیار بالاتر از میانگین



متحرک بازده قرار گیرد. این تعریف دقیقاً با رویکرد مورد استفاده در مطالعه کاپوراله و پلاستون^۱ (۲۰۱۹) مطابقت دارد. همچنین در اغلب مطالعات، بازده قیمت عمده‌تاً بر اساس تفاضل میان قیمت آغازین و قیمت پایانی مورد سنجش قرار می‌گیرد. با این حال، در این پژوهش بازده روزانه (R_t) به عنوان تفاوت میان حداکثر و حداقل قیمت ثبت شده در طول روز تعریف شده است. اتخاذ این رویکرد از آن جهت مناسب‌تر است که هدف مطالعه، تمرکز بر رفتار نقاط حدی نوسانات روزانه است. علاوه بر این، استفاده از دامنه قیمتی حداکثر در مقایسه با معیار بازگشایی - پایانی، امکان ارزیابی جامع‌تری از دامنه واقعی نوسانات روزانه را فراهم می‌سازد و تصویر کامل‌تری از شدت تغییرات قیمتی ارائه می‌دهد [۲].

$$R_t = \ln(\text{high}_t / \text{low}_t) \times 100 \quad \text{رابطه ۱}$$

سپس یک بیش واکنش به صورت زیر تعریف می‌شود که در آن R_t بازده روز t ام و $\bar{R}_n$ میانگین بازده n روز گذشته، δ_n انحراف استاندارد بازده‌های روزانه برای دوره n روزه و k تعداد انحرافات استاندارد مورد استفاده برای شناسایی بیش واکنش است:

$$R_t > \bar{R}_n + K\delta_n \quad \text{رابطه ۲}$$

$$\bar{R}_n = \sum_{t=1}^n R_t / n \quad \text{رابطه ۳}$$

$$\delta_n = \sqrt{\frac{1}{n} \sum_{t=1}^n (R_t - \bar{R})^2} \quad \text{رابطه ۴}$$

۳-۳- بررسی وجود بازده‌های غیرعادی پس از بیش واکنش

بر اساس فرضیه بیش واکنش، انتظار می‌رود پس از وقوع ناهنجاری بیش واکنش، تغییر جهت در حرکت قیمت رخ دهد که به دو صورت انجام می‌شود: ۱. اصلاح در روز بعد (حرکت برگشتی)^۲ که بازده بلافاصله در روز پس از بیش واکنش تغییر جهت می‌دهد. ۲. اصلاح با تأخیر (حرکت تداومی)^۳ که بازده در روز بعد همچنان در جهت بیش واکنش باقی مانده و اصلاح قیمت با چند روز تأخیر رخ می‌دهد. در هر دو سناریوی حرکت برگشتی و تداومی، بازده روز

^۱ Caporale & Plastun

^۲ Counter movement

^۳ Momentum movement



بعد به صورت تفاوت بین قیمت باز شدن روز بعد و حداکثر انحراف از آن در جهت مخالف حرکت قیمت در روز بیش‌واکنش اندازه‌گیری می‌شود. در حرکت برگشتی، اگر قیمت در روز بیش‌واکنش، افزایش یافته باشد، اندازه «واکنش معکوس» در روز بعد به صورت زیر محاسبه می‌شود:

$$cR_{t+1} = \ln\left(\frac{open_{t+1}}{low_{t+1}}\right) \times 100 \quad \text{رابطه ۵}$$

در این رابطه، cR_{t+1} اندازه واکنش معکوس را نشان می‌دهد، و $Open_{t+1}$ معرف قیمت بازگشایی در روز بعد از بیش‌واکنش است. چنانچه قیمت در روز بیش‌واکنش با کاهش مواجه شده باشد، تعریف متناظر آن به صورت زیر ارائه می‌شود:

$$cR_{t+1} = \ln\left(\frac{high_{t+1}}{open_{t+1}}\right) \times 100 \quad \text{رابطه ۶}$$

اما در مورد حرکت تداومی، بازده روز بعد باتوجه به افزایش یا کاهش قیمت به ترتیب به صورت زیر محاسبه می‌شود:

$$mR_{t+1} = \ln\left(\frac{high_{t+1}}{open_{t+1}}\right) \times 100 \quad \text{رابطه ۷}$$

$$mR_{t+1} = \ln\left(\frac{open_{t+1}}{low_{t+1}}\right) \times 100 \quad \text{رابطه ۸}$$

برای بررسی وجود بازده‌های غیرعادی پس از بیش‌واکنش، از آزمون‌های تی‌استیودنت (برای داده‌های نرمال) و مان-ویتنی (برای داده‌های غیرنرمال) استفاده می‌شود. در این آزمون‌ها، توزیع بازده روز پس از بیش‌واکنش در دو حالت حرکت برگشتی و تداومی، با بازده روزهای عادی مقایسه می‌شود. فرضیات پژوهش به شرح زیر تعریف می‌شوند: H_0 : بازده روز بعد از رویداد بیش‌واکنش، تفاوت معناداری با بازده یک روز عادی ندارد. H_1 : بازده روز بعد از رویداد بیش‌واکنش، به‌طور معناداری با بازده یک روز عادی متفاوت است.

۳-۴- توسعه مدل طبقه‌بندی چندمتغیره

احساسات شدید معامله‌گران در روز وقوع بیش‌واکنش (مانند ترس یا طمع) می‌تواند مسیر قیمت در روز بعد را تحت تأثیر قرار دهد و موجب نوسانات قابل توجهی شود که خود فرصتی برای معاملات کوتاه‌مدت ایجاد می‌کند. برای تحلیل این اثر، یک مدل چندمتغیره مبتنی بر



یادگیری عمیق طراحی گردید تا نقش مجموعه‌ای از ویژگی‌های مستقل را در پیش‌بینی جهت حرکت قیمت بیت‌کوین پس از وقوع بیش‌واکنش بررسی کند. در این مدل، متغیر هدف به‌صورت باینری (۱ برای افزایش و ۰ برای کاهش قیمت) تعریف شده است. مجموعاً ۱۵۸ ویژگی در دسته‌های مختلف (روزانه و درون‌روزی) استخراج گردیده که جزئیات آن‌ها در جدول ۲ ارائه شده است.

جدول ۲: دسته، ویژگی و بازه زمانی داده‌های جمع‌آوری شده بیت‌کوین

دسته	ویژگی	بازه زمانی	تعداد ویژگی
معاملاتی	قیمت بسته شدن روز	روزانه	۱
	حجم معاملات	روزانه- درون روزی	۵۰
	تعداد معاملات	روزانه- درون روزی	۵۰
	بازده	روزانه- درون روزی	۵۳
فنی	حمایت و مقاومت	روزانه	۱
درون زنجیره‌ای	تعداد تراکنش	روزانه	۱
	میانگین ارزش تراکنش	روزانه	۱
	روند گوگل	روزانه	۱
اجتماعی			
	تعداد کل ویژگی‌ها		۱۵۸

۳-۵- بررسی اهمیت ویژگی‌ها و تحلیل وابستگی آن‌ها

در گام نخست، برای شناسایی مؤثرترین ویژگی‌ها، فرآیند پیش‌انتخاب با الگوریتم جنگل تصادفی انجام و اهمیت هر ویژگی بر اساس معیارهایی مانند کاهش ناخالصی جینی تعیین می‌شود. سپس، جهت جلوگیری از هم‌خطی چندگانه و حذف اطلاعات زائد، ضرایب همبستگی پیرسون محاسبه شده و در صورت وجود همبستگی قوی میان دو ویژگی، متغیر کم‌اهمیت‌تر حذف می‌گردد [۲۶].

۳-۶- مدل‌سازی با یادگیری عمیق

در این بخش، چارچوب مدل‌سازی برای پیش‌بینی جهت بازده روز پس از بیش‌واکنش معرفی می‌شود. مدل اصلی، شبکه عصبی LSTM است که به دلیل توانایی در یادگیری وابستگی‌های زمانی و روابط غیرخطی در داده‌های ترتیبی، انتخاب شده است [۲۷]. در کنار LSTM،



معماری‌هایی نظیر شبکه‌های کانولوشنی زمانی (TCN) و مدل‌های مبتنی بر Attention از جمله Transformerها نیز در پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گیرند. TCNها در استخراج الگوهای زمانی کارآمد هستند و مدل‌های Attention در یادگیری وابستگی‌های بلندمدت توانمندند؛ با این حال، این معماری‌ها معمولاً به حجم داده‌های بزرگ‌تر و تنظیمات پیچیده‌تری نیاز دارند. با توجه به اینکه مسئله این پژوهش بر پیش‌بینی جهت قیمت در یک افق کوتاه‌مدت (روز پس از بیش‌واکنش) و در چارچوب داده‌های رویدادمحور با حجم محدود متمرکز است، استفاده از LSTM به‌عنوان گزینه‌ای متوازن از نظر دقت، پیچیدگی محاسباتی و قابلیت تعمیم انتخاب شد. ارزیابی نهایی مدل در این تحقیق، بر اساس معیار دقت^۱ محاسبه شده بر روی مجموعه داده‌های آزمایش^۲ انجام شد که نشان می‌دهد چقدر مدل به طور کلی درست عمل می‌کند [۲۸]. به منظور کنترل ریسک بیش‌برازش در فرآیند آموزش مدل، از تکنیک منظم‌سازی Dropout در معماری شبکه LSTM استفاده شد. کل فرآیند در پایتون پیاده‌سازی شده و کتابخانه‌هایی مانند Keras و Scikit-learn برای آموزش مدل، Requests برای دریافت داده‌ها، و NumPy و Pandas برای پیش‌پردازش داده‌ها به کار رفته‌اند.

۳-۷- صحت سنجی مدل

برای ارزیابی عملکرد و اطمینان از تعمیم‌پذیری مدل در پیش‌بینی‌های آینده، از اعتبارسنجی پنجره لغزان^۳ استفاده شد تا از بروز پدیده نشت اطلاعات زمانی^۴ جلوگیری شود. برای ارزیابی عملکرد و اطمینان از تعمیم‌پذیری مدل، از روش اعتبارسنجی پنجره لغزان استفاده شد تا از نشت اطلاعات جلوگیری شود. در این رویکرد، ۸۰٪ ابتدایی داده‌ها برای آموزش اولیه و ۲۰٪ انتهایی به پنج زیرمجموعه آزمون متوالی تقسیم گردید. پس از هر مرحله ارزیابی، داده‌های آزمون به مجموعه آموزش افزوده شده و مدل برای پیش‌بینی پنجره زمانی بعدی بازآموزی شد. این فرآیند تکراری تضمین می‌کند که پیش‌بینی‌ها صرفاً بر اساس داده‌های گذشته انجام شده و نتایج، نمایانگر عملکرد واقعی مدل در شرایط عملیاتی باشد.

^۱. Accuracy

^۲. Test set

^۳. Sliding Windows

^۴. look-ahead bias



۴- یافته‌های پژوهش

۴-۱- شناسایی بیش واکنش

بر اساس متدولوژی مورد استفاده توسط کاپوراله و پلاستون^۱ (۲۰۱۹) شناسایی روزهای بیش واکنش به صورت روزانه و با اتکا بر میانگین بازده ۳۰ روز گذشته و در نظر گرفتن یک انحراف معیار از آن تعریف و اجرا می‌شود [۲]. یک انحراف معیار بر اساس پیشنهاد مرجع فوق در مطالعه انجام شده و بر اساس تحلیل‌های انجام گرفته توسط ایشان در خصوص تاثیر و کارایی انحراف معیارهای مختلف روی شناسایی بیش واکنش سرمایه گذاران انتخاب شده است. در چارچوب مطالعه حاضر، با به کارگیری از این روش، از مجموع ۲۳۳۸ روز داده مورد بررسی، تعداد ۳۰۳ روز به عنوان روزهای بیش واکنش شناسایی گردید. این تعداد نشان می‌دهد که بیش واکنش‌ها ۱۳ درصد از کل روزهای بازه زمانی مورد مطالعه را به خود اختصاص داده‌اند (جدول ۳).

جدول ۳: تعداد بیش واکنش شناسایی شده بیت‌کوین برای دوره میانگین = ۳۰ و تعداد انحراف معیار = ۱

دوره	تعداد روزهای بیش واکنش	تعداد روزهای عادی	درصد روزهای بیش واکنش
۲۰۱۷ تا ۲۰۲۳	۳۰۳	۲۰۳۵	۱۳٪

۴-۲- اثبات وجود بازده غیر عادی در روزهای پس از بیش واکنش

قیمت پس از وقوع بیش واکنش معمولاً یکی از دو مسیر را دنبال می‌کند: حرکت برگشتی یا حرکت تداومی. ابتدا سناریوی حرکت برگشتی تحلیل شده است. نتایج جدول ۴ نشان می‌دهد که میانگین بازده روز پس از بیش واکنش به طور معناداری بالاتر از بازده روزهای عادی است. آزمون‌های تی و مان-ویتنی نیز با رد فرضیه صفر، وجود این تفاوت و وقوع یک ناهنجاری آماری قوی در قالب حرکت برگشتی پس از روزهای بیش واکنش را تأیید می‌کنند.

^۱. Caporale & Plastun



جدول ۴: آزمون تی‌استیودنت حرکت برگشتی پس از روز بیش‌واکنش بیت‌کوین (سال ۲۰۱۷ تا ۲۰۲۳)

نوع روز	روز بعد از بیش‌واکنش	عادی
تعداد نمونه	۱۷۰	۱۰۷۹
میانگین	۵/۱ %	۳/۹ %
انحراف معیار	۴/۳ %	۳/۳ %
آزمون تی‌استیودنت	۰/۰۰۰	
آزمون مان-ویتنی	۰/۰۰۰	
فرض صفر	رد	

همچنین، در سناریوی حرکت تداومی، جدول ۵ شواهد آماری را ارائه می‌دهد. در این زمینه، فرضیه‌ای که بیان می‌دارد نوسانات قیمت پس از وقوع بیش‌واکنش، تفاوت معناداری با نوسانات مشاهده شده در یک روز عادی ندارد، به‌طور قاطع رد شده است.

جدول ۵: آزمون تی‌استیودنت حرکت تداومی پس از روز بیش‌واکنش بیت‌کوین (سال ۲۰۱۷ تا ۲۰۲۳)

نوع روز	روز بعد از بیش‌واکنش	عادی
تعداد نمونه	۱۳۳	۹۳۲
میانگین	۶/۳ %	۵/۳ %
انحراف معیار	۶/۱ %	۴/۳ %
آزمون تی‌استیودنت	۰/۰۰۰	
آزمون مان-ویتنی	۰/۰۰۰	
فرض صفر	رد	

۴-۳- انتخاب ویژگی‌های تاثیرگذار

برای فرآیند مدل‌سازی، در ابتدا مجموعه‌ای شامل ۱۵۸ ویژگی به عنوان متغیرهای مستقل برای پیش‌بینی جهت حرکت قیمت در روز پس از بیش‌واکنش در نظر گرفته می‌شود. جهت کاهش ابعاد و انتخاب مؤثرترین ورودی‌ها، از الگوریتم جنگل تصادفی به عنوان روش غربالگری اولیه استفاده می‌شود. این الگوریتم اهمیت نسبی هر ویژگی را مشخص می‌کند؛ اهمیت ویژگی‌ها در محدوده‌ای از ۰/۱ درصد تا ۱/۳ درصد متغیر است. در مرحله اول، تنها آن دسته از ویژگی‌هایی که دارای درجه اهمیت بیشتر از ۱ درصد هستند، برای ورود به مرحله دوم انتخاب می‌شوند که این امر منجر به کاهش مجموعه به ۱۷ ویژگی کلیدی می‌گردد (جدول ۶). این ویژگی‌های



منتخب شامل بازده‌های درون‌روزی و روزانه، شاخص‌های حمایت و مقاومت، حجم معاملات درون‌روزی، و تعداد تراکنش‌های روزانه هستند که اثربخشی برجسته‌تری در پیش‌بینی نسبت به سایرین دارند. در مرحله بعدی، برای افزایش دقت و پایداری مدل با حذف اثرات همخطی چندگانه، از ماتریس همبستگی (شکل ۲) استفاده می‌شود. ویژگی‌هایی که مقدار همبستگی پیرسون آن‌ها بیش از ۰/۵ است، حذف می‌شوند. به عنوان نمونه، «بازده هشت ساعته سوم» به دلیل داشتن همبستگی ۰/۹ با «بازده شش ساعته چهارم» و با در نظر گرفتن تاثیر آن‌ها بر متغیر هدف، از مجموعه نهایی حذف می‌شود. در نهایت، پس از این فرآیند کاهش، ۱۱ متغیر نهایی (که در جدول ۶ با ستاره مشخص شده‌اند) به عنوان ویژگی‌های ورودی بهینه برای مدل نهایی انتخاب می‌شوند. به منظور اطمینان بیشتر از نبود همخطی چندگانه میان این ۱۱ متغیر منتخب، شاخص تورم واریانس^۱ نیز محاسبه شد. نتایج نشان داد که مقدار VIF برای تمامی متغیرهای نهایی کمتر از ۱/۹۸ بوده است که بیانگر عدم وجود همخطی معنادار میان آن‌ها و مناسب بودن مجموعه ویژگی‌های منتخب برای ورود به مدل نهایی است.


جدول ۶: متغیرهای انتخاب شده با استفاده از روش رندوم فارست و بر اساس درجه اهمیت

ردیف	نام ویژگی	تعریف
۱	BTC_Number_transaction*	تعداد تراکنش در روز بیش‌واکنش
۲	BTC_Rto-۳*	بازده روزانه سه روز قبل از وقوع بیش‌واکنش
۳	BTC_SR_t*	سطوح حمایت و مقاومت در روز بیش‌واکنش
۴	BTC_Rt_۱h_۲*	بازده ساعت دوم در روز بیش‌واکنش
۵	BTC_Rt_۱h_۵*	بازده ساعت پنجم در روز بیش‌واکنش
۶	BTC_Rt_۱h_۱۰*	بازده ساعت دهم در روز بیش‌واکنش
۷	BTC_Rt_۲h_۱	بازده دو ساعته اول در روز بیش‌واکنش
۸	BTC_Rt_۲h_۶*	بازده دو ساعته ششم در روز بیش‌واکنش
۹	BTC_Rt_۲h_۱۱	بازده دو ساعته یازدهم در روز بیش‌واکنش
۱۰	BTC_Rt_۴h_۱	بازده چهار ساعته اول در روز بیش‌واکنش
۱۱	BTC_Rt_۴h_۶	بازده چهار ساعته ششم در روز بیش‌واکنش
۱۲	BTC_Rt_۶h_۴*	بازده شش ساعته چهارم در روز بیش‌واکنش
۱۳	BTC_Rt_۸h_۱*	بازده هشت ساعته اول در روز بیش‌واکنش

^۱ Variance Inflation Factor (VIF)



ردیف	نام ویژگی	تعریف
۱۴	BTC_Rt_1h_۲*	بازده هشت ساعته دوم در روز بیش واکنش
۱۵	BTC_Rt_1h_۳	بازده هشت ساعته سوم در روز بیش واکنش
۱۶	BTC_Volume_1h_۳*	حجم معاملات ساعت سوم در روز بیش واکنش
۱۷	BTC_Volume_1h_۱۱	حجم معاملات ۲ ساعته یازدهم در روز بیش واکنش



شکل ۲. نقشه حرارتی همبستگی ویژگی‌ها

۴-۴- پیش‌بینی روند قیمت روز بعد از بیش واکنش سرمایه‌گذاران با استفاده از مدل طبقه‌بندی چندمتغیره

با توجه به مشاهده‌ی بازده‌های غیرعادی در روزهای پس از وقوع بیش‌واکنش، این پژوهش بر این فرض استوار است که با برآورد دقیق جهت حرکت قیمت در این دوره‌ها، می‌توان به سودآوری معاملاتی دست یافت. برای مدل‌سازی این پیش‌بینی، یک مدل طبقه‌بندی چندمتغیره توسعه داده شده است که از مجموعه‌ای از داده‌های روزهای بیش‌واکنش به عنوان ویژگی‌های پیش‌بینی‌کننده بهره می‌گیرد. بردار هدف به صورت یک متغیر باینری تعریف شده است که جهت حرکت قیمت در روز بعد از بیش‌واکنش را مشخص می‌کند؛ این بردار برای تغییرات مثبت



قیمت (شمع سبز) مقدار ۱ و برای تغییرات منفی قیمت (شمع قرمز) مقدار ۰ می‌گیرد. این رویکرد باینری‌سازی، تحلیل را بر روی تصمیم‌گیری "خرید" یا "فروش" متمرکز می‌سازد. برای مدل‌سازی این مسئله، از یک شبکه حافظه بلند-کوتاه مدت (LSTM) به عنوان هسته اصلی مدل استفاده شد. با توجه به محدود بودن تعداد مشاهدات مربوط به روزهای بیش‌واکنش ۳۰۳ مشاهده، برای کنترل ریسک بیش‌برازش از تکنیک منظم‌سازی^۱ با نرخ ۰/۲ در ساختار مدل استفاده شد. به این ترتیب، قابلیت تعمیم مدل بر روی داده‌های مشاهده‌نشده بهبود یافته و پایداری نتایج افزایش می‌یابد.

به منظور ارزیابی مدل داده‌ها با حفظ ترتیب زمانی به مجموعه‌های آموزش و آزمایش تقسیم شده و مدل به طور مداوم بر روی داده‌های جدیدتر اعتبارسنجی می‌شود. به طور خاص، ابتدا داده‌ها به مجموعه آموزش اولیه و مجموعه آزمایش اول تقسیم گردیدند. مدل بر روی مجموعه آموزش اولیه آموزش دیده و سپس بر روی مجموعه آزمایش اول ارزیابی شد. پس از آن، مجموعه آزمایش اول به انتهای مجموعه آموزش افزوده شد و یک مجموعه آزمایش جدید ایجاد گردید و این فرآیند تکرار شد. این رویکرد تضمین می‌کند که اعتبارسنجی همیشه بر روی داده‌هایی که بعد از داده‌های آموزشی قرار دارند، انجام می‌شود. دقت مدل، از طریق اجرای این فرآیند اعتبارسنجی به صورت تکرارشونده مورد اطمینان‌سنجی قرار گرفت. همچنین بررسی روند تابع زیان^۲ (شکل ۳) در طول فرایند آموزش نشان داد که مقدار زیان آموزشی و آزمایشی هر دو رفتار کاهشی و باثباتی دارند و فاصله میان آن‌ها در کل دوره یادگیری کوچک و کنترل‌شده باقی مانده است؛ این موضوع بیانگر عدم بروز بیش‌برازش شدید و توانایی مدل در یادگیری الگوهای واقعی موجود در داده‌های روزهای بیش‌واکنش است. در مجموع، ارزیابی‌های انجام‌شده نشان داد که عملکرد مدل در سطح قابل قبولی تثبیت شده و میانگین دقت حاصل از اعتبارسنجی زمانی برابر با حدود ۶۷ درصد بوده است. برای اطمینان از اعتبار این نتیجه، آزمون فرض انجام شد تا نشان دهد میانگین دقت به‌طور معناداری از ۵۰ درصد (نقطه تصادفی) و در سطح اطمینان ۹۹٪ بالاتر است. همان‌طور که انتظار می‌رفت، فرض صفر

^۱ Dropout

^۲ Loss function



مبنی بر دقت کمتر از ۵۰ درصد رد شد، که این امر اثبات می‌کند مدل ما فراتر از شانس تصادفی عمل می‌کند و اعتبار نتایج گزارش شده با استفاده از روش اعتبارسنجی زمانی تأیید می‌گردد.



شکل ۳. نمودار روند زیان در آموزش و ارزیابی مدل

همچنین به منظور ارزیابی ارزش واقعی عملکرد مدل پیشنهادی و ایجاد یک مبنای مقایسه، مدل کلاسیک رگرسیون لجستیک نیز با استفاده از داده‌های مشابه آموزش داده و آزمایش شدند. نتایج حاصل از این مقایسه نشان داد که مدل رگرسیون لجستیک به دقت ۵۳.۴٪ در پیش‌بینی جهت حرکت قیمت دست یافت که به طور معناداری پایین‌تر از عملکرد مدل LSTM چندمتغیره (۶۷٪) است. این برتری عملکردی، تأییدکننده توانایی ویژه شبکه LSTM در پردازش و استخراج الگوهای غیرخطی و وابستگی‌های زمانی بلندمدت در داده‌های پویای رمزارزها است. به علاوه برای اعتبارسنجی دقیق‌تر مدل پیشنهادی، عملکرد مدل پیشنهادی با مدل کاپوراله و پلاستون (۲۰۱۹) در یک بستر آزمایشی کاملاً یکسان ارزیابی گردید. بدین منظور، مدل کاپوراله و پلاستون با استفاده از داده‌های موجود مجدداً برازش شد تا خروجی‌های آماری آن در شرایطی هم‌تراز با پژوهش حاضر تولید گردد. یافته‌های حاصل از این آزمون مجدد نشان داد که مدل مذکور در این بازه زمانی، دقتی در حدود ۵۰ درصد کسب کرده است که از نظر آماری با پیش‌بینی تصادفی تفاوت معناداری ندارد. این مقایسه مستقیم و مبتنی بر داده‌های مشترک، گواهی بر آن است که بهبود عملکرد مدل پیشنهادی، ناشی از نوآوری در روش‌شناسی است و نه صرفاً تفاوت در بازه زمانی مورد بررسی. به عبارت دیگر بر اساس مدل کاپوراله و



پلاستون (۲۰۱۹)، جهت حرکت قیمت پس از بیش‌واکنش در بازار رمزارزها ذاتاً غیرقابل پیش‌بینی است و به نوعی فرضیه کارایی بازار را تأیید می‌کند. در نقطه مقابل، مدل چندمتغیره توسعه داده شده در این مطالعه، با بهره‌گیری از یک مجموعه ویژگی گسترده‌تر و جامع‌تر که تعاملات پیچیده بازار را در نظر می‌گیرد، موفق به دستیابی به میانگین دقت ۶۷٪ شد. این افزایش قابل توجه در دقت، مستقیماً قابلیت پیش‌بینی رفتار قیمت در زمان وقوع ناهنجاری بیش‌واکنش را نشان می‌دهد. تفاوت عمده در عملکرد این دو مدل در رویکرد ویژگی‌محور مدل پیشنهادی نهفته است. مدل حاضر با ادغام ابعاد مختلف (مانند داده‌های درون‌روزی، شاخص‌های فنی و تراکنش‌ها) توانسته است ناهنجاری‌های ساختاری بازار را بهتر مدل‌سازی کند. بنابراین، یافته‌های ما نه تنها برتری فنی مدل جدید را اثبات می‌کند، بلکه از منظر نظری، نیز، با نشان دادن قابلیت پیش‌بینی معنادار در بازار بیت‌کوین از طریق ناهنجاری‌های قیمتی، فرضیه بازار کارا را به چالش می‌کشد و شواهدی قوی علیه آن ارائه می‌دهد.

۵- نتیجه‌گیری و پیشنهادها

یافته‌های این پژوهش نشان می‌دهد که پدیده بیش‌واکنش در بازار بیت‌کوین صرفاً یک نوسان مقطعی یا رفتار تصادفی قیمت نیست، بلکه یک الگوی معنادار، تکرارشونده و قابل شناسایی است که می‌تواند بازده‌های غیرعادی روزهای پس از وقوع را به‌طور مؤثر توضیح دهد. نتایج آزمون‌های آماری به‌کاررفته در این مطالعه بیانگر آن است که بازده پس از جابه‌جایی‌های شدید قیمت از الگوی معمول بازده فاصله‌ای معنادار دارد و این انحراف، صرفاً ناشی از نویز بازار نیست. از سوی دیگر، نتایج مدل LSTM چندمتغیره که با استفاده از ۱۱ متغیر کلیدی بازار و داده‌های جستجوی گوگل طراحی شد، نشان داد که امکان شناسایی جهت حرکت قیمت با دقت ۶۷ درصد و به‌صورت معنادار بالاتر از حد تصادفی وجود دارد. همچنین کاهش باثبات تابع زیان در طول آموزش نشان‌دهنده پایداری مدل و عدم بروز بیش‌برازش است؛ همچنین برتری دقت مدل پیشنهادی در مقایسه با رگرسیون لجستیک (۵۳.۴ درصد)، توانمندی بالاتر یادگیری عمیق را در پیش‌بینی جهت حرکت قیمت بیت‌کوین اثبات می‌کند. این امر حاکی از آن است که اطلاعات نهفته در ویژگی‌های انتخابی مدل به‌صورت هم‌افزا در شکل‌گیری بازده‌های آتی نقش دارند و مدل‌های یادگیری عمیق می‌توانند این ساختار پنهان را تا حد قابل قبولی استخراج کنند. بنابراین، دستاورد اصلی این پژوهش صرفاً ارائه یک دقت پیش‌بینی بالاتر نیست،



بلکه اثبات تجربی نقش مستقل بیش‌واکنش در ایجاد عدم‌تقارن و بازده‌های غیرعادی در بازار بیت‌کوین و ارائه یک چارچوب تحلیلی نوین برای ترکیب تحلیل رفتاری با یادگیری عمیق در بازارهای رمزارز است. از دیدگاه کاربردی، یافته‌های این پژوهش به معامله‌گران الگوریتمی کمک می‌کند تا با شناسایی نقاط بیش‌واکنش بازار، استراتژی‌های سودآور بازگشت به میانگین را طراحی کنند. همزمان، مدیران صندوق‌های سرمایه‌گذاری می‌توانند با ادغام سیگنال‌های پیش‌بینی این مدل در سیستم‌های خود، در زمان نوسانات شدید قیمت موقعیت‌های معاملاتی را به طور پویا تعدیل کرده و ریسک سقوط ناگهانی دارایی‌ها را مدیریت کنند. برای تعمیق و گسترش نتایج این پژوهش، پیشنهاد می‌شود در مطالعات آینده مجموعه متغیرهای توضیحی مدل با افزودن شاخص‌های پیشرفته احساسات بازار، جریان اخبار، داده‌های آن‌چین و همچنین شاخص‌های رفتاری مبتنی بر شبکه‌های اجتماعی توسعه یابد تا قدرت تبیین و پیش‌بینی مدل افزایش یابد. مقایسه عملکرد LSTM با معماری‌های دیگر مانند CNN، GRU، Transformer و مدل‌های هیبریدی می‌تواند به شناسایی الگوهای زمانی پیچیده‌تر کمک کند. بررسی دقیق‌تر بازده‌های غیرعادی در دم‌های توزیع، دوره‌های بحران و فازهای مختلف چرخه بازار نیز برای درک بهتر سازوکار بیش‌واکنش ضروری است. علاوه بر این، آزمون مدل در بازه‌های زمانی متفاوت، محیط‌های معاملاتی واقعی و پلتفرم‌های با نقدشوندگی متغیر، می‌تواند قابلیت تعمیم و کاربردپذیری نتایج را ارزیابی کند. در نهایت، طراحی چارچوب‌های علیتی یا مبتنی بر توضیح‌پذیری مدل (XAI) می‌تواند به شفاف شدن نقش متغیرهای کلیدی در ایجاد بیش‌واکنش و بازده‌های غیرعادی کمک کرده و مسیر پژوهش‌های پیشرفته‌تر را هموار سازد.

۶- منابع

- [۱] Bush, P.J., Stephens, J., & Mehdian, S. (۲۰۲۰). An Investigation of the Presence of Anomalies in Digital Asset Market: The Case of Bitcoin. *Applied Finance Letters*, ۹, ۷۳-۸۰. <https://doi.org/10.24135/afl.v9i0.266>.
- [۲] Caporale, G.M., & Plastun, A. (۲۰۱۹). Price overreactions in the cryptocurrency market. *Journal of Economic Studies*, ۴۶, ۱۱۳۷-۱۱۵۵. <https://doi.org/10.1108/JES-09-2018-0310>.
- [۳] Amini, S., Gebka, B., Hudson, R., & Keasey, K. (۲۰۱۳). A review of the international literature on the short term predictability of stock prices conditional on



- large prior price changes: microstructure, behavioral and risk related explanations. International Review of Financial Analysis, ۲۶, ۱-۱۷. <https://doi.org/10.1016/j.irfa.2012.04.002>.
- [۴] Brown, N.C., Wei, K.D., & Wermers, R. (۲۰۱۴). Analyst recommendations, mutual fund herding, and overreaction in stock prices. Management Science, ۶۰, ۱-۲۰. <https://doi.org/10.1287/mnsc.2013.1751>.
- [۵] Borgards, O., & Czudaj, R.L. (۲۰۲۰). The prevalence of price overreactions in the cryptocurrency market. Journal of International Financial Markets, Institutions and Money, ۶۵, ۱۰۱۱۹۴. <https://doi.org/10.1016/j.intfin.2020.101194>.
- [۶] Borri, N. (۲۰۱۹). Conditional tail-risk in cryptocurrency markets. Journal of Empirical Finance, ۵۰, ۱-۱۹. <https://doi.org/10.1016/j.jempfin.2018.11.002>.
- [۷] Klein, T., Pham Thu, H., & Walther, T. (۲۰۱۸). Bitcoin is not the New Gold – a comparison of volatility, correlation, and portfolio performance. International Review of Financial Analysis, ۵۹, ۱۰۵-۱۱۶. <https://doi.org/10.1016/j.irfa.2018.07.010>.
- [۸] Urquhart, A. (۲۰۱۸). What causes the attention of Bitcoin? Economics Letters, ۱۶۶, ۴۰-۴۴. <https://doi.org/10.1016/j.econlet.2018.02.017>.
- [۹] Donier, J., & Bouchaud, J.P. (۲۰۱۵). Why do markets crash? Bitcoin data offers unprecedented insights. PLoS ONE, ۱۰(۱۰), e۰۱۳۹۳۵۶. <https://doi.org/10.1371/journal.pone.0139356>.
- [۱۰] John, D.L., Binnewies, S., & Stantic, B. (۲۰۲۴). Cryptocurrency Price Prediction Algorithms: A Survey and Future Directions. Forecasting, ۶(۳), ۶۳۷-۶۷۱. <https://doi.org/10.3390/forecast630034>.
- [۱۱] Nakano, M., Takahashi, A., & Takahashi, S. (۲۰۱۸). Bitcoin technical trading with artificial neural network. Physica A, ۵۸۷, ۶۰۹-۶۱۸. <https://doi.org/10.1016/j.physa.2018.07.017>.
- [۱۲] Phillips, R.C., & Gorse, D. (۲۰۱۷). Predicting cryptocurrency price bubbles using social media data and epidemic modelling. IEEE SSCI, ۱-۷.



- <https://doi.org/10.1109/SSCI.2017.8280809>.
- [۱۳] Dubey, R., & Enke, D. (۲۰۲۵). Bitcoin price direction prediction using on-chain data and feature selection. *Machine Learning with Applications*, ۲۰, ۱۰۰۶۷۴. <https://doi.org/10.1016/j.mlwa.2025.100674>.
- [۱۴] Khedr, A.M., Arif, I., Raj P.V.P., El-Bannany, M., Alhashmi, S.M., & Sreedharan, M. (۲۰۲۱). Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, ۲۸(۱), ۳-۳۴. <https://doi.org/10.1002/isaf.1488>.
- [۱۵] Boozary, P., Sheykhani, S., & GhorbanTanhaei, H. (۲۰۲۵). Forecasting the Bitcoin price using various machine learning techniques: A systematic review in data-driven marketing. *Systems and Soft Computing*, ۷. <https://doi.org/10.1016/j.sasc.2025.200209>.
- [۱۶] Caporale, G.M., Gil-Alana, L., & Plastun, A. (۲۰۲۰). Long-term price overreactions: Are markets inefficient? *Journal of Economics and Finance*, ۴۳, ۶۵۷-۶۸۰. <https://doi.org/10.1007/s12197-018-9464-8>.
- [۱۷] Chevapatrakul, T., & Mascia, D.V. (۲۰۱۹). Detecting overreaction in the Bitcoin market: A quantile autoregression approach. *Finance Research Letters*, ۳۰, ۳۷۱-۳۷۷. <https://doi.org/10.1016/j.frl.2018.11.004>.
- [۱۸] Corbet, S., & Katsiampa, P. (۲۰۲۰). Asymmetric mean reversion of Bitcoin price returns. *International Review of Financial Analysis*, ۷۱, ۱۰۱۲۶۷. <https://doi.org/10.1016/j.irfa.2018.10.004>.
- [۱۹] Gil-Alana, L.A., Aikins, E.J., & Romero, M.F. (۲۰۲۰). Cryptocurrencies and stock market indices: are they related? *Research in International Business and Finance*, ۵۱, ۱۰۱۰-۱۰۶۳. <https://doi.org/10.1016/j.ribaf.2019.101063>.
- [۲۰] Martins, C.H.P. (۲۰۲۰). Do cryptocurrency overreact? Evidence of extreme one-day price movements. Master's Dissertation, Faculty of Economics, Porto University. https://sigarra.up.pt/fep/en/pub_geral.show_file?pi_doc_id=353747.
- [۲۱] Kellner, T., & Maltritz, D. (۲۰۲۱). A broad analysis of short-term overreactions



- in the market for cryptocurrencies. *Journal of Economic Studies*, ۴۹, ۱۵۸۵–۱۶۰۸. <https://doi.org/10.1108/JES-09-2021-0488>.
- [۲۲] Schaub, M. (۲۰۲۲). Outlier events in major cryptocurrency markets: Is there evidence of overreaction? *The Journal of Wealth Management*, ۲۴, ۱۴۲–۱۴۸. <https://doi.org/10.3905/jwm.2021.1.155>.
- [۲۳] Dias, R., Chambino, M., & Palma, C.M. (۲۰۲۳). Cryptocurrency market: overreaction to news and herd instincts. In Bevanda, V. (ed.), *Knowledge-Based Sustainable Development*, Prague, ۶۷–۷۵. doi:10.31410/ERAZ.2023.67.
- [۲۴] Giudici, P., & Abu-Hashish, I. (۲۰۱۹). What determines Bitcoin exchange prices? A network VAR approach. *Finance Research Letters*, ۲۸, ۳۰۹–۳۱۸. <https://doi.org/10.1016/j.frl.2018.05.013>.
- [۲۵] Afsar, A., & Helyel, F. (۲۰۱۷). A hybrid approach to portfolio optimization using technical analysis and data mining. *Modern Research in Decision Making*, ۲(۲), ۱–۲۲. https://journal.saim.ir/article_۲۶۷۸۵_۷eef۶ff۹۱f۶۹d۴۳۶ef۳۸۲۶۲b_b۳eef۵۲.pdf. [In Persian]
- [۲۶] Khani, A.M., Jafarnjad, A., & Rezasoltani, A. (۲۰۲۰). A hybrid machine learning model based on weighted voting for intelligent classification of bank customer value. *Modern Research in Decision Making*, ۱۰(۴), ۲۶–۵۸. https://journal.saim.ir/article_۷۳۳۹۹۱_۰b۶۹۷۵۷۷۲۰۲۱c۵۰۸f۰d۶ad۲۸۹۸c۱c۹fb.pdf. [In Persian]
- [۲۷] Zolfaghar, P., Khadivar, A., & Abbasi, F. (۲۰۲۲). Investigating the impact of perceived risk by social media users on the price of Bitcoin using sentiment analysis and the NARX neural network technique. *Management Research in Iran*, ۲۶(۲), ۱۸–۴۱. https://mri.modares.ac.ir/article_۵۹۳_acc۳e۰۴۰۴۶۴۶c۰۷۵۰۲b۴۸۰d۰c۰۵۲c۴fe۱.pdf. [In Persian]
- [۲۸] Mirashk, H., Albadvi, A., Kargari, M., Rastegar Sorkhe, M., & Talebi, M. (۲۰۲۴). A DSR approach to predict liquidity risk using CNN and sentiment analysis. *Management Research in Iran*, ۲۷(۴), ۱۳۸–۱۶۸. https://mri.modares.ac.ir/article_۶۳۹_۰f۹۶۶۱۳۲۳۵۰۶۲۹۶۳ccde۷۱۷b۱۸f۹۷۵۹۲.pdf. [In Persian]