



پیش‌بینی نوسانات بازدهی ارزهای رمزنگاری شده با استفاده از روش‌های مارکوف پنهان و گارچ - مارکوف

مریم باقرزاده سهرابی^۱

حسین ممبینی^۲

صفیه مهری‌نژاد^۳

تاریخ دریافت مقاله: ۱۴۰۳/۰۲/۱۳ تاریخ پذیرش مقاله: ۱۴۰۳/۱۰/۱۵

چکیده

بر اساس ادبیات نظری پیش‌بینی دقیق در بازار ارزهای دیجیتال نقش اساسی در مدیریت ریسک، بهینه‌سازی پرتفوی، کارایی بازار و مدیریت بهتر بازارها دارد و به سرمایه‌گذاران در تصمیم‌گیری آگاهانه‌تر، مدیریت ریسک و حداکثر سازی بازده کمک خواهد کرد. بر این اساس این پژوهش با توجه به اهمیت روزافزون دو رمز ارز بیت کوین و اتریوم، بر اساس اطلاعات روزانه، اقدام به پیش‌بینی بازدهی و نوسانات قیمتی آن‌ها با روش مارکوف پنهان و مدل ترکیبی گارچ - مارکوف پنهان نموده است. بر اساس نتایج، دقت پیش‌بینی بازدهی اتریوم بر اساس روش مارکوف پنهان با شاخص $DAP = 65.38\%$ و با شاخص $MAPE = 1.76\%$ بوده است. همچنین عملکرد شاخص‌های پیش‌بینی بر اساس مدل گارچ مارکوف پنهان بر اساس شاخص $DAP = 91.02\%$ و $MAPE = 2.30\%$ بوده است. برای رمز ارز بیت کوین نیز نتایج پیش‌بینی حاکی از آن است که دقت مدل بر اساس شاخص $DAP = 76.92\%$ و بر اساس شاخص $MAPE = 1.43\%$ بوده است. پس از به‌کارگیری روش گارچ - مارکوف عملکرد مدل در پیش‌بینی روند ۵ درصد بهتر شده است اما شاخص قدر مطلق مقادیر بدتر شده است. بنابراین استفاده از روش ترکیبی گارچ - مارکوف پنهان برای هر دو رمز ارز باعث بهبود تشخیص روند حرکتی شده است.

کلمات کلیدی

روش مارکوف پنهان، روش گارچ، اتریوم، بیت کوین

۱- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. Maryamsohrabi98@yahoo.com

۲- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول) h.mombeini@gmail.com

۳- گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. S.mehrenejad@gmail.com

مقدمه

پیش‌بینی سری‌های زمانی مالی یکی از چالش‌برانگیزترین مسائل در حوزه بازارهای مالی است. این چالش به‌ویژه در افزایش دقت و بازده پیش‌بینی‌ها نمود پیدا می‌کند، چراکه بازارهای مالی به دلیل ماهیت نوسانی و ناپایدار خود، محدودیت‌هایی را در پیش‌بینی ایجاد می‌کنند. برای پیش‌بینی بازارهای مالی با استفاده از داده‌های تاریخی، روش‌های متعددی پیشنهاد شده‌اند که به‌طور کلی به دودسته کلاسیک و هوشمند تقسیم می‌شوند.

مدل‌های کلاسیک، مانند رگرسیون خطی و آریما، فرض می‌کنند که روند آینده بازار خطی و مبتنی بر داده‌های گذشته است. اما روش‌های هوشمند، مانند شبکه‌های عصبی، منطق فازی، ماشین‌های بردار پشتیبان، و مدل‌های مارکوف، توانایی بیشتری در درک الگوهای پیچیده و غیرخطی بازار دارند. مطالعات متعددی نشان داده‌اند که روش‌های هوشمند نسبت به روش‌های کلاسیک دقت و عملکرد بهتری در پیش‌بینی بازارهای مالی دارند (کواکانتی و همکاران^۱، ۲۰۱۶، پادماجا^۲، ۲۰۲۰، یان و همکاران^۳، ۲۰۱۷ و آدبی و همکاران^۴، ۲۰۱۴). علاوه بر این، ترکیب روش‌های مختلف و استفاده از ویژگی‌های مثبت هر یک از آن‌ها می‌تواند بهبود چشمگیری در دقت پیش‌بینی‌ها ایجاد کند. (لی و همکاران^۵، ۲۰۲۳، ونگ^۶، ۲۰۲۰، تابر و همکاران^۷، ۲۰۲۰، شو و همکاران^۸، ۲۰۲۰، ماروتی^۹، ۲۰۱۹، حسن^{۱۰}، ۲۰۰۹....). بنابراین استفاده از روش‌های هوشمند جدید و با ویژگی‌های مناسب و همچنین ترکیب آن با روش‌های دیگر به نظر می‌رسد در نهایت بتواند نتایج بهتر و دقیق‌تری را ارائه نماید.

هرکدام از این روش‌های هوشمند علی‌رغم وجود ویژگی‌های مناسب دارای محدودیت‌هایی نیز هستند برای نمونه تکنیک شبکه‌های عصبی مصنوعی به‌عنوان پرکاربردترین این روش‌ها (اتسالاکیس و والاتیس^{۱۱}، ۲۰۰۹، تکاچ و ورتز^{۱۲}، ۲۰۱۶) به‌عنوان مثال، شبکه‌های عصبی مصنوعی به دلیل نحوه پیکربندی، در معرض مشکل برازش بیش‌ازحد و حساسیت به نویز هستند و ممکن است با تغییر دامنه داده‌ها نیاز به تنظیم مجدد داشته باشند (حسن و ناص^{۱۳}، ۲۰۰۵). برای اساس روش‌های جدیدتری که ویژگی‌های بهتری دارند در طول زمان توسعه داده شده‌اند. یکی از این روش‌ها که در ادبیات تحقیق به دلیل ویژگی‌های آن در زمینه‌های مختلف از جمله پیش‌بینی بازارهای مالی بدان توجه ویژه می‌شود روش مارکوف پنهان^{۱۴} است. مدل مارکوف پنهان در اواخر دهه ۱۹۶۰ میلادی برای شناسایی صدا معرفی گردید و در حال حاضر به‌سرعت در حال گسترش دامنه کاربردها می‌باشد. دو دلیل مهم برای این موفقیت وجود دارد. اول اینکه این مدل از لحاظ ساختار ریاضی بسیار قدرتمند است. دوم اینکه

پیش بینی نوسانات بازدهی ارزشهای رمزنگاری شده.../باقرزاده سهرابی، ممبینی و مهری نژاد

مدل مارکوف پنهان اگر به صورت مناسبی ایجاد شود می تواند برای کاربردهای بسیاری مورد استفاده قرار گیرد (نادری و همکاران^{۱۵}، ۲۰۲۴، حسن و ناص، ۲۰۰۵).

حسن و ناص (۲۰۰۵ و ۲۰۰۶)، گوپتا و هینگرا^{۱۶} (۲۰۱۲) از مدل مارکوف پنهان برای پیش بینی قیمت سهام در بازارهای مختلف استفاده کرده اند. سپس نتایج را با روش شبکه های عصبی مصنوعی مقایسه کردند که نتایج پیش بینی بهبود دقت پیش بینی به وسیله این مدل را در قیاس با شبکه های عصبی نشان می دهد. لازوز^{۱۷} (۲۰۱۱) از این روش برای پیش بینی بازدهی بازار سهام استفاده کرده است و نشان می دهد که عملکرد این مدل از روش میانگین متحرک بسیار بهتر بوده است. الغیب و همکاران^{۱۸} (۲۰۱۴) بر کارایی این مدل در پیش بینی بازده سهام در بازار هند تأکید می کند. لی و همکاران (۲۰۲۳) شو و همکاران (۲۰۲۰)، ماروتی و همکاران (۲۰۱۹) همگی بر قدرت پیش بینی این روش در بازار رمز ارزها تأکید داشته اند. براین اساس این پژوهش در نظر دارد با توجه به قدرت روش مارکوف پنهان در پیش بینی بازدهی در بازارهای مالی، با استفاده از این روش بازدهی رمز ارزها را مورد بررسی قرار دهد.

بازار ارزشهای رمزنگاری شده به دلیل نوسانات شدید قیمتی، فرصت ها و چالش های بی سابقه ای را برای سرمایه گذاران و تحلیلگران مالی ایجاد کرده است. پیش بینی بازدهی ارزشهایی مانند بیت کوین و اتریوم، به دلیل پتانسیل بالای این دارایی ها در کسب سود، یکی از مهم ترین و چالش برانگیزترین مسائل در بازارهای مالی است. با این حال، ماهیت بسیار ناپایدار و نوسانی این ارزها ضرورت استفاده از مدل هایی قدرتمند و دقیق را برجسته می کند. مطالعات نشان داده اند که ویژگی اصلی بازارهای رمز ارز، نوسانات شدیدتر آن ها نسبت به سایر بازارهای مالی است (شو و همکاران، ۲۰۲۰). عدم توجه به این نوسانات می تواند دقت و عملکرد مدل های پیش بینی را با چالش مواجه کند. بنابراین، استفاده از هر مدل هوشمند یا سنتی باید با در نظر گرفتن این ویژگی انجام شود تا بتواند نتایج دقیق تری ارائه دهد و بازدهی را به درستی پیش بینی کند.

در ادبیات اقتصادی در پاسخ به اهمیت نوسانات، مدل های اقتصادسنجی فراوانی توسط پژوهشگران در این زمینه معرفی شده است. که دلیل اصلی این توسعه روش ها نیاز به مدل سازی شرایط عدم اطمینان و لزوم مدیریت ریسک نهفته در بازارهای مالی را نشان می دهد. بازدهی دارایی های مالی دارای سه ویژگی مهم است: نوسان خوشه ای، رابطه نامتقارن، و غیرخطی بودن. لذا مدل های ناهمسانی واریانس شرطی به دلیل انطباق با این ویژگی ها، در تحقیقات مالی مورد استفاده فراوان قرار گرفته است (بیلدریچی^{۱۹}، ۲۰۰۹). بنابراین یکی از گام های اساسی برای پیش بینی دقیق بازار بشدت متلاطم رمز

ارزها توجه به مسئله نوسانات در این بازار و استفاده از مدل‌های گارچ به دلیل ویژگی‌های خاص این مدل‌ها در ترکیب با روش‌های هوشمند است.

ادامه این مقاله به شکل زیر سازمان‌دهی می‌شود در قسمت دوم این مقاله مروری بر ادبیات نظری و پیشینه ارائه می‌شود. سپس روش انجام کار شامل معرفی روش و نحوه انجام کار آورده می‌شود. در قسمت بعدی نتایج مربوط به پیاده‌سازی مدل آورده می‌شود و در نهایت در قسمت آخر کار نتیجه‌گیری و جمع‌بندی ارائه می‌گردد.

پیشینه و مبانی نظری

پیش‌بینی در بازارهای مالی نیز برای رعایت قوانین و نظارت بر بازار حائز اهمیت است. ناظران و سیاست‌گذاران نیاز دارند تا رفتار و دینامیک بازار ارزهای رمزنگاری را درک کنند تا مقررات مناسب را تعیین کرده و بر بازار نظارت کنند (پاتل و همکاران^{۲۰}، ۲۰۲۴). پیش‌بینی‌های دقیق بازدهی ارزهای رمزنگاری به سیاست‌گذاران امکان می‌دهد تا خطرات و مزایای مرتبط با پذیرش ارزهای رمزنگاری را ارزیابی کنند. این اطلاعات می‌توانند در تصمیم‌گیری‌های مربوط به یکپارچه‌سازی ارزهای رمزنگاری با سامانه مالی سنتی، سیاست‌های پولی و برنامه‌ریزی مالی بلندمدت مؤثر باشند (سیماران و شارما^{۲۱}، ۲۰۲۳).

بنابراین و با توجه به مزیت‌های در اختیار داشتن روش‌های مناسب پیش‌بینی مدیران، سیاست‌گذاران و سرمایه‌گذاران تمایل دارند مکانیزمی در اختیار داشته باشند که بتواند آن‌ها را در امور تصمیم‌گیری‌شان یاری نماید. در مورد امکان‌پذیری و مفید بودن پیش‌بینی، نظریات به دودسته کلی تقسیم می‌شود: دسته اول محققان معتقد می‌باشند، که حرکت بازار از الگوهای مشخصی پیروی می‌کند. اگرچه این الگوها می‌توانند ساده یا پیچیده و آسان یا سخت برای پیدا کردن باشند، ولی در هر حال الگو می‌باشند و به همین دلیل می‌شود، بازار مالی را پیش‌بینی کرد. این افراد معتقد هستند که بررسی روندها و رفتار بازار در گذشته می‌تواند این الگوها را مشخص کنند. با پیدا کردن این الگوها می‌توان در مورد آینده صحبت کرد چراکه این الگوها همیشه در طول تاریخ تکرار شده‌اند و در آینده نیز می‌تواند تکرار شوند. دسته دوم معتقد هستند که پیش‌بینی بازار بورس امکان‌پذیر نیست. این افراد معتقد هستند که شاخص سهام به گذشته ارتباطی ندارد، بلکه اتفاقات آینده است وضعیت شاخص‌ها را در اقتصاد رقم می‌زند. اگر اقتصاد رشد خوبی داشته باشد. سرمایه‌گذارها به امید اینکه این رشد در بازار تأثیر خواهد گذاشت، تمایل به خرید سهم خواهند داشت. این یعنی اینکه تقاضا برای بازار سهام بالا و به همین دلیل شاخص‌های مالی هم افزایش پیدا می‌کند (فطروس و همکاران^{۲۲}، ۲۰۲۱). با این وجود در

پیش بینی نوسانات بازدهی ارزشهای رمزنگاری شده.../باقرزاده سهرابی، ممبینی و مهری نژاد

روندهای مالی، اغلب شرایطی به وجود می‌آید که قوانین را به هم می‌ریزد و پیش‌بینی‌ها را دشوار می‌سازد.

همان‌گونه که ملاحظه شد ادبیات تحقیق در مورد امکان پیش‌بینی دقیق قیمت در بازارهای مالی بسیار محتاطانه است و معتقد است که با توجه به ماهیت پویا و بشدت نوساناتی بازارهای مالی امکان ارائه مدل‌های دقیق پیش‌بینی در این بازارها وجود ندارد. اما علی‌رغم وجود این مسئله هنوز حجم وسیعی از ادبیات تحقیق به دلیل اهمیت موضوع پیش‌بینی به بررسی و ارائه روش‌های پیش‌بینی در این بازارها اختصاص دارند.

حسن و ناص (۲۰۰۶) از روش مارکوف پنهان برای پیش‌بینی قیمت سهام در بازار سهام استفاده کردند. آن‌ها از سری‌های زمانی قیمت‌های آغازین، آخرین قیمت، بیشترین قیمت و کمترین قیمت در هرروز از سال ۲۰۰۲ تا ۲۰۰۴ برای آموزش مدل استفاده کردند و از داده‌های سه ماه بعد نیز برای تست مدل استفاده نمودند. سپس دقت پیش‌بینی خود را با استفاده از MAPE به دست آورده و نتایج را با دقت پیش‌بینی به روش شبکه‌های عصبی مصنوعی مقایسه کردند که نتایج پیش‌بینی بهبود دقت پیش‌بینی به وسیله HMM را نشان می‌دهد. حسن و ناص (۲۰۰۹) مدلی ترکیبی متشکل از مارکوف پنهان، شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک برای پیش‌بینی رفتار بازارهای مالی ارائه دادند. آن‌ها از روش شبکه‌های عصبی برای مرتب‌سازی و تبدیل قیمت‌های روزانه سهام به ورودی‌های مدل مارکوف پنهان استفاده نمودند. بر اساس نتایج کارایی این مدل از روش‌های سنتی بسیار بالاتر بوده است. گوپتا و هینگرا (۲۰۱۲) از مدل مخفی مارکوف برای پیش‌بینی قیمت بسته‌شده سهام فردا در بازار هند استفاده کرده‌اند. مدل پیشنهادی HMM Map است که حداکثر احتمال قیمت فردا را پیش‌بینی می‌کند. مقایسه دقت پیش‌بینی این روش با شبکه‌های عصبی مصنوعی نشان از بهبود دقت پیش‌بینی با استفاده از این روش بود. الغیب (۲۰۱۴) در تحقیقی به بررسی شاخص بورس اوراق بهادار هند پرداخت و دقت پیش‌بینی مدل مارکوف مخفی را با دقت پیش‌بینی الگوریتم نزدیک‌ترین همسایه مقایسه نمود. آن‌ها در نتیجه‌گیری خود بیان کردند که HMM نسبت به نزدیک‌ترین همسایه بسیار حرفه‌ای‌تر عمل می‌کند. ماروتی و همکاران (۲۰۱۹) در پژوهش بازدهی بازار سهام نیویورک را با استفاده از روش مارکوف پنهان و نیمه پنهان از ۲۰۰۳ تا ۲۰۱۶ مورد بررسی قرار داده است. بر اساس نتایج عملکرد این مدل‌ها در پیش‌بینی شاخص این بازار موفق عمل کرده است. کائو (۲۰۱۹) در مطالعه مدل مارکوف پنهان چندلایه برای تحلیل رفتار بین بازار و پیش‌بینی روند، پرداخته است. در این پژوهش یک رویکرد جدید مدل مارکوف پنهان چندلایه همراه پنهان برای تحلیل رفتار سلسله مراتبی

بین بازار را پیشنهاد می‌کند. نتایج تجربی ۱۱ سال داده از دو نوع بازار (بازار سهام و بازار ارز) ۱۳ کشور نشان می‌دهد که روش پیشنهادی پژوهش از چهار معیار دیگر بهتر است. شوی و همکاران (۲۰۲۰) قیمت رمز ارز لایت کوین را در سال ۲۰۱۷ با استفاده از یک روش ترکیبی بر اساس مدل مارکوف خاکستری پیش‌بینی کرده‌اند. بر اساس نتایج عملکرد روش پیشنهادی ۷۸ درصد می‌باشد. لی و همکاران (۲۰۲۳) مطالعه یک مدل فازی مبتنی بر مدل مارکوف پنهان (HMM) را برای پیش‌بینی سری‌های زمانی مورد استفاده قرار دادند. در این پژوهش برای بررسی کارایی روش پیشنهادی از اطلاعات مربوط به سهام بازار نیویورک، استانبول و بیت کوین استفاده شده است. بر اساس نتایج عملکرد مدل در همه بازارها از روش‌های فازی بدون مارکوف پنهان ضعیف‌تر است.

روش کار

همان‌گونه که در قسمت‌های قبل گفته شد به دلیل کارایی مارکوف پنهان در پیش‌بینی در این قسمت مبانی و چارچوب این مدل معرفی می‌گردد.


زنجیره مارکوف

زنجیره مارکوف یک مدل تصادفی است که دنباله‌ای از رویدادها یا حالت‌ها را نشان می‌دهد. در تجزیه و تحلیل خود، ما به‌طور خاص بر زنجیره‌های مارکوف مرتبه اول تمرکز خواهیم کرد که به ویژگی مارکوف پایبند هستند.

فرض کنید $S = \{S_1, S_2, \dots, S_n\}$ مجموعه همه حالت‌های ممکن باشند و $X = \{X_k | X_k \in S, k = 1, \dots, T\}$ سری زمانی حالت‌ها باشد. ویژگی مارکوف بیان می‌کند که برای هر $k \geq 0$ و حالت‌های $X_0, \dots, X_k$:

$$P(X_{k+1} = S_j | X_k = S_i, X_{k-1}, \dots, X_0) = P(X_{k+1} = S_j | X_k = S_i) \quad (۱)$$

به عبارت دیگر، احتمال انتقال به یک حالت خاص S_j در مرحله زمانی $k + ۱$ فقط به حالت فعلی S_i در مرحله زمانی k بستگی دارد و نه به هیچ حالت قبلی. این ویژگی به ما اجازه می‌دهد تا توزیع احتمال زنجیره مارکوف را در هر مرحله زمانی آینده منحصراً بر اساس حالت فعلی آن محاسبه کنیم. به‌طور رسمی، یک زنجیره مارکوف مرتبه اول با مجموعه حالت‌های S و یک ماتریس احتمال انتقال $A = [a_{ij}]$ تعریف می‌شود، که در آن a_{ij} احتمال انتقال از حالت S_i به حالت S_j را در یک مرحله نشان می‌دهد.



شکل ۱: نمونه‌ای از زنجیره مارکوف با سه حالت

عناصر ماتریس انتقال باید محدودیت‌های تصادفی استاندارد را برآورده کنند:

$$\begin{aligned} 0 \leq a_{ij} \leq 1 \quad \forall i, j \\ \sum_{j=1}^n a_{ij} = 1 \quad \forall i \end{aligned}$$

فرض کنید بردار حاوی احتمالات بودن در هر حالت در زمان k باشد، سیستم مطابق با

زیر تکامل می‌یابد:

$$x_{k+1}^T = x_k^T A \quad (۲)$$

ما به توزیع اولیه احتمالات به‌عنوان $\pi = \{\pi_1, \dots, \pi_n\}$ اشاره می‌کنیم.

مدل‌های پنهان مارکوف


مدل ارائه‌شده در بالا به‌طور ضمنی فرض می‌کند که هر حالت با یک رویداد قابل مشاهده (فیزیکی) مطابقت دارد. زنجیره‌های مارکوف ابزار ارزشمندی برای مدل‌سازی داده‌های متوالی در حوزه‌های مختلف هستند. با این حال، بسیاری از سناریوهای دنیای واقعی شامل حالات زیربنایی هستند که مشاهدات را تحت تأثیر قرار می‌دهند اما مستقیماً قابل مشاهده نیستند. این محدودیت منجر به توسعه مدل‌های مارکوف پنهان شد که مدل اصلی زنجیره مارکوف را با معرفی حالت‌های پنهان یا غیرقابل مشاهده که بر داده‌های مشاهده‌شده تأثیر می‌گذارند، گسترش می‌دهند.

فرآیند حالت پنهان یک HMM یک زنجیره مارکوف است، که در آن هر حالت یک مشاهده با توزیع احتمال مشخصی تولید می‌کند که فقط به خود حالت بستگی دارد.

فرض کنید $O = \{O_k | O_k \in O, k = 1, \dots, T\}$ دنباله مشاهده‌شده است، که در آن O مجموعه مشاهدات ممکن است. حالت‌های پنهان طبق معادله ۲ تکامل می‌یابند.

احتمال منتشرشده نماد $o \in O$ توسط حالت S_i با تابع احتمال انتشار $b_i(o) \rightarrow b_i(o)$ توصیف شده است. $[0, 1], \forall i$

هم‌دربخش جاری و هم‌دربخش بعدی، به ماتریس احتمال انتشار $B = \{b_{ij} = b_i(o_j)\}$ اشاره می‌کنیم.



شکل ۲: نمونه‌ای از زنجیره مارکوف مخفی با دو حالت و دو خروجی محتمل

کاربردهای HMM مسائل و راه‌حل‌های رایج

رایج‌ترین مشکلاتی که با استفاده از HMM ها تحلیل می‌شوند عبارت‌اند از: مسئله ارزیابی، مشکل رمزگشایی و مشکل تخمین پارامتر. این مسائل و راه‌حل‌های مربوط به آن‌ها به‌طور گسترده در ادبیات مطالعه و مستند شده‌اند. در پاراگراف‌های بعدی به بررسی اجمالی این مسائل و راه‌حل‌های آن‌ها می‌پردازیم.

الف) مساله ارزیابی: مسئله ارزیابی در HMM ها شامل محاسبه احتمال یک توالی مشاهده شناخته‌شده با توجه به مدل است. به‌طور خاص، با توجه به HMM با پارامترهای π ، A ، و B ، و یک دنباله مشاهده‌شده O ، می‌خواهیم $P(O|\pi, A, B)$ را محاسبه کنیم.

ب) مسئله رمزگشایی: مسئله رمزگشایی شامل تعیین محتمل‌ترین توالی حالت‌های پنهان با توجه به یک دنباله مشاهده و مدل است. با توجه به HMM با پارامترهای π ، A و B ، و یک دنباله مشاهده‌شده O ، می‌خواهیم دنباله حالت پنهان X را پیدا کنیم که $P(X|O, \pi, A, B)$ را به حداکثر می‌رساند. راه‌حل مسئله رمزگشایی معمولاً با استفاده از الگوریتم ویتربی مورد بررسی قرار می‌گیرد.

ج) مسئله تخمین پارامتر: مسئله تخمین پارامتر در HMM ها شامل تنظیم پارامترهای مدل برای به حداکثر رساندن احتمال یک دنباله مشاهده‌شده است. با توجه به دنباله مشاهده O ، می‌خواهیم مقادیر بهینه را برای پارامترهای π ، A و B که حداکثر $P(O|\pi, A, B)$ می‌کنند، تخمین بزنیم.

راه‌حل این مساله معمولاً با استفاده از الگوریتم پسرو که به نام الگوریتم Baum-Welch نیز شناخته می‌شود، پرداخته می‌شود. الگوریتم Baum-Welch یک پیاده‌سازی خاص از الگوریتم بیشینه‌سازی امید (EM) است که متناسب با آن برای HMM ها طراحی شده است. به‌طور مکرر سه مرحله اصلی را انجام می‌دهد: پیشرو، پسرو و مرحله به‌روزرسانی. در گام پیشرو، الگوریتم با توجه به

پیش بینی نوسانات بازدهی ارزشهای رمزنگاری شده.../بازر زاده سهرابی، ممبینی و مهری نژاد

دنباله مشاهده شده تا آن نقطه، احتمال قرار گرفتن در یک حالت خاص را در هر مرحله زمانی محاسبه می کند. این مساله ارزیابی است که قبلاً توضیح داده شد.

در گام پسرو، الگوریتم احتمال مشاهده قسمت باقیمانده از دنباله را از یک حالت معین در هر مرحله زمانی محاسبه می کند. این روش پیشرو را با محاسبه متغیر پسرو، که با $\beta_k(i)$ نشان داده می شود، تکمیل می کند، که نشان دهنده احتمال قرار گرفتن در حالت S_i در زمان k و مشاهده دنباله باقی مانده از زمان $k + 1$ تا پایان است. متغیر پسرو برای هر مرحله زمانی k و حالت S_i به صورت بازگشتی محاسبه می شود. در مرحله مقداردهی اولیه، متغیر پسرو برای مرحله زمانی نهایی به صورت:

$$\beta_T(i) = 1, \forall i$$

پرسش های پژوهش

سؤال اول: کدام یک از دومدل مارکوف پنهان و گارچ مارکوف در پیش بینی قیمت بیت کوین موفق تر است؟

سؤال دوم: کدام یک از دومدل مارکوف پنهان و گارچ مارکوف در پیش بینی قیمت اتریوم موفق تر است؟

پیاده سازی و ارائه نتایج

پیاده سازی

در مطالعه ما، از سه تابع خاص ارائه شده توسط Statistics and Machine Learning Toolbox در MATLAB برای آموزش و آزمایش HMM استفاده شد: `hmmtrain`, `hmmdecode` and `fitgmdist`.

این مدل در دو سناریوی مبتنی بر قیمت های روزانه و بازده تاریخی سهام که به صورت عمومی در **یاهو فاینانس**^{۲۳} در دسترس هستند، اطلاعات مورد استفاده برای پیش بینی دو رمز ارز اتریوم و بیت کوین از تاریخ ۲۰۲۲/۱۲/۱۷ تا ۲۰۲۳/۱۲/۱۷ بوده است. که از این مجموع داده ها ۸۰ درصد آن برای آموزش بوده است و ۲۰ درصد برای آزمایش استفاده شده است. هر مشاهده در مجموعه داده ما شامل سه مقدار متمایز است که نشان دهنده تغییرات کسری روزانه، کسری زیاد و کسری پایین قیمت است.

$$O_{k1} = \left(\frac{close-open}{open}, \frac{high-open}{open}, \frac{open-low}{open} \right) \quad (3)$$

$$O_{k2} = \left(\frac{garchclose-garchopen}{garchopen}, \frac{garchhigh-garchopen}{garchopen}, \frac{garchopen-garchlow}{garchopen} \right) \quad (4)$$

$$O_k := (fracClose, fracHigh, fracLow) \quad (5)$$

ارائه O_k یک ارائه سه‌بعدی است که از مقادیر واقعی تشکیل شده است. از آنجایی که احتمال حدس زدن هر مقدار واقعی از نظر ریاضی صفر است، لازم است مشاهدات گسسته شوند. تعداد نقاط استفاده‌شده برای گسسته سازی در جدول (۱) مشخص شده است.

ما از لبه‌های دینامیکی برای گسسته سازی استفاده کردیم: در هر آموزش، حداکثر و حداقل مقادیر fracChange ، fracHigh و fracLow محاسبه می‌شود. سپس سه بردار بافاصله خطی برای لبه‌ها ایجاد کردیم که به‌عنوان کمترین مقدار از $\min$ و به‌عنوان بالاترین مقادیر $\max$ مقادیر استفاده کردیم. درنهایت، به هر مقدار گسسته، شاخص مربوط به آن را در ارائه لبه‌ها اختصاص دادیم.

جدول ۱: تعداد نقاط گسسته برای هر بعد

متغیر	تعداد نقاط
fracChange	۱۵
fracHigh	۳
fracLow	۳

آموزش

در طول آموزش‌های اولیه، چهار حالت پنهان زیرین در نظر گرفته می‌شود، که در آن هر حالت خروجی‌هایی تولید می‌کند که توسط یک GMM با چهار جزء نشان داده می‌شود. سپس مدل با تغییر مقادیر، دوباره آموزش داده می‌شود. پارامترهای این GMM ها با استفاده از تابع MATLAB fitgmdist برآورد شد که مدل را با استفاده از الگوریتم انتظار بیشینه‌سازی (EM) بهینه می‌کند. پارامترهای اولیه GMM از طریق خوشه‌بندی k-means به دست می‌آیند. تابع چگالی احتمال حاصل به‌عنوان تخمین اولیه برای ماتریس انتشار عمل می‌کند. علاوه بر این، یک توزیع یکنواخت از احتمالات به‌عنوان تخمین اولیه برای ماتریس انتقال اختصاص یافته است. داده‌های آموزشی برای HMM با استفاده از رویکرد پنجره رولینگ^{۲۴} ساخته شده است. در این رویکرد، هر دنباله مشاهده مدت‌زمان ثابتی از ۱۰ روز را در برمی‌گیرد. به این مدت‌زمان به‌عنوان تأخیر^{۲۵} اشاره می‌گردد. پنجره به‌صورت تدریجی در طول دوره آموزشی جابه‌جا می‌شود: دنباله اول مشاهدات را از نقطه زمانی اولیه ثبت می‌کند، درحالی‌که هر دنباله بعدی مشاهدات جدید را با لغزاندن پنجره به مدت یک روز ترکیب می‌کند. سپس مجموعه داده به‌عنوان ورودی به تابع MATLAB hmmtrain ارائه می‌شود. این تابع از الگوریتم Baum-Welch برای تخمین ماتریس‌های انتقال و انتشار استفاده می‌کند. این تخمین‌ها با حدس‌های اولیه که قبلاً بحث شد، مقداردهی اولیه می‌شوند.

پیش‌بینی نوسانات بازدهی ارزش‌های رمزنگاری شده.../بازر زاده سهرابی، ممبینی و مهری نژاد

پیش‌بینی

در ادامه مرحله آموزش، با پیش‌بینی قیمت بسته روزانه سهام برای بازه‌های زمانی مختلف، اقدام به آزمایش مدل خود کردیم. برای هرروز d در دوره هدف، فرآیند پیش‌بینی شامل مراحل زیر است:

(۱) ما آخرین $9 = latency - 1$ مشاهدات موجود را در نظر گرفتیم. این مشاهدات نشان‌دهنده ۹ روز قبل است.

(۲) سپس، هر خروجی ممکن برای روز جاری d اضافه‌شده و یک دنباله ۱۰ روزه ایجاد گردیده است. این دنباله اکنون شامل ۹ مشاهدات تاریخی و یک مشاهده بالقوه برای روز بعد است. احتمالات n_{fc}, n_{fh}, n_{fl} برای روز جاری وجود دارد.

(۳) احتمال تولید هر دنباله از مدل آموزش‌دیده محاسبه می‌شود. درنهایت، مشاهده با بیشترین احتمال انتشار به‌عنوان پیش‌بینی برای روز بعد انتخاب می‌گردد.

در موارد خاص، ممکن است شرایطی پیش بیاید که احتمال انتشار مشاهدات تاریخی، همراه با هر مشاهدات فرضی، ۰ یا بسیار نزدیک به ۰ شود. این می‌تواند به دلیل خطاهای عددی یا محدودیت‌های ذاتی مدل رخ دهد. باین‌حال، می‌توان دریافت که ترکیب یک پنجره پویا می‌تواند عملکرد مدل را افزایش دهد. برای پرداختن به این موضوع، الگوریتم پیش‌بینی به این صورت تغییر یافته است: اگر بالاترین احتمال به‌دست‌آمده ۰ باشد، الگوریتم پیش‌بینی تکرار می‌شود درحالی‌که به‌تدریج تأخیر یک روز کاهش می‌یابد. با کاهش تأخیر، هدف یافتن راه‌حلی مناسب است که در آن احتمالات منتشرشده غیر صفر باشد. این روند کاهش تأخیر به‌طور مکرر تکرار می‌شود تا زمانی که راه‌حلی پیدا شود، درحالی‌که اطمینان حاصل می‌شود که توالی تاریخی به‌اندازه کافی طولانی باقی می‌ماند. در این سناریو، حداقل شرط چهار روز برای دنباله تاریخی تعیین شده است.

ارائه نتایج

چندین معیار برای ارزیابی عملکرد مدل‌ها استفاده می‌شود. یکی از معروف‌ترین این روش‌ها، میانگین درصد خطای مطلق (MAPE) است که از تفاضل قیمت‌های بسته شدن واقعی و پیش‌بینی شده محاسبه می‌شود.

$$MAPE = \frac{1}{n_p} \sum_{i=1}^{n_p} \frac{|p_i - c_i|}{c_i} \cdot 100\% \quad (7)$$


در روز i ، p_i قیمت و یا بازده بسته شدن سهام پیش‌بینی شده، c_i قیمت یا بازدهی واقعی بسته شدن سهام، و n_p تعداد کل پیش‌بینی‌ها است که به‌نوعی دقت پیش‌بینی را برای هرروز جدای از بحث

روند آن نشان می‌دهد. پیش‌بینی حرکت قیمت برای یک روز به‌خودی‌خود یک کار چالش‌برانگیز است. دستیابی به دقت در پیش‌بینی چند روز متوالی حتی دشوارتر می‌شود و اغلب به قلمرو غیرممکن نزدیک می‌شود. با شناخت جهت بالقوه پیش‌بینی افزایش یا کاهش ارزش سهام در طول روز، یک معیار ارزیابی جدید به نام دقت پیش‌بینی جهت (DPA) معرفی می‌گردد. DPA درصد پیش‌بینی‌های جهت‌گیری صحیح را اندازه‌گیری می‌کند و اطلاعات ارزشمندی در مورد دقت مدل ارائه می‌دهد. یا به عبارتی نشان می‌دهد که این مدل به چه میزان در تشخیص روند حرکتی با روند واقعی دقت داشته است.


$$DPA = \frac{1}{n_p} \sum_{i=1}^{n_p} \delta(\text{sgn}(p_i - s_i), \text{sgn}(c_i - s_i)) \cdot 100\% \quad (8)$$

در معادله (۸)، n_p تعداد کل پیش‌بینی‌ها، δ تابع دلتای کرونکر، p_i قیمت یا بازده بسته شدن سهام پیش‌بینی‌شده، c_i قیمت یا بازدهی بسته شدن واقعی، و s_i قیمت باز شدن سهام است. بنابراین برای ارزیابی مدل‌های پیش‌بینی از دو معیار DPA و MAPE استفاده می‌شود.

در شکل (۳) نمودار کندل استیک با مقادیر قیمتی بسته‌شده رمز ارز اتریوم برای داده‌های تست ارائه شده است. همچنین شکل (۴) مقادیر واقعی و پیش‌بینی‌شده بازدهی بسته‌شده رمز ارز اتریوم برای داده‌های تست نشان می‌دهد. این اشکال به‌وضوح نشان می‌دهند که الگوریتم پیشنهادی توانسته از بین ۷۸ مورد داده توانسته جهت حرکت سهام را در ۵۱ روز به‌درستی پیش‌بینی کرده است. به عبارت دیگر $DAP = 65.38\%$ و $MAPE = 1.76\%$ است. که نشان از قدرت مناسب پیش‌بینی مدل ساده مارکوف پنهان است.




شکل ۳: نمودار کندل استیک با مقادیر قیمتی بسته‌شده سهام ETH



شکل ۴: مقادیر واقعی و پیش‌بینی‌شده بازدهی قیمت بسته‌شده سهام ETH


پیش بینی نوسانات بازدهی ارزهای رمزنگاری شده.../باقرزاده سهرابی، ممبینی و مهری نژاد

سپس و همان گونه که بحث شد در ادامه نوسانات بازدهی توسط گارچ مدل سازی می شود و این بار بازدهی بر اساس مدل سازی این نوسانات شبیه سازی می شود و به عبارتی ریسک تغییرات بازدهی نیز در مدل آورده می شود. مقادیر واقعی و پیش بینی شده نوسانات بازدهی رمز ارز اتریوم در شکل (۵) آمده است. بر اساس نتایج الگوریتم روند قیمت سهام را برای ۷۸ روز پیش بینی نموده که از این تعداد جهت حرکت نوسانات قیمت سهام را در ۷۱ مورد (یا به عبارت دیگر ۹۱.۰۲٪) درست تشخیص داده است. از این رو به کارگیری قیمت سهم منجر به دستیابی به $DAP = 91.02\%$ و $MAPE = 2.30\%$ شده است. بنابراین مدل سازی نوسانات رمز ارز اتریوم باعث بهبود عملکرد شاخص DAP به اندازه ۲۵ درصد شده است اما دقت پیش بینی به معنای یکسان بودن قدر مطلق مقدار پیش بینی با مقدار واقعی در قیاس با مدل مارکوف ساده کمی بدتر شده است.




شکل ۵: مقادیر واقعی و پیش بینی شده نوسانات قیمت سهام ETH

در شکل (۶) نمودار کندل استیک با مقادیر قیمتی بسته شده رمز ارز بیت کوین برای داده های تست ارائه شده است. همچنین شکل (۷) مقادیر واقعی و پیش بینی شده قیمت بسته شده رمز ارز بیت کوین برای داده های تست نشان می دهد. بر اساس نتایج و محاسبات پژوهش الگوریتم پیشنهادی توانسته از بین ۷۸ مورد داده توانسته جهت حرکت سهام را در ۶۰ روز به درستی پیش بینی کرده است. به عبارت دیگر $DAP = 76.92\%$ و $MAPE = 1.43\%$ است.




شکل ۶: نمودار کندل استیک با مقادیر قیمتی بسته شده سهام BTC



شکل ۷: مقادیر واقعی و پیش‌بینی‌شده بازدهی قیمت بسته‌شده سهام BTC

سپس و همان‌گونه که بحث شد در ادامه نوسانات قیمت توسط مدل گارچ مدل‌سازی می‌شود و این بار قیمت بر اساس مدل‌سازی این نوسانات شبیه‌سازی می‌شود و به عبارتی ریسک تغییرات قیمت نیز در مدل آورده می‌شود. مقادیر واقعی و پیش‌بینی‌شده نوسانات قیمت رمز ارز بیت کوین که در شکل (۸) آمده است، مؤید این است که الگوریتم روند قیمت سهام را برای ۷۸ روز پیش‌بینی نموده و از این تعداد جهت حرکت قیمت سهام را در ۶۴ مورد ۸۲ درصد درست تشخیص داده است. از این‌رو به‌کارگیری نوسانات قیمت رمز ارز منجر به دستیابی به $DAP = 82\%$ و $MAPE = 5/5\%$ شده است. برای رمز ارز بیت کوین نیز مانند رمز ارز اتریوم مدل ترکیبی توانایی بهتر در درست پیش‌بینی کردن جهت حرکت نوسانات قیمت داشته است و توانسته است ۵ درصد این شاخص را بهبود بخشد اما نکته مهمی که برای بیت کوین وجود دارد این است که قدر مطلق دقت به معنی دقیق پیش‌بینی کردن مقادیر مطلق نوسانات قیمت عملکرد آن به‌طور معنی‌داری بدتر شده است. لذا برای بیت کوین به‌کارگیری روش ترکیبی باعث بدتر شدن دقت قدر مطلق مقادیر می‌شود. لذا مدل مارکوف پنهان ساده به نظرمی‌رسد عملکرد بهتری در زمینه پیش‌بینی قدر مطلق مقادیر برای این رمز ارز داشته است.



شکل ۸: مقادیر واقعی و پیش‌بینی‌شده نوسانات قیمت سهام BTC

نتیجه‌گیری

بازار ارزهای دیجیتال طی سال‌های اخیر با وجود نوسان بودن، توجه گسترده‌ای از سوی سرمایه‌گذاران جلب کرده است. به همین دلیل، پژوهش‌های بسیاری به بررسی این بازار و ارائه مدل‌های پیش‌بینی

پیش‌بینی نوسانات بازدهی ارزش‌های رمزنگاری شده.../بافر زاده سهرابی، ممبینی و مهری نژاد

برای کاهش زیان سرمایه‌گذاران و افزایش کارایی سرمایه‌گذاری پرداخته‌اند. در این پژوهش، پیش‌بینی قیمت دو رمز ارز بزرگ، بیت‌کوین و اتریوم، که حدود ۶۰ درصد از ارزش کل بازار را تشکیل می‌دهند، با استفاده از مدل‌های ترکیبی انجام شده است. داده‌های روزانه این رمز ارزها در بازه زمانی سال‌های ۲۰۲۲ تا ۲۰۲۳ مورد تحلیل قرار گرفته است. روش مارکوف پنهان (HMM) به‌عنوان روش پایه پیش‌بینی در این پژوهش انتخاب شده است. با توجه به نوسانات شدید بازار رمز ارزها، عدم در نظر گرفتن این نوسانات ممکن است نتایج پیش‌بینی را با چالش مواجه کند. بنابراین، ابتدا نوسانات قیمت با استفاده از مدل‌های گارچ مدل‌سازی و سپس در پیش‌بینی مارکوف پنهان به کار گرفته شده است. نتایج پیش‌بینی با استفاده از دو معیار دقت جهت‌گیری (DAP) و خطای مطلق میانگین درصدی (MAPE) ارزیابی شده است.

در مورد اتریوم، مدل مارکوف ساده، دقت DAP برابر ۶۵.۳۸٪ و MAPE برابر ۱۱.۷۶٪ را نشان داد. پس از افزودن نوسانات از طریق مدل گارچ، دقت DAP به ۹۱.۰۲٪ افزایش یافت، اما دقت قدر مطلق پیش‌بینی (MAPE) به ۲.۳۰٪ کاهش یافت. در مورد بیت‌کوین، مدل مارکوف ساده دقت DAP برابر ۷۶.۹۲٪ و MAPE برابر ۱۱.۴۳٪ را ارائه داد. پس از ترکیب مدل گارچ، دقت DAP به ۸۲٪ افزایش یافت، اما MAPE به ۵.۵٪ افزایش یافت.

بنابراین استفاده از مدل ترکیبی گارچ-مارکوف پنهان برای هر دو رمز ارز بهبود چشمگیری در تشخیص روندهای حرکتی ایجاد کرده است. با این حال، مدل مارکوف ساده در پیش‌بینی دقیق مقادیر مطلق عملکرد بهتری داشته است. این نتایج نشان می‌دهد که بسته به هدف تحلیل (تشخیص روند یا پیش‌بینی مقدار دقیق)، می‌توان از مدل مناسب استفاده کرد.

منابع

- ۱) فطرس، م.، میری، ا. و ایوب میری. (۲۰۲۰). مقایسه بهینه‌سازی سبد سرمایه‌گذاری برای سرمایه‌گذاران در سطوح مختلف ریسک‌گریزی در بورس تهران با الگوریتم‌های فرا ابتکاری، پیشرفت‌های مالی و کاربردهای ریاضی. (۱۵)۱
<https://doi.org/10.22034/amfa.2019.1870129.1235>
- ۲) نادری، ح.، قنبری، م.، جمشیدی، ب. و عاش نادمی. (۲۰۲۴). مدل‌های مارکوف تغییر نیمه پارامتریک بهبودیافته برای پیش‌بینی قیمت سهام. پیشرفت‌های مالی و کاربردهای ریاضی.
- 3) <https://doi.org/10.22034/amfa.2021.1923297.1565>
- 4) Adebisi, A. A., Adewumi, A.O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. Journal of Applied Mathematics, 2014, 1-7
- 5) Al Galib, A., Alam, M. and Rahman, R.M. (2014) Prediction of stock price based on hidden Markov model and nearest neighbour algorithm', Int. J. Information and Decision Sciences, Vol. 6, No. 3, pp.262–292.
- 6) Antonello Maruotti, Antonio Punzo, Luca Bagnato, Hidden Markov and Semi-Markov Models with Multivariate Leptokurtic-Normal Components for Robust Modeling of Daily Returns Series, Journal of Financial Econometrics, Volume 17, Issue 1, Winter 2019, Pages 91–117, <https://doi.org/10.1093/jjfinec/nby019>
- 7) Atsalakis, G. S., & Valavanis, K. P. (2009a). Forecasting stock market short-term trends using a neuro-fuzzy based methodology. Expert Systems with Applications, 36(7), 10696-10707 .
- 8) Bildirici, M., Ersin, O. O. (2009). "Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul stock exchange" Expert Systems with Application.
- 9) Cao, W., Zhu, W., & Demazeau, Y. (2019). Multi-Layer Coupled Hidden Markov Model for CrossMarket Behavior Analysis and Trend Foreca.
- 10) & ,P J ,Nobrega ,F.L .V ,Souza ,C .R ,Brasileiro ,C .R ,teCavalcan A :Markets Financial and Intelligence Computational .(۲۰۱۶) .I.L .A ,Oliveira .۲۱-۱۹۴ ,۵۵ ,Applications with Systems Expert .Directions Future and Survey
- 11) Gupta, A., & Dhingra, B. (2012, March). Stock market prediction using hidden Markov models. In Engineering and Systems (SCES), 2012 Students Conference on (pp. 1-4). IEEE.
- 12) Hassan, M. R., & Nath, B. (2005, September). Stock market forecasting using hidden Markov model: a new approach. In Intelligent Systems Design and

- Applications, 2005. ISDA'05. Proceedings. 5th International Conference on (pp. 192-196). IEEE.
- 13) Hassan, M. R. (2009). A combination of hidden Markov model and fuzzy model for stock market forecasting. *Neurocomputing*, 72(16), 3439-3446.
- 14) JAROSLAV LAJOS,(2011)" Computer Modeling Using Hidden Markov Model Approach Applied to the financial "Doctoral dissertation, Oklahoma State University,United states of America
- 15) Li, J., Pedrycz, W., Wang, X. et al. A Hidden Markov Model-based fuzzy modeling of multivariate time series. *Soft Comput* 27, 837–854 (2023). <https://doi.org/10.1007/s00500-022-07623-6>
- 16) Padmaja Dhenuvakonda, R. Amandan, N. Kumar,(2020, November), "Stock Price Prediction Using Artificial Neural Networks " ,*Journal of Critical Reviews* ,Vol 7, pp.846-850.
- 17) Chishti Zubair Muhammad ,Gubareva Mariya ,Patel Ritesh (2024) the Assessing ,cryptos green and index attention environment cryptocurrency between connectedness ,assets financial green and ,cryptos energy and Business International in Research ,Finance ,۷۰ Volume.<https://doi.org/10.1016/j.ribaf.2024.102339>.
- 18) uncertainty policy economic of impact Asymmetric ,Sharma Kumar Anil ,Simran of Journal The , proachap NARDL from Evidence :market cryptocurrency on EconomicAsymmetries ,<https://doi.org/10.1016/j.jeca.2023.100298>.
- 19) H.-M. ,Shou Forecasting" ,T.-Y. ,Zhou and .D.-D ,Li ,X.-Z ,Wang , stochastic the integrating model hybrid a :currency digital of trends price the and Theory :Systems Grey,"methods chain Markov grey and index .۰۰۶۸-۲۰۱۹-۱۲-GS/۱۰.۱۱۰۸/org/doi//:https .۴۵-۲۲ .pp ,۱ .No ۱۱ .Vol ,Application
- 20) Tabar, S., Sharma, S., & Volkman, D. (2020). A new method for predicting stock market crashes using classification and artificial neural networks. *International Journal of Business and Data Analytics*, 1(3), 203-217.
- 21) Tkáč, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38(1), 788-804.
- 22) Wang, S. (2020, February). The Prediction of Stock Index Movements Based on Machine Learning. In *Proceedings of the 2020 12th International Conference on Computer and Automation Engineering* (pp. 1-6).

23) Yan, D., Zhou, Qi, Wang, J., & Zhang, N. (2017). Bayesian regularization neural network based on artificial intelligence optimization. International Journal of Production Research, 55(8), 2266-2287

یادداشت‌ها:

-
- 1 Cavalcante & at al
 - 2 Padmaja
 - 3 Yan et al
 - 4 Adebiyi & at al
 - 5 Li et al
 - 6 Wang
 - 7 Tabar et al
 - 8Shou et al
 - 9 Maroutti et al
 - 10 Hasan
 - 11 Atsalakis & Valavanis
 - 12 Tkáč & Verner
 - 13 Hasan & Nath
 - 14 Hidden Markov model
 - 15 Naderi et al
 - 16 Gupta & Dhingra
 - 17 LAJOS
 - 18 Asadullah Al Galib
 - 19 Bildirici et al
 - 20 Patel et al
 - 21 Simaran & Sharma
 - 22 Fetros et al
 - 23 Yahoo finance
 - 24 rolling window
 - 25 Latency

Predicting Volatility of Cryptocurrency Returns Using Hidden Markov Models & Garch Markov

Maryam Bagherzadeh Sohrabi¹

Receipt: 02/05/2024 Acceptance: 04/01/2025

Hossein Mombeini²

Safieh Mehrenejad³

Abstract

According to theoretical literature, accurate prediction in the digital currency market plays a fundamental role in risk management, portfolio optimization, market efficiency, and better market management. It assists investors in making more informed decisions, managing risk, and maximizing returns. Based on the importance of the ever-growing cryptocurrencies Bitcoin and Ethereum, this research has predicted their performance and yield fluctuations using a combination of Hidden Markov Models and the Garch-Markov method, based on daily data. Based on the prediction results, the accuracy of Ethereum's performance prediction using the Hidden Markov Model method with the DAP = 65.38%, and with the MAPE = 1.76%. Additionally, the performance of prediction indices based on the Hidden Markov Garch model is DAP = 91.02% and MAPE = 2.30%. For the cryptocurrency Bitcoin, the prediction results indicate that the model's accuracy based on the DAP = 76.92%, and based on the MAPE = 1.43%. After employing the GARCH-Markov method, the model's performance in predicting trends has improved by 5%, but the absolute value index has reached 5/5%. Consequently, using the combined GARCH-Markov hidden method for both cryptocurrencies significantly enhance the accuracy of trend prediction.

Keywords

Hidden Markov Model, GARCH method, Ethereum, Bitcoin

1-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. Maryamsohrabi98@yahoo.com

2-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. (Corresponding Author) h.mombeini@gmail.com

3-Department of Financial Management, Central Tehran Branch, Islamic Azad University, Tehran, Iran. S.mehrenejad@gmail.com