

Cross Relation Modeling for Financial Time Series Conditional Heteroskedasticity Using MLP Neural Network and Genetic Algorithm

¹ Masoud Omidvari Abarghouie, ^{2*} Sasan H. Alizadeh, ³ Ahmad Khademzadeh

¹ PhD Student of Department of Computer Engineering, Science and Research branch, Islamic Azad University, Tehran, Iran.

masoud.omidvari@iran.ir

² Assistant Professor of Faculty of Information Technology, Iran Telecommunication Research Center, Tehran, Iran

s.alizadeh@itrc.ac.ir

³ Professor of Iran Telecommunication Research Center, Tehran, Iran

Zadeh@itrc.ac.ir

Abstract

Always variation in risk levels may alter the behavior of individual investors. Thus, give more accuracy of future variance prediction in financial time series using past data has been interest to many researchers. GARCH family models as the most common statistical methods are considered in conditional heteroskedasticity prediction that used past observations. Also, recent research shows that the observed value of a time series is relevant to other time series values. This paper in the first, use the GARCH as a statistical model to modeling and prediction the conditional heteroskedasticity financial time series, then using a genetic algorithm to find best inputs for cross relations volatility with Neural Network modeling. In order to demonstrate the performance of the proposed method compared with statistical and neural network methods, the G7 time series dataset is used. The results show a reduction of 40% in the Mean Square Error (MSE) in S&P 500 time series conditional heteroskedasticity prediction.

Keywords: Prediction, Cross Relations, Conditional Heteroskedasticity, Neural Network, Genetic Algorithm.

مدلسازی روابط متقابل ناپایداری واریانس شرطی سری های زمانی مالی با استفاده از شبکه عصبی MLP و الگوریتم ژنتیک

مسعود امیدواری ابرقوئی^۱، ساسان حسینعلی زاده^{۲*}، احمد خادم زاده^۳

^۱ دانشجوی دکتری تخصصی، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، گروه مهندسی کامپیوتر، تهران، ایران

masoud.omidvari@iran.ir

^۲ استادیار، پژوهشکده فناوری اطلاعات، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

s.alizadeh@itrc.ac.ir

^۳ استاد، پژوهشگاه ارتباطات و فناوری اطلاعات، تهران، ایران

Zadeh@itrc.ac.ir

چکیده

همواره تغییرات در سطوح ریسک، رفتار سرمایه‌گذاران فردی را تغییر می‌دهد. از این روی، پیش‌بینی هر چه دقیق‌تر واریانس شرطی آتی سری زمانی مالی با استفاده از داده‌های گذشته مورد توجه بسیاری از پژوهشگران قرار گرفته است. مدل‌های خانواده گارچ به عنوان رایج‌ترین روش‌های آماری در زمینه پیش‌بینی ناپایداری واریانس آتی به شرط مشاهدات گذشته مورد استفاده قرار گرفته‌اند. همچنین تحقیقات اخیر نشان می‌دهد، مقدار مشاهده شده در یک سری زمانی با مقادیر سری‌های زمانی دیگر مرتبط است. در این مقاله با استفاده از مدل آماری گارچ، ناپایداری واریانس شرطی سری‌های زمانی مالی مدلسازی و پیش‌بینی شده، سپس با استفاده از الگوریتم ژنتیک بهترین ترکیب ورودی جهت مدلسازی روابط متقابل نوسانات توسط مدل شبکه عصبی پرسپترون چندلایه انتخاب می‌گردد. به منظور ارزیابی کارایی روش پیشنهادی در مقایسه با روش‌های آماری و مبتنی بر شبکه عصبی، از مجموعه سری‌های زمانی G7 استفاده شده است. نتایج نشان دهنده کاهش ۴۰ درصدی خطای پیش‌بینی ناپایداری واریانس شرطی سری زمانی S&P 500 با توجه به معیار MSE می‌باشد.

کلمات کلیدی

پیش‌بینی، روابط متقابل، ناپایداری واریانس شرطی، شبکه عصبی، الگوریتم ژنتیک.

نوسانات قیمت طلا [۴، ۵]، پیش‌بینی نوسانات بازار بورس [۶]، پیش‌بینی نوسانات قیمت برق [۷، ۸] و پیش‌بینی نوسانات بیت کوین [۹، ۱۰] می‌باشد.

بررسی سری‌های زمانی مالی نشان می‌دهد رویدادهای اقتصادی علاوه بر اینکه به مشاهدات قبلی وابسته‌اند، تحت تاثیر عوامل اجتماعی، سیاسی و فرهنگی نیز می‌باشند که باعث ایجاد حلت‌های پیچیده در سری زمانی می‌شود [۱۱]. از این روی، رفتار خطی در سری‌های زمانی مالی به ندرت مشاهده شده و رفتار غیرخطی به عنوان هسته اصلی تجزیه و تحلیل اینگونه سری‌های زمانی در نظر گرفته می‌شود [۱۲]. در مرجع [۱۳] نشان داده شده روش‌های مرسوم اقتصادسنجی مانند رگرسیون، تخمینی دقیق و ناریب^۲ از سری‌های زمانی در جایی که فرآیندهای سیستم معمولاً غیرخطی، غیر ثابت^۴ و از قبل تعریف نشده^۵ است، ارائه نمی‌دهند. شبکه‌های عصبی مصنوعی یک راه حل مناسب جهت مدلسازی سری‌های زمانی با وجود این شرایط هستند [۱۴].

۱- مقدمه

ناپایداری تغییرات سود یا بازدهی^۱ سری‌های زمانی مالی نقش مهمی در تصمیم‌گیری‌های اقتصادی دارد [۱] بطوریکه امروزه پیش‌بینی سری زمانی با استفاده از داده‌های گذشته به یک ابزار مهم جهت کاهش عدم قطعیت در تصمیم‌گیری فردی و سازمانی تبدیل شده است [۲]. از نقطه نظر مالی، سرمایه‌گذاران با توجه به میزان ریسک فعالیت‌های تجاری اقدام به سرمایه‌گذاری می‌کنند و هر گونه تغییر در سطوح ریسک، رفتار سرمایه‌گذاران فردی را تغییر می‌دهد [۳]. از این روی، کاهش خطای پیش‌بینی مقدار آتی ناپایداری واریانس شرطی^۲ سری زمانی همواره مورد توجه پژوهشگران قرار گرفته است. از جمله تحقیقات اخیر انجام شده در این زمینه، پیش‌بینی

۲- مروری بر ادبیات

به طور کلی روش‌های پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی را می‌توان به دو دسته روش‌های آماری و روش‌های مبتنی بر شبکه عصبی تقسیم‌بندی نمود. اخیراً نیز روش‌هایی مرکب از روش‌های مذکور ارائه شده‌اند که دسته سوم را تحت عنوان "روش‌های ترکیبی" تشکیل خواهند داد.

روش‌های آماری، مدل‌های اقتصادسنجی را شامل می‌شوند که عمدتاً رویکردی پارامتری دارند. مدل اتورگرسیو با واریانس شرطی ناپایدار تعمیم یافته^۱ (GARCH) [۱۹] به عنوان رایج‌ترین مدل اقتصادسنجی در پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی مطرح می‌باشد [۴, ۱۶, ۲۰-۲۶]. این مدل تعمیمی از مدل ARCH [۲۷] است که در سال ۱۹۸۲ میلادی توسط انگل^۲ ارائه شده است.

هر چند مدل GARCH در پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی عملکرد مناسبی از خود نشان داده است [۱۹] اما تحقیقات در زمینه بهبود عملکرد GARCH با رویکرد پارامتریک ادامه دارد. از جمله مشتقات GARCH می‌توان به مدل اتورگرسیو با واریانس شرطی ناپایدار تعمیم یافته نمایی^۳ (EGARCH) [۲۸] و همچنین مدل GJR-GARCH^۹ [۲۹] اشاره نمود. اخیراً نیز در مسیر توسعه آماری مدل‌های مبتنی بر GARCH، مدل مبتنی بر زنجیره مارکوف با تابع انتقال نرم^{۱۰} (MS-STGARCH) [۳۰] ارائه شده است.

مدل EGARCH برای لحاظ نمودن اثرات نامتقارن بازدهی‌های مثبت و منفی دارایی‌ها بر تلاطم^{۱۱} بازدهی‌ها طراحی شده بطوری که منحنی اثر اخبار، واکنش تلاطم شرطی را به اخبار نشان می‌دهد. تحقیقات نیز نشان می‌دهد واکنش فعالان بازارهای مالی به اخبار بد بیشتر از واکنش آن‌ها به اخبار خوب بوده و معمولاً در بسیاری از برآوردها $\theta < 0$ است. این دلالت بر آن دارد که شوک‌های مثبت، تلاطم‌های کوچکتری را برای قدر مطلق تغییرات یکسان در بازدهی، در مقایسه با شوک‌های منفی ایجاد می‌کنند. اگر $\gamma = 0$ باشد، شوک‌های منفی و مثبت اثرات یکسانی بر تلاطم خواهند داشت. در ادبیات اقتصادسنجی مالی γ را اثر علامت و θ را اثر اهرمی می‌نامند.

نوع دیگری از مدل GARCH که می‌تواند اثرات اهرمی را مدلسازی کند، آستانه است که به دلیل دقت بالای آن در تحقیقات ریسک به افتخار مبتکران آن [۲۹] به GJR-GARCH معروف شده است. این مدل بستگی به مقدار بازدهی در زمان t دارد که در بالا یا پایین مقدار آستانه قرار می‌گیرد، توان دوم بازدهی اثرات متفاوتی را بر واریانس شرطی σ_t^2 می‌گذارد. به طوریکه برای اگر بازدهی بیشتر از صفر باشد اثر کل به وسیله ضریب α_i تعیین می‌شود و هنگامی که بازدهی کمتر از صفر باشد، اثر کل یک شوک وارد شده بر بازدهی به وسیله ضریب $(\alpha_i + \gamma_i)$ اندازه‌گیری می‌گردد. در این حالت می‌توان انتظار داشت که برای اخبار بد مقدار برآورد شده برای γ_i مثبت باشد.

دسته دوم از روش‌های پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی را روش‌های مبتنی بر شبکه عصبی تشکیل می‌دهند که رویکردی داده‌محور و ناپارامتری^{۱۲} دارند. عدم نیاز به دانش قبلی، یادگیری

توانایی پیش‌بینی نوسانات یکی از مهم‌ترین تحلیل‌های بازار به حساب می‌آید که با ماهیت پیچیده و به هم پیوسته بازارهای مالی جهان روبرو است. این پیچیدگی نیاز به ابزارهای تحلیلی دارد که بتواند روابط متقابل متغیرهای زیادی را در بازار کشف کند. شبکه عصبی، توانمندی لازم در مدلسازی این شرایط را دارد و به طور گسترده‌ای در محدوده علم اقتصاد از پیش‌بینی چرخه کسب و کار تا ارزیابی گزینه‌های واقعی مورد استفاده قرار گرفته است [۱۵].

اولین گام در پیش‌بینی سری زمانی، مدلسازی و تحلیل دقیق داده‌های مشاهده شده قبلی است که می‌توان دو رویکرد کلی را برای این کار در نظر گرفت. رویکرد نخست، شناخت هر چه بهتر متغیر مورد نظر و کشف بیشتر اطلاعات پنهان در داده‌های گذشته است. روش‌های آماری دستاوردهایی را در این زمینه داشته‌اند اما همچنان با نقاط ضعفی همراه هستند. عدم مدلسازی دقیق اثر اهرمی و همچنین نیاز به دانش قبلی از جمله نقاط ضعف روش‌های آماری به حساب می‌آید. یک راه حل مناسب در این زمینه، ترکیب روش‌های آماری با روش‌های مبتنی بر شبکه عصبی می‌باشد [۱۶].

رویکرد دوم، مدلسازی و تحلیل توأم متغیر پیش‌بینی به همراه سایر متغیرهای مرتبط است. در مرجع [۱۷] با استفاده از مجموعه داده شبکه اجتماعی توئیتر، میزان تاثیر داده‌های میکرو بلاگ در پیش‌بینی بازار سهام مورد بررسی قرار گرفته است. همچنین در [۴, ۱۸] پژوهشگران مدلسازی توأم متغیر پیش‌بینی به همراه سایر متغیرهای مرتبط را انجام داده‌اند که نتایج بهتری را نسبت به رویکرد قبلی از خود نشان داده است.

در تحقیقات اخیر ابزار شبکه عصبی نقش بسزایی در مدلسازی روابط متقابل متغیرها را ایفا نموده است اما پژوهشگران مدلسازی روابط متقابل متغیرها را در فضای ناپایداری واریانس شرطی مورد بررسی قرار نداده‌اند. از این روی، در این مقاله، مدلسازی روابط متقابل ناپایداری واریانس شرطی سری‌های زمانی مالی با استفاده از شبکه عصبی پرسپترون چندلایه جهت دستیابی به کمترین خطای پیش‌بینی انجام گرفته است. همچنین با توجه به نبود دانش قبلی در وجود یا عدم وجود ارتباط خطی یا غیرخطی بین متغیرهای ورودی از الگوریتم ژنتیک جهت یافتن بهترین ترکیب ورودی شبکه عصبی استفاده شده است. به طور خلاصه می‌توان سوالات این تحقیق را در موارد زیر بیان نمود:

- آیا مدلسازی روابط متقابل ناپایداری واریانس شرطی سری‌های زمانی مالی منجر به کاهش خطای پیش‌بینی می‌شود؟
- آیا استفاده از روش ترکیبی در مدلسازی ناپایداری واریانس شرطی سری‌های زمانی مالی نسبت به سایر روش‌ها از کارآمدی بالاتری برخوردار است؟

در ادامه، مروری بر روش‌های پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی انجام گرفته و در بخش ۳ روش پیشنهادی GARCH-GA-MLP ارائه شده است. بخش ۴ نتایج آزمایش‌ها را نشان داده و در نهایت بخش ۵ شامل نتیجه‌گیری کلی پژوهش می‌باشد.

تحقیقات حاضر نشان دهنده عملکرد رقابتی روش‌های ترکیبی نسبت به سایر روش‌ها است که در ادامه به بررسی بیشتر آنها می‌پردازیم.

حاجی زاده و همکاران در [۱۶] انگیزه پژوهش خود را افزایش توانایی مدل GARCH در پیش‌بینی ناپایداری نوسانات با توجه به رایج بودن این مدل در پژوهش‌های اقتصادی مطرح کرده‌اند. روش پیشنهادی آنها ترکیبی از مدل EGARCH و شبکه عصبی مصنوعی است که جهت پیش‌بینی نوسانات شاخص S&P 500 مورد استفاده قرار گرفته است. در این پژوهش دو مدل ارائه شده که ورودی مدل اول، مقادیر گذشته متغیرهای توضیحی را شامل می‌شود و ورودی مدل دوم متشکل از متغیرهای توضیحی و داده‌های شبیه سازی شده است. نتایج در مقایسه با سایر روش‌ها که از EGARCH استفاده کرده‌اند نشان دهنده قابلیت بیشتر مدل دوم در روش پیشنهادی است.

در مرجع [۴] مدلی ترکیبی از شبکه عصبی مصنوعی و مدل GARCH ارائه شده است که در مقایسه با خانواده GARCH پیش‌بینی دقیق‌تری از نوسانات قیمت طلا را ارائه می‌کند و خطای پیش‌بینی را با توجه به معیار MAPE، ۲۵ درصد کاهش می‌دهد. در این مقاله با مدل‌سازی روابط بین متغیرهای مالی نشان داده شده که سایر سری‌های زمانی مالی از جمله نرخ ارز، سری بازدهی قیمت نفت و شاخص DJI^{۲۲} نیز بر قیمت طلا تاثیر گذارند و خطای پیش‌بینی را کاهش می‌دهند. پژوهشگران در این مقاله روابط متقابل بین متغیرهای مالی را مدل‌سازی کرده‌اند اما روابط متقابل ناپایداری واریانس شرطی متغیرها را مورد بررسی قرار نداده‌اند.

اخیراً در [۴۰] یک مدل جدید محاسبات فازی با ترکیب مدل EGARCH جهت پیش‌بینی نوسانات بازار بورس ارائه شده است که نتایج نشان دهنده افزایش دقت پیش‌بینی در مقایسه با مدل‌های خانواده GARCH و سیستم‌های ترکیبی فازی می‌باشد. مدل ارائه شده یک برآورد مشترک از پارامترهای تابع عضویت سیستم استنتاج فازی نوع TSK^{۲۳} را در شرایط شوک-های نامتقارن اثر اهرمی مدل EGARCH نشان می‌دهد که در پیش‌بینی فضای غیرخطی و پیچیده سری‌های زمانی مالی کارآمد است.

جدول (۱) مروری اجمالی بر روش‌های پیشین را ارائه می‌کند. سه مدل آماری پایه و همچنین سه مدل شبکه عصبی رایج در ادبیات تحقیق به طور خاص مورد بررسی قرار گرفته‌اند و سایر مدل‌های آماری و شبکه عصبی در قالب سایر روش‌ها تدوین شده‌اند.

اولین مدل آماری، مدل GARCH است که در [۱، ۴، ۷، ۹، ۱۲، ۱۶، ۱۸، ۱۹، ۲۵-۲۸، ۳۸، ۴۴-۴۶] مورد استفاده پژوهشگران قرار گرفته است. همچنین این مدل در مقالات [۱، ۶، ۷، ۱۲، ۱۶، ۱۸، ۲۱-۲۴، ۲۶، ۴۰-۴۲، ۴۷-۴۹] با سایر مدل‌های آماری مورد ارزیابی و مقایسه قرار گرفته است. در مراجع [۴، ۶، ۱۲، ۱۸، ۲۰، ۴۰، ۴۲، ۴۵] نیز مدل GARCH با مدل‌های شبکه عصبی مقایسه شده است.

دومین مدل آماری، مدل EGARCH است که در [۶، ۱۶، ۲۳، ۲۸، ۴۱، ۴۳، ۴۸، ۴۹] مورد استفاده قرار گرفته است. مدل آماری EGARCH در مراجع [۶، ۲۰، ۲۳، ۴۰، ۴۱، ۴۳، ۴۹، ۵۰] با سایر مدل‌های آماری مقایسه شده و در مراجع [۶، ۱۶، ۲۰، ۲۳، ۴۰، ۴۸] با مدل‌های شبکه عصبی به رقابت پرداخته است.

غیرخطی و توانایی کار با داده‌های نویزی [۲، ۱۲] شبکه‌های عصبی را به عنوان یک رقیب جدی برای روش‌های آماری در زمینه پیش‌بینی سری‌های زمانی تبدیل کرده است [۱۳]. همچنین از شبکه‌های عصبی در پیش‌بینی سری‌های زمانی علی‌الخصوص در جایی که شرایطی از قبیل ایستایی یا شرایط دیگری که راه را برای بکارگیری تکنیک‌های آماری فراهم می‌سازد، برقرار نیست و سری‌های زمانی پیچیده می‌باشند بسیار استفاده شده است [۳۱].

با توجه به اینکه هسته اصلی تجزیه و تحلیل سری‌های زمانی رفتار غیرخطی است [۱۲]، پیش‌بینی سری‌های زمانی مالی با استفاده از شبکه‌های عصبی مورد توجه پژوهشگران قرار گرفته است [۲، ۱۱-۱۳، ۳۲]. از جمله ویژگی‌های شبکه عصبی که موجب جذاب بودن استفاده از آن در مدل‌سازی سیستم‌های غیر خطی شده می‌توان به توانایی تقریب جهانی^{۲۴}، توانایی پردازش موازی توزیع شده^{۲۵}، یادگیری و انطباق^{۲۶}، تعمیم‌پذیری و تحمل خطای ورودی^{۲۶} و نیز امکان پیاده‌سازی سخت افزاری اشاره نمود [۳۳].

در مرجع [۳۴] مروری بر ادبیات تحقیق نشان می‌دهد پژوهشگران غالباً از شبکه عصبی پرسپترون چندلایه^{۲۷} (MLP) در زمینه پیش‌بینی سری‌های زمانی مالی استفاده کرده‌اند. MLP یک نوع شبکه عصبی پیش‌رو است که توسط الگوریتم یادگیری با نظارت پس انتشار خطا^{۲۸} (BP) توسعه یافته و در کاربردهای عملی مورد استفاده قرار گرفته است [۳۵]. الگوریتم پس انتشار خطا به عنوان تعمیمی از الگوریتم حداقل میانگین مربعات دارای دو فاز رو به جلو و رو به عقب می‌باشد. در فاز رو به جلو، ورودی‌ها لایه به لایه در شبکه توزیع می‌شوند و در نهایت خروجی نمایش داده می‌شود. تمام وزن‌ها در طول این فرایند ثابت است. در فاز رو به عقب، وزن‌ها به عنوان یک سیگنال خطا از طریق شبکه باز انتشار داده می‌شوند.

شبکه عصبی پرسپترون چند لایه اغلب در فرار از کمینه محلی و همگرایی به گندی عمل می‌کند. از این روی، انطباق یا یادگیری تمرکز اصلی تحقیقات بر روی پرسپترون چند لایه بوده و پژوهشگران به دنبال شرایطی هستند که شبکه عصبی را با درجه بالایی از توانمندی ارائه کنند. MLP دارای نوروتهایی با توابع فعال‌سازی غیرخطی و مشتق پذیر است و عواملی از جمله تعداد نوروتهای لایه پنهان، میزان آموزش پذیری، توزیع وزن‌های اولیه و شیب تابع در ایجاد آن موثر می‌باشد.

انواع دیگر شبکه عصبی نیز در زمینه پیش‌بینی سری‌های زمانی مالی مورد استفاده قرار گرفته‌اند که از جمله آنها می‌توان به شبکه عصبی شعاعی پایه^{۲۹} (RBF) و شبکه عصبی بازگشتی^{۳۰} (RNN) اشاره نمود [۱۴، ۲۲] اما رایج‌ترین نوع شبکه عصبی در این زمینه، پرسپترون چندلایه می‌باشد [۳۴، ۳۶] که در این تحقیق نیز از شبکه عصبی MLP استفاده شده است. هر چند شبکه‌های عصبی نسبت به روش‌های آماری سطح بالایی از اطمینان را ایجاد می‌کنند اما با محدودیت‌هایی از جمله نیاز به پارامترهای کنترلی زیاد، مشکل بدست آمدن راه حل پایدار و خطر ابتلا به آموزش بیش از حد^{۳۱} روبرو هستند [۱۱]. به همین دلیل تحقیقات در این زمینه به طور متداوم در حال رشد است.

روش‌های ترکیبی دسته سوم را در اقتصادسنجی سری‌های زمانی مالی تشکیل خواهند داد. اخیراً پژوهشگران به استفاده ترکیبی از روش‌های آماری و روش‌های مبتنی بر شبکه عصبی روی آورده‌اند [۴، ۵، ۹، ۱۶، ۲۰-۲۶، ۳۷-۳۹].

جدول (۱) - مروری بر روش‌های پیش‌بینی سری زمانی

تعداد مقالات	مراجع	نام مدل	دسته بندی روش‌ها
۲۰	[۱, ۷, ۹, ۱۲, ۱۶, ۱۸, ۱۹, ۲۵-۲۱, ۳۷, ۴۴-۴۱]	GARCH	روش‌های آماری
۸	[۶, ۱۶, ۲۳, ۲۸, ۴۱, ۴۳, ۴۸, ۴۹]	EGARCH	
۶	[۱۶, ۲۹, ۴۱, ۴۷-۴۵]	GJR-GARCH	
۱۷	[۳, ۱۷, ۲۰, ۲۶, ۲۷, ۳۰, ۳۰, ۴۰, ۵۱-۴۹, ۵۷, ۶۵-۶۰]	Other St. ^a	
۲۰	[۳, ۴, ۸, ۱۸-۱۵, ۲۰, ۲۳-۲۳, ۳۲, ۳۴, ۳۵, ۴۸, ۵۲-۵۰, ۶۶]	MLP	روش‌های مبتنی بر شبکه عصبی
۶	[۱۱, ۱۳, ۱۷, ۲۱, ۴۲, ۵۸]	SVM	
۳	[۲۲, ۵۹, ۶۰]	RBF	
۱۳	[۲, ۷, ۱۲, ۱۴, ۲۳, ۳۸, ۴۰, ۴۵, ۵۶, ۶۹-۶۷]	other ANN ^b	

^a سایر روش‌های آماری: CE-EGARCH, MS-STGARCH, MN-NGARCH, VC-MGARCH, HVAR و ...

^b سایر روش‌های مبتنی بر شبکه عصبی: AWNN, STNN, RSOM, TDNN, CEFLANN, RNN, EANN, LSTM, BNN و ...

توأم متغیر پیش‌بینی به همراه سایر متغیرهای مرتبط، در این مقاله یک روش جدید ترکیبی جهت کاهش خطای پیش‌بینی ارائه شده است. روش پیشنهادی در ابتدا با استفاده از مدل GARCH سعی در مدلسازی پارامتریک نوسانات مجموعه سری‌های زمانی مالی دارد و سپس با استفاده از الگوریتم ژنتیک بهترین ترکیب ورودی جهت مدلسازی روابط متقابل ناپایداری واریانس شرطی توسط شبکه عصبی MLP را انتخاب می‌کند که در نهایت با مدلسازی روابط متقابل نوسانات، خطای پیش‌بینی کاهش می‌یابد. نوآوری‌های روش پیشنهادی نسبت به روش‌های قبلی در فهرست زیر جای می‌گیرد:

- مدلسازی روابط متقابل ناپایداری واریانس شرطی یک سری زمانی مالی با سایر سری‌های زمانی مالی مرتبط که در مرجع [۴, ۱۶] این مدلسازی روابط متقابل در فضای میانگین انجام گرفته است.
- استفاده از روش بهینه‌سازی ژنتیک در انتخاب بهترین مجموعه سری‌های زمانی مرتبط به عنوان ورودی مدل پیش‌بین که در مراجع [۴, ۱۴] از روش آزمون خطا و در مرجع [۴۲] از ضریب همبستگی استفاده شده است.

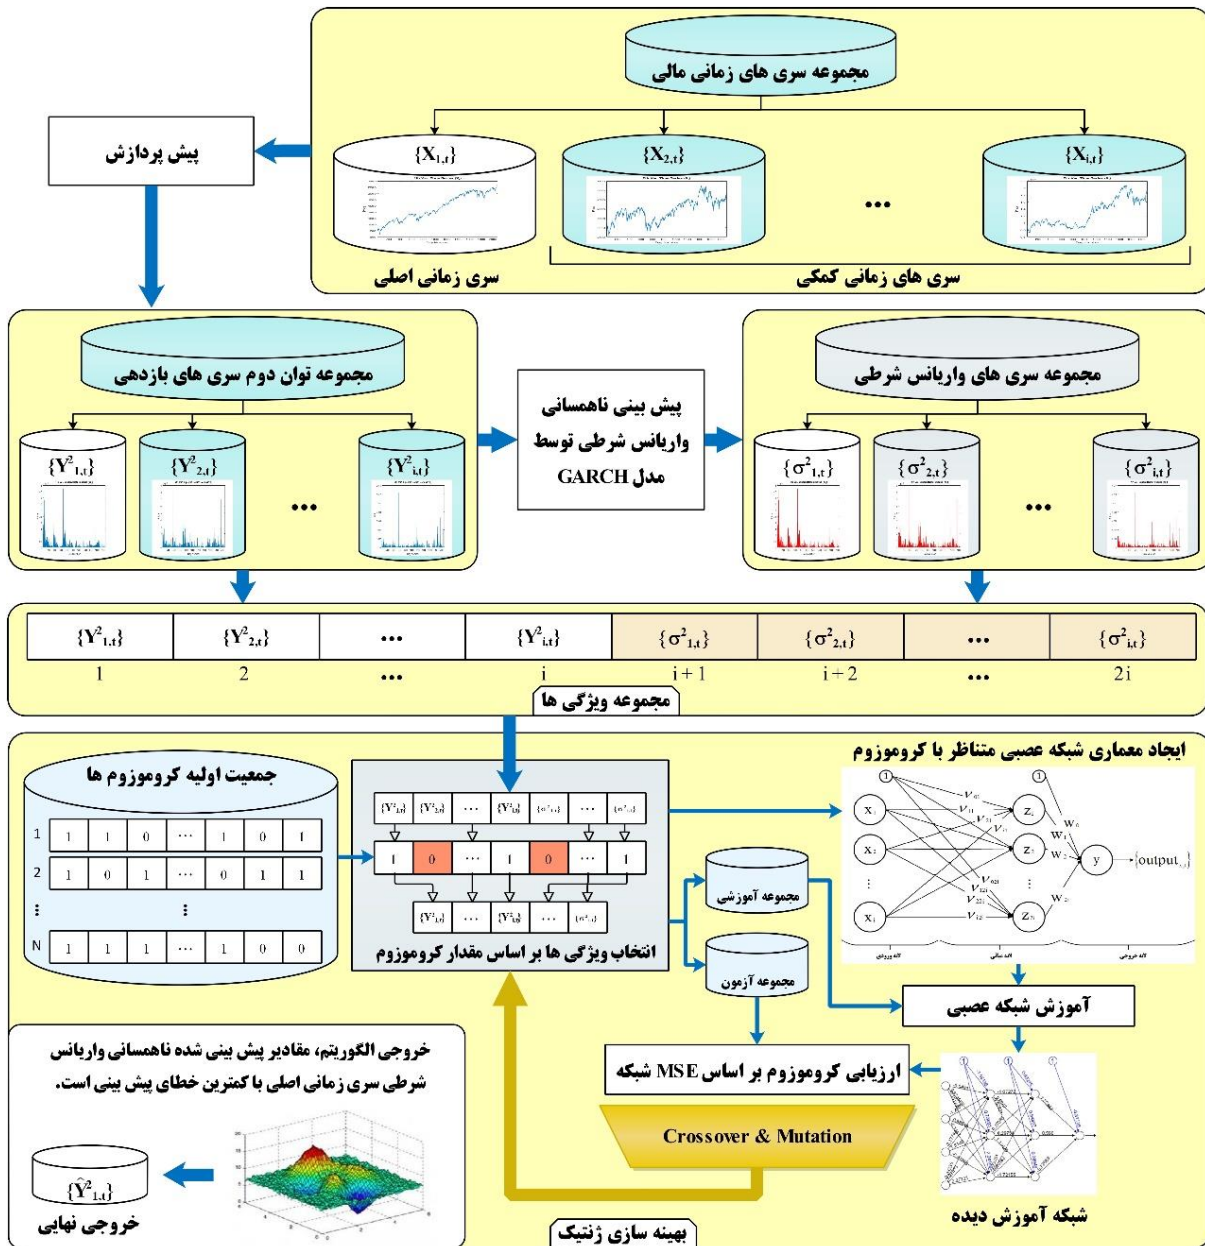
۳- روش پیشنهادی GARCH-GA-MLP

معماری روش پیشنهادی بدین صورت است که ابتدا مجموعه سری‌های زمانی مالی مرتبط به عنوان ورودی در نظر گرفته می‌شود. پس از پیش‌پردازش مجموعه داده‌ها، پیش‌بینی ناپایداری واریانس شرطی هر یک از سری‌های زمانی توسط مدل GARCH انجام می‌گیرد. سپس با ایجاد مجموعه ورودی‌های شبکه عصبی که متشکل از مجموعه توان دوم سری‌های بازدهی و مجموعه سری‌های واریانس شرطی است، بهترین

سومین مدل آماری که مورد بررسی قرار گرفته GJR-GARCH می‌باشد. این مدل در مراجع [۱۶, ۲۹, ۴۱, ۴۵-۴۷] مورد استفاده پژوهشگران قرار گرفته و در مراجع [۶, ۱۶, ۲۰, ۲۰, ۴۰, ۴۱, ۴۵-۴۷, ۵۰, ۵۱] با سایر مدل‌های آماری به رقابت پرداخته است. پژوهشگران در [۱۶, ۲۰, ۲۰, ۴۰, ۴۵-۴۷] ارزیابی مدل‌های شبکه عصبی با مدل GJR-GARCH را در نتایج آزمایشات خود نشان داده‌اند.

در بین مدل‌های شبکه عصبی، پرسپترون چندلایه یا MLP به عنوان اولین مدل مورد بررسی قرار گرفته که در مراجع [۳, ۴, ۸, ۱۵-۱۸, ۲۰, ۲۳-۲۵, ۳۲, ۳۴, ۳۵, ۴۸, ۵۲-۵۵] پژوهشگران از این مدل استفاده کرده‌اند. رقابت بین مدل MLP و سایر مدل‌های شبکه عصبی در نتایج آزمایشات [۳, ۸, ۱۵-۱۷, ۲۰, ۲۳, ۳۲, ۳۵, ۴۲, ۴۵, ۴۷, ۴۸, ۵۲, ۵۴-۵۶] نشان داده شده است. همچنین در مراجع [۳, ۴, ۸, ۱۶-۱۸, ۲۰, ۲۳, ۳۴, ۳۵, ۴۸, ۵۷] عملکرد پرسپترون چندلایه با مدل‌های آماری مورد مقایسه و ارزیابی قرار گرفته است. دومین نوع شبکه عصبی که مورد بررسی قرار گرفته است SVM نام دارد و در مراجع [۱۱, ۱۳, ۱۷, ۲۱, ۴۲, ۵۸]، پژوهشگران از این مدل جهت پیش‌بینی استفاده نموده‌اند. در [۲, ۱۷, ۲۱, ۴۲, ۴۵, ۴۶] نیز ماشین‌های بردار پشتیبان با سایر شبکه‌های عصبی به رقابت پرداخته و در [۱۱, ۱۳, ۱۷, ۲۱, ۴۲, ۴۷-۴۵] با سایر مدل‌های آماری مقایسه شده است.

سومین و آخرین مدل شبکه عصبی، RBF است که در [۲۲, ۵۹, ۶۰] به کار گرفته شده است. در [۸, ۲۱, ۳۳, ۴۰, ۴۶, ۴۸, ۵۹, ۶۰] شبکه عصبی شعاعی پایه با سایر مدل‌های شبکه عصبی مقایسه شده و همچنین در [۳, ۸, ۲۱, ۲۲, ۲۲, ۴۰, ۴۶, ۴۸, ۶۰] به رقابت با مدل‌های آماری پرداخته است. با وجود پژوهش‌های انجام گرفته در زمینه پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی، افزایش دقت پیش‌بینی کماکان مورد توجه محققان می‌باشد. از این روی با توجه به دستاورد تحقیقات اخیر در مدلسازی



کل (۱) - معماری روش پیشنهادی

۱-۱-۳- داده های مفقود شده

سری های زمانی مالی اغلب شامل داده های مفقود شده^{۲۵} می باشند [۷۰] که به علت های مختلف مانند تعطیلی بازار و یا عدم ثبت اطلاعات در مجموعه داده ها مشاهده می شوند. این فقدان اطلاعات باعث می شود در مدلسازی روابط متقابل ناپایداری واریانس شرطی، اطلاعات نادرستی از مقدار واریانس شرطی در لحظه t در اختیار مدل پیش بین قرار گیرد. از این روی، به منظور یکپارچه سازی مجموعه داده های ورودی از لحاظ زمانی و همچنین جلوگیری از ورود اطلاعات اشتباه به فرایند آموزش مدل، تخمین داده های مفقود شده انجام می گیرد تا اطلاعات ناقص مجموعه داده ها تکمیل گردد. تکنیک های مختلفی جهت

ترکیب ورودی توسط الگوریتم ژنتیک انتخاب شده که با در نظر گرفتن متغیر پیش بینی به عنوان هدف^{۲۶}، فرایند مدلسازی و پیش بینی انجام می گیرد. در نهایت، خروجی روش پیشنهادی سری زمانی ناپایداری واریانس شرطی متغیر پیش بینی می باشد. شکل (۱) معماری کلی روش پیشنهادی را نشان می دهد. در ادامه، هر یک از بخش های روش پیشنهادی مورد بررسی بیشتر قرار گرفته است.

۱-۳- پیش پردازش

که در آن $\rho_{i,h}$ ضریب خودهمبستگی متغیر i ام در وقفه زمانی h و N تعداد کل مشاهدات سری بازشده می‌باشد. همچنین $SE_{i,\rho}$ یا بازه‌ی معناداری ضریب خودهمبستگی متغیر i ام در وقفه زمانی h با سطح اصمیان ۹۵ درصد توسط فرمول (۴) تعیین می‌شود [۷۲]:

$$SE_{i,\rho} = \sqrt{\frac{1+2\sum_{i=1}^{h-1} \rho_i^2}{N}} \quad (4)$$

در صورتی که ضرایب خودهمبستگی توان دوم سری بازشده خارج از بازه‌ی معناداری یعنی $-2SE_{i,\rho} \leq \rho_{i,h} \leq +2SE_{i,\rho}$ قرار گیرند فرضیه نوفه سفید بودن آن در سطح اطمینان رد می‌شود. بنابراین می‌توان گفت سری بازشده دارای خاصیت ایستایی ضعیف می‌باشد و امکان مدل‌سازی ناپایداری واریانس شرطی برای مدل GARCH فراهم گردیده است [۷۲].

۴-۱-۳- تقسیم‌بندی مجموعه داده‌های ورودی

با تعیین ضابطه‌ی برون نمونه‌ای جهت پیش‌بینی سری زمانی، مجموعه داده‌ها با استفاده از یک طرح ترتیب‌بندی زمانی به دو زیر مجموعه تقسیم‌بندی می‌شوند که ۷۰ درصد مشاهدات به عنوان داده‌های آموزشی و ۳۰ درصد مشاهدات به عنوان داده‌های آزمون در نظر گرفته می‌شود. تقسیم بندی ۷۰ به ۳۰ متداول است و عملکرد بهتری نسبت به طرح‌های ۶۰ به ۴۰ و ۸۰ به ۲۰ در پیش‌بینی سری‌های زمانی از خود نشان داده است [۲].

۲-۳- پیش‌بینی ناپایداری واریانس شرطی

مدل GARCH [۱۹] یکی از متداول‌ترین مدل‌های اقتصادسنجی است که در زمینه پیش‌بینی ناپایداری واریانس شرطی مورد استفاده پژوهشگران قرار گرفته است [۴، ۹، ۱۶، ۲۰-۲۶، ۳۷، ۴۴]. در این مقاله نیز از مدل $GARCH(p, q)$ استفاده شده است. این مدل، واریانس شرطی مشاهده آتی متغیر i ام در زمان t را طبق فرمول (۵) محاسبه می‌کند که در آن $\mathcal{Y}_{i,t}^2$ توان دوم سری بازشده متغیر i ام در لحظه t است. همچنین (p, q) مرتبه مدل و α_i ، $\alpha_{i,0}$ و β_i ضرایب مدل برای متغیر i ام هستند که به ترتیب مقدار ثابت واریانس شرطی، ضریب پسماند واریانس شرطی و ضریب باقیمانده واریانس شرطی را شامل می‌شوند.

$$\sigma_{i,t}^2 = \alpha_{i,0} + \sum_{s=1}^q \alpha_{i,s} \mathcal{Y}_{i,t-s}^2 + \sum_{s=1}^p \beta_{i,s} \sigma_{i,t-s}^2 \quad (5)$$

در مدل GARCH جهت اطمینان از مثبت بودن واریانس شرطی قیدهای زیر در نظر گرفته می‌شود [۱۹]:

$$\begin{cases} p \geq 0, & q > 0 \\ \alpha_{i,0} > 0, & \alpha_i \geq 0 \quad i = 1, \dots, q. \\ \beta_i \geq 0 & i = 1, \dots, p. \end{cases}$$

همچنین برای ایستا بودن مدل لازم است که مجموع α_i و β_i ها از یک کمتر باشد [۱].

تخمین داده‌های مفقود شده وجود دارد که از جمله آنها می‌توان به روش استناد به نزدیکترین همسایه^{۲۶} (KNN impute)، روش آنالیز مولفه‌های اصلی بیزی^{۲۷} (BPCA)، روش استناد به تجزیه مقدار منفرد^{۲۸} (SVD impute) و روش استناد به میانگین اشاره نمود [۷]. در این مقاله جهت تخمین داده‌های مفقود شده از روش میانگین با توجه به سادگی این روش طبق فرمول (۱) استفاده شده است:

$$x_{i,t} = \frac{x_{i,t-1} + x_{i,t+1}}{2} \quad (1)$$

که در آن $x_{i,t}$ مشاهده سری زمانی متغیر i ام در زمان t می‌باشد.

۳-۱-۲- تبدیل لوگ-ریترن

از آنجایی که سری‌های زمانی مالی عمدتاً غیرایستا هستند به منظور برقراری شرایط ایستایی جهت مدل‌سازی ناپایداری واریانس شرطی توسط مدل GARCH و همچنین حذف روند^{۲۹}، در این مقاله از تبدیل لوگ-ریترن^{۳۰} استفاده شده است [۴، ۱]. فرمول (۲) نحوه تبدیل مشاهده سری زمانی به سری بازشده را نشان می‌دهد:

$$y_{i,t} = \log\left(\frac{x_{i,t}}{x_{i,t-1}}\right) \quad (2)$$

که در آن $y_{i,t}$ بازشده سری زمانی متغیر i ام در زمان t است. در سری $\{y_{i,t}\}$ میانگین مشاهدات نزدیک به صفر و واریانس آنها ثابت می‌باشد.

۳-۱-۳- بررسی ایستایی ضعیف

به منظور مدل‌سازی دقیق دینامیک یک مسئله پیش‌بینی ناپایداری واریانس شرطی، بررسی وجود خاصیت ایستایی ضعیف^{۳۱} یا ایستایی مرتبه دوم در سری بازشده مشاهدات لازمه‌ی مدل‌سازی توسط مدل GARCH می‌باشد. در شرایطی که فرض ایستایی ضعیف برای مجموعه داده ورودی برقرار باشد، مدل‌سازی و پیش‌بینی ناپایداری واریانس شرطی انجام خواهد گرفت و در غیر اینصورت مدل‌سازی برای آن سری بازشده انجام نخواهد گرفت. جهت بررسی خاصیت ایستایی ضعیف از توابع خودهمبستگی^{۳۲} (ACF) و خودهمبستگی جزئی^{۳۳} (PACF) استفاده می‌شود. چنانچه رفتار سری بازشده نوفه سفید بوده و یا عبارات دیگر کاملاً تصادفی باشد ولی توان دوم بازشده دارای ضریب خودهمبستگی معنی دار بوده و فرضیه نوفه سفید بودن آن در سطح اطمینان رد شود، این نتیجه حکایت از وجود ناهمسانی واریانس شرطی به شرط اطلاعات گذشته در سری بازشده دارد که می‌توان گفت سری بازشده دارای خاصیت ایستایی ضعیف است. در این پژوهش ضریب خودهمبستگی توسط فرمول (۳) محاسبه شده است [۷۲]:

$$\rho_{i,h} = \frac{\sum_{t=h+1}^N (y_{i,t} - \bar{y}_i)(y_{i,t-h} - \bar{y}_i)}{\sum_{t=1}^N (y_{i,t} - \bar{y}_i)^2} \quad (3)$$

روش پیشنهادی در فضای ناپایداری واریانس شرطی، مدلسازی روابط متقابل سری‌های زمانی مالی انجام می‌گیرد.

در این پژوهش از شبکه عصبی پرسپترون چندلایه جهت انجام مدلسازی و پیش‌بینی استفاده شده است. رایج‌ترین نوع شبکه عصبی در تحقیقات اخیر، شبکه عصبی MLP با الگوریتم آموزش پس‌انتشار خطا است [۳۴] که با توجه به استفاده گسترده آن در پیشینه پژوهش و همچنین عملکرد بهتر آن در مقایسه با سایر شبکه‌ها در روش پیشنهادی نیز از این نوع شبکه عصبی استفاده شده است. در حالت کلی، MLP شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه میانی می‌باشد که هر لایه شامل یک یا چند نورون است. خروجی هر نورون برابر با مجموع حاصل ضرب بردار ورودی در بردار وزن‌ها است که طبق فرمول (۶) محاسبه می‌گردد:

$$y = f \left(\sum_{i=1}^n x_i w_{i,j} \right) \quad (6)$$

که در آن، y خروجی نورون، f تابع فعال‌سازی، x_i ورودی i ام، $w_{i,j}$ وزن اتصال ورودی i ام و n تعداد کل ورودی‌ها است.

شکل (۳) معماری شبکه عصبی MLP با ساختار $i-2i-1$ را نشان می‌دهد که شامل i نورون در لایه ورودی، $2i$ نورون در لایه میانی و یک نورون در لایه خروجی است. در این مقاله جهت جلوگیری از آموزش بیش از حد شبکه، تعداد نورون‌های لایه میانی، ۲ برابر تعداد نورون‌های لایه ورودی در نظر گرفته شده است [۵۵]. ورودی‌های شبکه عصبی، مجموعه توان دوم سری بازدهی متغیرهای ورودی $\{y_{i,t}^2\}$ به همراه سری‌های ناپایداری واریانس شرطی $\{\sigma_{i,t}^2\}$ می‌باشد. خروجی مورد انتظار^{۳۵} نیز توان دوم سری بازدهی متغیر پیش‌بینی است. خروجی هر نورون در لایه میانی طبق فرمول (۷) محاسبه می‌گردد:

$$z_j = f \left(v_{0j} + \sum_{i=1}^n x_i v_{ij} \right) \quad (7)$$

همچنین نحوه محاسبه خروجی در نورون در لایه خروجی طبق فرمول (۸) می‌باشد:

$$y_t = f \left(w_{0t} + \sum_{j=1}^p z_j w_{jt} \right) \quad (8)$$

در ادامه‌ی مدلسازی و پیش‌بینی روابط متقابل، انتخاب بهترین ترکیب از مجموعه ورودی‌های شبکه عصبی جهت دستیابی به کمترین خطای پیش‌بینی در دستور کار قرار می‌گیرد.

در این مقاله جهت یافتن بهترین ترکیب از مجموعه ورودی‌های شبکه عصبی در فضای حالت به اندازه 2^{2i} ، از روش بهینه‌سازی ژنتیک استفاده شده است. این الگوریتم تکاملی شامل عملگرهای انتخاب، تقاطع^{۳۶}، جهش^{۳۷} و ارزیابی می‌باشد [۷۳]. مراحل الگوریتم ژنتیک ساده را می‌توان در فهرست زیر مشاهده نمود [۵۸]:

۱- تولید تصادفی جمعیت اولیه با N فرزند که هر فرزند یک ژنوتایپ 2i بیتی است (کروموزوم).

در روش پیشنهادی، پس از برازش مدل GARCH به مجموعه داده‌های آموزشی، ضرائب آموزش دیده شده در رابطه (۵) جایگذاری شده و پیش‌بینی ناپایداری واریانس شرطی مشاهدات انجام می‌گیرد. سپس آزمون نیکویی برازش جهت تأیید مرتبه مدل انجام می‌شود [۱]. در این آزمون مشابه بخش ۳-۱ از توابع خودهمبستگی و خودهمبستگی جزئی جهت بررسی سری جدید تغییرات^{۳۸} استفاده می‌شود. چنانچه این سری، رفتار نوفه سفید داشته و کاملاً تصادفی باشد، مدل برازش داده شده تأیید شده و در غیر این صورت مرتبه مدل برورسانی می‌شود و فرایند مدلسازی و پیش‌بینی دوباره انجام می‌گیرد.

شکل (۲) الگوریتم پیش‌بینی ناپایداری واریانس شرطی را نشان می‌دهد. در این الگوریتم، $varNum$ تعداد متغیرهای ورودی و $lagNum$ تعداد وقفه‌های مورد بررسی می‌باشد. $\rho_{i,h}$ یا ضریب خودهمبستگی متغیر i در وقفه زمانی h طبق فرمول (۳) محاسبه شده و مقدار بازه معناداری یا $SE_{i,\rho}$ طبق فرمول (۴) محاسبه گردیده است.

۳-۳- مدلسازی روابط متقابل ناپایداری واریانس شرطی

نوآوری روش پیشنهادی مدلسازی روابط متقابل ناپایداری واریانس شرطی سری‌های زمانی مالی جهت کاهش خطای پیش‌بینی است. بر اساس پژوهشی که در [۴] انجام گرفته نشان داده شده، مدلسازی روابط متغیرهای مالی در پیش‌بینی قیمت طلا باعث کاهش خطای پیش‌بینی می‌گردد. از این روی، در

Algorithm 1: Conditional Heteroskedasticity Prediction

```

1: Function CHPred ( returnSeries, N, lagNum, trianSet )
2:   for p = 1 to 2
3:     for q = 1 to 2
4:       {α0 α1 β1} = fit GARCH ( p, q ) on trianSet
5:       for t = 1 to N
6:         σt2 = α0 + ∑i=1q αi returnSeriest-i + ∑j=1p βj σt-j2
7:       end for
8:       for h = 1 to lagNum
9:         compute ρh
10:        if ρh Between the meaningful interval
11:          significanceLevel = significanceLevel + 1
12:        end if
13:      end for
14:      if significanceLevel ≥ lagNum
15:        return {σt2}t=1N
16:      end if
17:    end for
18:  end for
19: END Function

```

شکل (۲) - الگوریتم پیش‌بینی ناپایداری واریانس شرطی


میزان کارایی شبکه‌های عصبی در مقایسه با سایر روش‌ها، توسط معیارهای MSE، RMSE، MAE و MAPE با توجه به فاصله مقدار پیش‌بینی شده از مقدار واقعی محاسبه می‌گردد [۱، ۸، ۱۶]. در این مقاله نیز، عملکرد روش پیشنهادی در مقایسه با روش آماری GARCH [۱۹] با توجه به معیارهای ارزیابی انجام گرفته که نتایج آزمایشات در بخش بعدی ارائه شده است.

۴- بحث و آزمایشات

۴-۱- مجموعه داده‌های آموزشی

در ابتدا مجموعه داده‌ای جهت پیش‌بینی ناپایداری واریانس سری زمانی مالی انتخاب می‌گردد. این انتخاب با توجه به مجموعه داده‌های مورد استفاده در پژوهش‌های اخیر صورت گرفته تا امکان مقایسه روش پیشنهادی با روش‌های دیگر فراهم گردد. سری زمانی S&P 500 یک مجموعه داده مالی می‌باشد که به طور متداول مورد استفاده قرار گرفته است [۱، ۱۵، ۱۶، ۳۷، ۵۳، ۶۷]. این سری زمانی که شاخص قیمت ۵۰۰ شرکت پیشرو در صنایع بالادستی ایالات متحده آمریکا را شامل می‌شود به صورت روزانه از سال ۲۰۰۶ تا ۲۰۱۶ با مجموع ۲۶۴۶ مشاهده در [۷۴] قابل دریافت می‌باشد. شکل (۵) مشاهدات روزانه این سری زمانی را نشان می‌دهد.

همچنین جهت مدل‌سازی روابط متقابل ناپایداری واریانس سری‌های زمانی مالی مرتبط، از مجموعه داده‌های مرتبط نیز استفاده شده که بر اساس پژوهش‌های صورت گرفته در مراجع [۴۲، ۴۵، ۴۶]، سری‌های زمانی CAC40 (فرانسه)، FTSE100 (انگلستان)، DAX30 (آلمان)، MIB40 (ایتالیا)، TSK60 (کانادا) و NK225 (ژاپن) با سری زمانی S&P500 (آمریکا) مرتبط می‌باشند. شکل (۶) مشاهدات روزانه سایر سری‌های زمانی مرتبط را نشان می‌دهد که هر کدام شامل ۲۰۸۴ مشاهده از سال ۲۰۰۹ تا ۲۰۱۶ می‌باشند.




شکل (۵) - مشاهدات روزانه سری زمانی S&P 500


- ۲- محاسبه تابع هزینه برای هر یک فرزندان.
- ۳- تکرار مراحل زیر جهت ایجاد فرزندان جدید:
 - a. انتخاب یک زوج از والدین جهت تولید مثل.
 - b. اعمال عملگرهای تقاطع و جهش.
- ۴- جایگزینی جمعیت فعلی به عنوان جمعیت جدید.
- ۵- بازگشت به مرحله ۲ تا زمانی که شرایط خاتمه برقرار نیست.

شکل (۴) معماری کروموزوم را نشان می‌دهد که طول آن دوبرابر تعداد متغیرهای ورودی است. مقادیر هر ژن به صورت باینری بوده و تنها مقادیر صفر و یک را در خود جای می‌دهد. مقدار صفر به معنی عدم عضویت متغیر در مجموعه ورودی شبکه عصبی و مقدار یک به معنی عضویت متغیر در مجموعه ورودی است. اندیس شماره ۱ تا اندیس شماره i متعلق به مجموعه توان دوم سری بازدهی و اندیس $i + 1$ الی $2i$ متعلق به مجموعه‌ی سری ناپایداری واریانس می‌باشد.

پس از ایجاد جمعیت اولیه به صورت تصادفی، هر کروموزوم به تابع هزینه ارجاع داده می‌شود. تابع هزینه بر اساس کروموزوم ورودی، زیرمجموعه‌ای از مجموعه ورودی‌های شبکه عصبی ایجاد می‌کند و بر اساس آن، مدل‌سازی روابط متقابل و پیش‌بینی مقدار آتی ناپایداری واریانس شرطی متغیر پیش‌بینی را توسط شبکه عصبی انجام می‌دهد. در نهایت، میانگین مربعات خطا یا MSE توسط تابع هزینه در اختیار الگوریتم ژنتیک قرار می‌گیرد تا فرایند جستجو در جهت دستیابی به کمترین خطای پیش‌بینی ادامه پیدا کند. با اتمام فرایند جستجو، بهترین زیر مجموعه از مجموعه ورودی‌های شبکه عصبی که در فرایند پیش‌بینی کمترین خطای پیش‌بینی را داشته است به عنوان خروجی نهایی تعیین می‌شود.



شکل (۳) - معماری شبکه عصبی MLP



شکل (۴) - معماری کروموزوم

که در آنها N تعداد کل مشاهدات سری زمانی، X_t مقدار واقعی مشاهده و Y_t مقدار پیش‌بینی شده است.

۲-۴- معیارهای ارزیابی

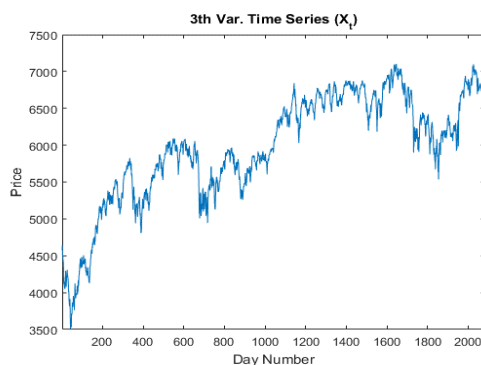
معیارهایی ارزیابی مورد استفاده در این مقاله که میزان کارایی شبکه‌های عصبی را با توجه به فاصله مقدار پیش‌بینی شده از مقدار واقعی محاسبه می‌کنند [۱، ۸، ۱۶] طبق فرمول ۹ و ۱۰ می‌باشد:

$$MSE = \frac{1}{N} \sum_{t=1}^N (X_t - Y_t)^2 \quad (9)$$


$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (X_t - Y_t)^2} \quad (10)$$

۳-۴- تنظیمات آزمایش

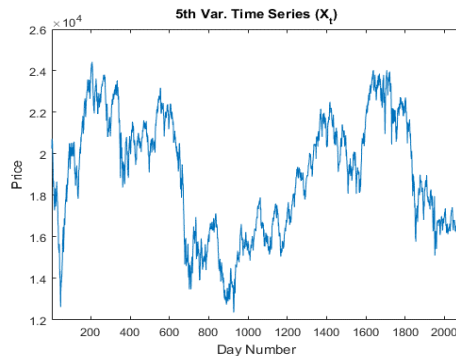
مقادیر تعیین شده در پارامترهای روش پیشنهادی که قابلیت تنظیم مجدد را نیز دارد در جدول (۲) نشان داده شده است. در ابتدا درصد تقسیم‌بندی مجموعه داده ورودی به مجموعه آموزشی و آزمون ارائه شده که ۷۰ درصد از مشاهدات سری زمانی به عنوان مجموعه آموزشی ۳۰ درصد از مشاهدات، به عنوان مجموعه آزمون در نظر گرفته شده است. همچنین در آموزش شبکه عصبی از ۳۰ درصد مجموعه آزمون، ۱۵ درصد به عنوان مجموعه اعتبارسنجی^{۳۸} و ۱۵ درصد به عنوان مجموعه تست در نظر گرفته شده است.



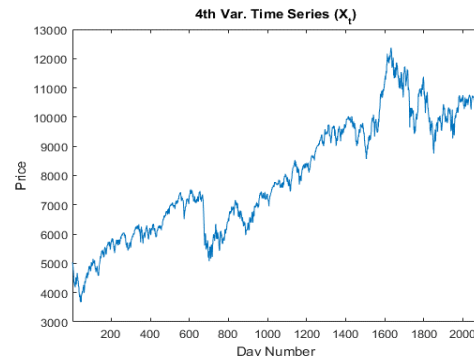
(ب) سری زمانی FTSE100



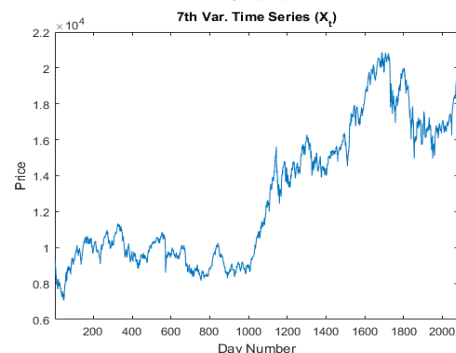
(الف) سری زمانی CAC40




(د) سری زمانی MIB40



(ج) سری زمانی DAX30



(و) سری زمانی NK225

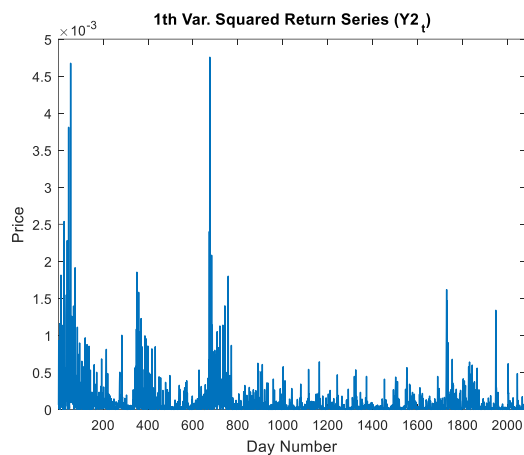


(د) سری زمانی TSK60

شکل (۶) - مشاهدات روزانه سری‌های زمانی مرتبط

جدول (۲) - پارامترهای روش پیشنهادی

بخش	پیش پردازش	مدلسازی GARCH		مدلسازی MLP							بهبودسازی ژنتیک															
		متغیر q	متغیر p	درصد مجموعه آزمون	درصد مجموعه آموزشی	تعداد سری زمانی مرتبط	تعداد سری زمانی اصلی	پارامتر	مقدار	تعداد لایه ورودی		تعداد لایه میانی	تعداد لایه خروجی	بازه تعداد نورون ورودی	بازه تعداد نورون پنهان	درصد مجموعه آرزایی	درصد مجموعه تست	تعداد جمعیت اولیه	تعداد تکرار	کران پایین	کران بالا	احتمال قطع	احتمال جهش			
		۱	۱	۳۰	۷۰	۶	۱	مقدار		۱	۱	۱	[۲ ۴۲]	[۱ ۲۱]	۱	۱	۱	۱۵	۱۵	۰	۱۰۰	۱۰۰	۰/۲	۰/۷	۲۴	



شکل (۷) - نتیجه اعمال تبدیل لوگ-ریترن بر روی سری زمانی S&P 500

زمانی S&P 500 است. همچنین این تبدیل بر روی سایر سری‌های زمانی نیز انجام شده است.


در ادامه بخش پیش‌پردازش با توجه به اینکه مدلسازی ناپایداری واریانس شرطی سری‌های زمانی مالی توسط مدل GARCH نیازمند برقراری فرضیه ایستایی ضعیف است در مجموعه داده ورودی است، توابع ACF و PACF بر روی مجموعه داده ورودی اعمال گردیده که شکل (۸) و (۹) نشان دهنده نتیجه اعمال توابع ذکر شده بر روی سری زمانی S&P 500 می‌باشد. قسمت (الف) شکل (۸) بیانگر نمودار خروجی اعمال تابع ACF بر روی سری بازدهی سری زمانی S&P 500 است که نشان می‌دهد سری بازدهی در ارتباط به مقادیر گذشته خود در وقفه‌های زمانی ۰ تا ۲۰ روزه ارتباط خاصی ندارد و رفتاری کاملاً تصادفی را از خود نشان داده است. همچنین قسمت (ب) نیز رفتار تصادفی سری بازدهی در تابع خودهمبستگی جزئی نیز نشان می‌دهد. اما در قسمت‌های (الف) و (ب) شکل (۹) قضیه متفاوت است. بدین معنی که نمودار ACF توان دوم سری بازدهی S&P 500 در وقفه‌های زمانی متعدد رفتاری وابسته به گذشته از خود نشان داده و در اکثر وقفه‌های زمانی خارج از بازه معناداری یا محدوده فرضیه نوفه سفید قرار دارد. نمودار PACF توان دوم سری بازدهی نیز حداقل برای وقفه‌های زمانی ۱ و ۲ و ۳ و ۵ و چند وقفه دیگر، وابستگی قابل قبولی را از

مطابق با بخش پیش‌پردازش جدول (۲)، تعداد کل سری‌های زمانی به عنوان ورودی‌های روش پیشنهادی ۷ عدد می‌باشد که یک سری زمانی به عنوان سری زمانی اصلی و ۶ سری زمانی به عنوان سری‌های زمانی مرتبط در نظر گرفته شده‌اند. در قسمت "مدلسازی GARCH" متغیر p که تعیین کننده تعداد وقفه‌های واریانس شرطی و متغیر q که بیانگر تعداد وقفه‌های سری جدید تغییرات است هر دو مقدار یک را دارا می‌باشند و به منزله‌ی این است که مدلسازی ناپایداری واریانس شرطی توسط مدل گارچ با مرتبه (۱و۱) انجام خواهد گرفت. در بخش مربوط به مدلسازی توسط شبکه عصبی MLP، تعداد لایه ورودی، میانی و خروجی هر سه مقدار یک را دارا می‌باشند و تعداد نورون‌های لایه ورودی با توجه به اینکه مجموع سری‌های زمانی ورودی ۷ عدد بوده و حداکثر تعداد ژن در یک کروموزوم ۲۱ است، این تعداد در بازه ۱ الی ۲۱ قرار می‌گیرد چراکه در فرایند جستجو ممکن است تعداد متغیری از مجموعه ورودی‌ها به عنوان بهترین ترکیب ورودی توسط الگوریتم ژنتیک انتخاب شود. همچنین با وجود این شرایط، تعداد نورون‌ها در لایه میانی که با توجه به پژوهش‌های قبلی، دو برابر تعداد نورون ورودی در نظر گرفته شده، در بازه عددی ۱ الی ۴۲ قرار می‌گیرد. پارامتر دیگری که در شبکه عصبی MLP مقداردهی شده است، میزان درصد تقسیم‌بندی مجموعه داده آزمون به دو زیر مجموعه آرزایی و تست است که مقدار ۱۵ درصد از برای هر کدام از این دو زیرمجموعه در نظر گرفته شده است. پارامترهای مقداردهی شده در بهینه‌سازی ژنتیک شامل تعداد جمعیت اولیه، تعداد تکرار^۳، کران پایین و کران بالا می‌باشد که مقدار ۱۰۰۰ برای جمعیت اولیه و تعداد تکرار و مقادیر ۰ و ۲۴ برای کران‌های بالا و پایین تعیین شده است. همچنین مقدار احتمال تقاطع ۰/۷ و مقدار احتمال جهش ۰/۲ در نظر گرفته شده است.


۴-۴-۴ - نتایج آزمایشات

۴-۴-۴-۱ - پیش پردازش

در این مرحله بر روی هر سری زمانی تبدیل لوگ-ریترن انجام می‌شود و سری بازدهی بدست می‌آید که شکل (۷) بیانگر اعمال این تبدیل بر روی سری




شکل (ب) نمودار PACF سری بازدهی S&P 500




شکل (الف) نمودار ACF سری بازدهی S&P 500

شکل (۸) - نمودار خروجی اعمال توابع ACF و PACF بر سری بازدهی S&P 500



شکل (ب) نمودار PACF توان دوم سری بازدهی S&P 500



شکل (الف) نمودار ACF توان دوم سری بازدهی S&P 500

شکل (۹) - نمودار خروجی اعمال توابع ACF و PACF بر توان دوم سری بازدهی S&P 500

۴-۳- روش پیشنهادی GARCH-GA-MLP

شکل (۱۰) رفتار الگوریتم ژنتیک در کمینه سازی معیار MSE روش پیشنهادی را نشان می دهد. همچنین جدول (۵) بیانگر نتایج بدست آمده توسط روش آماری GARCH در مقایسه با روش پیشنهادی می باشد که نشان دهنده ۴۳ درصد کاهش خطای پیش بینی توسط روش پیشنهادی است.

۵- نتیجه گیری کلی

همواره تغییرات در سطوح ریسک، رفتار سرمایه گذاران فردی را تغییر می دهد. از این روی، پیش بینی هر چه دقیق تر واریانس شرطی آتی سری زمانی مالی با استفاده از داده های گذشته مورد توجه پژوهشگران قرار گرفته است. با ارائه مدلی مناسب که پیش بینی دقیقی از واریانس شرطی آتی را انجام می دهد، سرمایه گذاران این امکان را خواهند داشت تا با توجه به میزان ریسک فعالیت های تجاری اقدام به سرمایه گذاری کنند. با وجود پژوهش های انجام گرفته در زمینه پیش بینی ناپایداری واریانس شرطی سری های زمانی مالی، افزایش دقت پیش بینی کماکان مورد توجه محققان می باشد. از این روی در این مقاله جهت مدلسازی روابط متقابل ناپایداری واریانس شرطی سری های زمانی مالی بر اساس پژوهش های صورت گرفته در [۴۲, ۴۵, ۴۶] از مجموعه

خود نشان داده است. بنابراین با توجه به نتایج بررسی توابع ACF و PACF بر روی سری بازدهی و توان دوم سری بازدهی سری زمانی S&P 500 می توان این نتیجه را گرفت که در توان دوم سری بازدهی S&P 500 ناهمسانی واریانس شرطی وجود دارد و امکان مدلسازی ناپایداری واریانس شرطی برای روش پیشنهادی امکان پذیر است. همچنین توابع مذکور بر روی سایر سری زمانی مرتبط را نیز اعمال شده که همگی بیانگر وجود ناهمسانی واریانس شرطی در سری های زمانی مرتبط انتخاب شده هستند.

۴-۲- مدلسازی ناپایداری واریانس شرطی

جدول (۳) نتایج حاصل از انجام مدلسازی توسط مدل آماری GARCH(1,1) بر روی مجموعه داده های ورودی با توجه به میزان خطای پیش بینی را ارائه نموده است. جدول (۴) نیز نتایج آزمون Q-test بر خطاهای GARCH را نشان می دهد که مقدار ۱ برای h به معنی رد فرضیه صفر است و در صورتی که p-Value زیر ۰/۰۵ درصد باشد فرضیه صفر برای نبود خودهمبستگی رد می شود، در نتیجه می توان گفت خودهمبستگی وجود دارد.

جدول (۳) - میزان خطای پیش‌بینی مدل GARCH برای مجموعه داده ورودی

	S&P 500	CAC40	FTSE100	DAX30	MIB40	TSK60	NK225
MSE ¹	0.0994	0.2229	0.0685	0.1708	0.5513	0.0560	0.2942
RMSE ²	0.3153	0.4721	0.2617	0.4133	0.7425	0.2367	0.5424

¹ کلیه مقادیر MSE این جدول دارای ۶ رقم اعشار می‌باشد. ² کلیه مقادیر RMSE دارای ۳ رقم اعشار می‌باشد.

جدول (۴) - نتایج آزمون Q-test بر خطاهای GARCH در وقفه‌های زمانی ۱ الی ۲۰

	S&P 500	CAC40	FTSE100	DAX30	MIB40	TSK60	NK225
p-Value	0.1110e-15	0.1237e-07	0	0.6378e-10	0.1728e-09	0	0
h	1	1	1	1	1	1	1

GARCH به عنوان یک روش پایه اقتصادسنجی و همچنین شبکه عصبی MLP به صورت گسترده‌ای مورد استفاده پژوهشگران قرار گرفته است که در این مقاله نیز از ترکیب مدل‌های مذکور به عنوان ابزار مدل‌سازی و پیش‌بینی ناپایداری واریانس شرطی سری‌های زمانی مالی استفاده گردید. بطور کلی نوآوری‌های روش پیشنهادی نسبت به روش‌های قبلی را می‌توان در فهرست زیر جای داد:

- مدل‌سازی روابط متقابل ناپایداری واریانس شرطی یک سری زمانی مالی با سایر سری‌های زمانی مالی مرتبط که در مرجع [۴, ۱۶] این مدل‌سازی روابط متقابل در فضای میانگین انجام گرفته است.
- استفاده از روش بهینه‌سازی ژنتیک در انتخاب بهترین مجموعه سری‌های زمانی مرتبط به عنوان ورودی مدل پیش‌بین که در مراجع [۴, ۱۴] از روش آزمون خطا و در مرجع [۴۲] از ضریب همبستگی استفاده شده است.


بر اساس پژوهش صورت گرفته در مرجع [۶۰] نشان داده شده که سایر متغیرها از جمله احساسات در پیام‌های توئیتری نیز بر قیمت سهام تاثیر گذار است. از این روی با توجه به کارکرد مطلوب روش پیشنهادی در مدل‌سازی دقیق‌تر ناپایداری واریانس شرطی سری‌های زمانی مالی، پیشنهاد می‌شود به عنوان تحقیق آتی مدل‌سازی ناپایداری واریانس شرطی علاوه بر در نظر گرفتن تاثیر روابط متقابل سایر سری‌های زمانی مالی مرتبط با مدل‌سازی روابط متقابل سایر سری‌ها از جمله احساسات پیام‌های موجود در شبکه‌های اجتماعی انجام پذیرد.

مراجع

- [۱] حسینعلی‌زاده، ساسان و صفابخش، رضا، "پیش‌بینی سری‌های زمانی مالی با استفاده از مدل ARMA-GARCH-GRNN"، چهاردهمین کنفرانس سالانه انجمن کامپیوتر ایران، ۱۳۸۷.

جدول (۵) - مقایسه خطای پیش‌بینی روش پیشنهادی با GARCH

	GARCH	روش پیشنهادی
MSE	0.0994e-06	5.6584e-08
RMSE	0.3153e-03	2.3787e-04



شکل (۱۰) - نمودار رفتار الگوریتم ژنتیک در کمینه سازی معیار MSE

سری زمانی G7 استفاده گردید که نتایج حاصل از مدل‌سازی روابط متقابل ناپایداری واریانس شرطی آنها نشان دهنده کاهش خطای پیش‌بینی می‌باشد. همچنین باتوجه به وجود رقابت بین استفاده از روش‌های آماری و استفاده از روش‌های مبتنی بر شبکه عصبی جهت پیش‌بینی، بهترین انتخاب استفاده از روش‌های ترکیبی است چراکه تحقیقات اخیر بیانگر انجام پیش‌بینی‌های دقیق‌تر توسط روش‌های ترکیبی نسبت به روش‌های قبلی می‌باشد. در این مقاله نیز از یک روش جدید ترکیبی استفاده گردید که نتایج نشان دهنده کارآمدی بالاتر روش ترکیبی نسبت به سایر روش‌ها است. علاوه بر این، با توجه به دستاورد تحقیقات اخیر در مدل‌سازی توأم متغیر پیش‌بینی به همراه سایر متغیرهای مرتبط، در روش پیشنهادی، ابتدا با استفاده از مدل GARCH سعی در مدل‌سازی پارامتریک نوسانات مجموعه سری‌های زمانی مالی گردید و سپس با استفاده از الگوریتم ژنتیک بهترین ترکیب ورودی جهت مدل‌سازی روابط متقابل ناپایداری واریانس شرطی انتخاب شد. در ادامه با استفاده از شبکه عصبی MLP مدل‌سازی روابط متقابل نوسانات نیز انجام گرفت که در نتیجه آن، خطای پیش‌بینی کاهش یافت. مدل آماری

- [13] Stojanović, M. B., Božić, M. M., Stanković, M. M., and Stajić, Z. P., "A methodology for training set instance selection using mutual information in time series prediction", *Neurocomputing*, Vol. 141, pp. 236-245, 2014.
- [14] Smith, C. and Jin, Y., "Evolutionary multi-objective generation of recurrent neural network ensembles for time series prediction", *Neurocomputing*, Vol. 143, pp. 302-311, 2014.
- [15] Hamid, S. A. and Iqbal, Z., "Using neural networks for forecasting volatility of S&P 500 Index futures prices", *Journal of Business Research*, Vol. 57, No. 10, pp. 1116-1125, 2004.
- [16] Hajizadeh, E., Seifi, A., Fazel Zarandi, M. H., and Turksen, I. B., "A hybrid modeling approach for forecasting the volatility of S&P 500 index return", *Expert Systems with Applications*, Vol. 39, No. 1, pp. 431-436, 2012.
- [17] Oliveira, N., Cortez, P., and Areal N., "The impact of microblogging data for stock market prediction: Using Twitter to predict returns, volatility, trading volume and survey sentiment indices", *Expert Systems with Applications*, Vol. 73, pp. 125-144, 2017.
- [18] Kristjanpoller, W. and Minutolo, M. C., "Forecasting volatility of oil price using an artificial neural network-GARCH model", *Expert Systems with Applications*, Vol. 65, pp. 233-241, 2016.
- [19] Bollerslev, T., "Generalized autoregressive conditional heteroskedasticity", *Journal of Econometrics*, Vol. 31, No. 3, pp. 307-327, 1986.
- [20] Bildirici, M. and Ersin, Ö. Ö., "Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul Stock Exchange", *Expert Systems with Applications*, Vol. 36, No. 4, pp. 7355-7362, 2009.
- [21] Chang, B. R. and Tsai, H. F., "Forecast approach using neural network adaptation to support vector regression grey model and generalized autoregressive conditional heteroscedasticity", *Expert Systems with Applications*, Vol. 34, No. 2, pp. 925-934, 2008.
- [22] Coelho, L. d. S. and Santos, A. A. P., "A RBF neural network model with GARCH errors: Application to electricity price forecasting", *Electric Power Systems Research*, Vol. 81, No. 1, pp. 74-83, 2011.
- [23] Guresen, E., Kayakutlu, G., and Daim, T. U., "Using artificial neural network models in stock market index prediction", *Expert Systems with Applications*, Vol. 38, No. 8, pp. 10389-10397, 2011.
- [24] Khosravi, A., Nahavandi, S., and Creighton, D., "A neural network-GARCH-based method for construction of Prediction Intervals", *Electric Power Systems Research*, Vol. 96, pp. 185-193, 2013.
- [۸] شایقی، حسین و قاسمی، علی، "پیش‌بینی قیمت روزانه برق با شبکه عصبی بهبودیافته مبتنی بر تبدیل موجک و روش آشوبناک جستجوی گرانشی"، *مجله مهندسی برق دانشگاه تبریز*، ۱۳۹۴.
- [۳۱] منہاج، محمدباقر، مبانی شبکه‌های عصبی (هوش محاسباتی)، چاپ هشتم، انتشارات دانشگاه صنعتی امیرکبیر، تهران، ۱۳۹۴.
- [۵۵] به نام، مرتضی و پورقاسم، حسین، "شناسایی صرع بر اساس بهینه‌سازی ویژگی‌های ادغامی تبدیل هارتلی با مدل ترکیبی MLP و GA همراه با استراتژی یادگیری ممتیک"، *مجله مهندسی برق دانشگاه تبریز*، ۱۳۹۴.
- [2] Donate, J. Peralta and Cortez P., "Evolutionary optimization of sparsely connected and time-lagged neural networks for time series forecasting", *Applied Soft Computing*, Vol. 23, pp. 432-443, 2014.
- [3] Matías, J. M., Febrero-Bande M., González-Manteiga W., and Reboredo J. C., "Boosting GARCH and neural networks for the prediction of heteroskedastic time series", *Mathematical and Computer Modelling*, Vol. 51, No. 3-4, pp. 256-271, 2010.
- [4] Kristjanpoller, W. and Minutolo, M. C., "Gold price volatility: A forecasting approach using the Artificial Neural Network-GARCH model", *Expert Systems with Applications*, Vol. 42, No. 20, pp. 7245-7251, 2015.
- [5] Vidal, A. and Kristjanpoller, W., "Gold volatility prediction using a CNN-LSTM approach", *Expert Systems with Applications*, Vol. 157, p. 113481, 2020.
- [6] Dash, R., Dash, P. K., and Bisoi, R., "A differential harmony search based hybrid interval type2 fuzzy EGARCH model for stock market volatility prediction", *International Journal of Approximate Reasoning*, Vol. 59, pp. 81-104, 2015.
- [7] Wu, L. and Shahidehpour, M., "A Hybrid Model for Day-Ahead Price Forecasting", *IEEE Transactions on Power Systems*, Vol. 25, No. 3, pp. 1519-1530, 2010.
- [9] Aras, S., "On improving GARCH volatility forecasts for Bitcoin via a meta-learning approach", *Knowledge-Based Systems*, Vol. 230, p. 107393, 2021.
- [10] Chen, Z., Li, C., and Sun, W., "Bitcoin price prediction using machine learning: An approach to sample dimension engineering", *Journal of Computational and Applied Mathematics*, Vol. 365, p. 112395, 2020.
- [11] Kao, L.-J., Chiu, C.-C., Lu, C.-J., and Yang, J.-L., "Integration of nonlinear independent component analysis and support vector regression for stock price forecasting", *Neurocomputing*, Vol. 99, pp. 534-542, 2013.
- [12] Ouyang, Y. and Yin, H., "A neural gas mixture autoregressive network for modelling and forecasting FX time series", *Neurocomputing*, Vol. 135, pp. 171-179, 2014.

- [38] Liu, R., Jiang, Y., and Lin, J., "Forecasting the Volatility of Specific Risk for Stocks with LSTM", *Procedia Computer Science*, vol. 202, pp. 111-114, 2022.
- [39] Amirshahi, B. and Lahmiri, S., "Hybrid deep learning and GARCH-family models for forecasting volatility of cryptocurrencies", *Machine Learning with Applications*, p. 100465, 2023.
- [40] Dash, R. and Dash, P. K., "An evolutionary hybrid Fuzzy Computationally Efficient EGARCH model for volatility prediction", *Applied Soft Computing*, Vol. 45, pp. 40-60, 2016.
- [41] Awartani, B. M. A. and Corradi, V., "Predicting the volatility of the S&P-500 stock index via GARCH models: the role of asymmetries", *International Journal of Forecasting*, Vol. 21, No. 1, pp. 167-183, 2005.
- [42] Huang, S.-C. and Wu, T.-K., "Integrating GA-based time-scale feature extractions with SVMs for stock index forecasting", *Expert Systems with Applications*, Vol. 35, No. 4, pp. 2080-2088, 2008.
- [43] Choi, J. and Richardson, M., "The volatility of a firm's assets and the leverage effect", *Journal of Financial Economics*, Vol. 121, No. 2, pp. 254-277, 2016.
- [44] Chen, C. W. S., Watanabe, T., and Lin, E. M. H., "Bayesian estimation of realized GARCH-type models with application to financial tail risk management", *Econometrics and Statistics*, 2021.
- [45] Huang, S.-C. and Wu, T.-K., "Integrating recurrent SOM with wavelet-based kernel partial least square regressions for financial forecasting", *Expert Systems with Applications*, Vol. 37, No. 8, pp. 5698-5705, 2010.
- [46] Huang, S.-C., "Forecasting stock indices with wavelet domain kernel partial least square regressions", *Applied Soft Computing*, Vol. 11, No. 8, pp. 5433-5443, 2011.
- [47] Huang, S.-C., "Integrating spectral clustering with wavelet based kernel partial least square regressions for financial modeling and forecasting", *Applied Mathematics and Computation*, Vol. 217, No. 15, pp. 6755-6764, 2011.
- [48] Yumlu, M. S., Gurgen, F. S., and Okay, N., "Financial Time Series Prediction Using Mixture of Experts", in *Computer and Information Sciences - ISCIS 2003: 18th International Symposium, Antalya, Turkey, 2003*.
- [49] Ferreira, N. B., Menezes, R., and Mendes, D. A., "Asymmetric conditional volatility in international stock markets", *Physica A: Statistical Mechanics and its Applications*, Vol. 382, No. 1, pp. 73-80, 2007.
- [50] Long, L., Tsui, A. K., and Zhang, Z., "Conditional heteroscedasticity with leverage effect in stock returns: Kristjanpoller, W., Fadic, A., and Minutolo, M. C., "Volatility forecast using hybrid Neural Network models", *Expert Systems with Applications*, Vol. 41, No. 5, pp. 2437-2442, 2014.
- [25] Rombouts, J. V. K. and Stentoft, L., "Option pricing with asymmetric heteroskedastic normal mixture models", *International Journal of Forecasting*, Vol. 31, No. 3, pp. 635-650, 2015.
- [26] Engle, R. F., "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation", *Econometrica*, Vol. 50, No. 4, pp. 987-1007, 1982.
- [27] Nelson, D. B., "Conditional Heteroskedasticity in Asset Returns: A New Approach", *Econometrica*, Vol. 59, No. 2, pp. 347-370, 1991.
- [28] Glosten, L. R., Jagannathan, R., and Runkle, D. E., "On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks", *The Journal of Finance*, Vol. 48, No. 5, pp. 1779-1801, 1993.
- [29] AleMohammad, N., Rezakhah, S., and Hoseinalizadeh, S., "Markov Switching Smooth Transition GARCH Model", *arXiv preprint arXiv:1603.01795*, 2016.
- [30] Asadi, S., Hadavandi, E., Mehmanpazir, F., and Nakhostin, M. M., "Hybridization of evolutionary Levenberg-Marquardt neural networks and data pre-processing for stock market prediction", *Knowledge-Based Systems*, Vol. 35, pp. 245-258, 2012.
- [32] Gutiérrez, P. A., Hervás, C., Carbonero, M., and Fernández, J. C., "Combined projection and kernel basis functions for classification in evolutionary neural networks", *Neurocomputing*, Vol. 72, No. 13-15, pp. 2731-2742, 2009.
- [33] Panapakidis, I. P. and Dagoumas, A. S., "Day-ahead electricity price forecasting via the application of artificial neural network based models", *Applied Energy*, Vol. 172, pp. 132-151, 2016.
- [34] Ebrahimpour, R., Nikoo, H., Masoudnia, S., Yousefi, M. R., and Ghaemi, M. S., "Mixture of MLP-experts for trend forecasting of time series: A case study of the Tehran stock exchange", *International Journal of Forecasting*, Vol. 27, No. 3, pp. 804-816, 2011.
- [35] Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., and Oliveira, A. L. I., "Computational Intelligence and Financial Markets: A Survey and Future Directions", *Expert Systems with Applications*, Vol. 55, pp. 194-211, 2016.
- [36] Clerk, L. De and Savel'ev, S., "AI algorithms for fitting GARCH parameters to empirical financial data", *Physica A: Statistical Mechanics and its Applications*, Vol. 603, p. 127869, 2022.

- predictions", *Physica A: Statistical Mechanics and its Applications*, Vol. 589, p. 126635, 2022.
- [64] Cerqueti, R., Giacalone, M., and Mattera, R., "Skewed non-Gaussian GARCH models for cryptocurrencies volatility modelling", *Information Sciences*, Vol. 527, pp. 1-26, 2020.
- [65] Caporale, G. M. and Zekokh, T., "Modelling volatility of cryptocurrencies using Markov-Switching GARCH models", *Research in International Business and Finance*, Vol. 48, pp. 143-155, 2019.
- [66] Maqbool, J., Aggarwal, P., Kaur, R., Mittal, A., and Ganaie, I. A., "Stock Prediction by Integrating Sentiment Scores of Financial News and MLP-Regressor: A Machine Learning Approach", *Procedia Computer Science*, Vol. 218, pp. 1067-1078, 2023.
- [67] Sitte, R. and Sitte, J., "Analysis of the predictive ability of time delay neural networks applied to the S&P 500 time series", *Trans. Sys. Man Cyber Part C*, Vol. 30, No. 4, pp. 568-572, 2000.
- [68] Liao, Z. and Wang, J., "Forecasting model of global stock index by stochastic time effective neural network", *Expert Systems with Applications*, Vol. 37, No. 1, pp. 834-841, 2010.
- [69] Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., and Khatri, R. K. C., "Predicting stock market index using LSTM", *Machine Learning with Applications*, Vol. 9, p. 100320, 2022.
- [70] DiCesare, G., "Imputation, Estimation and Missing Data in Finance", UWSpace, 2006. [Online]. Available: <http://hdl.handle.net/10012/2920>.
- [71] Sridevi, S., Rajaram, S., Parthiban, C., SibiArasan, S., and Swadhikar, C., "Imputation for the analysis of missing values and prediction of time series data", in *2011 International Conference on Recent Trends in Information Technology (ICRTIT)*, 2011.
- [72] Box, G. E. P., Jenkins, G. M., and Reinsel, G. C., *Time Series Analysis: Forecasting and Control*, 3rd. ed. Englewood Cliffs, NJ: Prentice Hall, 1994.
- [73] Lin, P.-C. and Ko, P.-C., "Portfolio value-at-risk forecasting with GA-based extreme value theory", *Expert Systems with Applications*, Vol. 36, No. 2, pp. 2503-2512, 2009.
- [74] S&P Dow Jones Indices LLC, S&P 500 [SP500], retrieved from FRED, Federal Reserve Bank of St. Louis, <https://fred.stlouisfed.org/series/SP500>, July 26, 2016.
- Evidence from the Chinese stock market", *Economic Modelling*, vol. 37, pp. 89-102, 2014.
- [51] Verhoeven, P., Pilgram, B., McAleer, M., and Mees, A., "Non-linear modelling and forecasting of S&P 500 volatility", *Mathematics and Computers in Simulation*, Vol. 59, No. 1-3, pp. 233-241, 2002.
- [52] Majhi, R., Panda, G., Sahoo, G., Dash, P. K., and Das, D. P., "Stock market prediction of S&P 500 and DJIA using Bacterial Foraging Optimization Technique", in *2007 IEEE Congress on Evolutionary Computation*, 2007.
- [53] Zhang, Y. and Wu, L., "Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network", *Expert Systems with Applications*, Vol. 36, No. 5, pp. 8849-8854, 2009.
- [54] Mirjalili, S., Mirjalili, S. M., and Lewis, A., "Let a biogeography-based optimizer train your Multi-Layer Perceptron", *Information Sciences*, Vol. 269, pp. 188-209, 2014.
- [56] Niu, D.-x., Shi, H.-f., and Wu, D. D., "Short-term load forecasting using bayesian neural networks learned by Hybrid Monte Carlo algorithm", *Applied Soft Computing*, Vol. 12, No. 6, pp. 1822-1827, 2012.
- [57] Kiani, K. M., "On business cycle fluctuations in USA macroeconomic time series", *Economic Modelling*, Vol. 53, pp. 179-186, 2016.
- [58] Huang, C.-F., "A hybrid stock selection model using genetic algorithms and support vector regression", *Applied Soft Computing*, Vol. 12, No. 2, pp. 807-818, 2012.
- [59] Xu, L., "RBF nets, mixture experts, and Bayesian Ying-Yang learning", *Neurocomputing*, Vol. 19, No. 1-3, pp. 223-257, 1998.
- [60] Oh, S.-K., Kim, M.-S., Eom, T.-D., and Lee, J.-J., "Heterogeneous local model networks for time series prediction", *Applied Mathematics and Computation*, Vol. 168, No. 1, pp. 164-177, 2005.
- [61] Asai, M. and Brugal, I., "Forecasting volatility via stock return, range, trading volume and spillover effects: The case of Brazil", *The North American Journal of Economics and Finance*, Vol. 25, pp. 202-213, 2013.
- [62] Hammoudeh, S., Araújo Santos, P., and Al-Hassan, A., "Downside risk management and VaR-based optimal portfolios for precious metals, oil and stocks", *The North American Journal of Economics and Finance*, Vol. 25, pp. 318-334, 2013.
- [63] Chen, X., Zhu, H., Zhang, X., and Zhao, L., "A novel time-varying FIGARCH model for improving volatility

زیر نویس ها

⁴ Nonstationary

⁵ Not Defined a Priori

⁶ Generalized Autoregressive Conditional Heteroskedasticity

¹ Return

² Conditional heteroskedasticity

³ Unbiased

7 Engle
8 Exponential GARCH
9 Glosten-Jagannathan-Runkle GARCH
10 Markov Switching Smooth Transition GARCH Model
11 Volatility
12 Nonparametric
13 Universal Approximation
14 Parallel Distributed Processing
15 Adaptation
16 Natural Fault Tolerance
17 Multilayer Perceptron
18 Error Backpropagation
19 Radial Basis Function
20 Recurrent Neural Network
21 Overfitting
22 Dow Jones industrial stock market Index
23 Takagi-Sugeno-Kang
24 Target

25 Missing Data
26 K-Nearest Neighbours imputation
27 Bayesian Principal Component Analysis
28 Singular Value Decomposition imputation
29 Trend
30 Log Return
31 Weak stationary
32 Autocorrelation Function
33 Partial Autocorrelation Function
34 Innovation Series
35 Target
36 Crossover
37 Mutation
38 Validation
39 Iteration