فصلنامه‌ی اقتصاد مقداری (بررسی‌های اقتصادی سابق) زمستان ۱۴۰۴ ۲۲(۴) ۲۱۵-۱۷۵



فصلنامه‌ی اقتصاد مقداری

صفحه ی اصلی وب سایت مجله:
www.jqe.scu.ac.ir
شاپا الکترونیکی: ۴۲۷۱-۲۷۱۷
شاپا چاپی: ۵۸۵۰-۲۰۰۸

انتخاب مدل بهینه برای پیش بینی بازدهی دارایی: مقایسه مدل‌های ARIMA-GARCH و MIDAS

سعید صدرزاده مقدم*، کامبیز هژبر کیانی **، کامبیز پیکارجو***، علیرضا مرادی****

*دانشجوی دکتری گروه اقتصاد، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

**استاد گروه اقتصاد، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول)

***استادیار گروه اقتصاد، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

****استادیار گروه اقتصاد،دانشکده علوم انسانی، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران.

اطلاعات مقاله

تاریخ دریافت: ۱ شهریور ۱۴۰۲
تاریخ بازنگری: ۳ فروردین ۱۴۰۳
تاریخ پذیرش: ۱۹ خرداد ۱۴۰۳

ارتباط با نویسنده (گان) مسئول:
ایمیل:kianikh@yahoo.com
0000-0002-0191-2138

آدرس پستی:
تهران- انتهای بزرگراه شهید ستاری- میدان دانشگاه- بلوار شهدای حصارک- دانشگاه آزاد اسلامی واحد علوم وتحقیقات . صندوق پستی : ۱۴۵۱۵/۷۷۵

طبقه‌بندیJEL: *G17،C89،C22*

واژگان کلیدی:
مدل میداس، خودرگرسیون میانگین متحرک، واریانس ناهمسان شرطی، بیت‌کوین، داده‌های پرتواتر

اطلاعات تکمیلی:

این مقاله برگرفته از رساله دکتری سعید صدرزاده مقدم در رشته اقتصاد به راهنمایی آقای دکتر کامبیز هژبرکیانی و مشاوره آقای دکتر کامبیز پیکارجو و آقای دکتر علیرضا مرادی در دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران است.

قدردانی: از تمامی افراد و موسساتی که در انجام این تحقیق مولف را مساعدت نمودند، قدردانی می‌شود.

تضاد منافع: نویسندگان مقاله اعلام می‌کنند که در انتشار مقاله ارائه شده تضاد منافعی وجود ندارد.

منابع مالی: نویسنده‌ها هیچگونه حمایت مالی برای تحقیق، تألیف و انتشار این مقاله دریافت نکرده‌اند.

دانشگاه شهید چمران اهواز
فصلنامه علمی پژوهش‌های اقتصاد مقداری (بررسی‌های اقتصادی سابق)

چکیده

در این مطالعه به منظور بررسی و مقایسه دو رویکرد مدل‌سازی در اقتصادسنجی از نظر دقت پیش‌بینی، سری زمانی قیمت بیت‌کوین برای بازه زمانی ۲۰۱۵ تا ۲۰۲۳ میلادی انتخاب شده است. بیت‌کوین بعنوان محبوب‌ترین و شناخته شده‌ترین رمزارز، در سالیان اخیر تبدیل به یک دارایی مهم برای بسیاری از سرمایه‌گذاران بازارهای مالی و حتی مردم عادی گردیده، لذا مطالعات بسیاری برای کشف ساختار قیمتی و تغییرات این دارایی در طول زمان در حال انجام می‌باشد. نوسانات بسیار بالای این رمزارز پیچیدگی‌های زیادی در این مطالعات ایجاد کرده است. رویکرد مدل‌سازی برای داده‌های با تواترهای زمانی متفاوت (MIDAS) بعنوان یک رویکرد جدید در مدل‌سازی در سالیان گذشته مطرح و با توجه به حذف محدودیت‌های مهم در مدل‌سازی اقتصادسنجی، به صورت روزافزون در حال بررسی و مطالعه است. در این مطالعه میزان دقت پیش‌بینی مدل خودرگرسیون جمعی میانگین متحرک همراه با واریانس ناهمسان شرطی و مدل‌سازی با رویکرد داده‌های ترکیبی با تواتر زمانی متفاوت مقایسه شده است. مدل‌سازی انجام شده در این تحقیق براساس داده‌های درون روزانه‌ای قیمت بیت‌کوین (با تواتر بالا – ۵ دقیقه‌ای) بر روی متغیرهای بازدهی روزانه و هفتگی بیت‌کوین صورت گرفته است. ابتدا یک مدل خودرگرسیون جمعی میانگین متحرک با وجود اثرات ناهمسانی در واریانس شرطی و با در نظر گرفتن انواع مدل‌های گارچ و توزیع‌های متفاوت در هریک و سپس مدل داده‌های با تواتر زمانی متفاوت با توابع وزنی مختلف برآورد گردیده است. درنهایت با تقسیم بازه نمونه‌گیری به دو بخش، پیش‌بینی بازدهی سری زمانی بیت‌کوین با استفاده از هر دو رویکرد انجام و با اطلاعات واقعی مقایسه شده است. نتایج نشان می‌دهد مدل سازی با رویکرد داده‌های با تواتر زمانی متفاوت نتایج بهتری در خصوص پیش‌بینی بازدهی هر دو سری زمانی بازدهی روزانه و هفتگی بیت‌کوین ارائه می نماید. محاسبات و برآوردها توسط زبان برنامه نویسی R انجام شده است.

ارجاع به مقاله:
صدرزاده مقدم, سعید , هژبر کیانی, کامبیز , پیکارجو, کامبیز و مرادی, علیرضا . (۱۴۰۴). انتخاب مدل بهینه برای پیش بینی بازدهی دارایی : مقایسه مدل‌های ARIMA-GARCH و MIDAS. . *فصلنامه اقتصاد مقداری (بررسی‌های مقداری سابق)*، ۲۲(۴)، ۲۱۵-۱۷۵.

10.22055/jqe.2024.44610.2572

© 2026 Shahid Chamran University of Ahvaz, Ahvaz, Iran. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0 license) (http://creativecommons.org/licenses/by-nc/4.0/)

۱- مقدمه

اهمیت پیش‌بینی دقیق بازدهی دارایی‌ها، به‌ویژه در مورد دارایی‌های نوظهور مانند رمزارزها، یکی از موضوعات اصلی و با اهمیت در این حوزه است. بیت‌کوین، که به سرعت به یکی از مهم‌ترین دارایی‌های مالی در سطح جهانی تبدیل شده است، نقش محوری در تصمیم‌گیری‌های سرمایه‌گذاری و استراتژی‌های مدیریت ریسک دارد. پیش‌بینی‌های دقیق بازدهی بیت‌کوین می‌تواند به سرمایه‌گذاران کمک کند تا فرصت‌های سرمایه‌گذاری را شناسایی کرده و از نوسانات قیمتی به نفع خود استفاده کنند. علاوه بر این، درک بهتری از روند بازار می‌تواند به کاهش ریسک‌های مالی و افزایش ثبات در بازارهای مالی کمک کند. بنابراین، توسعه مدل‌های پیش‌بینی که قادر به مقابله با پیچیدگی‌های بازارهای رمزارز هستند، از اهمیت بالایی برخوردار است و می‌تواند تأثیرات مثبتی بر اقتصاد جهانی داشته باشد. پیش‌بینی مقادیر آینده یک سری زمانیِ اقتصادی یا مالی همواره موردتوجه محققین بوده و روش‌های متنوعی نیز در این حوزه بکار گرفته‌شده و یا در طول سال‌های گذشته ابداع گردیده است. مفهوم پیش‌بینی متناظر بر آینده و رویدادهای دوره زمانی آتی است،که غیرقطعی بودن و نقص در اطلاعات از ویژگی‌های اصلی آن است. رویکردهای پیش‌بینی به دو گروه رویکردهای کمی و کیفی تقسیم می‌شوند. این تقسیم‌بندی بر اساس میزان وابستگیِ رویکرد پیش‌بینی، به الگوها و روش‌های ریاضیاتی و آماری است. روش‌های کمی پیش‌بینی که بر اساس محاسبات صرفاً ریاضی صورت می‌گیرند به دو گروه روش‌های کمیِ رگرسیونی و روش‌های کمیِ غیررگرسیونی تقسیم می‌شوند. مواردی مانند میانگین ساده، تعدیل نمایی و ... در گروه روش‌های ریاضیاتی غیررگرسیونی قرار می‌گیرند. در گروه مقابل و در حوزه روش اقتصادسنجی، الگوهای رگرسیونی علّي و غیرعلّي وجود دارند که مدل‌های خود رگرسیون با واریانس ناهمسان شرطی، خودرگرسیون جمعی میانگین‌متحرک از روش‌های علی در حوزه پیش‌بینی متغیرهای اقتصادی هستند (Brockwell et al,2002). یک مدل خودرگرسیون میانگین‌متحرک متشکل از دو فرآیند خودرگرسیون و میانگین‌متحرك است که با تحلیل روند تغییرات گذشته و حال یک سری زمانی، ساختار درونی آن را کشف و امکان پیش‌بینی مقادیر آینده را برای محقق فراهم می‌نماید. لذا یکی از الگوهای مهم و کاربردی در اقتصادسنجی، مدل‌سازی سری‌های زمانی با استفاده از مقادیر گذشته و با وقفه سری‌زمانی می‌باشد که در این مطالعه، به‌عنوان یک روش سنتی مدل‌سازی و پیش‌بینی مقادیر آتی سری‌زمانی

معرفی می‌شود. در فرآیند توسعه مدل‌های پیش‌بینی بازارهای مالی، از زمان‌های اولیه، که مدل‌های ساده رگرسیونی برای تحلیل داده‌های مالی استفاده می‌شدند، تا دوران کنونی که مدل‌های پیچیده‌تر و دقیق‌تری بکار گرفته می شـود، طراحی مدل مناسـب با چالش‌های خاص خود همراه بوده است. مدل‌های خـودرگرسـیون بـا واریانس ناهمسان شرطی و خودرگرسـیون جمعی میانگین‌متحرک، که در دهه‌های اخیر مورد اسـتفاده قرار گرفته‌اند، نمونه‌هایی از تلاش‌های علمی برای فهم بهتر و پیش‌بینی رفتار بازارهای مالی هسـتند. با این حال، این مدل‌ها نیز با محدودیت‌هایی، به‌ویژه در برخورد با داده‌های با تواترهای زمانی متفاوت مواجه بودند. بعبارت دیگر یکی از محدودیت‌های مهم در مدل‌سـازی که تا سـالیان اخیر، محققین این حوزه ملزم به رعایت و پیروی از آن بودند، لزوم تواتر یکسـان در متغیرهای مدل بود. محققین به‌منظور مدل‌سـازی متغیرهای سـری زمانی با تواترهای زمانی متفاوت، بایستی ابتدا تمام متغیرها را هم‌تواتر کرده و سپس وارد مدل نمایند. برای اینکار دو راهکار وجود دارد. یکسان‌سازی تواتر متغیرها به سمت متغیر با تواتر زمانی بالاتر و یا یکسـان‌سـازی به سـمت متغیر با تواتر زمانی پایین‌تر. که روش اول هم‌فزونی زمانی[1] و روش دوم جداسـازی زمانی[2] نام‌گذاری شـده اسـت(Bayat & Noferesti, 2015).

هم‌فزونی زمـانی عبـارت اسـت از کـاهش تواتر یـک متغیر از طریق میـانگین‌گیری یـا مجموع‌یابی آن در طول زمان که موجب برآورد مدل در پایین‌ترین تواتر زمانی خواهد شـد. لذا با هم‌فزونی زمانی مجموعه اطلاعاتی در دسـترس کوچک شـده و سـری زمانی هم‌فزون شـده نسـبت به سـری زمانی ابتدایی هموارتر می‌شـود. این اثر در تبدیل به تواترهای زمانی بزرگتر (مانند ماه به سـال نسـبت به فصـل به سـال) شـدیدتر رخ داده و به همین دلیل در زمان مواجهه با حجم نمونه کم اسـتفاده از هم‌فزونی زمانی توصـیه نمی‌شـود. در روش جداسـازی مدل در بالاترین تواتر زمانی تخمین زده می‌شـود لذا فرض می‌شـود که سـری زمانی در بستر با تواتر بالا تولید می‌شود در حالیکه بصورت سیستماتیک متغیرها تنها در برخی از مقاطع زمانی مشاهده شده‌اند. بعبارت دیگر مشاهدات مفقود شده در این روش بازیابی می‌شـوند. مزیت این روش نسـیت به روش هم‌فزونی عدم از دسـت‌دادن اطلاعات مربوط به متغیر با تواتر زمانی بالا اسـت(Silvestrini & erdas,2008). در اکثر موارد به‌کارگیری این روش‌ها موجب کاهش کارایی مدل برآورد شـده و از دسـت رفتن اطلاعات

[1] Temporal Aggregation

[2] Temporal Disaggregation

مفید می‌گردد. تا سال‌ها یافتن الگویی که بتواند از متغیرهای با تواتر بالا، به‌منظور پیش‌بینی متغیرهایی با تواتر پایین استفاده نموده و پیش‌بینی مناسبی از متغیر کم تواتر را ممکن نماید، چالشی اساسی بود. این محدودیت‌ها منجر به توسعه مدل‌های جدیدی گردید که قادر به ادغام داده‌های با تواتر بالا و پایین برای ارائه پیش‌بینی‌های دقیق‌تر باشند. روش داده‌های ترکیبی با تواتر زمانی متفاوت به‌عنوان یک رویکرد جدید و نوآورانه در مدل‌سازی متغیرهای اقتصادی توسط کلاین و سوجو[3] (۱۹۸۹) ارائه و بعدها توسط گیسلز (۲۰۰٤) توسعه یافت (Ghysels,2004). مدل‌های داده‌های با تواتر زمانی متفاوت به مدل‌هایی گفته می‌شود که در آنها متغیرها با تواترهای زمانی مختلف وارد مدل می‌شوند. این مدل‌ها به دو دسته الهام گرفته شده از هم‌فزونی زمانی و جداسازی زمانی تقسیم می‌شوند. مدل‌های معرفی شده توسط گیسلز نمونه تکامل یافته روش هم‌فزونی زمانی و مدل‌های حالت-فضا[4] نیز حالت توسعه یافته روش جداسازی زمانی است. در یک مدل حالت-فضا تمام متغیرهای با تواتر زمانی بالا مدل‌سازی شده و از طریق یک فیلتر کالمن[5] پارامترهای مدل برآورد می‌شود. لذا در این مدل‌ها هرچه تعداد متغیرهای مدا بیشتر باشد و یا اختلاف میان تواتر زمانی متغیرها بالاتر باشد پیچیدگی‌های مدل افزایش می‌یابد. مزیت اصلی مدل‌های رگرسیون با داده‌های تواتر زمانی متفاوت نسبت به مدل‌های حالت-فضا استفاده از پارامترهای کمتر و در نتیجه فرم خلاصه‌تر و پیچیدگی‌های محاسباتی کمتر است. مطالعات اندرو و همکاران (۲۰۱۲) نشان داد که دقت پیش‌بینی به استفاده از مدل‌های رگرسیون با داده‌های زمانی متفاوت نسبت به مدل‌های حالت-فضا افزایش می‌یابد(Andreou et al, 2012). در این مطالعه با استفاده از اطلاعات یک سری‌زمانی، تلاش شده است رویکردهای سنتی در پیش‌بینی در مقابل رویکرد نوین معرفی‌شده مورد آزمون قرار گیرد. این سؤال اصلی مطرح می‌شود که آیا روش‌های سنتی اقتصادسنجی نسبت به رویکردهای نوین، ازنظر خطای کمتر و دقت بالاتر در پیش‌بینی، مدل‌های بهتری را ارائه می‌دهد یا خیر؟ به شکل خاص در این مطالعه مدل سنتی خودرگرسیون جمعی میانگین‌متحرک در مقابل رویکرد مدل‌سازی داده‌های ترکیبی با تواتر زمانی متفاوت مقایسه شده است. در این مقایسه از داده‌های تواتر زمانی بالا سری زمانی

[3] Klien & Sojo (1989).

[4] Stat-Space

[5] Kalman Filter

بیت کوین (داده‌های میان روزانه ۵ دقیقه‌ای) استفاده شده و بر اساس معیارهای نمایش‌دهنده‌ی میزان خطای پیش‌بینی و بررسی برتری مدل‌ها نسبت به یکدیگر، مقایسه میان دو رویکرد انجام‌شده است.

۲- پیشینه تحقیق

۲-۱- مطالعات انجام شده با مدل‌های ARIMA و GARCH

مطالعات مربوط به پيش‌بيني در علم اقتصاد در طول دهه‌های آغازین قرن بیستم بسیار مورد توجه محققین قرار گرفت. در سال‌های اخیر الگوهاي سري‌زماني به منظور پيش‌بيني تناسب بیشتری نشان داده‌اند، چرا که متغيرهاي اقتصادي سري‌زماني، تمام اطلاعات مربوط به خود را در بردارند و مي توان قوي‌ترين منبع براي توضيح هر متغير را خود متغير دانست(Moshiri, 2001). ارائه‌ي الگوهاي متفاوت در اين حوزه نيز دال بر اهميت پيش‌بيني‌هاي سري زماني است. البته در مورد برخي از سري‌ها مانند قيمت سهام، اين توجه بيشتر مشهود است. به عنوان مثال وو و لو (۱۹۹۳)، قيمت سهام در آمريكا را برای بازه‌های زمانی متفاوت با استفاده از مدل‌های اقتصادسنجی پيش‌بيني كردند. نتايج مطالعه‌ي آنها نشان داد كه در پيش‌بيني كوتاه‌مدتِ قيمت سهام، شبكه‌ي عصبي مصنوعي[6] در مقايسه با روش ARIMA پيش‌بينی‌های دقيق‌تري را ارايه مي‌كند، اما در بلندمدت فرآيند ARIMA توانايي بالاتری برای پيش‌بيني دارد (Wu and Lu, 1993). رينگ وود و همكاران (۱۹۹۳)، مصرف هفتگي برق در كشور انگلستان را با استفاده از مدل‌هايی مختلف پيش‌بيني كردند. نتايج اين مطالعه نشان داد كه پيش‌بيني سری زمانی مصرف انرژی براساس يک فرآيند AR دقيق‌تر از مدل‌سازی اين سری زمانی بر اساس يک فرآيند ARIMA است، اما در مقابل فرآيند ARIMA خطاي كمتری در مقايسه با مدل AR دارد (Ringwood et al, 1993). غفاری و فرهادی (۱۳۹٤) در مقاله‌ای به مقايسه دقت پيش‌بيني چهار مدل GARCH[7]، ARIMA، ARIMA-GARCH و مدل حالت-فضا در تخمين و پيش‌بيني شاخص قيمت بورس اوراق بهادار تهران (تپيكس) پرداختند. آنها در اين مطالعه از داده‌هاي روزانه برای پيش‌بينی درون و برون‌نمونه‌ای استفاده كردند. همچنين براي بررسي بيشتر و افزايش دقت پيش‌بيني مدل‌هاي بكار گرفته شده در تحقيق،

[6] Artificial Neural Networks (ANN).

[7] Generalized Autoregressive Conditional Heteroscedasticity (GARCH).

شبیه‌سازي با روش مونت کارلو[8] براي دو دوره زماني ميان‌مدت و کوتاه‌مدت با استفاده از برون‌داده و نيز براي يک مقايسه کلي با درون‌داده انجام دادند. دقت پيش‌بيني نتايج مدل‌ها با استفاده از معيار RMSE ارزيابي شد. نتايج اين مطالعه نشان داد که مدل GARCH برای پیش‌بینی‌های برون‌نمونه‌ای و در سه دوره زماني (بلندمدت، ميان‌مدت و کوتاه‌مدت) از دقت پيش‌بيني بيشتري نسبت به ساير مدل‌ها برخوردار است، اما در هنگام مقايسه با پیش‌بینی‌های درون نمونه‌ای، مدل ARIMA مدل مناسب‌تري است(Ghafari & Farhadi, 2015). پهلوانی و روشن (۱۳۹٤) در مقاله‌ای به مقایسه کارایی پیش‌بینی مدل ARIMA و مدل ترکیبی ARIMA-GARCH با استفاده از سری زمانی نرخ ارز در ایران پرداختند. در این مطالعه از داده‌های نرخ دلار منتشر شده توسط بانک مرکزی ج.ا.ا برای بازه زمانی یک‌سال استفاده شد. آنها با محاسبه بازدهی دلار و تقسیم بازه زمانی داده‌های جمع‌آوری شده به دو بخش، پیش‌بینی‌های درون و برون‌نمونه‌ای را انجام و قدرت پیش‌بینی مدل‌های مذکور را بر اساس معیارهای MAE، RMSE مورد مقایسه قرار گرفت. نتایج نشان داد که مدل ترکیبی EGARCH(2,1) - ((7,2),(12)) ARIMA دارای کمترین میزان خطا در پیش‌بینی مقادیر درون و برون نمونه‌ای سری زمانی بازدهی دلار است(Pahlevani & Roshan, 2015). صالحی فر (۱۳۹۸) در مطالعه‌ای به منظور بررسی بازدهی و ریسک رمزارز بیت‌کوین در مقایسه با بازارهای رقیب (طلا، ارز و بورس) از مدل‌های GJR-GARCH و GARCH آستانه استفاده کرد. وی با استفاده از داده‌های روزانه بیت‌کوین و شاخص‌های مرتبط با بازارهای رقیب در یک بازه زمانی ۵ ساله، بازدهی لگاریتمی را برای هر یک از شاخص‌ها محاسبه و نوسانات بازدهی را مدل‌سازی کرد. یافته‌های مطالعه نشان داد اگرچه بازده و ریسک بیت‌کوین نسبت به سایر فرصت‌های سرمایه‌گذاری مانند ارز، طلا، سکه و بورس در داخل کشور به طور قابل ملاحظه‌ای بیشتر است، اما نمی‌توان رفتار آن را از نظر ریسک و بازدهی با بازارهای رقیب مرتبط دانست. همچنین برخلاف سایر دارایی‌ها، در معاملات بیت‌کوین اثر اخبار مثبت بیشتر از اخبار منفی است. درنهایت فرضیه دایربرگ[9] مبنی بر اینکه بیت‌کوین چیزی بین طلا و ارز است، مورد تایید قرار نگرفت(Salehifar, 2019). باریوریا (۲۰۱۷) در مطالعه‌ای نوسانات قیمت بیت کوین را با استفاده از مدل‌های خانواده GARCH و درنظر گرفتن توزیع خطای نرمال مدل‌سازی کرد و نتیجه گرفت مدل

[8] Monte Carlo Simulation

[9] Dyhrberg, 2016

AR (1)-CGARCH (1, 1) بهترین عملکرد برای پیش بینی نوسان قیمتی بیت کوین دارد (Bariviera,2017). کاتانیا، گراسی و راوازولو (۲۰۱۹) توانایی چندین مدل تک‌متغیره و دومتغیره را برای پیش‌بینی برخی رمزارزها مانند بیت‌کوین، لایت‌کوین، ریپل و اتریوم مقایسه کردند. نتایج نشان داد که ترکیب مدل‌های تک‌متغیره، بهبود قابل‌توجهی در پیش‌بینی‌های نقطه‌ای، برای دو رمزارز بیت‌کوین و اتریوم بوجود می‌آورد (Catania, Grassi & Ravazzolo, 2019). ئیجینگ هووا (۲۰۲۰) در مطالعه‌ای دقت مدل‌های ARIMA و مدل ترکیبی شبکه عصبی مصنوعی با حافظه کوتاه‌مدت طولانی[10] را در پیش‌بینی قیمت رمزارزهای بیت‌کوین و اتریوم مقایسه نمود. در این مطالعه با جمع‌آوری ۱۰ هزار داده مربوط به دو رمز ارز بیت‌کوین و اتریوم، مدل ARIMA(1,1,0) برای هر دو سری زمانی انتخاب و پیش‌بینی‌های به‌دست‌آمده از این مدل را با نتایج شبیه‌سازی در شبکه عصبی مقایسه شد. نتایج نشان داد که هر دو مدل دقت کافی در پیش‌بینی قیمت بیت‌کوین و اتریوم را دارند. با اینکه مدل شبکه عصبی زمان طولانی‌تر و منابع بیشتر (ازنظر قدرت پردازش سیستم) برای آموزش و شبیه‌سازی صرف می‌کند، اما کارایی بالاتری در پیش‌بینی نسبت به مدل ARIMA نشان می‌دهد. بر اساس نتایج مدل شبکه عصبی با تعداد داده‌های کمتر، پیش‌بینی‌های بهتری ارائه می‌کند و مدل ARIMA برای بازه‌های زمانی طولانی‌تر نسبت به بازه‌های نزدیک‌تر پیش‌بینی‌های بهتری ارائه می‌نماید (Yiqing Hua, 2020). چگنی و گردعزیز (۱۳۹۹) به مقایسه کارایی دو روش پیش‌بینی ANN و روش ARIMA ، در پیش‌بینی قیمت سهام در بازار سهام ایران پرداختند. بدین منظور از داده‌های دو شرکت دارویی البرز دارو و جام دارو استفاده و مدل‌های ARIMA و ANN برای هر دو شرکت برآورد شد. نتایج نشان داد که مدل ANN پیش‌بینی بهتری از قیمت سهام در مقایسه با روش ARIMA دارد (Chegeni & Gord, 2020). عباسی (۱۴۰۰) به منظور معرفی بهترین مدل GARCH با عملکرد بهینه در افق‌های زمانی، از سری زمانی قیمت نفت‌خام وست تگزاس اینترمدیت[11] استفاده نمود. در این مطالعه نوسانات قیمت روزانه و هفتگی نفت‌خام براساس الگوهای GARCH تک‌رژیمی (GJR-،GARCH(1,1) HYGARCH،FIGARCH،EGARCH،GARCH) و مدل‌های تغییر رژیم (MRS-GARCH و MMGARCH) پیش‌بینی و مدل‌سازی شدند. نتایج حاکی از دقت بالای مدل MRS-

[10] Long-Short Term Memory (LSTM)

[11] West Texas Intermediate

GARCH بر حسب داده‌های هفتگی برای پیش‌بینی‌های درون‌نمونه‌ای و برتری مدل‌های GARCH تک‌رژیمی برای پیش‌بینی‌های برون‌نمونه‌ای بود(Abasi, 2021).

۲-۲- مطالعات انجام شده با مدل‌های MIDAS

کلمنتس و گالوائو (۲۰۰۸) برای پیش‌بینی رشد تولید کل در ایالت متحده، از رویکرد MIDAS استفاده کردند. آن‌ها نتیجه گرفتند که استفاده از رویکرد مدل‌سازی MIDAS نسبت به مدل AR و خودرگرسیون با وقفه‌های توزیعی[12] منجر به کاهش خطای مجذور میانگین مربعات می‌شود و با در نظرگرفتن شاخص‌های ماهیانه، این رویکرد برای پیش‌بینی‌های کوتاه‌مدت کاربرد دارد (Clements & Galvao,2008). برکچیان و رضایی (۱۳۹۵) در مطالعه‌ای دقت پیش‌بینی مدل ARDL و مدل MIDAS را برای پیش‌بینی نرخ تورم فصلی ایران مورد مقایسه قرار دادند. نتایج مطالعه نشان داد که به‌کارگیری مدل MIDAS با استفاده از مشاهدات ماهیانه نرخ تورم برای پیش‌بینی تورم فصلی، اغلب منجر به نتایج دقیق‌تری نسبت به مدل‌های ARDL می‌شوند. این بهبود به‌ویژه در پیش‌بینی‌های یک گام به جلو خود را بهتر نشان می‌دهد (Barakchian & Rezaei, 2016). پیش بهار و همکاران (۱۳۹۸) ضمن بررسی عوامل موثر بر رشد ارزش‌افزوده بخش کشاورزی، به پیش‌بینی مقادیر آتی با استفاده از مدل MIDAS پرداخته و برآوردها را با نتایج به‌دست‌آمده از پیش‌بینی الگوی ARIMA مقایسه نمودند. مقایسه نتایج به‌دست‌آمده برای رشد ارزش‌افزوده بخش کشاورزی در مقایسه با داده‌های واقعی، حاکی از قدرت پیش‌بینی الگوی MIDAS نسبت به مدل‌سازی با الگوی ARIMA بود (Pishbahar et al, 2019). دشتبان و همکاران (۱۳۹۸) با به‌کارگیری یک الگوی تلاطم تصادفی با اثرات اهرمی و داده‌های ترکیبی با تواتر متفاوت، به بررسی اثر نااطمینانی نرخ ارز بر جریان گردشگری در ایران پرداختند. آن‌ها با استفاده از داده‌های فصلی و سالیانه برای بازه زمانی ۱۳٦۸ الی ۱۳۹٤، ابتدا نااطمینانی نرخ ارز را با یک الگوی تلاطم تصادفی با اثر اهرمی استخراج و سپس با استفاده از روش داده‌های ترکیبی با تواتر زمانی متفاوت اثر تلاطم نرخ ارز واقعی را بر جریان گردشگری در ایران برآورد نمودند. نتایج نشان داد تلاطم نرخ ارز واقعی و تولید ناخالص داخلی بر ورود گردشگران خارجی به ایران، به‌ترتیب اثرات منفی و مثبت داشته است (Dashtban et al, 2019). فنگ‌ما و همکاران (۲۰۲۰) با رویکرد MIDAS و استفاده از الگوهای تغییر جهت مارکوف در

[12] Autoregressive Distributed Lag (ARDL).

برآورد ضرایب، به مدل‌سازی نوسانات رمزارزها پرداختند. آن‌ها با استفاده از داده‌های میان روزانه و تجزیه واریانس تحقق‌یافته[۱۳] رمزارزها، چهار مدل ترتیبی (با اضافه کردن مرحله‌ای متغیر و شرایط به مدل) معرفی و بر اساس میزان خطا در پیش‌بینی‌های برون‌نمونه‌ای، مدل بهینه برای پیش‌بینی واریانس تحقق‌یافته را انتخاب نمودند. نتایج این مطالعه نشان‌دهنده بهبود قابل‌توجه قدرت پیش‌بینی برای بازه زمانی دو هفته و یک‌ماهه، در صورت استفاده از مدل تکمیلی بود (Feng Ma et al, 2020). نوفرستی و سزاوار (۲۰۲۱) به منظور پیش‌بینی متغیرهای کلان اقتصادی جهت ارزیابی دقیق سیاست‌های اقتصادی و لزوم واکنش سریع به شوک‌های وارده و برنامه‌ریزی متناسب، یک الگوی کلان‌سنجی داده‌های ترکیبی با تواتر زمانی متفاوت را براساس چارچوب الگوي عرضه کل- تقاضاي کل و متشکل از چهار بازار عمده بازار کالاها و خدمات، پول، ارز و کار طراحی نمودند. نتایج مطالعه نشان داد که استفاده از مشاهدات جدید در متغیرهاي با تواتر بالا در الگو، منجر به بهبود دقت نتایج در پیش‌بینی متغیرهاي درون‌زاي الگو خواهد شد. همچنین نتایج مطالعه میزان تاثیر سیاست های مالی اجرا شده توسط دولت را بر بخش های مختلف اقتصاد را نشان می‌دهد (Noferesti & Sezavar, 2021).

همانگونه که مشاهده می شود اغلب مطالعات انجام شده در خصوص پیش‌بینی سری‌های زمانی مبتنی بر مدل‌سازی‌های اقتصادسنجی براساس الگوهای ARIMA و مدل‌های مبتنی بر ناهمسانی واریانس شرطی (GARCH،ARCH) انجام شده و در برخی از موارد مقایسه مدل‌های مذکور با الگوریتم های شبیه سازی شبکه عصبی صورت گرفته است. در اغلب این مطالعات یک مدل پایه با چند توزیع خطا و یا چند مدل از خانواده مدل‌های ARIMA-GARCH با یک توزیع خطا مورد بررسی قرار گرفته است. همچنین مطالعات انجام شده در حوزه مدل‌سازی MIDAS مخصوصاً در ادبیات داخلی، براساس داده‌های با تواترهای زمانی متفاوت سالیانه، فصلی و نهایتا ماهیانه است. حال آنکه داده‌های موجود در بازارهای مالی مانند بازار سهام و رمزارزها بصورت میان‌روزانه نیز در دسترس است. مدل‌های MIDAS امکان بررسی میزان اهمیت و همچنین تاثیر داده‌های میان‌روزانه در دقت پیش‌بینی‌های روزانه و هفتگی را فراهم می‌نماید. بنابراین بررسی این موضوع که آیا اطلاعات اضافی بدست آمده بعلت تواتر زمانی بالای داده‌های میان‌روزانه با مدل‌سازی MIDAS

[13] Realized Variance (RV)

می‌تواند موجب افزایش محسوس میزان دقت پیش‌بینی‌ها نسبت به رویکردهای سنتی مدل‌سازی اقتصادسنجی شود چالش مهمی است.

لذا در این مطالعه ضمن ترکیب مدل‌سازی خودرگرسیون جمعی میانگین‌متحرک با فرض ناهمسانی واریانس شرطی که حالت‌های مختلف مدل‌های GARCH شامل (gjrGARCH،eGARCH،sGARCH) و توزیع‌های مختلف (توزیع نرمال[۱۴]، توزیع چوله نرمال[۱۵]، توزیع تی‌استیودنت[۱۶] ،توزیع چوله تی‌استیودنت[۱۷] و توزیع خطای تعمیم یافته[۱۸]) در نظر گرفته شده، از رویکرد جدید مدل‌سازی MIDAS نیز استفاده‌شده است. همچنین به منظور بررسی جامع در بخش مدل‌سازی MIDAS، سه مدل با توابع وزن‌دهی آلمون[۱۹]، آلمون نمایی[۲۰] و بتا[۲۱] مورد برآورد قرار گرفته است. داده‌های مورد استفاده در این مطالعه، داده‌های پرتواتر میان‌روزانه (سری زمانی قیمت بیت کوین بصورت ۵ دقیقه‌ای) است که بازدهی روزانه و هفتگی، از طریق این داده‌ها محاسبه و مدل‌سازی داده‌های با تواتر متفاوت براین اساس انجام شده است. به‌عبارت‌دیگر مقایسه انجام‌شده در این مطالعه مقایسه‌ای میان روش‌های سنتی پیش‌بینی در اقتصادسنجی و رویکردهای نوین در این حوزه است با این تفاوت که در استفاده از روش‌های سنتی، تجمیعی از الگوهای استفاده‌شده تاکنون بکار گرفته‌شده است.

۳- روش شناسی تحقیق

در دهه‌های اخیر، علاقه محققین برای استفاده از مدل‌های اقتصادسنجي به منظور پیش‌بیني متغیرها در انواع بازارهاي مالي و غیر مالي افزایش یافته است. براي هر بازار بخصوص، باید مدل مناسب با وضعیت آن بازار انتخاب شود، در این راستا اقتصاددانان و محققان زیادي دست به مقایسه مدل‌هاي مناسب‌تر براي بازارهاي مختلف زدند. اغلب این

[14] Normal Distribution
[15] Skew Normal Distribution
[16] t-Student distribution
[17] Skew t-Student distribution
[18] Generalized error distribution (GED)
[19] Almon weight function
[20] Exponential Almon weight function
[21] Beta weight function

مدل‌ها با تحلیل الگوها و روند داده‌های گذشته تلاش می‌کنند رفتارهای آینده را پیش‌بینی و اطلاعات مورد نیاز برای تصمیم‌گیری‌های موثر را فراهم نمایند. در این راستا یکی از عوامل موثر در توسعه مدل‌های پیش‌بینی مواجهه با خصوصیات منحصربه‌فرد داده‌ها مانند بازه زمانی جمع‌آوری یا ویژگی‌های ذاتی مانند نوسانات بالا است که موجب تلاش برای طراحی مدل‌های جدید شده است.در این بخش ابتدا رویکردهای پایه‌ای تجزیه تحلیل سری‌های زمانی ارائه و سپس یک رویکرد جدید در مدل‌سازی سری‌های زمانی برای داده‌های با تواتر زمانی متفاوت مورد بررسی قرار گرفته است.

۱-۳- مدل‌های خودرگرسیون میانگین متحرک هم انباشته(ARIMA)

باکس و جنکینز (۱۹۷۶) در کتاب خود با عنوان؛ تجزیه تحلیل سری‌های زمانی، پیش‌بینی و کنترل[۲۲]، شکل جدیدی از مدل‌سازی برای پیش‌بینی متغیرهای اقتصادی را معرفی نمودند. در این رویکرد با استخراج ساختار حاکم بر گذشته یک سری زمانی، می‌توان نسبت به توضیح و پیش‌بینی مقادیر آینده اقدام نمود(Box & Jenkins,1976). در حالت کلی مدل‌سازی سری‌های زمانی، فرض مانایی[۲۳] به‌عنوان اولین گام مطرح می‌شود. در صورت نامانا[۲۴] بودن سری زمانی، برای مدل‌سازی ابتدا باید سری زمانی را با رویکردهایی مانند تفاضل‌گیری مانا کرد. اگر یک سری زمانی با d مرتبه تفاضل‌گیری تبدیل به سری زمانی مانا شود، آن را سری زمانی هم‌انباشته از مرتبه d نامیده و مدلسازی از طریق مدل خودرگرسیون میانگین متحرک انباشته ARIMA(p,d,q) که شکل کلی آن به‌صورت روابط

$$\Delta^d y_t = \alpha + \beta_1 \Delta^d y_{t-1} + \ldots + \beta_p \Delta^d y_{t-p} + \varepsilon_t + \gamma_1 \varepsilon_{t-1} + \ldots + \gamma_q \varepsilon_{t-q} + v_t \quad (۱)$$

$$\beta(L)\Delta^d y_t = \alpha + \gamma(L)\varepsilon_t + v_t \quad (۲)$$

است، انجام خواهد شد. که در اینجا y_t سری زمانی مورد بررسی در زمان t که با وقفه‌های خود (y_{t-1})، جمله اختلال (ε_t) و وقفه‌های جمله اختلال (ε_{t-1}) ارتباط دارد. مانایی یک سری زمانی از طریق آزمون‌های دیکی فولر[۲۵] و یا فیلیپس پرون[۲۶] بررسی و فرضیه وجود

---

[22] Time Series Analysis: Forecasting and Control

[23] Stationary

[24] Non-Stationary

[25] Dicky-Fuller

[26] Phillips-Perron

ریشه واحد[۲۷] در سری زمانی آزمون می‌شود. پس از شناسایی ساختار مانایی سری زمانی، با استفاده از روش سه مرحله‌ای باکس جنکینز، مدل بهینه برای پیش‌بینی مقادیر آتی انتخاب می‌گردد. باکس-جنکینز یک روش استاندارد سه مرحله‌ای برای ساخت یک مدل ARIMA معرفی کردند.

(۱) شناسایی و انتخاب نوع مدل : مرتبه‌های p و q برای مدل‌های AR ، MA یا ARMA تعیین می‌شود.
(۲) برآورد ضرایب : ضرایب مدل‌های انتخاب شده برآورد می‌شود.
(۳) بررسی مدل : باقیمانده‌های مدل برآورد شده، تجزیه و تحلیل می‌شود.
مرحله برآورد شامل یک فرآیند بهینه‌سازی با استفاده از معیارهای خطا مانند معیار اطلاعات آکائیک (AIC)، بیزین (BIC) و یا معیار حنان‌کوین (HQIC) است. در این پژوهش از معیار AIC استفاده شده است.

$$AIC = -2ln(\hat{L}) + 2k \qquad (۳)$$

در اینجا $\ln(\hat{L})$ مقدار تابع درستنمایی و K درجه آزادی است. مدلی که کمترین مقدار AIC را داشته باشد بعنوان مدل بهتر در میان مدل‌های مورد بررسی انتخاب می‌شود. روش‌های متفاوتی برای محاسبه تابع درستنمایی وجود دارد که در این پژوهش از برآوردگر حداکثر درستنمایی[۲۸] استفاده شده که با وجود افزایش زمان محاسبات، نتایج دقیق‌تری را ارئه می‌دهد. در نهایت در مرحله بررسی مدل و بررسی باقیمانده‌های آن، در صورتیکه نتایج نشان دهد باقیمانده‌ها حالت استاندارد ندارند، مراحل قبلی تا زمان رسیدن به مدل بهینه تکرار می‌شود.

۲-۳- ناهمسانی واریانس مشروط و مدل‌های (GARCH)

در اغلب سري‌هاي زماني اقتصادی و مالی، دلايلي برای وجود واريانس ناهمسان مشاهده می‌شود. بروز ناهمسانی واریانس، به همراه یک همبستگی خطی میان واریانس‌های شرطی در سری زمانی، باعث شد محققاني نظير انگل چگونگي مدل‌سازي نوسانات شرطي (واريانس شرطي) را بررسی نمایند. در تحلیل و کشف رابطه ساختاری یک سری زمانی، همواره جزئی به‌عنوان خطا موردنظر قرار می‌گیرد که مطابق با فروض اولیه در مدل‌سازی،

[27] Unit Root
[28] Maximum Likelihood Estimator

متغیری با واریانس ثابت در طول زمان تعریف می‌شود. حال‌آنکه سری‌های زمانی معمولاً در طول زمان نوسانات شدیدی را تجربه می‌کنند. این موضوع فرض واریانس ثابت یا بعبارتی واریانس همسان را مورد تردید قرار می‌دهد. انگل، نشان داد که مي‌توان به‌صورت هم‌زمان میانگین و واریانس شرطي يك سري زمانی را مدل‌سازي كرد. هدف اصلي مدل‌سازي نوسانات، استفاده از يك فرايند ARMA به‌منظور شناسايي هرگونه روند پايدار، در تغييرات جزء خطا است. در صورتیکه یک سری زمانی خودرگرسیون مرتبه اول (p=۱) را در نظر بگیریم:

$$var(y_t) = E[(y_{t-1} - \alpha_0 - \alpha_1 y_t)^2] = E_t(\varepsilon_{t+1})^2 \qquad (۴)$$

در اینجا $E_t(\varepsilon_{t+1})^2$ یک فرآیند خودرگرسیون از مرتبه p در نظر گرفته می‌شود و براساس رابطه

$$\hat{\varepsilon}_t^2 = \beta_0 + \beta_1 \hat{\varepsilon}_{t-1}^2 + \cdots + \beta_p \hat{\varepsilon}_{t-p}^2 + u_t \qquad (۵)$$

برآورد خواهد شد.

در صورتیکه $\beta_1 = \beta_2 = \cdots = \beta_p = 0$ باشد، واریانس جمله اختلال ثابت و برابر با β_0 خواهد بود. در غیر این صورت واریانس شرطی y_t مطابق با فرآیند خودهمبسته معرفی‌شده در (٤) تغییر می‌کند. به این الگو واریانس ناهمسان شرطی خودرگرسیونی گفته می‌شود. جملات اختلال می‌توانند از الگوهای مختلفی پیروی نمایند. لذا شکل‌های متفاوتی از الگوی ARCH وجود دارد. الگوی معرفی‌شده توسط انگل برای واریانس شرطی توسط بولرسلف(۱۹۸٦) توسعه داده شد(Balerslov,1986). در این مدل الگوی واریانس شرطی از اجزای $ARCH(\varepsilon_{t-i}^2)$ و نیز $GARCH(\sigma_{t-i}^2)$ به‌صورت ترکیبی، با مرتبه‌های متفاوت بصورت رابطه

$$\sigma_t^2 = \alpha_0 + \sum_1^q \alpha_i \varepsilon_{t-i}^2 + \sum_1^p \beta_i \sigma_{t-i}^2 \qquad (۶)$$

تعیین می‌شود.

که در آن σ_t واریانس شرطی ε_t است. گلاستن، جگنزان و رانکل (۱۹۹۳) فرض عدم تقارن اثر شوک‌های مثبت و منفی بر واریانس‌های شرطی را مطرح کردند(Glosten, Jaganathan & Runkle,1993). مدل‌های GARCH با این ویژگی به مدل‌های GJR-

GARCH مشهور است. در این الگو $\varepsilon_{t-1} = 0$ یک آستانه[۲۹] در نظر گرفته می‌شود که شوک‌های بزرگتر از شوک آستانه، تاثیرات متفاوتی نسبت به شوک‌های کوچکتر از شوک آستانه دارند. مدل GARCH در این حالت به صورت رابطه

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \gamma_1 d_{t-1} \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (۷)$$

خواهد بود.

در اینجا d_{t-1} یک متغیر مجازی است که با ازای $\varepsilon_{t-1} < 0$ برابر با یک و به ازای $\varepsilon_{t-1} \geq 0$ برابر با صفر می‌باشد(Enders, 1948). از دیگر مشکلات مدل‌های GARCH، تضمین مثبت بودن تمامی ضرایب است. نلسون (۱۹۹۱) به منظور بررسی اثر عدم تقارن در اطلاعات یا چولگی‌هایی که اغلب در بازده‌های مالی مشاهده می شوند، مدل GARCH نمایی[۳۰] را معرفی کرد که شرط نامنفی بودن پارامترها حذف و معادله واریانس شرطی به‌شکل رابطه

$$ln\sigma_t^2 = \alpha_0 + \sum_{i=1}^{p} \alpha_i (|\varepsilon_{t-i}| + \gamma_i \varepsilon_{t-i}) + \sum_{j=1}^{q} \beta_j \, ln(\sigma_{t-j}^2) \quad (۸)$$

معرفی می‌شود(Nelson,1991).

از دیگر خصوصیات مدل‌های GARCH خصوصیت لپتوکورتوسیس[۳۱] توزیع تجربی بازده‌های مالی است. محققان اغلب به‌منظور ایجاد توزیع‌های دنباله‌دار، از توزیع خطای تعمیم‌یافته (GED) یا توزیع t استیودنت استفاده می‌کنند که علاوه بر فرض گوسی سنتی، خطاهای ε_t براساس توزیع GED یا توزیع t استیودنت توزیع می شود. تابع چگالی احتمال توزیع t استیودنت با در نظر گرفتن درجه آزادی ν و با این فرض که برای وجود گشتاور مرتبه دوم، باید درجه آزادی بزرگتر از دو باشد، به‌صورت رابطه

$$f(\varepsilon_t) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\pi}\Gamma\left(\frac{\nu}{2}\right)} (\nu-2)^{-\frac{1}{2}} (h_t)^{-\frac{1}{2}} \left[1 + \frac{\varepsilon_t^2}{h_t(\nu-2)}\right]^{-\frac{(\nu+1)}{2}} \quad (۹)$$

است. تابع توزیع GED نیز به‌صورت رابطه

[29] Threshold

[30] Exponential GARCH (eGARCH).

[31] Leptokurtosis

$$f(\varepsilon_t)=\frac{\nu\, exp\left[-\left(\frac{1}{2}\right)\left|\frac{\varepsilon_t}{\lambda h_t^{\frac{1}{2}}}\right|^{\nu}\right]}{h_t^{1/2}\lambda 2^{\left(1+\frac{1}{\nu}\right)}\Gamma\left(\frac{1}{\nu}\right)} \qquad (۱۰)$$

تعریف می‌شود.

در اینجا ν پارامتری است که ضخامت دنباله توزیع را در مقایسه با توزیع نرمال نشان می‌دهد. زمانیکه $\nu = 2$ باشد توزیع GED تبدیل به توزیع نرمال استاندار خواهد شد. برای $\nu < 2$ و $\nu > 2$ توزیع GED به ترتیب دنباله ضخیم‌تر و نازک‌تر از توزیع نرمال خواهد داشت.

۳-۳- مدل‌سازی داده‌های ترکیبی با تواتر زمانی متفاوت (MIDAS)

در روش‌های سنتی مدل‌سازی سری‌های زمانی برای پیش‌بینی متغیرهای اقتصادی، تمام متغیرهای درگیر در الگو لزوماً از تواتر زمانی یکسانی برخوردارند، به‌عنوان‌مثال چنانچه متغیر وابسته فصلی باشد، متغیرهای توضیح دهنده نیز باید فصلی باشند. حال چنانچه در یک رابطه رگرسیونی متغیرهایی وجود داشته باشند، که تواترهای زمانی یکسانی نداشته و به‌صورت سالیانه، فصلی، ماهیانه و ... مشاهده و جمع‌آوری‌شده باشند، بر اساس الگوهای سنتی امکان برآورد ضرایب در این رگرسیون وجود نخواهد داشت، مگر آنکه کلیه متغیرهای مدل با استفاده از روش‌هایی، در یک تواتر زمانی تجمیع و سپس ضرایب رگرسیون برآورد شود. بعنوان مثال داده‌های فصلی و یا ماهیانه با استفاده از تجمیع زمانی به داده‌های سالیانه تبدیل شوند. ایده برآورد مدل رگرسیون داده‌های با تواترهای زمانی متفاوت، اولین بار توسط کلاین و سوجو(۱۹۸۹) ارائه و بعدها توسط گیسلز(۲۰۰۴) توسعه یافت. این رویکرد امکان انجام برآورد رگرسیون، بدون توجه به تواتر متفاوت در متغیرها را فراهم می‌نماید. ساخت الگویی با این رویکرد دو مزیت عمده را در مدل‌سازی اقتصادسنجی ایجاد می‌نماید. نخست آنکه قرار گرفتن متغیرهای با تواتر زمانی بالا (پُرتواتر به‌عنوان متغیرهای توضیح‌دهنده) در کنار متغیرهای با تواتر زمانی پایین (کم تواتر به‌عنوان متغیرهای وابسته) در یک مدل و در کنار همدیگر، این امکان را فراهم می‌کند تا پیش‌بینی‌های دقیق‌تری برای متغیر وابسته در آینده‌ای نزدیک ارائه شود. دومین مزیت در زمان ارائه اطلاعات جدید برای متغیر با تواتر زمانی بالا فراهم می‌شود. گیسلز، سینکو و والکانو (۲۰۰۶) رگرسیون ساده MIDAS را به شکل روابط زیر (۱۱) تا (۱۳)تعریف کردند(Ghysels, Sinko & Valkanov,2006).

$$y_t = \beta_0 + \beta_1 B\left(L^{1/m};\theta\right) x_{t-h}^{(m)} + \varepsilon_t \quad (۱۱)$$

$$B\left(L^{1/m};\theta\right) = \sum_{j=1}^{K} b(k;\theta)\, L^{(j-1)/m} \quad (۱۲)$$

$$L^{s/m} x_{t-1}^{(m)} = x_{t-1-\frac{s}{m}}^{(m)} \quad (۱۳)$$

که t واحد زمانی مربط به متغیر وابسته (کم‌تواتر) y_t است و m تواتر زمانی مربوط به متغیر توضیح‌دهنده $x_t^{(m)}$ (پُرتواتر) است که ارتباط میان این دو متغیر را از طریق تعداد مشاهده متغیر پُرتواتر در بازه زمانی متغیر کم‌تواتر مشخص می‌کند. به‌عنوان‌مثال اگر متغیر وابسته (کم‌تواتر) بصورت سالیانه و متغیر توضیح دهنده (پُرتواتر) بصورت فصلی جمع‌آوری شود، مقدار m برابر با ٤ خواهد بود. یعنی برای هر مقدار در هر سال از متغیر کم تواتر، ٤ مشاهده (٤ فصل) برای متغیر پُرتواتر وجود دارد. k تعداد وقفه بهینه برای متغیر پُرتواتر است که در مدل وارد و مشخص می‌شود که متغیر وابسته با چند وقفه از متغیر پُرتواتر در ارتباط است. به‌صورت بنیادی اگر به ازای هر مقدار از متغیر کم تواتر، کلیه مقادیر متغیر پُرتواتر در مدل رگرسیون وارد شود، تعداد ضرایب موردنیاز برای برآورد افزایش خواهد یافت. به‌عنوان‌مثال به ازای هر مقدار از y_t باید ٤ مقدار از متغیر x_t در نظر گرفته شده و ٤ ضریب مشخص برآورد شود. با در نظر گرفتن یک بازه ۱۰ ساله برای برآورد مدل مشاهده می‌شود که نیاز به برآورد ٤۰ ضریب برای متغیر توضیح‌دهنده خواهد بود. این موضوع مدل رگرسیون را ازنظر فرم و درجه آزادی با مشکلات جدی مواجه می‌نماید. لذا در مدل MIDAS به‌منظور حل این موضوع و ارائه فرم خلاصه‌شده رگرسیون از توابع وزن‌دهی استفاده‌شده

است. $b(k;\theta)$ تابع وزن‌دهی چندجمله ای، برای اعمال وزن‌های خاص به وقفه‌های x_t است، که به تعداد وقفه k و بردار θ وابسته می‌باشد و در حالت کلی بصورت رابطه

$$b(k;\theta) = f\left(\frac{k}{k^{max}}, \theta \Big/ \sum_{i=1}^{k^{max}} f\left(\frac{k}{k^{max}}, \theta\right)\right) \quad (۱۴)$$

تعریف می شود. گیسلز ضمن معرفی فرم کلی برای تابع وزن‌دهی مطابق با معادله شماره ۱۳، نمونه‌هایی از توابع وزن‌دهی مانند تابع وزن‌دهی آلمون، تابع وزن دهی آلمون نمایی، تابع وزن‌دهی بتا، به ترتیب روابط

$$\beta . b(k;\theta) = \sum_{k=0}^{k\ max} \sum_{p=0}^{P} \theta_p . k^p \quad (۱۵)$$

$$b\left({}^{k}/_{m}; \theta_1; \theta_2\right) = \frac{F\left({}^{k}/_{m}, \theta_1, \theta_2\right)}{\sum_{k=1}^{k\ max} F\left({}^{k}/_{m}, \theta_1, \theta_2\right)} \quad (۱۶)$$

را معرفی نمود. در تابع وزن دهی آلمون ضـــرایب و وزن‌ها بصـــورت یک پارامتر مشترک برآورد می‌شود.

که در رابطه

$$b\left({}^{k}/_{m}; \theta_1; \theta_2\right) = \frac{F\left({}^{k}/_{m}, \theta_1, \theta_2\right)}{\sum_{k=1}^{k\ max} F\left({}^{k}/_{m}, \theta_1, \theta_2\right)} \quad (۱۷)$$

تابع F به صورت رابطه

$$F(x, a, b) = \frac{x^{a-1}(1-x)^{b-1}\Gamma(a+b)}{\Gamma(a)\Gamma(b)} \quad (۱۸)$$

تعریف می شود.

که $\Gamma(a)$ و $\Gamma(b)$ و $\Gamma(a+b)$ توابع گاما بوده و بصورت رابطه

$$\Gamma(a) = \int_0^{\infty} e^{-x} . x^{a-1} \quad (۱۹)$$

تعریف شد. شکل تابع وزن‌دهی و حداکثر تعداد وقفه‌های بهینه متغیر پرتواتر در هر مدل رگرسیون می‌تواند متفاوت باشد؛ اما به‌صورت کلی توابع وزن‌دهی معرفی‌شده بر اساس پارامترهای تعریف‌شده، وزن‌های غیرمنفی ایجاد می‌کنند و برای تعیین مقدار ضریب متغیر پُرتواتر و وقفه‌های آن (β)، از فرض برابر یک بودن مجموع وزن‌های ایجادشده در مدل رگرسیون استفاده می‌شود. ازنظر پارامتریک الگوی معرفی‌شده MIDAS یک الگوی خطی است که با واردکردن تابع وزن‌دهی و اعمال وزن به وقفه‌های متغیر پُرتواتر، از حالت خطی به غیرخطی تبدیل می‌شود. بر اساس مطالعه گیسلز و همکارانش لازم است از

روش‌های برآورد غیرخطی[۳۲] و حداقل نمودن مجموع مربعات جملات اختلال برای تخمین ضرایب مدل معرفی‌شده استفاده کرد.

۴-۳- معیارهای ارزیابی پیش‌بینی مدل‌های رگرسیون

پس از برآورد مدل‌های رگرسیون، به‌منظور مقایسه قدرت پیش‌بینی جهت انتخاب بهترین مدل برای پیش‌بینی یک سری زمانی می‌توان از معیارهای مختلفی استفاده نمود. معیارهای مورد استفاده جهت ارزیابی مدل برآورد شده و دقت پیش‌بینی، در این مطالعه به‌صورت روابط (۲۰) تا (۲۶) است.

$$Sum\ of\ Square\ Error:\ SSE\ =\ \sum_{t=1}^{T}(y_t-\hat{y}_t)^2 \quad (۲۰)$$

$$Sum\ of\ Square\ Error:\ SSE\ =\ \sum_{t=1}^{T}(y_t-\hat{y}_t)^2 \quad (۲۱)$$

$$Relative\ Square\ Error:RSE\ =\ \frac{\sum_{t=1}^{T}(y_t-\hat{y}_t)^2}{\sum_{t=1}^{T}(y_t-\bar{y}_t)^2} \quad (۲۲)$$

$$Root\ Relative\ Square\ Error:RSE\ =\ \sqrt{\frac{\sum_{t=1}^{T}(y_t-\hat{y}_t)^2}{\sum_{t=1}^{T}(y_t-\bar{y}_t)^2}} \quad (۲۳)$$

$$Mean\ Squared\ Error:\ MSE=\frac{\sum_{t=T+1}^{T+m}\left(y_t^f-y_t\right)^2}{m} \quad (۲۴)$$

$$Root\ Mean\ Square\ Error:\ RMSE=\sqrt{\frac{\sum_{t=T+1}^{T+m}\left(y_t^f-y_t\right)^2}{m}} \quad (۲۵)$$

$$Mean\ Absolute\ Error:\ MAE=\frac{\sum_{t=T+1}^{T+m}\left|y_t^f-y_t\right|}{m} \quad (۲۶)$$

$$Mean\ Absolute\ Percentage\ Error:MAPE=\frac{100\sum_{t=T+1}^{T+m}\left|\frac{y_t^f-y_t}{y_t}\right|}{m} \quad (۲۷)$$

m طول دوره پیش‌بینی، y_t مقادیر واقعی و y_t^f مقادیر پیش‌بینی شده است. همچنین به منظورمقایسه صحت پیش‌بینی از آزمون برابری توانایی پیش‌بینی که توسط دیبولد و ماریانو (۱۹۹۵) ارائه شده، استفاده می‌شود .این آزمون براساس قدرت پیش‌بینی را تحت فرض برابری قدرت پیش‌بینی دو مدل بررسی می کند (Diebold-Mariano,1995). آماره دیبولد-ماریانو براساس رابطه

[32] Nonlinear Estimation

$$DM = {d}\Big/{\sqrt{v_d/F}} \quad (۲۸)$$

بدست می‌آید:

$$DM = {d}\Big/{\sqrt{v_d/F}} \quad (۲۹)$$

$$d = {(\sum_{t=1}^{F} d_t)}\Big/{F} \quad (۳۰)$$

$$v_d = \gamma_0 + 2\sum_{t=1}^{\infty}\gamma_t \quad (۳۱)$$

$$\gamma_t = cov(d_t, d_{t-1}) \quad (۳۲)$$

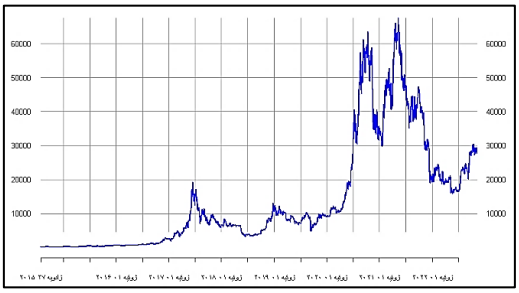
۴- داده‌ها و نتایج تجربی

در سال‌های گذشته، بیت‌کوین به‌عنوان ارز دیجیتال پیشرو در جهان، موردتوجه مصرف‌کنندگان، کسب‌وکارها و سرمایه‌گذاران قرارگرفته است. روند قیمت بیت‌کوین نشان می‌دهد که علاوه بر حجم بالای عرضه و تقاضا، این رمز ارز نوسانات شدید قیمتی را نیز در طول زمان تجربه می‌کند. تاکنون مطالعات بسیاری بر روی تأثیر بیت‌کوین بر بازار و قیمت سایر دارایی‌ها انجام‌شده است. نتایج این مطالعات می‌تواند در راستای مقابله با آسیب‌پذیری‌های ناشی از نوسانات شدید بیت‌کوین مورداستفاده قرار گیرد. ارزش فعلی بیت‌کوین به‌عنوان یک دارایی و همچنین مقبولیت ایجادشده برای این رمزارز، انگیزه‌ای برای بررسی و تحلیل ساختار تغییرات قیمت این رمز ارز و کشف الگوهایی برای پیش‌بینی قیمت آتی را ایجاد می‌نماید.

در این مطالعه داده‌های میان روزانه‌ای قیمت بیت‌کوین با فواصل زمانی ۵ دقیقه‌ای و در بازه زمانی ابتدای سال ۲۰۱۵ میلادی تا ششمین ماه سال ۲۰۲۳ میلادی جمع‌آوری شده است.[۳۳] کلیه محاسبات انجام‌شده در این مطالعه توسط زبان برنامه‌نویسی و محاسباتی R و بسته‌های نرم‌افزاری مرتبط صورت پذیرفته است.

---

[۳۳] اطلاعات جمع آوری شده از طریق ایجاد اکانت کاربری در وب سایت (https://www.cryptodatadownload.com) و دریافت داده‌های ۱ دقیقه ای انجام و سپس پردازش لازم با استفاده از نرم افزار *R* صورت پذیرفته است. به منظور قابل استفاده بودن داده‌های روزانه و هفتگی در مدل تواتر متفاوت، به صورت ۲۰۱۵/۰۱/۲۷ الی ۲۰۲۳/۰۵/۰۸ مرتب شده است.



نمودار ۱. روند قیمت بیت‌کوین (۲۰۱۵ تا ۲۰۲۳)

ماخذ : (https://www.cryptodatadownload.com)

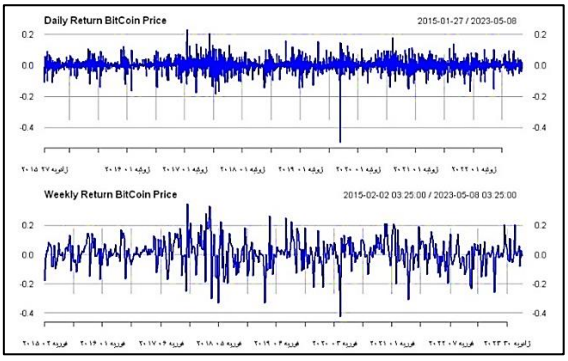
Figure 1.Bitcoin Daily Price Trend (2015 to 2023)

Source : (https://www.cryptodatadownload.com)

نمودار ۱ نشان می‌دهد که قیمت این رمزارز، روندهای متفاوتی را در بازه‌های زمانی مختلف تجربه کرده است. بازده قیمت بیت کوین در یک بازه زمانی مشخص از رابطه

$$R_t = ln(P_t) - ln(P_{t-1}) \qquad (۳۳)$$

محاسبه می شود.



نمودار ۲.بازدهی روزانه و هفتگی بیت‌کوین از سال ۲۰۱۵ تا ۲۰۲۳

ماخذ : نتایج پژوهش

Figure 2. Bitcoin Daily and Weekly Returns (2015 to 2023)

Source: Research Results

که در اینجا R_t بازدهی در زمان t اســت که می‌تواند بازدهی میان روزانه (اختلاف میان t و t-1 یک زمان ۵ دقیقه‌ای میان‌روزانه)، بازدهی روزانه (اختلاف میان t و t-1 دو روز متوالی و بـازدهی هفتگی (اختلاف میـان t و t-1 دو روز ابتـدایی برای دو هفتـه متوالی) در نظر گرفته‌شـــود. در این حالت در هر روز ۲۸۸ داده ۵ دقیقه‌ای برای قیمت بیت‌کوین و ۲۸۸ داده برای بازدهی میان روزانه بیت‌کوین محاســـبه می‌گردد. **نمودار ۲** بازدهی روزانه (بالا) و بازدهی هفتگی (پایین) را نشان می‌دهد.

جدول ۱. خلاصه اطلاعات سری زمانی قیمت روزانه، میان روزانه (۵ دقیقه‌ای)، بازدهی روزانه و هفتگی بیت‌کوین
ماخذ : نتایج پژوهش

Table 1.Time Series Information Summary of Daily, Inter-daily (5-minute), Daily and Weekly Returns of Bitcoin
Source*:* Research Results

	BTC 5-min (intardaily)	BTC (Daily)	Return BTC (Daily)	Return BTC (Weekly)
تعداد مشاهدات	۸۷۰۹۱۲	۳۰۲٤	۳۰۲٤	٤۳۲
کمترین	-۰٫۲۰۲٦	۲۱۱٫٤	-۰٫٤۹۷۲	-۰٫٤۲۵۱
بیشترین	۰٫۱۱٦۷	٦۷۵۲۷٫۹	۰٫۲۲۷٦	۰٫۳٤۷۷
چارک اول	-۰٫۰۰۰۸٦	۱۰٤۰٫۹	-۰٫۰۱۲۸	-۰٫۰۳۱۸
چارک سوم	۰٫۰۰۰۹۰	۱۹۹۵۸٫۳	۰٫۰۱۷۷	۰٫۰٦۵٦
میانگین	۵ e-۰٫۰۶	۱۳۸۹۲٫۷۷	۰٫۰۰۱۵	۰٫۰۱۰۷
میانه	۰	۷۹۳٦٫۰۵	۰٫۰۰۱۵	۰٫۰۱۱۸
واریانس	۷ e-۰٫۰۶	۲٦۰٦۰٤۳۷۹	۰٫۰۰۱٤	۰٫۰۱۰۲
انحراف معیار	۰٫۰۰۲۵۹	۱٦۱٤۳٫۲٤	۰٫۰۳۸۱	۰٫۱۰۱۲
کشیدگی	-۱٫۱۳۳۹	۱٫۳۹۹۷۱۱	-۰٫۸۳٤۷	-۰٫۳٦۲۱
چولگی	۱۰۲٫۸٦۳۰	۰٫۹۵۳۵	۱۲٫۷٤	۱٫٦۱۰۱

خلاصـــه اطلاعات مربوط به ســـری زمانی قیمت روزانه، قیمت میان روزانه‌ی ۵ دقیقه‌ای، بازدهی روزانه و بازدهی هفتگی در بازه زمانی سـال ۲۰۱۵ میلادی تا سـال ۲۰۲۳ میلادی در جدول ۱ آورده شده است.

۲-۴- آزمون مانایی سری زمانی

در اولین گام برای تجزیه‌وتحلیل سری زمانی قیمت بیت‌کوین، مانایی این سری زمانی موردبررسی قرار می‌گیرد. نتایج آزمون دیکی فولر تعمیم‌یافته و آزمون فیلیپس پرون، وجود

ریشه واحد در سری زمانی قیمت روزانه بیت‌کوین و همچنین فرم لگاریتمی آن و نامانایی این دو سری زمانی را تائید می‌کنند.

جدول ۲. آزمون ریشه واحد (سری زمانی قیمت بیت‌کوین، فرم لگاریتمی قیمت، بازدهی روزانه و بازدهی هفتگی)
ماخذ : نتایج پژوهش

Table 2. Unit Root Test
Source : Research Result

آزمون	آماره	قیمت روزانه	لگاریتم قیمت روزانه	بازدهی روزانه	بازدهی هفتگی
دیکی فولر تعمیم یافته	Dickey-Fuller	-۲٫۱۶۴۷	-۱٫۳۹۵۲	-۱۳٫۴۶	-۶٫۶۶۷۱
	p-value	۰٫۵۰۸۶	۰٫۸۳۴۴	۰٫۰۱*	۰٫۰۱*
فیلیپس پرون	Dickey-Fuller Z(alpha)	-۸٫۸۵۶۲	-۳٫۹۳۳	-۳۲۹۳٫۵	-۴۰۶٫۱۱۸۲
	p-value	۰٫۶۱۵۸	۰٫۸۹۰۴	۰٫۰۱*	۰٫۰۱*

نتایج این دو آزمون در **جدول ۲** نشان می‌دهد که سری‌های زمانی مورد استفاده در این پژوهش، یعنی سری‌زمانی بازدهی روزانه و سری‌زمانی بازدهی هفتگی بیت‌کوین مانا هستند.

۳-۴- انتخاب مدل ARIMA-GARCH

به‌منظور انتخاب مرتبه‌های p و q در الگوی ARIMA، ضمن بررسی شهودی توابع خودهمبستگی[۳۴] و خودهمبستگی جزئی[۳۵] ، یک مجموعه مدل با مرتبه‌های متفاوت از p و q برآورد و معیارهای اطلاعات[۳۶] برای آن مجموعه محاسبه می‌شود. بهترین مدل ARIMA در این بخش مدلی است که کمترین مقدار آماره آکائیک را داشته باشد. نرم‌افزار R با استفاده از بسته‌های tseries و forecast امکان برآورد مدل ARIMA با مراتب مختلف را فراهم می‌کند. همچنین تابع auto.arima به‌صورت پیش فرض بهترین مدل ARIMA را برای یک سری زمانی معرفی می‌نماید. مطابق با نتایج، برای سری زمانی بازدهی روزانه بیت‌کوین، در مدل ARIMA(1,0,2) ضرایب برآورد شده در سطح اطمینان ۹۵ درصد معنادار بوده و این مدل کمترین مقدار معیار آکائیک را دارد. همچنین برای سری زمانی بازدهی هفتگی بیت

[34] Auto Correlation Function
[35] Partial Auto Correlation Function
[36] Information Criteria

کوین، ضرایب مدل ARIMA(2,0,2) در سطح اطمینان ۹۵ درصد معنادار و مقدار آماره آکائیک، کمترین مقدار است.

جدول ۳. مدل ARIMA بر اساس معیار آکائیک
ماخذ : نتایج پژوهش

Table 3.ARIMA Model Based on Akaike Criterion
Source : Research Result

سری زمانی بازدهی روزانه بیت کوین ARIMA(1,0,2)				
	Estimate	Std. Error	z value	Pr(>|z|)
ar1	۰٫۸۵۷	۰٫۲۳۷	۳٫۶۰	۰٫۰۰۰۳***
ma1	-۰٫۸۹۶	۰٫۲۳۸	-۳٫۷۶	۰٫۰۰۰۱***
ma2	۰٫۰۵۳	۰٫۰۱۸	۲٫۹۱	۰٫۰۰۳۵**
intercept	۰٫۰۰۱۵	۰٫۰۰۰۷	۱٫۹۸	۰٫۰۴۶۹*
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
AIC= -۱۱۱۷۳٫۴۳	log likelihood =۵۵۹۰٫۷۱۵		sigma^2 =۰٫۰۰۱۴۵۱	
سری زمانی بازدهی هفتگی بیت کوین ARIMA(2,0,2)				
	Estimate	Std. Error	z value	Pr(>|z|)
ar1	-۱٫۰۲۵	۰٫۰۱۰	-۹۸٫۵۱	۲e-۱۶***
ar1	-۰٫۹۸۶	۰٫۰۰۹	-۱۰۸٫۰۸	۲e-۱۶***
ma1	۱٫۰۰۷	۰٫۰۱۰	۹۱٫۸۵	۲e-۱۶***
ma2	۰٫۹۹۹۹	۰٫۰۱۳۰۷	۷۶٫۵۰۴۷	۲e-۱۶***
intercept	۰٫۰۱۱۱	۰٫۰۰۴۹۳	۲٫۲۵۵۸	۰٫۰۲۴۰۸*
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
AIC= -۷۲۶٫۶۹	log likelihood =۳۶۸٫۲۹		sigma^2 =۰٫۰۱۰۵۳	

نتایج برآورد مدل به همراه معناداری ضرایب برآورد شده و معیار آکائیک در جدول ۳ آورده شده است. بررسی شهودی باقیمانده‌های مدل‌های برآورد شده برای سری زمانی بازدهی روزانه و هفتگی بیت‌کوین نشان‌دهنده وجود نوسان در سری‌های زمانی مذکور است. به‌منظور بررسی دقیق وجود ناهمسان‌واریانس مشروط، از آزمون ARCHTEST در نرم‌افزار R استفاده می‌شود.

جدول ٤.آزمون وجود اثرات ARCH
ماخذ : نتایج پژوهش

Table 4.ARCH Effect Test
Source : Research Result

ARCH LM-test; Null hypothesis: no ARCH effects		
	بازدهی روزانه	بازدهی هفتگی
Chi-squared	۶۷٫۵۴۹۸	۲۱٫۳۷
p-value	۹٫۱۷e-۱۰	۰٫۰٤٦

نتیجه آزمون در **جدول ٤** نشان‌دهنده رد فرض صفر، مبنی بر عدم وجود اثر واریانس ناهمسان برای سری‌های زمانی بازدهی روزانه و هفتگی بیت‌کوین است. در مرحله بعدی با در نظر گرفتن مدل پایه GARCH (1,1) ، هر یک از سری‌های زمانی بازدهی روزانه و هفتگی بیت‌کوین در ۳ حالت sGARCH، eGARCH و gjrGARCH برآورد می‌گردند.[۳۷] همچنین در هر یک از مدل‌های برآورد شده ۵ حالت توزیع نرمال، توزیع نرمال چوله، توزیع استیودنت، توزیع استیودنت چوله و توزیع خطای تعمیم یافته در نظر گرفته شده است که در مجموع ۱۵ مدل برای هر سری زمانی در این مرحله برآورده گردیده است. به منظور آماده‌سازی داده‌ها برای مقایسه دقت پیش‌بینی مدل‌های مختلف، داده‌های روزانه (۳۰۲۴ داده) و هفتگی (۴۳۲ داده هفتگی) به دو بخش تقسیم شده است. بازدهی روزانه از ابتدای سال ۲۰۱۵ تا انتهای سال ۲۰۲۲ (۲۵۲۸) در برآورد مدل مورد استفاده قرار گرفته و از ابتدای ۲۰۲۳ تا ۲۰۲۳/۰۵/۰۸ (۴۹۶ داده) به منظور پیش بینی مورد استفاده قرار گرفته‌اند. همچنین برای بازدهی هفتگی، اطلاعات هفتگی تا پایان سال ۲۰۲۲ در مدل برآورد شده مورد استفاده قرار گرفته (۴۱۳ داده هفتگی) و اطلاعات سال ۲۰۲۳ به منظور سنجش دقت پیش‌بینی از مدل خارج شده است.

[۳۷] به منظور تخمین مدل مذکور در نرم‌افزار *R* از بسته نرم افزاری *rugarch* استفاده می شود.

جدول ۵.اطلاعات مدل ARIMA(1,2)-GARCH(1,1) - بازدهی روزانه بیت‌کوین
ماخذ : نتایج پژوهش

Table 5. Data from ARIMA(1,2)-GARCH(1,1) Model - Bitcoin Daily Return
Source : Research Result

	sGARCH					eGARCH					gjrGARCH				
	normal	Skew-normal	t-Student	Skwe-t-Student	GED	normal	Skew-normal	t-Student	Skwe-t-Student	GED	normal	Skew-normal	t-Student	Skwe-t-Student	GED
Log likelihood	٤٨١٥	٤٨٢٢	٥١٧٤	٥١٧٤	٥١٨٧	٤٨٦٢	٤٨٣٣	٥٢٠١	٥٢٠٢	٥٢٠٠	٤٨١٨	٤٨٢٤	٥١٧٧	٥١٧٧	٥١٨٩
AIC	-٣/٨٠	-٣/٨٠	-٤/٠٨	-٤/٠٨	-٤/٠٩	-٣/٨١	-٣/٨١	-٤/١١	-٤/١٠	-٤/١٠	-٣/٨٠	-٣/٨٠	-٤/٠٨	-٤/٠٨	-٤/٠٨

جدول ۶. اطلاعات مدل ARIMA(2,2)-GARCH(1,1) - بازدهی هفتگی بیت‌کوین
ماخذ : نتایج پژوهش

Table 6. Data from ARIMA(۲,2)-GARCH(1,1) Model - Bitcoin Weekly Returns
Source : Research Result

	sGARCh					eGARCH					gjrGARCH				
	normal	Skew-normal	tStudent	Skwe-TStudent	GED	normal	Skew-normal	tStudent	Skwe-TStudent	GED	normal	Skew-normal	tStudent	Skwe-TStudent	GED
Log likelihood	٣٦٠/٢٧	٣٦٤/٩٤	٣٨٤/٩٠	٣٨٥٠٦٤	٣٨٥/٥٢	٣٦٢/١٦	٣٦٦/١٨	٣٩٣/٧١	٤٠٣/١٧	٣٨٩/٩١	٣٦٢/١٧	٣٦٤/٢٩	٣٩١/٦٠	٣٩١/٧١	٣٨٨/٤٤
AIC	-١/٧١	-١/٧٢	-١/٨٢	-١/٨٢	-١/٨٢	-١/٧١	-١/٧١	-١/٨٦	-١/٩٠	-١/٨٤	-١/٧١	-١/٧٢	-١/٨٥	-١/٨٤	-١/٨٣

مقادیر معیار آکائیک و لگاریتم درست‌نمایی برای مدل‌های برآورد شده در **جدول ۵** و جدول ٦ آورده شده است.[۳۸] این نتایج نشان می‌دهد برای بازدهی روزانه بیت‌کوین مدلARIMA(1,2)-eGARCH(1,1) با توزیع خطای تی‌استیودنت و برای بازدهی هفتگی بیت‌کوین مدل ARIMA(2,2)-eGARCH(1,1) با توزیع خطای تی‌استیودنت چوله دارای کمترین مقدار در معیار آکائیک و بالاترین مقدار لگاریتم درستنمایی را دارد لذا این دو مدل در میان مدل‌های خانواده GARCH بعنوان بهترین مدل برای بازدهی روزانه و هفتگی بیت‌کوین انتخاب می‌شوند. نتیجه آزمون لیونگ باکس[۳۹]روی باقیمانده‌های استانداردشده در تمام مدل‌های برآورد شده، نشان‌دهنده عدم وجود خودهمبستگی میان باقیمانده‌ها می‌باشد.

۴-۴- مدل داده‌های ترکیبی با تواتر زمانی متفاوت

در این بخش با استفاده از رویکرد جدید مدل‌سازی داده‌های ترکیبی با تواتر زمانی متفاوت، سری‌های زمانی بازدهی روزانه و هفتگی بیت‌کوین بررسی و مدل‌سازی می‌شود. بدین منظور از داده‌های بازدهی روزانه و هفتگی که با استفاد از بازدهی‌های میان‌وزانه (۵ دقیقه‌ای) ساخته می شوند، استفاده شده است. با توجه به انجام معاملات در بازار رمزارزها به‌صورت ۷ روز هفته، مدل‌سازی در این بخش با در نظر گرفتن متغیر m=۲۸۸ برای متناظر کردن داده‌های پُرتواتر(بازدهی میان‌روزانه ۵ دقیقه‌ای) بعنوان متغیر توضیح دهنده با داده‌های کم‌تواتر (بازدهی روزانه) بعنوان متغیر وابسته و همچنین m=۷ برای ایجاد تناظر میان داده‌های روزانه (بعنوان متغیر توضیح دهنده) و هفتگی بعنوان متغیر وابسته تعریف می‌شود. توابع وزن‌دهی معمول در الگوی MIDAS توابع آلمون، آلمون نمایی و بتا می‌باشند که هر سه تابع وزن‌دهی بصورت جداگانه در مدل وارد و نتایج برای پیش‌بینی سری زمانی بازدهی روزانه و هفتگی مورد استفاده قرار گرفته است. کلیه برآوردها از طریق بسته نرم‌افزاری midas_r که توسط گیسلز و همکاران توسعه داده شده و بصورت اتوماتیک مقادیر اولیه و تعداد وقفه بهینه را انتخاب می‌کند، انجام شده است. با توجه به اینکه هدف نهایی این مطالعه سنجش قدرت پیش‌بینی مدل است، از میان مدل‌های موجود، بهترین مدل با کمترین مقدار آکائیک در هر مرحله بصورت خودکار توسط نرم‌افزار انتخاب می‌شود.

---

[۳۸] به منظور خلاصه سازی متن، ضرایب و جزئیات مدل‌های برآورد شده در پیوست آورده شده است.

[39] Ljung-Box Test

جدول ۷ .نتایج وقفه بهینه و معیار آکائیک در مدل MIDAS
ماخذ : نتایج پژوهش

Table 7 .Results of Optimal Lag and Akaike's Criterion in MIDAS Model
Source : Research Result

سری زمانی بازدهی روزانه			
nbeta	nealmon	almonp	
۰:۱۵۵	۰:۱۹۹	۰:۲۸۷	K
-۱۱۲۹۵٫۳۲	-۱۲۵۶۰٫۹۹	-۲۲۹۷۹٫۸۸	AIC
سری زمانی بازدهی هفتگی			
nbeta	nealmon	almonp	
۰:۲	۰:۲	۰:۲	K
-۸۷۶٫۵۳	-۸۷۶٫۵۳	-۸۷۶٫۹۲	AIC

نتایج تعداد وقفه‌های بهینه مطابق با کمترین مقدار برای معیار آکائیک مربوط به برآورد سری‌های زمانی بازدهی روزانه و هفتگی با استفاده از هر سه تابع وزن‌دهی معرفی شده در **جدول ۷** آورده شده است.

۵-۴- پیش‌بینی

هدف اصلی در این مطالعه بررسی دو رویکرد در مدل‌سازی سری‌های زمانی، به منظور تعیین مدل بهینه برای پیش‌بینی است. در این بخش، مدل بهینه بر اساس کمترین میزان خطا و بیشترین مقدار دقت انتخاب می‌شود. به‌منظور انجام پیش‌بینی، محدوده داده‌های جمع‌آوری‌شده به دو بخش آموزش[۴۰] و آزمون[۴۱] تقسیم‌بندی و هر دو الگوی مورد نظر با در نظر گرفتن داده‌های بخش آموزش برآورد می‌گردد. سپس با استفاده از مدل برآورد شده، مقادیر سری زمانی برای بخش آزمون پیش‌بینی و با مقادیر واقعی مقایسه می‌گردد. به‌منظور یکسان بودن بازه زمانی موردنظر جهت پیش‌بینی، کلیه داده‌های مربوط به سال ۲۰۲۳ از نمونه خارج گردیده و هر دو رویکرد برای بازه زمانی ابتدای ۲۰۱۵ تا انتهای ۲۰۲۲ برآورد شده است. پیش‌بینی برای مدل‌های خانوادهARIMA-GARCH در ۳ حالت sGARCH، eGARCH و gjrGARCH و هر یک برای ۵ حالت توزیع نرمال، توزیع نرمال چوله، توزیع استیودنت، توزیع استیودنت چوله و توزیع خطای تعمیم یافته، با تکنیک پنجره

[40] Train
[41] Test

غلتان[۴۲] یک گام رو به جلو انجام شده است.[۴۳] در بخش مدل‌سازی با داده‌های با تواتر متفاوت پیش‌بینی برای سه تابع وزن‌دهی آلمون، آلمون نمایی و بتا، براساس الگوی پنجره غلتان و الگوی بازگشتی[۴۴] انجام و در مجموع ۶ مدل در این بخش برآورد و پیش‌بینی شده است.[۴۵]

۵- نتایج ارزیابی دقت پیش‌بینی

نتایج معیارهای ارزیابی میزان خطای پیش‌بینی برای تمام مدل‌های برآورد شده روی سری زمانی بازدهی روزانه، در جدول ۸ آورده شده است[۴۶]. نتایج این مرحله نشان می‌دهد برای سری زمانی بازدهی روزانه، مدل برآورد شده با الگوی MIDAS و تابع وزن‌دهی آلمون، از نظر دقت در پیش‌بینی برتری کامل نسبت به مدل‌های خانواده ARIMA-GARCH با توزیع‌های مختلف و مدل‌های MIDAS با توابع وزن‌دهی بتا و آلمون نمایی دارد. در دو معیار قدرمطلق میانگین خطا (MAE) و میانگین درصد قدر مطلق خطا (MAPE) پیش‌بینی با رویکرد پنجره غلتان با مدل MIDAS و تابع وزن دهی آلمون نسبت به دیگر روش‌ها برتری دارد و در معیار (RMSE) پیش‌بینی با استفاده از الگوی بازگشتی نتایج بهتری را نشان می‌دهد. معیارهای (RSE) و (SSE) و (RRSE) نیز نشان‌دهنده خطای کمتر در مدل MIDAS با تابع وزن‌دهی آلمون می باشند. نتایج پیش‌بینی برای سری زمانی بازدهی هفتگی در جدول ۸، نشان دهنده برتری کامل مدل MIDAS با تابع وزن‌دهی آلمون نمایی و رویکرد پیش‌بینی پنجره غلتان است بگونه‌ای که کلیه معیارهای ارزیابی دقت پیش‌بینی برای این رویکرد، دارای مقادیر کمتر نسبت به دیگر روش‌های معرفی شده در این پژوهش می‌باشند. بصورت کلی نتایج این بخش نشان می‌دهد دقت پیش‌بینی رگرسیون MIDAS نسبت به مدل‌های خانواده ARIMA-GARCH بالاتر بوده و انتخاب تابع وزن‌دهی مناسب می تواند در افزایش دقت پیش‌بینی رگرسیون MIDAS تاثیرگذار باشد.

---

[42] Rolling window

[۴۳] از تابع ugarchforecast استفاده شده است.

[44] Recursive

[۴۵] از تابع average_forecast در بسته نرم‌افزاری midas_r استفاده شده است.

[۴۶] به‌منظور محاسبه معیارهای مذکور از بسته Metrics در نرم‌افزار R استفاده‌شده است.

فصلنامه علمی پژوهش اقتصاد مقداری (بررسی های اقتصادی سابق) دانشگاه شهید چمران اهواز

جدول ۸.نتایج معیارهای ارزیابی برای سری زمانی بازدهی روزانه

ماخذ : نتایج پژوهش

Table 8 . Criteria Results for Daily Return Time Series

Source : Research Result

	ARIMA(1,2) - GARCH (1,1)															MIDAS (Almon)		MIDAS (nealmon)		MIDAS (beta)	
	GARCH					eGARCH					gjrGARCH										
	Normal	Normal	S.Normal	Student	Student	S.Normal	Normal	Student	S.Normal	S.Student	Ged	Normal	S.Normal	Student	S.Student	Ged	rolling	recursive	rolling	recursive	rolling	recursive
MAE	۰,۰۲	۰,۰۲۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۲	۰,۰۰۱	۰,۰۱۹	۰,۰۲	۰,۰۲۱	۰,۰۲۱
MAPE	۱,۹۹	۱,۶۱۵	۱,۵۴	۱,۴۹	۱,۴۴	۱,۸۱	۱,۳۸	۱,۵۶	۱,۴۹	۱,۴۷	۱,۸۳	۱,۵۳	۱,۶۴	۱,۶۰	۱,۴۹	۱,۴۴	۰,۴۲۳	۱,۶۸۸	۱,۹	۱,۴۴	۱,۴۴
MSE	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰۱	۰,۰۰	۰,۰۰۸	۰,۰۰۸	۰,۰۰۱	۰,۰۰۱
RMSE	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۳	۰,۰۰۳	۰,۰۲۹	۰,۰۲	۰,۰۳	۰,۰۳
RSE	۱,۰۰	۱,۰۰۸	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۲	۱,۰۰	۱,۰۰	۱,۰۱	۱,۰۱	۱,۰۱	۱,۰۱	۰,۰۱۵	۰,۸۱۹	۰,۸۵	۰,۹۹	۰,۹۹
SSE	۰,۵۲	۰,۵۱	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۱	۰,۵۲	۰,۵۲	۰,۵۲	۰,۵۲	۰,۰۰۷	۰,۴۲	۰,۴۴	۰,۵۱	۰,۵۱
RRSE	۱,۰۰	۱,۰۰۳	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۱	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۱,۰۰	۰,۱۲۲	۰,۹۰۵	۰,۹۲	۰,۹۹	۰,۹۹

جدول ۹. نتایج معیارهای ارزیابی برای سری زمانی بازدهی هفتگی
ماخذ: نتایج پژوهش

Table 9 .Criteria Results for Weekly Return Time Series
Source : Research Result

MIDAS (beta)		MIDAS (nealmon)		MIDAS (Almon)		ARIMA(2,2)- GARCH(1,1)															
						gjrGARCH					eGARCH					GARCH					
recursive	rolling	recursive	rolling	recursive	rolling	Ged	S.Student	Student	S.Normal	Normal	Ged	S.Student	Student	S.Normal	Normal	Ged	S.Student	Student	S.Normal	Normal	
۰٫۰۷۱	۰٫۰۷	۰٫۰۷۵۱	۰٫۰۵	۰٫۰۵	۰٫۰۵	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	۰٫۰۷	MAE
۱٫۰۴	۱٫۰۴	۰٫۸۴۸	۰٫۸۴	۰٫۸۵	۰٫۸۶	۰٫۹۲	۰٫۹۳	۰٫۹۵	۱٫۰۱	۱٫۰۱	۱٫۰۱	۱٫۰۸	۱٫۰۰	۰٫۹۹	۱٫۰۰	۰٫۹۲	۰٫۹۵	۰٫۹۳	۰٫۹۷	۰٫۹۹	MAPE
۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۴	۰٫۰۰۴	۰٫۰۰۴	۰٫۰۰۴	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	۰٫۰۰۹	MSE
۰٫۰۹	۰٫۰۹	۰٫۰۶۸	۰٫۰۶۸	۰٫۰۶۹	۰٫۰۶۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	۰٫۰۹	RMSE
۱٫۰	۱٫۰	۰٫۵۲	۰٫۵۲	۰٫۵۴	۰٫۵۴	۱٫۰۳	۱٫۰۲	۱٫۰۲	۱٫۰۵	۱٫۰۴	۱٫۰۲	۱٫۰۱	۱٫۰۲	۱٫۱۰	۱٫۰	۱٫۰۴	۱٫۰۷	۱٫۰۴	۱٫۱۰	۱٫۰۶	RSE
۰٫۱۷	۰٫۱۷	۰٫۰۸	۰٫۰۸	۰٫۰۹	۰٫۰۹	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۷	۰٫۱۸	۰٫۱۸	۰٫۱۷	۰٫۱۸	۰٫۱۷	۰٫۱۸	۰٫۱۸	SSE
۱٫۰۱۶	۱٫۰۱۶	۰٫۷۲۵	۰٫۷۲۱	۰٫۷۳۵	۰٫۷۳۵	۱٫۰۱۶	۱٫۰۱۳	۱٫۰۱۱	۱٫۰۲۵	۱٫۰۲۰	۱٫۰۱۳	۱٫۰۰۸	۱٫۰۰۹	۱٫۰۵۳	۱٫۰۲۶	۱٫۰۲۱	۱٫۰۳۶	۱٫۰۲۲	۱٫۰۵۱	۱٫۰۳۱	RRSE

در این پژوهش علاوه بر بررسی معیارهای خطای پیش‌بینی، از آزمون دیبولد ماریانو به منظور بررسی صحت پیش‌بینی و مقایسه میان یک مدل پایه، با دیگر مدل‌ها استفاده شده است. این آزمون قدرت پیش‌بینی را تحت فرض صفر برابری قدرت پیش‌بینی دو مدل بررسی می‌کند. بسته MultiDM در نرم افزار R، تغییر در فرض صفر و اجرای آزمون مذکور را امکان‌پذیر می‌نماید. لذا با در نظر گرفتن یک مدل پایه و فرض صفر برتری قدرت پیش‌بینی

مدل پایه نسبت به مدل‌های معرفی شده، آماره آزمون دیبولد ماریانو محاسبه می‌شود. آزمون دیبولد ماریانو ابتدا برای پیش‌بینی بدست‌آمده از مدل‌های خانواده ARIMA-GARCH اجرا شده‌است.

جدول ۱۰. نتایج آزمون دیبولد ماریانو برای سری زمانی بازدهی روزانه (تمام مدل‌ها)
ماخذ : نتایج پژوهش

Table 10. Diebold Mariano Test Results for Daily Return Time Series (all Models)
Source : Research Result

مدل	تابع وزن‌دهی/ توزیع خطا/ الگوی پیش‌بینی		آماره	ARIMA(1,2) - GARCH (1,1)				
				Normal	S.Normal	Student	S.Student	Ged
ARIMA (1,2) - GARCH (1,1)	Normal		pvalue	---	۰٫۹۶	۰٫۴۴	۰٫۴۷	۰٫۲۱
			statistic	---	-۱٫۷۲	۰٫۱۶	۰٫۰۸	۰٫۸۱
	S.Normal		pvalue	۰٫۰۴	---	۰٫۱۷	۰٫۱۹	۰٫۱۰
			statistic	۱٫۷۲	---	۰٫۹۵	۰٫۸۶	۱٫۳۰
	Student		pvalue	۰٫۵۶	۰٫۸۳	---	۰٫۹۰	۰٫۰۸
			statistic	-۰٫۱۶	-۰٫۹۵	---	-۱٫۲۶	۱٫۴۳
	S.Student		pvalue	۰٫۵۳	۰٫۸۱	۰٫۱۰	---	۰٫۰۶
			statistic	-۰٫۰۸	-۰٫۸۶	۱٫۲۶	---	۱٫۵۲
	Ged		pvalue	۰٫۷۹	۰٫۹۰	۰٫۹۲	۰٫۹۴	---
			statistic	-۰٫۸۱	-۱٫۳۰	-۱٫۴۳	-۱٫۵۲	---
MIDAS	almon	Rolling Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۸٫۵۴	۸٫۵۴	۸٫۴۹	۸٫۴۹	۸٫۴۲
		Recursive Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۸٫۵۴	۸٫۵۴	۸٫۴۹	۸٫۴۹	۸٫۴۲
	nealmon	Rolling Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۴٫۵۹	۴٫۵۵	۴٫۵۳	۴٫۵۳	۴٫۴۵
		Recursive Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۵٫۴۷	۵٫۳۹	۵٫۲۹	۵٫۲۸	۵٫۰۲
	beta	Rolling Forecast	pvalue	۰٫۲۴	۰٫۳۱	۰٫۲۴	۰٫۲۵	۰٫۱۹
			statistic	۰٫۷۲	۰٫۴۸	۰٫۶۹	۰٫۶۷	۰٫۸۸
		Recursive Forecast	pvalue	۰٫۲۳	۰٫۳۰	۰٫۲۴	۰٫۲۴	۰٫۱۸
			statistic	۰٫۷۵	۰٫۵۱	۰٫۷۲	۰٫۷۰	۰٫۹۱

نتایج جدول ۱۰ برای سری زمانی بازدهی روزانه نشان می‌دهد که در مدل سازی با رویکرد ARIMA-GARCH استفاده از توزیع خطای نرمال چوله، نسبت به توزیع خطای نرمال برتری

دارد. در مرحله بعدی رویکرد مدل‌سازی ARIMA-GARCH با رویکرد MIDAS برای پیش‌بینی سری زمانی بازدهی روزانه بیت‌کوین مورد مقایسه قرار گرفته‌است. نتایج در این بخش این آزمون نشان می‌دهد پیش‌بینی‌های رویکرد مدل‌سازی MIDAS با توابع وزن‌دهی آلمون و آلمون نمایی و در هر دو حالت پنجره غلتان و بازگشتی، نسبت به تمام مدل‌های خانواده ARIMA-GARCH بهتر عمل می‌کنند.

جدول ۱۱. نتایج آزمون دیبولد ماریانو برای سری زمانی بازدهی روزانه (مدل‌های MIDAS)
ماخذ: نتایج پژوهش

Table 11 .Diebold Mariano Test Results for Daily Return Time Series (MIDAS Models)
Source : Research Result

مدل	تابع وزن‌دهی	الگوی پیش‌بینی	آماره	MIDAS			
				nealmon		beta	
				Rolling Forecast	Rolling Forecast	Rolling Forecast	Rolling Forecast
MIDAS	almon	Rolling Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۹	۸٫۷۳	۸٫۷۱	۸٫۷۰
		Recursive Forecast	pvalue	۰٫۰۰	۰٫۰۰	۰٫۰۰	۰٫۰۰
			statistic	۹	۸٫۷۳	۸٫۷۱	۸٫۷۱
	nealmon	Rolling Forecast	pvalue	---	---	۰٫۰۰	۰٫۰۰
			statistic	---	---	٤٫۷۸	٤٫۷۸
		Recursive Forecast	pvalue	---	---	۰٫۰۰	۰٫۰۰
			statistic	---	---	۵٫٤۷	۵٫٤۹
	beta	Rolling Forecast	pvalue	۱	۱	---	---
			statistic	-٤٫۷۸	-۵٫٤۷	---	---
		Recursive Forecast	pvalue	۱	۱	---	---
			statistic	-٤٫۷۸	-۵٫٤۹	---	---

با توجه به این نتایج، مجددا برای سری زمانی بازدهی روزانه بیت‌کوین آزمون دیبولد ماریانو برای مدل‌های MIDAS با توابع وزن‌دهی مختلف اعمال و در جدول ۹ و جدول ۱۰ برای سری زمانی بازدهی روزانه نشان می‌دهد که در مدل سازی با رویکرد ARIMA-GARCH استفاده از توزیع خطای نرمال چوله، نسبت به توزیع خطای نرمال برتری دارد. در مرحله بعدی رویکرد مدل‌سازی ARIMA-GARCH با رویکرد MIDAS برای پیش‌بینی سری زمانی

بازدهی روزانه بیت‌کوین مورد مقایسه قرار گرفته‌است. نتایج در این بخش این آزمون نشان می‌دهد پیش‌بینی‌های رویکرد مدل‌سازی MIDAS با توابع وزن‌دهی آلمون و آلمون نمایی و در هر دو حالت پنجره غلتان و بازگشتی، نسبت به تمام مدل‌های خانواده ARIMA-GARCH بهتر عمل می‌کنند. مشخص می‌شود که مدل MIDAS با تابع وزن‌دهی آلمون نسبت به مدل MIDAS با توابع آلمون نمایی و بتا بهتر عمل می کند این نتایج، عملکرد بهتر مدل MIDAS با تابع وزن‌دهی آلمون در پیش‌بینی سری زمانی بازدهی روزانه را نشان می‌دهد که نتایج بدست‌آمده در بخش بررسی معیارهای خطای پیش‌بینی را نیز تایید می‌کند.

جدول ۱۲ .نتایج آزمون دیبولد ماریانو برای سری زمانی بازدهی هفتگی (تمام مدل‌ها)
ماخذ: نتایج پژوهش

Table 12 .Diebold Mariano Test Results for Weekly Return Time Series (all Models)
Source : Research Result

مدل	تابع وزن‌دهی/ توزیع خطا/ الگوی پیش‌بینی		آماره	ARIMA (2,2)- GARCH (1,1)				
				Normal	S.Normal	Student	S.Student	Ged
ARIMA (2,2)- GARCH (1,1)	Normal		pvalue	---	۰٫۲٤	۰٫۹۷	۰٫۵۲	۰٫۹۲
			statistic	---	۰٫٦۹	-۱٫۹٤	۰٫۰۷۳	-۱٫٤۵
	S.Normal		pvalue	۰٫۷۵	---	۰٫۹۵	۰٫۹۱	۰٫۹٦
			statistic	-۰٫٦۹	---	-۱٫٦۸	-۱٫۳۷	-۱٫۸۷
	Student		pvalue	۰٫۰۲	۰٫۰٤	---	۰٫۱۵	۰٫۵۹
			statistic	۱٫۹٤	۱٫٦۸	---	۱٫۰۳	-۰٫۲٤
	S.Student		pvalue	۰٫٤۷	۰٫۰۸	۰٫۸۵	---	۰٫۹۱
			statistic	۰٫۰۷	۱٫۳۷	-۱٫۰۳	---	-۱٫۳۷
	Ged		pvalue	۰٫۰۷	۰٫۰۳	۰٫٤۰	۰٫۰۸	---
			statistic	۱٫٤۵	۱٫۸۷	۰٫۲٤	۱٫۳۷	---
MIDAS	Rolling Forecast	almon	pvalue	۰٫۰۳	۰٫۰۳	۰٫۰٤	۰٫۰۳	۰٫۰٤
			statistic	۱٫۷۷	۱٫۸۲	۱٫٦۸	۱٫۷۷	۱٫٦۸
	Recursive Forecast		pvalue	۰٫۰۳	۰٫۰۳	۰٫۰٤	۰٫۰۳	۰٫۰٤
			statistic	۱٫۸۱	۱٫۸۷	۱٫۷۳	۱٫۸۱	۱٫۷۲
	Rolling Forecast	nealmon	pvalue	۰٫۰۲	۰٫۰۲	۰٫۰۳	۰٫۰۲	۰٫۰۳
			statistic	۱٫۸۹	۱٫۹٤	۱٫۸۱	۱٫۸۹	۱٫۸۰
			pvalue	۰٫۰۲	۰٫۰۲	۰٫۰۳	۰٫۰۲	۰٫۰۳

		Recursive Forecast	statistic	۱٫۹۰	۱٫۹۵	۱٫۸۱	۱٫۹۰	۱٫۸۱
	beta	Rolling Forecast	pvalue	۰٫۳۹	۰٫۲۸	۰٫۶۲	۰٫۴۰	۰٫۶۳
			statistic	۰٫۲۶	۰٫۵۶	-۰٫۳۲	۰٫۱۹	-۰٫۳۵
		Recursive Forecast	pvalue	۰٫۴۰	۰٫۲۸	۰٫۶۵	۰٫۴۳	۰٫۶۶
			statistic	۰٫۲۴	۰٫۵۵	-۰٫۳۹	۰٫۱۷	-۰٫۴۱

جدول ۱۳. نتایج آزمون دیبولد ماریانو برای سری زمانی بازدهی هفتگی (مدل‌های MIDAS)
ماخذ : نتایج پژوهش

Table 13. Diebold Mariano Test Results for Daily Return Time Series (MIDAS Models)
Source : Research Result

مدل	تابع وزن‌دهی	الگوی پیش‌بینی	آماره	MIDAS			
				almon		beta	
				Rolling Forecast	Rolling Forecast	Rolling Forecast	Rolling Forecast
MIDAS	almon	Rolling Forecast	pvalue	---	---	۰٫۰۳	۰٫۰۳
			statistic	---	---	۱٫۷۸	۱٫۷۹
		Recursive Forecast	pvalue	---	---	۰٫۰۳	۰٫۰۳
			statistic	---	---	۱٫۸۳	۱٫۸۴
	nealmon	Rolling Forecast	pvalue	۰٫۰۰	۰٫۰۰۶	۰٫۰۲	۰٫۰۲
			statistic	۲٫۹۶	۲٫۵۰	۱٫۹۲	۱٫۹۲
		Recursive Forecast	pvalue	۰٫۰۰۸	۰٫۰۰۹	۰٫۰۲۶	۰٫۰۲
			statistic	۲٫۳۸	۲٫۳۳	۱٫۹۲	۱٫۹۳
	beta	Rolling Forecast	pvalue	۰٫۹۶	۰٫۹۶	---	---
			statistic	-۱٫۷۸	-۱٫۸۳	---	---
		Recursive Forecast	pvalue	۰٫۹۶	۰٫۹۶	---	---
			statistic	-۱٫۷۹	-۱٫۸۴	---	---

نتایج آزمون دیبولد ماریانو در جدول ۱۳ برای سری زمانی بازدهی هفتگی نشان می‌دهد که مدلARIMA(1,2) - GARCH (1,1) با توزیع تی‌استیودنت نسبت به توزیع‌های نرمال و نرمال چوله بهتر عمل می‌کند. همچنین همین مدل با توزیع خطای تعمیم یافته نسبت به توزیع نرمال چوله عملکرد بهتری دارد. مانند مرحله قبلی تکرار آزمون دیبولد ماریانو برای سری زمانی بازدهی هفتگی نشان می‌دهد که مدل‌سازی MIDAS با توابع وزن‌دهی آلمون

و آلمون نمایی و در هر دو حالت پنجره غلتان و بازگشتی، نسبت به کلیه مدل‌های خانوده ARIMA-GARCH معرفی شده در این پژوهش عملکرد بهتری دارند. تفکیک نتایج و اجرای آزمون دیبولد ماریانو برای مدل MIDAS با انواع تابع وزن‌دهی، نشان می دهد تابع وزن‌دهی آلمون نمایی برتری کامل نسبت به دیگر توابع وزن‌دهی داشته و تابع وزن‌دهی آلمون نسبت به تابع وزن‌دهی بتا عملکرد بهتری دارد. نتایج **جدول ۱۲** نیز، عملکرد مطلوب مدل‌سازی MIDAS بهمراه تابع وزن‌دهی آلمون نمایی که در بخش بررسی معیارهای خطای پیش‌بینی برای پیش‌بینی بازدهی هفتگی مشاهده شد را تایید می کند.

۶- نتیجه‌گیری

در این پژوهش دو رویکرد در مدل‌سازی اطلاعات و داده‌های سری زمانی از نظر دقت در پیش‌بینی مورد بررسی قرار گرفت. رویکرد سنتی اقتصادسنجی در مدل‌سازی سری‌های زمانی که سالیان متمادی در حال استفاده است، در مقابل رویکردی نوین که در سالیان اخیر برای حل یکی از مشکلات مهم در مدل‌سازی اقتصادی، یعنی لزوم تواتر زمانی یکسان در یک مدل رگرسیون، طراحی‌شده است. در این مطالعه تلاش شد تمامی حالات ممکن در مدل‌سازی برای هر دو رویکرد، شامل انواع مدل‌های موجود، توزیع خطاهای مرسوم و توابع وزنی مورد استفاده در مطالعات گذشته، در کنار همدیگر مورد بررسی و آزمون قرار گیرند. همچنین از داده‌های با تواتر زمانی بالا (میان روزانه ۵ دقیقه‌ای) برای محاسبه بازدهی و مدل‌سازی استفاده شد. با توجه به معرفی رویکرد مدل‌سازی برای داده‌های با تواتر زمانی متفاوت به نظر می‌رسد توجه به موارد زیر می‌تواند نتایج به‌دست‌آمده در این مطالعه را شفاف‌تر نماید.

- قدرت مدل‌های خانواده ARIMA-GARCH بر پایه تولید خطای میانگین مربعات کوچک است. این موضوع می تواند در زمان مواجهه با نوسانات بالا در یک بازه زمانی کوتاه (داده‌های میان روزانه) یا شوک‌های موقتی، باعث ارائه پیش‌بینی‌های با دقت کمتر شود. مطالعات امره و همکاران (۲۰۱۲) و چلیک و ارگین (۲۰۱۳) نیز نشان می‌دهد مدل‌های MIDAS در پیش‌بینی قیمت و بازدهی دارایی‌هایی که نوسانات بالا در بازه‌های زمانی کوتاه دارند، عملکرد بهتری ارائه می‌کنند(Emre et al, 2012 & Celik & Ergin, 2013).
- درصورت وجود داده‌های با تواتر زمانی بالا برای یک دارایی (مانند رمزارزها و یا داده‌های سهام) و همچنین نوسانات بالا در اینگونه داده‌ها در صورتیکه هدف، پیش‌بینی بازدهی

باشد، استفاده از رویکرد مدل‌سازی داده‌های ترکیبی با تواترهای زمانی متفاوت (MIDAS) نسبت به رویکرد مدل‌سازی خودرگرسیون میانگین متحرک و مدل‌سازی واریانس ناهمسان مشروط (ARIMA-GARCH) ارجحیت خواهد داشت.

- پیچیدگی اصلی در مدل‌سازی با رویکرد MIDAS انتخاب تعداد وقفه‌های مناسب برای متغیر با تواتر زمانی بالا و انتخاب تابع وزن‌دهی مناسب است که هر دو تاثیر محسوسی در ارائه پیش‌بینی‌ها با دقت بالاتر خواهند داشت.
- براساس نتایج بدست آمده در این مطالعه، برای بازدهی روزانه، مدل‌سازی MIDAS با استفاده از تابع وزن دهی آلمون نتایج بهتری ارائه می‌کند. در حالیکه برای بازدهی هفتگی، استفاده از تابع وزن دهی آلمون نمایی پیشنهاد می‌شود. لذا به نظر می‌رسد تابع آلمون برای وزن‌دهی سری زمانی روزانه در مقابل داده‌های پرتواتر میان روزانه (۵ دقیقه ای) عملکرد بهتر و تابع وزن دهی آلمون نمایی برای وزن‌دهی سری زمانی هفتگی در مقابل داده‌های روزانه و میان روزانه بهتر عمل می‌کند.
- نتایج این مطالعه نشان می‌دهد استفاده از داده‌های پرتواتر میان روزانه (۵ دقیقه‌ای) و مدل‌سازی MIDAS، دقت پیش‌بینی‌ها را نسبت به رویکردهای مدل سازی سنتی اقتصادسنجی، افزایش و میزان خطای پیش‌بینی را به شکل محسوسی کاهش می‌دهد. این موضوع هم برای سری‌زمانی روزانه و هم هفتگی صدق می کند.
- با توجه به وجود داده‌های تواتر بالا(میان روزانه)، در سری‌های زمانی مالی، بازارهای سهام و رمزارزها که منجر به وجود اطلاعات باارزش در بازه‌های زمانی بسیار کوتاه شده است، پیشنهاد اصلی این مطالعه استفاده از رویکرد MIDAS در پیش‌بینی سری‌های زمانی مالی است.
- با توجه به خصوصیت ویژه مدل‌سازی MIDAS که امکان استفاده از چندین متغیر توضیح دهنده با تواترهای زمانی کاملا متفاوت در سمت راست رگرسیون را فراهم می نماید، استفاده از این رویکرد بخصوص برای داده‌های بازارهای مالی در داده‌های معاملات روزانه[47] می تواند منجر به تعیین استراتژی‌های بهینه برای سرمایه‌گذاران بازارهای مالی شود. این خصوصیت برای مدل‌های سنتی اقتصادسنجی متصور نیست.

[47] tick by tick data

- توسعه مدل‌های MIDAS منجر به طراحی مدل‌های ترکیبی GARCH-MIDAS به منظور استخراج اجزاء کوتاه مدت و بلندمدت متغیر توضیح دهنده با تواتر پایین نسبت به متغیر وابسته گردیده که این مطالعه پیشنهاد می‌کند مدل‌های GARCH-MIDAS نیز بر روی سری‌های زمانی مالی اجرا و نتایج پیش‌بینی مورد بررسی قرار گیرد.
- با توجه به خصوصیات منحصربه فرد سری زمانی قیمت بیت‌کوین مانند نوسانات بسیار بالا پیشنهاد می‌شود مطالعه حاضر روی یک سری زمانی دیگر نیز انجام و کارایی دو رویکرد در مقابل همدیگر موردسنجش قرار گیرند.

Acknowledgments: Acknowledgments may be made to individuals or institutions that have made an important contribution.

Conflict of Interest: The authors declare no conflict of interest.

Funding: The author(s) received no financial support for the research, authorship, and publication of this article.

Reference

Abasi Nami, H. (2021). Forecasting Crude Oil prices Volatility and Value at Risk: Single and Switching Regime GARCH Models. *Energy Economics review*,17(68), 141-174. SID: https://sid.ir/paper/380078/ [In Persian]

Amiri, H. , Pourjavan, A. and Zahedi, M. (2025). Gold, Currency and Bitcoin as Hedge or Safe Haven for Stocks: Evidence from Tehran Stock Exchange (TSE) using Smooth Transition Regression (STR) Models. *Quarterly Journal of Quantitative Economics (JQE)*, *21*(4), 220-272. [In Persian]

Andreou, E. Ghysels, E. Kourtellos, A. (2010). Regression Models with Mixed Sampling Frequencies. *Journal of Econometrics*. 158(2), Pages 246-261.

Barakchian, S. M., & Rezaei, M. (2016). Evaluation of Mixed-Frequency Regressions in Forecasting Seasonal Inflation Rate of Iran. *Journal of Economics and Modelling*, 7(25), 25-46. https://ecoj.sbu.ac.ir/article_52259_52c91c7c6bfd6ad4801b43f8e03ddda5.pdf [In Persian]

Bariviera, A.F. (2017). The In-efficiency of Bitcoin Revisited: A Dynamic Approach. *Economics Letters*, 161, 1- 4.

Bayat, M. Noferesti, M. (2015). *Applied Time Series Econometrics: Mixed Frequency Data Sampling Model*. Noor-e-Elm Pub. [In Persian]

Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327.

Box, G., Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control. Holden-Day.

Brockwell, P. Davis, R. and Calder, M. (2002). Introduction to Time Series and Forecasting. *Springer*,Vol 2.

Catania, L. Grassi, S. & Ravazzolo, F. (2019). Forecasting Cryptocurrencies Under Model and Parameter Instability. *International Journal of Forecasting*, 35, 485–501.

Celik & Ergin. (2013). Volatility Forecasting Using High Frequency Data: Evidence from Stock Markets. *Economic Modeling*, 36, 176-190.

Chegeni, A. & Gord, A. (2020). Stock Price Prediction in Tehran Stock Exchange Using Artificial Neural Network Model and ARIMA Model: A Case Study of Two Active Pharmaceutical Companies in Stock Exchange. *Financial Engineering and Securities Management*, 11(44), 350-371. SID : https://sid.ir/paper/396733 [In Persian]

Clements, M. P. and Galvão, A. B. (2008). Macroeconomic Forecasting with Mixed-Frequency Data: Forecasting Output Growth in the United States. *Journal of Business and Economic Statistics*, 26(4): 546-554.

Dashtban, M. Elyaspour, B. & Dashtban, S. (2019). The Effect of Exchange Rate Uncertainty on the Flow of Tourism in Iran: A Stochastic Volatility Model with Leverage Effects and Mixed Frequency Data Sampling (MIDAS) Approach. *Journal of Tourism Planning and Development*, 8(29), 173-190. SID : https://sid.ir/paper/375069/ [In Persian]

Diebold, F & Mariano, R. (1995). Comparing Predictive Accuracy. *Journal of Business & Economic Statistics*, 13(3), 253-63.

Emre, A. Fendoglu & Saltoglu. (2012). MIDAS Volatility Forecast Performance Under Market Stress: Evidence from Emerging Stock Markets. *Economics Letters*, 117(2), 528-532.

Enders, W. (2008). Applied Econometric Time Series. New York: John Wiley & Sons.

Feng Ma, M.I.M. Wahab, Chao Liang. (2020). Cryptocurrency Volatility Forecasting: A Markov Regime-Switching MIDAS Approach. *Energy*, 212 (2020), 118743.

Ghafari, F. & Farhadi, A. (2015). ARIMA-GARCH and State Space Models' Forecasting Power Case Study: Tehran Exchange Stock Index

(TEPIX). *Iranian Journal of Applied Economics*, 5(-), 33-42. SID: https://sid.ir/paper/202056/en [In Persian]

Ghysels, E. Santa-Clara, P. Volkanov, R.(2002b). The MIDAS Touch: Mixed Data Sampling Regression. Discussion Paper UCLA and UNC available at: http://www.unc.edu/eghysels

Ghysels, E. Santa-Clara, P. Volkanov, R.(2004).The MIDAS Touch: Mixed Data Sampling Regression Models. CIRANO Working Papers 2004s-20, CIRANO.

Ghysels, E. Sinko,A. Valkanov, R.(2006). Midas Regressions: Further Results and New Directions. *Econometric Reviews*, 26(1), 53-90.

Glosten, L. Jagannathan, R. & Runkle, D. (1993). On the Relation Between The Expected Value and The Volatility of Nominal Excess Return on stocks. *Journal of Finance*, 48, 1779-1801.

Hua,Yiqing. (2020). Bitcoin price prediction using ARIMA and LST, E3S Web of Conferences 218, 01050.

Klien, L.R. Sojo, E. (1989). Combinations of High and Low Frequency Data in Macroeconomic Model. *Economics in Theory and Practice*. Kluwer Academic Publishers, 3-14.

Moshiri, S. (2001). Forecasting Iranian Inflation Rates Using Structural, Time Series and Artificial Neural Networks Models . *Journal of Economic Research* ,(58), 147-184. SID: https://sid.ir/paper/12112/ [In Persian]

Nelson, D, B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *The Econometric Society*, 59(2), 347-370.

Noferesti, M. and M. Sezavar. (2021). Predicting the Effects of New Sanctions and Evaluating Fiscal Policies in the Context of a Macroeconomic Model with Mixed-Frequency Data Sampling for the Iranian Economy Under Sanctions. Journal of Economic Modeling Research 11(44): 85-104.

Pahlevani, M. Roshan, R (2015). The Comparison Among ARIMA and Hybrid ARIMA-GARCH Models in Forecasting the Exchange Rate of Iran. *International Journal of Business and Development Studies*, 7(1),31-50.

Pishbahar, E. BODAGH, S. & Dashti, G. (2019). Forecasting Iran's Agricultural Sector Growth: Using Mixed-frequency Data Sampling (MIDAS) Model. *Journal of Sustainable Growth and Development(the Economic Research)*, 19(3),145-161. SID: https://sid.ir/paper/371137. [In Persian]

Salehifar, M. (2019). Risk and Return Behavior of Bitcoin in Comparison with Gold, Currency, and Stock Markets by Application of GJR-GARCH and TGARCH Models. *Financial Engineering and Securities*

Management, 10(40), 152-168. SID: https://sid.ir/paper/197625/ [In Persian]

Silvestrini, A. & Veredas, D. (2008). Temporal Aggregation of Univariate and Multivariate Time Series Models: A survey. *Economic working papers*, 685, Bank of Italy, Economic Research and International Relations Area.

Torki, L. , Esmaeli, N. and Haghparast, M. (2023). Comparison of GARCH Family Models in Estimating Value at Risk and Conditional Value at Risk on the Tehran Stock Exchange. *Quarterly Journal of Quantitative Economics (JQE)*, *19*(4), 43-78. [In Persian]

Wu, S. I. and Lu, R. P. (1993). Combining Artificial Neural Network and Statistics for Stock Market. *Forecasting*, 257-264.