



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری  
دوره ۱۵ / شماره ۱ (پیاپی ۵۸) / تابستان ۱۴۰۵  
صفحه ۶۷۱ تا ۶۹۴

## پیش‌بینی و مقایسه روند بازدهی قیمتی با استفاده از روش مارکوف پنهان و روش گارچ- مارکوف مطالعه موردی بیت کوین و اتریوم و سولانا و بی ان بی

مریم باقرزاده سهرابی

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

حسین ممبینی

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

صفیه مهری نژاد

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

تاریخ دریافت: ۱۴۰۳/۰۶/۲۶ تاریخ پذیرش: ۱۴۰۳/۰۸/۰۲

### چکیده

پیش‌بینی روند حرکتی رمز ارزها، می‌تواند به سرمایه‌گذاران در تصمیم‌گیری آگاهانه‌تر، جلوگیری از ضرر، مدیریت ریسک و حداکثرسازی بازده کمک کند. لذا در این پژوهش برای چهار رمز ارز بیت کوین، اتریوم، بی ان بی و سولانا پیش‌بینی روند حرکتی بازدهی با استفاده از دو روش مارکوف پنهان و گارچ مارکوف پنهان در طی بازه یکسال ۲۰۲۲ تا ۲۰۲۳ صورت گرفت. براین اساس برای پیش‌بینی دقیق‌تر روند بازدهی، در ابتدا با استفاده از مدل‌های معروف گارچ نوسانات بازدهی مدل‌سازی شد سپس با بکاربردن نوسانات بازدهی به عنوان ورودی، مدل مارکوف پنهان تخمین زده شده است و در نهایت برای مقایسه و نتیجه‌گیری در مورد دقت پیش‌بینی روند بازدهی از معیار DAP استفاده شد. براساس نتایج، برای رمز ارز بیت کوین دقت مدل با روش مارکوف پنهان ساده ۷۶ درصد است اما دقت مدل با روش ترکیبی ۸۲ درصد شده است. برای رمز ارز اتریوم مارکوف پنهان توانسته است در ۶۵ درصد موارد روند حرکتی بازدهی را درست پیش‌بینی کند. اما براساس روش ترکیبی جهت حرکتی بازدهی قیمتی تا ۹۱ درصد درست پیش‌بینی شده است. همچنین برای رمز ارز بی ان بی نتایج حاکی از آن است که پیش‌بینی روند حرکتی بازدهی با مدل مارکوف پنهان ساده ۶۶ درصد است اما پیش‌بینی روند با استفاده از روش ترکیبی به ۷۴ درصد می‌رسد. در نهایت برای رمز ارز سولانا با روش مارکوف پنهان ساده دقت پیش‌بینی روند حرکتی بازدهی به ۵۵ درصد می‌رسد که با استفاده از مدل ترکیبی و وارد کردن نوسانات در آن دقت پیش‌بینی روند به ۷۴ درصد رسیده است. بنابراین و به طور کلی استفاده از روش ترکیبی گارچ- مارکوف پنهان برای هر چهار رمز ارز باعث بهبود تشخیص روند حرکتی به طور معنی‌داری می‌شود.

**واژه‌های کلیدی:** معیار DAP، گارچ- مارکوف پنهان، رمز ارز، پیش‌بینی روند.

## ۱- مقدمه

بازار رمز ارزها از سال ۲۰۰۹ تا کنون با رشد بسیار سریعی مواجه شده است و همزمان مورد توجه بسیاری از سرمایه‌گذاران قرار گرفته است. ارزش این بازار از عدد صفر در سال ۲۰۰۹ به حدود ۲ تریلیون دلار به مشارکت حدود چهار صد میلیون سرمایه‌گذار در سال ۲۰۲۴ رسیده است که حاکی از رشد سریع این بازار است. کارکرد بازار سهام بیشتر در اقتصاد کارکرد تامین مالی کسب و کارهای مختلف است و ارزش سهام نیز نماینده ارزش دارایی‌ها و عملیات مالی و اقتصادی یک شرکت است اما در بازار ارزهای رمز نگاری شده، قراردادهای هوشمند اجتماعی بر بستر تکنولوژی انقلاب زنجیره‌های بلوکی<sup>۱</sup> معامله می‌شود که به نوعی جایگزین برای پول‌های رایج<sup>۲</sup> در دنیا به شمار می‌رود و ارزش خود را نیز بیشتر از هر چیز از تکنولوژی منحصر بفرد خود گرفته‌اند که بستر و زمینه را برای اجرا دیگر قراردادهای اجتماعی هوشمند فراهم می‌کنند (سیف‌الدین آموس<sup>۳</sup>، ۲۰۰۸). در کنار توجه به ویژگی بازار ارزهای رمز نگاری شده موضوع دیگر تفاوت این بازار احتمال صفر شدن سرمایه‌گذاری است. از سال ۲۰۰۸ تا ۲۰۲۴ براساس آمارهای وب‌سایت معتبر کوین مارکت کپ<sup>۴</sup> حدود چهار هزار رمز ارز در این بازار از بین رفته و ضررهای زیادی را به سرمایه‌گذاران تحمیل کرده است. تفاوت مهم دیگر رمز ارزها، این است که همه بازارهای مالی علی‌رغم سطح متفاوت قانون‌گذاری سطحی از قوانین و مقررات بر معاملات و کارهای روزمره آنها وارد است اما در این بازارها دولت‌ها عملاً ابزاری برای مداخله و قانون‌گذاری در اختیار ندارند و البته مهمترین تفاوت تکنولوژی زنجیره‌های بلوکی با دیگر تکنولوژی‌های انقلابی در همین عدم توانایی دولت در دخالت در این قراردادهاست و به نحوی عدم تمرکز با ذات این بازارها و ارزش آنها در ارتباط است و جدای از بحث قانون‌گذاری برای این رمز ارزها، این پول‌ها در تحلیل آخر دنبال جایگزین شدن با پول‌های ملی کشورهای مختلف هستند و در حقیقت تهدیدی برای اجرای نقش‌های سنتی دولت‌ها به‌طور عمومی و تهدید برای نقش آقایی دولت‌ها در بازار پول به‌طور خاص هستند (تاپ اسکات و تاپ اسکات<sup>۵</sup>، ۲۰۱۸). بنابراین این مسئله بسیاری از دولت‌ها را به سمت اجرای قوانین محدودکننده یا غیرقانونی اعلام کردن معاملات این رمز ارزها سوق داده است و در نهایت همه اینها باعث ایجاد فضای بسیار ریسکی تر در قیاس با دیگر بازارهای مالی شده است.

براساس بررسی‌ها صورت گرفته در مورد اینکه چه رمز ارزهایی با چه ویژگی‌هایی احتمال صفر شدن (مردن) دارند مطالعه جدی صورت نگرفته است اما نکته مهمی که وجود دارد این است که تمام این ارزها بدون استثنا حجم معاملات و ارزش بازار در آنها بسیار کم بوده است (لی و همکاران<sup>۶</sup>، ۲۰۲۳). پس نکته‌ای که این رمز ارزها دارند این است که به هر دلیلی موفق به جلب اعتماد فعالین بازار رمز ارزها نشده‌اند و همین عدم موفقیت در جلب اعتماد افراد بیشتر باعث عدم شکل‌گیری شبکه حمایتی از این رمز ارزها شده است و در نهایت ارزش آنها در یک مدت چند ساله صفر شده است. از سوی دیگر نکته‌ای که باید بدان توجه شود این است که در این بازار

<sup>1</sup> Blockchain

<sup>2</sup> Fiat currency

<sup>3</sup> Amous

<sup>4</sup> www. CoinMarketcap.com

<sup>5</sup> Topscott & Topscott

<sup>6</sup> Li et al

در برهه های مختلف رمز ارزهایی با حجم معاملات زیاد مانند بیت کوین، اتریوم، سولانا و بی ان بی علی رغم از دست رفتن ۲۰ تا ۹۰ درصد ارزششان، اما به دلیل درگیر شدن منافع تعداد بیشتری از افراد و شکل گیری شبکه ای از افراد و اعتماد به این رمز ارزها در نهایت بارها ارزش خود را دوباره بدست آورده اند. بنابراین نکته اول برای جلوگیری از صفر شدن ارزش این رمز ارزها باید مدنظر قرار دادن حجم معاملات و ارزش بازار باشد.

نکته مهم دیگر که سرمایه گذاران در این بازار باید بدان توجه داشته باشند مسئله نوسانات غیرمتعارف در این بازارها است هم از نظر شدت نوسانات و هم از نظر تکرار آن است. بیت کوین<sup>۱</sup> به عنوان رهبر این بازار از سال ۲۰۰۹ تا کنون ۷ بار سقوط بالای ۵۰ درصد را تجربه کرده است. همچنین در این بازه ۱۳ سقوط بالای ۲۰ درصد را تجربه کرده است که در قیاس با بازار سهام آمریکا و بعد از بحران بزرگ ۱۹۲۹ (که پنج بار سقوط های بیشتر از ۲۰ درصد را تجربه کرده است) دارای نوسانات شدیدتر و همزمان تناوب بیشتر در این نوسانات است. بنابراین اهمیت پیش بینی در این بازار بسیار تعیین کننده تر از بازارهای دیگر مالی است زیرا که در این نوسانات برای سرمایه گذاران سودها و ضررهای بسیار وجود دارد. لذا در قیاس با دیگر بازارها اهمیت نوسانات و مدنظر قرار دادن آن در پیش بینی قیمت بسیار بیشتر است و همزمان در تفاوت با بازارهای مالی دیگر، کار پیش بینی دقیق در این بازار را بسیار سخت کرده است. بنابراین عدم توجه به اهمیت نوسانات در بازار رمز ارزها و اقتباس روش هایی معمولی که در بازارهای دیگر مالی از آن استفاده می شود بدون توجه به این خصلت می تواند تا حد زیادی دقت نتایج بدست آمده را کاهش دهد (شو و همکاران<sup>۲</sup>، ۲۰۲۰). لذا بکارگیری منطق پیش بینی به عنوان یکی از ابزارهای مدیریت ریسک در این بازار با مشکلات جدی تری مواجه است و باید دقت بیشتری در این باره شود.

## ۲- مبانی نظری و پیشینه

بازار رمز ارزها نوپاترین بازار مالی در سطح جهان است که ارزش معاملاتی دارایی های آن براساس تکنولوژی منحصر بفرد زنجیره بلوکی و امید جایگزینی این رمز ارزها با ارزهای رایج دنیا تعیین می شود. این رمز ارزها به مانند پول های واقعی چهار وظیفه اصلی پول ها را در دنیای واقع تا حد زیادی می توانند انجام دهند همزمان به دلیل تکنولوژی خاص بکارگرفته شده در آن ارزش آنها با چاپ آن توسط دولت یا هر قدرت دیگر نمی تواند تحت تاثیر قرار گیرد. در بستر این قراردادها همه چیز در ابتدا کار مشخص است. از نحوه استخراج ارزها تا حجم آنها و اگر به هر دلیلی در مفاد قرارداد هریک از رمز ارزها تغییراتی ایجاد شود در شبکه انحراف یا به اصطلاح فورک<sup>۳</sup> ایجاد می شود و یک رمز ارز جدید بوجود می آید که با رمز ارز اولیه و آن قرارداد کاملاً متفاوت است. لذا در اینجا و این ویژگی در کنار حل دیگر مشکلات فنی مربوط به پول های دیجیتال مانند خرج دوباره و ... تا حد زیادی موضوع اعتماد که در بانک های مرکزی دولتی به کرات نقض می شود حل می شود. به عبارتی این رمز ارزها نوعی واسطه مبادله هستند که تمام ویژگی های پول های معمولی را به طور کلی دارند (البته واسطه پرداختن بودن به دلیل نوسانی بودن بیشتر آنها در ابتدا تا حد غیرقابل دستیابی بود که تولد رمز ارزهای ثابت، معروف به استیبل

<sup>1</sup> Bitcoin

<sup>2</sup> Shou et al

<sup>3</sup> Fork

کوبین‌ها تا حدی این مشکل را نیز حل کرده است) اما عرضه آن برخلاف پول‌های رایج که توسط بانک مرکزی و به دلخواه آن تعیین می‌شود، براساس قواعد از پیش تعیین شده و غیر قابل تخطی است. بنابراین عرضه بی‌ثبات و رشد عرضه مدوام پول‌های معمولی ارزش این پول‌ها را به طور مداوم در معرض کاهش قرار می‌دهد که این به نوعی خود یعنی دامن زدن به مشکل تورم که البته موضوع تازه‌ای در سطح جهانی نیست (سیف‌الدین آموس ۲۰۱۸ و تاپ اسکات و تاپ اسکات، ۲۰۱۸).

در این فضا و همراه با تحولات تکنولوژی و حل مسائل فنی در مورد ایجاد سیستم مناسب، در واکنش به بحران مالی ۲۰۰۸ و چاپ بی‌رویه پول توسط بانک‌های مرکزی، ساتوشی با انتشار مقاله معروف خود در سال ۲۰۰۹ از ایجاد بیت‌کوبین به عنوان اولین رمز ارز دنیا مبتنی بر تکنولوژی زنجیره بلوکی خبر داد. عرضه این رمز ارز محدود است و فرایند استخراج، تایید تراکنش‌ها و همچنین فرایند نظارت بر آن نیز براساس یک کامپیوتر و یک رای تعیین شده است. اهمیت این موضوع در این است که این فرایند استخراج و تعداد زیاد استخراج‌کنندگان در این شبکه به نوعی امکان احاطه هر قدرتی را بر این شبکه از بین می‌برد. در نتیجه شبکه به شکل کاملاً خودجوش و کاملاً غیرمتمرکز امکان استخراج، معاملات و پرداخت‌ها را فراهم می‌آورد (نارایان و همکاران<sup>۱</sup>، ۲۰۱۶). این رمز ارزها عرضه پول را کاملاً براساس قرداد اولیه و خارج از کنترل دولت و هر قدرت متمرکز دیگر نگه می‌دارد. با توسعه این اکوسیستم بسیاری از مشکلات این رمز ارزها (سرعت تراکنش، سرعت نقل و انتقال پول و...) در یک بستر کاملاً غیر متمرکز بدون دخالت دولت‌ها حل شده است به نحوی که سرعت تراکنش آن از سرعت تراکنش بین‌المللی و داخلی بانکی هم بیشتر و هم ارزان‌تر است.

پیش‌بینی دقیق در بازار ارزهای رمزنگاری در مدیریت ریسک و بهینه‌سازی پرتفوی نقش بسزایی ایفا می‌کند. ارزهای رمزنگاری مانند بیت‌کوبین، اتریوم<sup>۲</sup>، بی‌ان‌بی<sup>۳</sup> و سولانا<sup>۴</sup> دارای نوسانات بالا و عدم قطعیت هستند. مدل‌های پیش‌بینی به سرمایه‌گذاران این امکان را می‌دهند تا ریسک‌های مرتبط را ارزیابی و کمیت سنجی کنند و بر اساس آن تصمیمات مناسب درباره تخصیص مناسب پرتفوی اتخاذ کنند. با پیش‌بینی بازدهی آینده، سرمایه‌گذاران قادرند با شناسایی بهترین تعادل بین ریسک و بازده، پرتفوی خود را بهینه‌سازی کنند. همچنین پیش‌بینی دقیق در بازار ارزهای رمزنگاری به کارایی بازار کمک می‌کند و سرمایه‌گذاران در بازار مزیت اطلاعاتی پیدا می‌کند. پیش‌بینی در بازارهای مالی نیز برای رعایت قوانین و نظارت بر بازار حائز اهمیت است (سیماران و شارما<sup>۵</sup>، ۲۰۲۳، پاتل و همکاران<sup>۶</sup>، ۲۰۲۴).

براساس ادبیات نظری، نظریات محققان درباره امکان پیش‌بینی در بازارهای مالی به دو دسته 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 از جهت پیدا کردن باشند، ولی در هر حال الگو می‌باشند و به همین

<sup>1</sup> Narayanan et al

<sup>2</sup> Ethereum

<sup>3</sup> BNB

<sup>4</sup> Solana

<sup>5</sup> Simaran & Sharma

<sup>6</sup> Patel et al

دلیل میتوان بازار مالی را پیش بینی کرد. این افراد معتقد هستند که بررسی روندها و رفتار بازار در گذشته می توانند این الگوها رو مشخص کنند. با پیدا کردن این الگوها می توان در مورد آینده صحبت کرد چرا که این الگوها همیشه در طول تاریخ تکرار شده اند و در آینده نیز می تواند تکرار شوند. دسته دوم معتقد هستند که پیش بینی بازارهای مالی امکان پذیر نیست. این افراد معتقد هستند که حرکت قیمت به گذشته ارتباطی ندارد، بلکه اتفاقات آینده است که وضعیت شاخص ها را در اقتصاد رقم می زند. اگر اقتصادی رشد خوبی داشته باشد. سرمایه گذارها به امید اینکه این رشد در بازار تاثیر خواهد گذاشت، تمایل به خرید سهم خواهد داشت. این یعنی اینکه تقاضا برای بازار سهام بالا و به همین دلیل شاخص های مالی هم افزایش پیدا می کند (فطروس و همکاران<sup>۱</sup>، ۲۰۲۱، سیماران و شارما<sup>۲</sup>، ۲۰۲۳، پاتل و همکاران<sup>۳</sup>، ۲۰۲۴).

حسن و ناص<sup>۴</sup> (۲۰۰۶) از روش مارکوف پنهان برای پیش بینی قیمت سهام در بازار سهام استفاده کردند. آنها از سری های زمانی قیمت های آغازین، آخرین قیمت، بیشترین قیمت و کمترین قیمت در هر روز از سال ۲۰۰۲ تا ۲۰۰۴ برای آموزش مدل استفاده کردند و از داده های سه ماه بعد نیز برای تست مدل استفاده نمودند. سپس آنها داده هایی را که در گذشته بیشترین مطابقت را با داده های مورد نظر داشتند را پیدا کرده و با ضرب نمودن ارزش های آنها تغییرات قیمت را محاسبه نمودند تا قیمت پایانی سهم را در روز بعد پیش بینی نمایند. سپس دقت پیش بینی خود را با استفاده از MAPE به دست آورده و نتایج را با دقت پیش بینی به روش شبکه های عصبی مصنوعی مقایسه کردند که نتایج پیش بینی بهبود دقت پیش بینی به وسیله HMM را نشان می دهد. حسن و ناص<sup>۵</sup> (۲۰۰۹) مدلی ترکیبی متشکل از مارکوف پنهان، شبکه های عصبی مصنوعی و الگوریتم ژنتیک برای پیش بینی رفتار بازار های مالی ارائه دادند. آنها از روش شبکه های عصبی برای مرتب سازی و تبدیل قیمت های روزانه سهام به ورودی های مدل مارکوف پنهان استفاده نمودند. سپس الگوریتم ژنتیک را به منظور بهینه سازی پارامتر های اولیه مدل مارکوف پنهان به کار بردند. آنها با این مدل قیمت تعدادی سهم از بخش ای تی را پیش بینی نمودند و نتایج را با مدل های سنتی مقایسه کردند. براساس نتایج کارایی این مدل از روش های سنتی بسیار بالاتر بوده است. گوپتا و هینگرا<sup>۶</sup> (۲۰۱۲) از مدل مخفی مارکوف برای پیش بینی قیمت بسته شده سهام فردا در بازار هند استفاده کرده اند. مدل پیشنهادی HMM Map است که حداکثر احتمال قیمت فردا را پیش بینی می کند. آنها رهیافت خود را بر روی سهم های مختلف تست کردند و نتایج عملکرد آن را با تعدادی از مطالعات موجود که از شبکه های عصبی مصنوعی استفاده کرده بودند مقایسه کردند. مقایسه دقت پیش بینی این روش با روش های دیگر نشان از بهبود دقت پیش بینی با استفاده از این روش بود. الغیب<sup>۷</sup> (۲۰۱۴) در تحقیقی به بررسی شاخص بورس اوراق بهادار هند پرداخت و دقت پیش بینی مدل مارکوف مخفی را با دقت پیش بینی الگوریتم نزدیکترین همسایه مقایسه نمود. آنها در نتیجه گیری خود بیان کردند که HMM نسبت به نزدیک ترین همسایه، بسیار حرفه ای تر عمل می کند. ماروتی و همکاران<sup>۸</sup> (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. براساس نتایج عملکرد این

<sup>1</sup> Fetros et al

<sup>2</sup> Simaran & Sharma

<sup>3</sup> Patel et al

مدل‌ها در پیش‌بینی شاخص این بازار موفق عمل کرده است. کائو (2019) در مطالعه مدل مارکوف پنهان چند لایه برای تحلیل رفتار بین‌بازار و پیش‌بینی روند، پرداخته است. در این پژوهش یک رویکرد جدید مدل مارکوف پنهان چند لایه همراه پنهان برای تحلیل رفتار سلسله مراتبی بین‌بازار را پیشنهاد می‌کند. نتایج تجربی ۱۱ ساله 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 براساس مدل مارکوف خاکستری پیش‌بینی کرده‌اند. براساس نتایج عملکرد روش پیشنهادی ۷۸ درصد می‌باشد. لی و همکاران (۲۰۲۳) مطالعه‌ای یک مدل فازی مبتنی بر مدل مارکوف پنهان (HMM) را برای پیش‌بینی سری‌های زمانی مورد استفاده قرار می‌گیرد. در این پژوهش برای بررسی کارایی روش پیشنهادی از اطلاعات مربوط به سهام بازار نیویورک، استانبول و بیت کوین استفاده شده است. براساس نتایج عملکرد مدل در همه بازارها از روش‌های فازی بدون مارکوف پنهان ضعیف‌تر است.

### ۳- انتخاب مدل و روش تحقیق

برای پیش‌بینی بازارهای مالی به کمک داده‌های تاریخی، روش‌های مختلفی وجود دارد. در یک طبقه بندی این روش‌ها در دو گروه خطی و غیرخطی قرار می‌گیرند و در نوع دیگر، به روش‌های یادگیری ماشین و آماری دسته بندی می‌شوند اما دسته بندی مناسب، گروه بندی آن‌ها به روش‌های هوشمند و کلاسیک است. در روش‌های پیش‌بینی کلاسیک، فرض بر این است که مقادیر آینده قیمت، روند خطی مقادیر گذشته را دنبال می‌کند و مدل‌های رگرسیونی و آریمای در این دسته جای دارند و در مقابل شبکه‌های عصبی، منطق فازی ماشین‌های بردار پشتیبان و مدل‌های مارکوف و... در دسته روش‌های هوشمند قرار می‌گیرند (کواکانتی و همکاران<sup>۱</sup>، ۲۰۱۶). نتیجه مقایسه‌ها نشان داده است که روش‌های هوشمند با غلبه بر محدودیت‌های موجود در مدل‌های خطی در مقایسه با روش‌های کلاسیک، توانایی بهتر و برای پیش‌بینی، دقت بیشتری دارند (پادماجا<sup>۲</sup>، ۲۰۲۰، بان و همکاران<sup>۳</sup>، ۲۰۱۷ و آدبی و همکاران<sup>۴</sup>، ۲۰۱۴).

هر کدام از این روش‌های هوشمند علی‌رغم وجود ویژگی‌های مناسب دارای محدودیت‌هایی نیز هستند برای نمونه تکنیک شبکه‌های عصبی مصنوعی به عنوان پرکاربردترین این روش‌ها (اتسالاکیس و والاتیس<sup>۵</sup>، ۲۰۰۹، تکاچ و ورتز<sup>۶</sup>، ۲۰۱۶) به دلیل نحوه پیکربندی آن بسیار مسئله محور هستند. مشکل اصلی شبکه‌های عصبی برآزش بیش از حد داده‌ها با در نظر گرفتن نویز می‌باشد و همچنین با تغییر دامنه داده‌ها نیاز به پیکر بندی مجدد دارد (حسن و ناص<sup>۷</sup>، ۲۰۰۵). براین اساس روش‌های جدید تری که ویژگی‌های بهتری دارند در طول زمان توسعه داده شده‌اند. یکی از این روش‌ها که در ادبیات تحقیق به دلیل ویژگی‌های آن در زمینه‌های

<sup>1</sup> Cavalcante & at al

<sup>2</sup> Padmaja

<sup>3</sup> Adebisi & at al

<sup>4</sup> Yan et al

<sup>5</sup> Atsalakis & Valavanis

<sup>6</sup> Tkáč & Verner

<sup>7</sup> Hasan & Nath

مختلف از جمله پیش بینی بازارهای مالی بدان توجه ویژه می شود روش مارکوف پنهان<sup>۱</sup> است. مدل مارکوف پنهان در اواخر دهه ۱۹۶۰ میلادی برای شناسایی صدا معرفی گردید و در حال حاضر به سرعت در حال گسترش دامنه کاربردها می باشد. دو دلیل مهم برای این موفقیت وجود دارد. اول اینکه این مدل از لحاظ ساختار ریاضی بسیار قدرتمند است. دوم اینکه مدل مارکوف پنهان اگر به صورت مناسبی ایجاد شود می تواند برای کاربردهای بسیاری مورد استفاده قرار گیرد (نادری و همکاران<sup>۲</sup>، ۲۰۲۴، حسن و ناص، ۲۰۰۵).

حسن و ناص (۲۰۰۵ و ۲۰۰۶)، گوپتا و هینگرا<sup>۳</sup> (۲۰۱۲) از مدل مارکوف پنهان برای پیش بینی قیمت سهام در بازار های 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. لائوز<sup>۴</sup> (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<sup>۵</sup> (۲۰۱۴) بر کارایی این مدل در پیش بینی بازده سهام در بازار هند تاکید میکنند. لی و همکاران (۲۰۲۳) شو و همکاران (۲۰۲۰)، ماروتی و همکاران (۲۰۱۹) همگی بر قدرت پیش بینی این روش در بازار رمز ارزها تاکید داشته اند.

همچنین در کنار این مسئله توجه به قدرت روش های جدید و ترکیب ویژگی های خوب مدل های مختلف با همدیگر، می تواند دقت مدل ها را افزایش دهد. براین اساس مطالعات جدید سعی بر این دارند که بتوانند مدل های متفاوت را با همدیگر ترکیب کنند و از ویژگی های خوب این روش ها در ترکیب باهم پیش بینی های بهتری را از روند حرکت قیمت ارائه دهند (لی و همکاران<sup>۶</sup>، ۲۳، ونگ<sup>۷</sup>، ۲۰۲۰، تابر و همکاران<sup>۸</sup>، ۲۰۲۰، شو و همکاران<sup>۹</sup>، ۲۰۲۰ ماروتی<sup>۱۰</sup>، ۲۰۱۹، حسن<sup>۱۱</sup>، ۲۰۰۹). بنابراین استفاده از روش های هوشمند جدید و با ویژگی های مناسب و همچنین ترکیب آن با روش های دیگر بنظر می رسد در نهایت بتواند نتایج بهتر و دقیق تری را ارائه نماید.

بازدهی دارایی های مالی دارای سه ویژگی مهم است: نوسان خوشه ای، رابطه نامتقارن، و غیر خطی بودن می باشد. لذا مدل های ناهمسانی واریانس شرطی به دلیل انطباق با این ویژگی ها، در تحقیقات مالی مورد استفاده فراوان قرار گرفته است (بیلدیرچی<sup>۱۲</sup>، 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 مدل-های گارچ به دلیل ویژگیهای خاص این مدل ها در ترکیب با روش های هوشمند است.

<sup>1</sup> Hidden Markov model

<sup>2</sup> Naderi et al

<sup>3</sup> Gupta & Dhingra

<sup>4</sup> LAJOS

<sup>5</sup> Asadullah Al Galib

<sup>6</sup> Li et al

<sup>7</sup> Wang

<sup>8</sup> Tabar et al

<sup>9</sup> Shou et al

<sup>10</sup> Maroutti et al

<sup>11</sup> Hasan


<sup>12</sup> Bildirici et al

## ۳-۱- زنجیره مارکوف

زنجیره مارکوف یک مدل تصادفی است که دنباله‌ای از رویدادها یا حالت‌ها را نشان می‌دهد. در تجزیه و تحلیل خود، ما به طور 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  $X_0, \dots, X_k$ :

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

به عبارت دیگر، احتمال انتقال به یک حالت خاص  $S_j$  در مرحله زمانی  $k + 1$  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. به طور 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:

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

فرض کنید بردار حاوی احتمالات بودن در هر حالت در زمان  $k$  باشد، سیستم مطابق با زیر تکامل می‌یابد:

$$x_{k+1}^T = x_k^T A \quad (2)$$

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

### ۲-۳- مدل های پنهان مارکوف


مدل ارائه شده در بالا به طور ضمنی فرض می کند که هر حالت با یک رویداد قابل مشاهده (فیزیکی) مطابقت دارد. زنجیره های مارکوف ابزار ارزشمندی برای مدل سازی داده های متوالی در حوزه های مختلف هستند. با این حال، بسیاری از سناریوهای دنیای واقعی شامل حالات زیربنایی هستند که مشاهدات را تحت تأثیر قرار می دهند اما مستقیماً قابل مشاهده نیستند. این محدودیت منجر به توسعه مدل های مارکوف پنهان شد که مدل اصلی زنجیره مارکوف را با معرفی حالت های پنهان یا غیرقابل مشاهده که بر داده های مشاهده شده تأثیر می گذارند، گسترش می دهند.

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

فرض کنید  $O = \{O_k | O_k \in O, k = 1, \dots, T\}$  دنباله مشاهده شده است، که در آن  $O$  مجموعه مشاهدات ممکن است. حالت های پنهان طبق معادله ۲ تکامل می یابند.

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

هم در بخش جاری و هم در بخش بعدی، به ماتریس احتمال انتشار  $B = \{b_{ij} = b_i(o_j)\}$  اشاره می کنیم.



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

### ۳-۳- کاربردهای HMM: مسایل و راه حل های رایج

رایج ترین مشکلاتی که با استفاده از HMM ها تحلیل می شوند عبارتند از: مسئله ارزیابی، مشکل رمزگشایی و مشکل تخمین پارامتر. این مسایل و راه حل های مربوط به آن ها به طور گسترده در ادبیات مطالعه و مستند شده اند. در پاراگراف های بعدی به بررسی اجمالی این مسایل و راه حل های آنها می پردازیم.

**الف) مساله ارزیابی:** مسئله ارزیابی در HMM ها شامل محاسبه احتمال یک توالی مشاهده شناخته شده با توجه به مدل است. به طور خاص، با توجه به HMM با پارامترهای  $\pi, A, B$ ، و یک دنباله مشاهده شده  $O$ ، می خواهیم  $P(O|\pi, A, B)$  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  $\pi, A, B$  و یک دنباله مشاهده شده  $O$ ، می‌خواهیم دنباله حالت پنهان  $X$  را پیدا کنیم که  $P(X|O, \pi, A, B)$  را به حداکثر می‌رساند. راه حل مسئله رمزگشایی معمولاً با استفاده از الگوریتم ویتربی مورد بررسی قرار می‌گیرد.

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

راه حل این مساله معمولاً با استفاده از الگوریتم پسر و 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. به طور مکرر سه مرحله اصلی را انجام می‌دهد: پیشرو، پسر و مرحله به روز رسانی. در گام پیشرو، الگوریتم با توجه به دنباله مشاهده شده تا آن نقطه، احتمال قرار گرفتن در یک حالت خاص را در هر مرحله زمانی محاسبه می‌کند. این مساله ارزیابی است که قبلاً توضیح داده شد.

در گام پسر، الگوریتم احتمال مشاهده قسمت باقیمانده از دنباله را از یک حالت معین در هر مرحله زمانی محاسبه می‌کند. این روش پیشرو را با محاسبه متغیر پسر، که با  $\beta_k(i)$  نشان داده می‌شود، تکمیل می‌کند، 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 پسر برای هر مرحله زمانی  $k$  و حالت  $S_i$  به صورت بازگشتی محاسبه می‌شود. در مرحله مقداردهی اولیه، متغیر پسر برای مرحله زمانی نهایی به صورت:  $\beta_T(i) = 1, \forall i$  تنظیم می‌شود.

#### د. مدل‌های مخلوط گاوسی

مدل‌های مخلوط گاوسی (GMMs) مدل‌های احتمالی قدرتمندی هستند که برای نمایش توزیع‌های احتمال پیچیده استفاده می‌شوند. یک GMM یک مجموع وزنی از چندین توزیع گاوسی است که در آن هر جزء نشان دهنده یک زیرجمعیت از داده‌ها است.

هنگامی که یک مشاهده تکی توسط داده‌های متعدد (داده‌های چند متغیره) تشکیل می‌شود، GMM‌ها به عنوان مدل‌های ترکیبی چند متغیره استفاده می‌شوند. هر مولفه ی گاوسی در یک GMM یک توزیع چند متغیره با بردار میانگین و ماتریس کوواریانس خود را نشان می‌دهد. تابع چگالی احتمال یک GMM چند متغیره توسط:

$$p(y) = \sum_{i=1}^K c_i N(y|\mu_i, \Sigma_i) \quad (3)$$

که در آن  $K$  تعداد مولفه‌های گاوسی است،  $c_i$  وزن مرتبط با مولفه  $i$ -ام را نشان می‌دهد و  $N(y|\mu_i, \Sigma_i)$  نشان دهنده توزیع گاوسی چند متغیره با میانگین بردار  $\mu_i$  و ماتریس کوواریانس  $\Sigma_i$  است. وزن‌های  $c_i$  قید  $\sum_{i=1}^K c_i = 1$  را برآورده می‌کنند، اطمینان حاصل می‌کند که احتمالات تا یک جمع می‌شوند. این وزن‌ها سهم هر جزء گاوسی را در توزیع کلی کنترل می‌کنند.

GMM ها به ویژه هنگام مدل سازی داده های چند متغیره پیچیده که حالت ها یا خوشه های متعددی را نشان می دهند مفید هستند، زیرا می توانند ساختار ذاتی و تنوع موجود در داده ها را ثبت کنند. در زمینه مدل های پنهان مارکوف، GMM ها برای مقداردهی اولیه احتمالات انتشار حالات مخفی استفاده می شوند. GMM بر روی مجموعه داده آموزشی قرار می گیرد: الگوریتم آموزشی پارامترهای هر مؤلفه گاوسی، یعنی بردارهای میانگین و ماتریس های کوواریانس را تخمین می زند. این پارامترها برای مقداردهی اولیه احتمالات انتشار حالت های پنهان مربوطه استفاده می شوند.

### پیاده سازی و ارائه نتایج

#### ۴-۱- 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<sup>۱</sup> در دسترس هستند، اطلاعات مورد استفاده برای پیش بینی چهار رمز ارز بیت کوین، اتریوم، بی ان بی و سولانا 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 مجموع داده ها شامل سه مقدار متمایز است که نشان دهنده تغییرات کسری روزانه، کسری زیاد و کسری پایین قیمت است.

$$O_{k1} = \left( \frac{close-open}{open}, \frac{high-open}{open}, \frac{open-low}{open} \right) \quad (4)$$

$$O_{k2} = \left( \frac{garchclose-garchopen}{garchopen}, \frac{garchhigh-garchopen}{garchopen}, \frac{garchopen-garchlow}{garchopen} \right) \quad (5)$$

$$O_k := (fracClose, fracHigh, fracLow) \quad (6)$$

آرایه  $O_k$  یک آرایه سه بعدی 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 استفاده شده برای گسسته سازی در جدول (۱) مشخص شده است.

جدول ۱: تعداد نقاط گسسته برای هر بعد

تعداد نقاط	متغیر
15	FracChange
3	FracHigh
3	FracLow

<sup>1</sup> Yahoo finance

ما از لبه‌های دینامیکی برای گسسته‌سازی استفاده کردیم: در هر آموزش، حداکثر و حداقل مقادیر  $\text{fracChange}$ ،  $\text{fracHigh}$  و  $\text{fracLow}$  محاسبه می‌شود. سپس سه بردار با فاصله خطی برای لبه‌ها ایجاد کردیم که به عنوان کمترین مقدار از  $\text{min}$  و به عنوان بالاترین مقادیر  $\text{max}$  مقادیر استفاده کردیم. در نهایت، به هر مقدار گسسته، شاخص مربوط به آن را در آرایه لبه‌ها اختصاص دادیم.

## ۲-۴-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  $\text{MATLAB fitgmdist}$  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 به عنوان تخمین اولیه برای ماتریس انتشار عمل می‌کند. علاوه بر این، یک توزیع یکنواخت از احتمالات به عنوان تخمین اولیه برای ماتریس انتقال اختصاص یافته است. داده‌های آموزشی برای HMM با استفاده از رویکرد پنجره رولینگ<sup>۱</sup> ساخته شده است. در این رویکرد، هر دنباله مشاهده مدت زمان ثابتی از ۱۰ روز را در بر می‌گیرد. به این مدت زمان بعنوان تاخیر<sup>۲</sup> اشاره می‌گردد. پنجره به صورت تدریجی در طول دوره آموزشی جابه‌جا می‌شود: دنباله اول مشاهدات را از نقطه زمانی اولیه ثبت می‌کند، در حالی که هر دنباله بعدی مشاهدات جدید را با لغزاندن پنجره به مدت یک روز ترکیب می‌کند. سپس مجموعه داده به عنوان ورودی به تابع  $\text{MATLAB hmmtrain}$  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.

## ۵-ارائه نتایج

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

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

(۲) سپس، هر خروجی ممکن برای روز جاری  $d$  اضافه شده و یک دنباله ۱۰ روزه ایجاد گردیده است. این دنباله اکنون شامل ۹ مشاهدات تاریخی و یک مشاهده بالقوه برای روز بعد است. احتمالات  $n_{fL}$ ،  $n_{fH}$ ،  $n_{fC}$  برای روز جاری وجود دارد.

<sup>۱</sup> rolling window

<sup>۲</sup> latency

۳) احتمال تولید هر دنباله از مدل آموزش دیده محاسبه می‌شود. در نهایت، مشاهده با بیشترین احتمال انتشار به عنوان پیش‌بینی برای روز بعد انتخاب می‌گردد.

در موارد خاص، ممکن است شرایطی پیش بیاید که احتمال انتشار مشاهدات تاریخی، همراه با هر مشاهدات فرضی، صفر یا بسیار نزدیک به صفر شود. این می‌تواند به دلیل خطاهای عددی یا محدودیت‌های ذاتی مدل رخ دهد. با این حال، 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 به دست آمده باشد، الگوریتم پیش‌بینی تکرار می‌شود در حالی که به تدریج تأخیر یک روز کاهش می‌یابد. با کاهش تأخیر، هدف یافتن راه حلی مناسب است که در آن احتمالات منتشر شده غیرصفر باشد. این روند کاهش تأخیر به طور مکرر تکرار می‌شود تا زمانی که راه حلی پیدا شود، در حالی که اطمینان حاصل می‌شود که توالی تاریخی به اندازه کافی طولانی باقی می‌ماند. در این سناریو، حداقل شرط چهار روز برای دنباله تاریخی تعیین شده است.

#### ۱-۵- انتخاب رمز ارزها

بازار رمز ارزها بازاری نوپا است که با توجه به اهمیت، توانایی فنی آن و همچنین روند تحولات اقتصادی اجتماعی توانایی این را دارد در قالب ارزهایی با کارایی‌های متنوع، اکوسیستمی را بوجود بیاورد که جایگزین ارزهای جهانشمول امروزی مانند دلار در سطح بین‌المللی و حتی داخل کشورها نیز شود. از زمان معرفی بیت کوین در سال ۲۰۰۹ تا کنون براساس اطلاعات سایت معتبر کوین مارکت کپ که رمز ارزهای مختلف را لیست می‌کند حدود ۱۱ هزار رمز ارز معرفی شده است. لازم به ذکر است حدود ۴۰۰ میلیون سرمایه‌گذار فعال در این بازار نیز وجود دارد (وب سایت کوین جیکو<sup>۱</sup>، ۲۰۲۳).

جدول شماره (۲): تعداد کوین‌های لیست شده در سایت کوین مارکت کپ

تعداد	سال
۷	آوریل ۲۰۱۳
۶۷	ژانویه ۲۰۱۴
۵۰۱	ژانویه ۲۰۱۵
۵۷۲	ژانویه ۲۰۱۶
۶۳۶	ژانویه ۲۰۱۷
۱۳۵۹	ژانویه ۲۰۱۸
۲۰۸۶	ژانویه ۲۰۱۹
۲۴۰۳	ژانویه ۲۰۲۰
۵۱۴۵	ژانویه ۲۰۲۱

<sup>۱</sup> Coin Gecko

تعداد	سال
۸۷۱۴	ژانویه ۲۰۲۲
۸۸۵۶	ژانویه ۲۰۲۳
۱۱۷۰۷	دسامبر ۲۰۲۳

منبع: کوین مارکت کپ

همچنین ارزش بازار این اکوسیستم در سال ۲۰۲۴ حدود ۲ تریلیون دلار است که در اوج خود در نوامبر ۲۰۲۱ به حدود ۳ تریلیون دلار نیز رسید. که از این ۲ تریلیون دلار بیت کوین حدود ۵۵ درصد کل ارزش بازار را دارد، اتریوم حدود ۲۴ درصد ارزش بازار را در اختیار دارند و با دو رمز ارز دیگر یعنی سولانا و بی ان بی از سال ۲۰۲۱ حدود ۸۰ درصد کل ارزش بازار را به خود اختصاص داده اند و بقیه رمز ارزها حدود ۲۰ درصد ارزش بازار را در اختیار دارند که البته از این ۲۰ درصد نیز حدود ۱۰ درصد آن مربوط به استیبل کوین ها<sup>۱</sup> می باشد.




نمودار شماره (۱): ارزش بازار بیت کوین، اتریوم، بی ان بی و سولانا

منبع: سایت کوین مارکت کپ

همچنین براساس متوسط حجم معاملات مربوط به بازار، بیت کوین بیشترین حجم معاملات ۲۴ ساعته را با میانگین حدود بیست میلیارد دلار بعد از آن اتریوم با ده میلیارد دلار، سولانا دو میلیارد دلار و بی ان بی حدود یک و نیم میلیارد دلار در سال ۲۰۲۴ دارند. مجموع میانگین حجم معاملات این چهار رمز ارز از سال ۲۰۲۳ تا ۲۰۲۴ حدود ۳۴ میلیارد دلار می باشد که حدود ۵۲ درصد از کل معاملات بازار رمز ارزها را شامل می شود. بنابراین و همانگونه که ملاحظه می شود این چهار رمز ارز به دلیل حجم معاملات و ارزش بازار آن تقریباً در کنار هم می توانند نمایی دقیق از بازار ارزهای دیجیتالی ارائه نمایند بنابراین به دلیل اهمیت و جامعیت این چهار رمز ارز این پژوهش پیش بینی روند بازدهی را برای آنها انجام می دهد.

<sup>۱</sup> StableCoin



نمودار شماره (۲): حجم معاملات ۲۴ ساعته بیت کوین، اتریوم، بی ان بی و سولانا

منبع: سایت کوین مارکت کپ

## ۲-۵- پیش بینی روند


پیش‌بینی حرکت قیمت برای یک روز به خودی خود یک کار چالش برانگیز 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 (روند) را اندازه‌گیری می‌کند و اطلاعات ارزشمندی در مورد دقت مدل در پیش‌بینی روند حرکتی بازدهی ارائه می‌دهد. یا به عبارتی نشان می‌دهد که این مدل به چه میزان در تشخیص روند حرکتی با روند واقعی دقت داشته است.

$$DPA = \frac{1}{n_p} \sum_{i=1}^{n_p} \delta(\text{sgn}(p_i - s_i), \text{sgn}(c_i - s_i)) \cdot 100\% \quad (7)$$

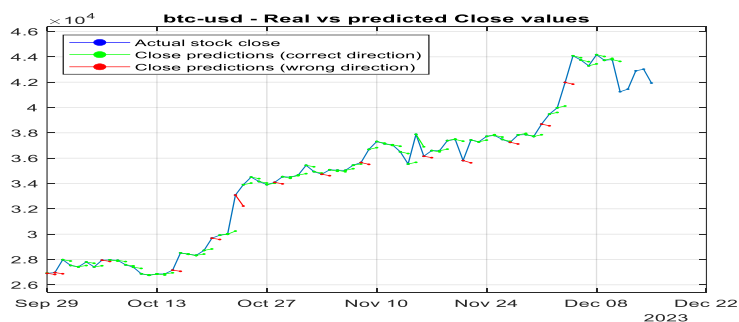
در معادله (۷)،  $n_p$  تعداد کل پیش‌بینی‌ها،  $\delta$  تابع دلتای کرونکر،  $p_i$  قیمت یا بازده بسته شدن سهام پیش‌بینی شده،  $c_i$  قیمت یا بازدهی بسته شدن واقعی، و  $s_i$  قیمت باز شدن سهام است. بنابراین برای ارزیابی مدل‌های پیش‌بینی از دو معیار DPA و MAPE استفاده می‌شود.

### ۱-۲-۵- بیت کوین

در شکل (۳) نمودار کندل استیک با مقادیر قیمتی بسته شده رمز ارز بیت کوین برای داده‌های تست ارائه شده است. همچنین شکل (۴) مقادیر واقعی و پیش‌بینی شده بازدهی بسته شده رمز ارز بیت کوین برای داده‌های تست نشان می‌دهد. براساس نتایج و محاسبات پژوهش الگوریتم پیشنهادی از بین ۷۸ مورد داده توانسته جهت حرکت سهام را در ۶۰ روز به درستی پیش‌بینی کند. عبارت دیگر  $DAP = 76.92\%$  می‌باشد. بنابراین روش مارکوف پنهان توانسته است روند حرکتی بازدهی را در حدود ۷۷ درصد موارد درست پیش‌بینی کند.




شکل ۳: نمودار کندل استیک با مقادیر قیمتی بسته شده سهام BTC



شکل ۴: مقادیر واقعی و پیش‌بینی شده بازدهی قیمت بسته شده سهام BTC


سپس و همانگونه که بحث شد در ادامه نوسانات بازدهی توسط مدل گارچ مدل سازی می‌شود و این بار بازدهی براساس مدل سازی این نوسانات شبیه سازی می‌شود و به عبارتی ریسک تغییرات بازدهی نیز در مدل آورده می‌شود. مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی رمز ارز بیت کوین آورده شده در شکل (۵)، مویده این است که الگوریتم ترکیبی روند بازدهی سهام را برای ۷۸ روز پیش‌بینی نموده و که از این تعداد جهت حرکت بازدهی سهام را در ۶۴ مورد ۸۲ درصد درست تشخیص داده است. از اینرو بکارگیری نوسانات بازدهی رمز ارز منجر به دستیابی به عملکرد ۸۲ درصدی شده است. در نهایت اینکه برای رمز ارز بیت کوین مدل ترکیبی توانایی بهتر در درست پیش‌بینی کردن جهت حرکت نوسانات بازدهی داشته است و توانسته است ۵ درصد این شاخص را بهبود ببخشد.




شکل ۵: مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی قیمت سهام BTC

### ۲-۲-۵- اتریوم

در شکل (۶) نمودار کندل استیک با مقادیر قیمتی بسته شده رمز ارز اتریوم برای داده های تست ارائه شده است. همچنین شکل (۷) مقادیر واقعی و پیش‌بینی شده بازدهی بسته شده رمز ارز اتریوم برای داده های تست نشان می دهد. این اشکال به وضوح نشان می دهند که الگوریتم پیشنهادی توانسته از بین ۷۸ مورد داده جهت حرکت رمز ارز (روند حرکتی بازدهی) را در ۵۱ روز به درستی پیش‌بینی نماید. بعبارت دیگر  $DAP = 65.38\%$  است. که نشان از قدرت مناسب پیش بینی مدل ساده مارکوف پنهان است.




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



شکل ۷: مقادیر واقعی و پیش‌بینی شده بازدهی قیمت بسته شده سهام ETH

سپس و همانگونه که بحث شد در ادامه نوسانات بازدهی توسط گارچ مدل سازی می‌شود و این بار بازدهی براساس مدل سازی این نوسانات شبیه سازی می‌شود و به عبارتی ریسک تغییرات بازدهی نیز در مدل آورده می‌شود. مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی رمز ارز اتریوم در شکل (۸) آمده است. براساس نتایج الگوریتم روند بازدهی سهام را برای ۷۸ روز پیش‌بینی نموده که از این تعداد جهت حرکت نوسانات بازدهی سهام را در ۷۱ مورد (یا بعبارت دیگر ۹۱.۰۲٪) درست تشخیص داده است. بنابراین استفاده از مدل ترکیبی نسبت به مدل ساده مارکوف منجر به دستیابی به  $DAP = 91.02\%$  شده است. بنابراین استفاده از مدل ترکیبی نسبت به مدل ساده مارکوف پنهان باعث بهبود عملکرد پیش‌بینی روند بازدهی اتریوم به اندازه ۲۵ درصد شده است.




شکل ۸: مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی قیمتی رمز ارز ETH


### ۳-۲-۵- بی ان بی

در شکل (۹) نمودار کندل استیک با مقادیر قیمتی بسته شده پیش‌بینی شده رمز ارز BNB برای داده‌های تست ارائه شده است.

همچنین شکل (۱۰) مقادیر واقعی و پیش‌بینی بازدهی شده قیمت بسته شده BNB برای داده‌های تست نشان می‌دهد. همانطور که از این دو شکل دیده می‌شود الگوریتم پیشنهادی در اینجا از بین ۷۸ مورد جهت حرکت رمز ارز (روند حرکت) را در ۵۲ روز به درستی پیش‌بینی کرده است. بعبارت دیگر  $DAP = 66.66\%$  است.




شکل ۹: نمودار کندل استیک با مقادیر قیمتی بسته شده پیش‌بینی شده سهام BNB



شکل ۱۰: مقادیر واقعی و پیش‌بینی شده قیمت بسته شده سهام BNB

اما شکل (۱۱) مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی BNB را نشان می‌دهد. در اینجا نیز الگوریتم ترکیبی توانسته جهت حرکت نوسانات بازدهی را در ۵۸ مورد (یا عبارت دیگر ۷۴.۳۴٪) درست تشخیص دهد. بنابراین با بکارگیری مدل ترکیبی DAP تقریباً ۸ درصد افزایش یافته است. لذا در اینجا نیز بکارگیری مدل ترکیبی قدرت پیش‌بینی روند حرکت سهم را ارتقا داده است.



شکل ۱۱: مقادیر واقعی و پیش‌بینی شده بازدهی سهام BNB


#### ۴-۲-۵- سولانا

شکل (۱۲) نمودار کندل استیک با مقادیر قیمتی بسته شده پیش‌بینی شده رمز ارز SOL برای داده‌های تست نشان می‌دهد.


همچنین شکل (۱۳) مقادیر واقعی و پیش‌بینی شده بازدهی قیمت بسته شده رمز ارز SOL برای داده‌های تست نشان می‌دهد. با دقت در این دو شکل می‌توان دریافت که الگوریتم پیشنهادی توانسته از بین ۷۸ مورد جهت حرکت بازدهی رمز ارز را در ۴۳ روز به درستی پیش‌بینی کرده است. عبارت دیگر  $DAP = 55.12\%$  است. که در میان چهار رمز ارز پایین‌ترین میزان دقت در پیش‌بینی روند بوده است.

در نهایت شکل (۱۴) مقادیر واقعی و پیش‌بینی شده نوسانات بازدهی رمز ارز SOL را نشان می‌دهد. این شکل مبین آن است که الگوریتم روند بازدهی را در ۵۸ مورد (یا عبارت دیگر ۷۴.۳۴٪) درست تشخیص داده است.


یعنی با بکارگیری مدل ترکیبی  $DAP = 74.34\%$  شده است. بنابراین با بکارگیری مدل ترکیبی به جای مدل ساده مارکوف به منظور پیش‌بینی روند سهم عملکرد تقریباً ۱۹ درصد افزایش یافته است.



شکل ۱۲: نمودار کندل استیک با مقادیر قیمتی بسته شده سهام SOL



شکل ۱۳: مقادیر واقعی و پیش‌بینی شده قیمت بسته شده سهام SOL



شکل ۱۴: مقادیر واقعی و پیش‌بینی شده بازدهی قیمت سهام SOL

## ۶- نتیجه گیری

بازار رمز ارزها در طی سالیان اخیر علی رغم جوان بودن آن بشدت مورد توجه سرمایه گذاران قرار گرفته است به همین دلیل مطالعات جدید تمایل به بررسی دقیق تر این بازار نوپا دارند. از سوی دیگر و همان گونه که بیان شد مهمترین ویژگی بازار رمز ارزها خصلت نوسانای آن است. لذا شدت و عمق این نوسانات به مراتب اهمیت پیش بینی در این بازارها را نسبت به دیگر بازارهای مالی نشان می دهد و بخصوص اینکه خود استفاده از پیش بینی در این بازارها می تواند به عنوان عاملی در جهت مدیریت ریسک بهتر عمل کند. اما نکته ای که باید توجه داشت این است که شدت و تناوب غیر متعارف این نوسانات عملاً کارایی خیلی از مدل ها را در ارائه نتایج با دقت بسیار زیاد ناکام گذاشته است. براین اساس بنظر می رسد پژوهشگران به جای پیش بینی دقیق بازدهی و قیمت (شامل پیش بینی روند و مقدار دقیق قیمت) باید بر مسئله پیش بینی روند بازدهی متمرکز شوند. که خود این مسئله به دلیل نوسانات زیاد و عمق آن (در صورت دقت بالا آن) عملاً امکان ایجاد بازدهی مناسب برای سرمایه گذاران را نیز فراهم می کند. در نتیجه این پژوهش نیز به دلیل اهمیت بکارگیری مدل های پیش بینی برای کارا تر کردن و جلوگیری از ضرر سرمایه گذاران، برای چهار رمز ارز بیت کوین، اتریوم، بی ان بی و سولانا پیش بینی روند حرکتی بازدهی را با استفاده از روش های هوشمند ترکیبی در طی بازه یکسال ۲۰۲۲ تا ۲۰۲۳ انجام داد.

براساس نتایج، برای رمز ارز بیت کوین نتایج مربوط به پیش بینی با روش مارکوف پنهان ساده حاکی از آن است که دقت مدل براساس شاخص  $DAP = 76.92\%$  است. و در روش ترکیبی  $DAP = 82\%$  شده است. برای رمز اتریوم دقت پیش بینی با شاخص  $DAP = 65.38\%$  و در روش ترکیبی  $DAP = 91.02\%$  همچنین برای رمز ارز بی ان بی نتایج مارکوف پنهان ساده  $DAP = 66\%$  و در روش ترکیبی  $DAP = 74\%$  میباشد. در نهایت برای رمز ارز سولانا نتایج پیش بینی با روش مارکوف پنهان ساده  $DAP = 55\%$  و در روش ترکیبی  $DAP = 74\%$  میباشد. بنابراین به طور کلی استفاده از روش ترکیبی گارچ- مارکوف پنهان برای هر چهار رمز ارز باعث بهبود تشخیص روند حرکتی به طور معنی داری می شود. لذا بر این اساس می توان گفت این شاخص ترکیبی در پیش بینی روند حرکت رمز ارزها موفق است.

بنابراین پژوهش نشان می دهد که استفاده از مدل های پیش بینی هوشمند ترکیبی، به ویژه روش ترکیبی گارچ- مارکوف پنهان، در پیش بینی روند بازدهی چهار رمز ارز بیت کوین، اتریوم، بی ان بی و سولانا بسیار مؤثر است. نتایج به دست آمده نشان از افزایش قابل توجه دقت پیش بینی با استفاده از روش ترکیبی نسبت به روش مارکوف پنهان ساده دارد. به طور خاص، افزایش دقت در پیش بینی اتریوم (از  $65.38\%$  به  $91.02\%$ ) بسیار چشمگیر است. این نتایج حاکی از آن است که با توجه به ویژگی های منحصر به فرد بازار رمز ارزها، لزوم استفاده از مدل های پیش بینی پیچیده تر و ترکیبی جهت افزایش دقت پیش بینی امری ضروری است. در واقع، اتکا به روش های معمول پیش بینی که در بازارهای سنتی مالی به کار گرفته می شوند، بدون توجه به ماهیت متفاوت بازار رمز ارزها، منجر به کاهش دقت پیش بینی خواهد شد. بنابراین، بکارگیری مدل های پیشرفته تر و ترکیبی راهکاری مؤثر در مدیریت ریسک و افزایش دقت پیش بینی قیمت رمز ارزها می باشد.

## فهرست منابع

- Adebiyi, 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
- 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.
- Ammous, S.(2018). *The Bitcoin Standard: The Decentralized Alternative to Central Banking*, Wiley publication.
- 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>
- 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 .
- 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*.
- Cao, W., Zhu, W., & Demazeau, Y. (2019). Multi-Layer Coupled Hidden Markov Model for CrossMarket Behavior Analysis and Trend Foreca.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L.F., Nobrega, J. P., & Oliveira, A. L.I. (۲۰۱۶). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, ۵۵, ۱۹۴-۲۱
- Fetroos, M, Miri, E and Ayoub Miri.(2020). Comparison of Portfolio Optimization for Investors at Different Levels of Investors' Risk Aversion in Tehran Stock Exchange with Meta-Heuristic Algorithms, *Advances in Mathematical Finance and Applications*. 1(15). <https://doi.org/10.22034/amfa.2019.1870129.1235>
- 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.
- 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.
- Hassan, M. R. (2009). A combination of hidden Markov model and fuzzy model for stock market forecasting. *Neurocomputing*, 72(16), 3439-3446.
- JAROSLAV LAJOS,(2011)" Computer Modeling Using Hidden Markov Model Approach Applied to the financial "Doctoraldissertation, Oklahoma State University,United states of America
- 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>
- Naderi, H, Ganbari, M, Jamshidi, B and Aash nademi. (2024). The improved Semi-parametric Markov switching models for predicting Stocks Prices, *Advances in Mathematical Finance and Applications*, <https://doi.org/10.22034/amfa.2021.1923297.1565>
- Padmaja Dhenuvakonda, R. Amandan, N. Kumar,(2020, November), "Stock Price Prediction Using Artificial Neurl Net works " ,*Journal of Critical Reviews* ,Vol 7, pp.846-850.
- ,Ritesh Patel, Mariya Gubareva, Muhammad Zubair Chishti(2024) Assessing the connectedness between cryptocurrency environment attention index and green cryptos, energy cryptos, and green financial ,assets ,*Research in International Business and Finance* Volume ,۷۰. <https://doi.org/10.1016/j.ribaf.2024.102339>.
- :Simran, Anil Kumar Sharma, Asymmetric impact of economic policy uncertainty on cryptocurrency market Evidence from NARDL approach, *The Journal of Economic Asymmetries* ,<https://doi.org/10.1016/j.jeca.2023.e00298>

- Tapscott, D & Tapscott, A. (2018), *Blockchain Revolution: How the Technology Behind Bitcoin Is Changing Money, Business, and the World* Hardcover, Portfolio Publication.
- :Shou, M.-H., Wang, Z.-X., Li, D.-D. and Zhou, Y.-T. (۲۰۲۱), "Forecasting the price trends of digital currency :a hybrid model integrating the stochastic index and grey Markov chain methods", *Grey Systems Theory and Application*, Vol. ۱۱ No. ۱, pp. ۲۲-۴۵. <https://doi.org/10.1108/GS-12-2019-0068>
- 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.
- Tkáč, M., & Verner, R. (2016). Artificial neural networks in business: Two decades of research. *Applied Soft Computing*, 38(1), 788-804.
- 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).
- 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  
<https://coinmarketcap.com>

## **Forecasting and comparing the trend of price return using hidden Markov method and Garch-Markov method, case study of Bitcoin, Ethereum, Solana and BNB**

**Maryam Bagherzadeh sohrabi**

Financial Management Group, Central Tehran Branch, Islamic Azad University, Tehran, Iran  
Maryamsohrabi98@yahoo.com

**Hossein Mombeini**

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

**Safieh Mehrenejad**

Financial Management Group, Central Tehran Branch, Islamic Azad University, Tehran, Iran  
S.mehrenejad@gmail.com

### **Abstract**

Predicting the movement of cryptocurrencies can help investors make more informed decisions, prevent losses, manage risk and maximize returns. Therefore, in this research, for the four cryptocurrencies Bitcoin, Ethereum, BNB and Solana, the movement trend of returns was predicted using hidden Markov and hidden Garch Markov methods during the one-year period from 2022 to 2023. Therefore, in order to predict the efficiency trend more accurately, at first, the efficiency fluctuations were modeled using the famous Garch models, then by using the efficiency fluctuations as input, the hidden Markov model was estimated, and finally, to compare and draw conclusions about The DAP criterion Based on the results, the accuracy of the model with the simple hidden Markov method is 76% for Bitcoin, but the accuracy of the model with the combined method is 82%. For the Ethereum cryptocurrency, hidden Markov has been able to correctly predict the movement of returns in 65% of cases. However, based on the combined method of moving direction, the price efficiency has been correctly predicted up to 91%. Also, for the BNB cryptocurrency, the results indicate that the prediction of the yield movement trend with the simple hidden Markov model is 66%, but the trend prediction using the combined method reaches 74%. was used to predict the efficiency trend.

Finally, for the Solana currency, with the simple hidden Markov method, the accuracy of predicting the yield movement trend reaches 55%, and by using the combined model and introducing fluctuations, the accuracy of predicting the trend has reached 74%. Therefore, in general, the use of the Garch-Hidden Markov combination method for all four currencies significantly improves the detection of movement trends.

**Keywords:** DAP measure, Garch-Hidden Markov, cryptocurrency, trend forecasting