

پیش‌بینی نوسانات بازده بازار با استفاده از مدل‌های ترکیبی گارچ - شبکه عصبی

حسین سعیدی^۱ / شاپور محمدی^۲

چکیده

در این پژوهش به مطالعه توان پیش‌بینی طیف وسیعی از مدل‌های ناهمسانی واریانس شرطی (G)ARCH طی یک دوره ۱۲۶ ماهه بر روی بازده روزانه شاخص کل بورس تهران (TEDPIX) پرداخته شده است. نتایج بررسی این مدل‌ها تأیید کننده وجود سه ویژگی نوسان خوشه‌ای، عدم تقارن و نیز غیر خطی بودن، در سری زمانی بازده می‌باشد. سپس با هدف افزایش قدرت پیش‌بینی، این مدل‌ها با شبکه‌های عصبی مصنوعی ترکیب شده‌اند و نتایج حاصل از طرق گوناگونی مورد آزمون قرار گرفته است. این نتایج نشان می‌دهد مدل‌های ترکیبی گارچ توان - میانگین، گارچ نمایی - میانگین و مدل GJR، کمترین خطای پیش‌بینی را داشته‌اند. بررسی تغییرات جهت نوسان نشان می‌دهد مدل‌های ترکیبی همسویی بیشتری با نوسان واقعی نسبت به مدل‌های پایه‌ای گارچ دارند. همچنین مدل‌های ترکیبی گارچ توانی نامتقارن، گارچ - میانگین نمایی و گارچ - میانگین توانی بطور معنی‌داری خطای پیش‌بینی کمتری نسبت به مدل‌های پایه‌ای خود داشته‌اند.

واژگان کلیدی: پیش‌بینی نوسان، بازده شاخص کل، مدل‌های گارچ، شبکه عصبی مصنوعی، مدل‌های ترکیبی.

طبقه‌بندی موضوعی: C45, C58, G17, G32.

۱. دانشجوی کارشناسی ارشد مدیریت مالی، دانشکده مدیریت، دانشگاه تهران. hossein.saeedi@ut.ac.ir.

۲. دانشیار دانشکده مدیریت، دانشگاه تهران

مقدمه

پیش‌بینی تغییرپذیری یا نوسان در مدیریت ریسک، ارزش‌گذاری سبد سرمایه، قیمت‌گذاری مشتقات و ... دارای کاربردهای فراوان است. اما از دیدگاه معامله‌گران بازار مشتقات، درک نوسان‌پذیری، پیش‌بینی دقیق آن و حفاظت از دارایی‌های پرتفوی در مقابل هزینه‌هایی که این متغیر به ارزش کل تحمیل می‌کند از اهمیت دو چندانی برخوردار می‌باشد. دانستن این واقعیت که معاملات و ابزارهای مشتقه در فضای بازار سرمایه ایران روندی تکاملی به خود گرفته است، بر ضرورت اجرای تحقیقات کاربردی بیشتر در این حوزه می‌افزاید.

بسیاری از تحقیقات مالی در سالهای اخیر بر این مسأله متمرکز بوده است که مدل‌های سنتی خطی و غیرخطی را برای دست‌یافتن به برآوردها و پیش‌بینی‌های دقیق‌تر، به نحوی ارتقا دهند و در این مسیر شبکه‌های عصبی و مدل‌های ترکیبی متنوعی پیشنهاد شده است. برای مدلسازی نوسانات بازده بطور مرسوم از مدل‌های ناهمسانی واریانس شرطی خودرگرسیون^۱ (ARCH) استفاده می‌شود که این مدل‌ها از پایه‌های تنوریک مالی و اقتصادی برخوردارند. ولی به هرحال اجرای این مدل‌ها به خصوص در مطالعاتی که در ایران صورت گرفته، در مواردی با کارایی کامل همراه نشده است (عرب مازار یزدی و همکاران، ۱۳۸۸). بنابراین، بهره‌گیری از این پایه‌های نظری به همراه تلفیق آن با مدل‌های ناپارامتری همانند شبکه‌های عصبی می‌تواند به دقت سیستم پیش‌بینی کننده بیافزاید. در این پژوهش سعی شده با ترکیب مدل‌های شبکه عصبی و مدل‌های تحلیل سری زمانی به مدل‌های مناسب‌تری برای مدلسازی نوسان بازدهی دست یابیم که نتایج به دست آمده حاکی از موفقیت نسبی مدل‌های ترکیبی در پیش‌بینی می‌باشد.

مبانی نظری

همان‌گونه که ذکر شد تغییرپذیری، یکی از مفاهیم مهم در مباحث اقتصادی و مالی است و از همین روی بسیاری از تحقیقات در حوزه بازار سرمایه متمرکز بر پژوهش در خصوص ویژگی‌ها و پیش‌بینی این متغیر است. یکی از شیوه‌های مناسب برای مدلسازی متغیرهای بازاری استفاده از شبکه عصبی مصنوعی^۲ (ANN) است که بدون محدود بودن به مدل‌های معین، می‌تواند خود را با نوسانات متغیرهای بازار هماهنگ و تعدیل نماید. در پژوهش‌های متعدد انواع شبکه‌های عصبی در مقابل روش‌های سری زمانی (اغلب خطی و در مواردی غیر خطی) مورد آزمون قرار گرفته‌اند و در بیشتر موارد

1. Autoregressive Conditional Heteroscedasticity Models.
2. Artificial Neural Network

مشاهده شده است که شبکه‌های عصبی مصنوعی نتایج به مراتب بهتری را از لحاظ دقت عملکرد رقم زده‌اند. اما به هر حال با وجود این ویژگی مثبت، پیاده‌سازی مستقیم شبکه عصبی مصنوعی در پیش‌بینی متغیرهای بازارهای پیچیده امروزی، در رابطه با تعیین متغیرهای ورودی دارای محدودیت است و انعکاس مستقیم متغیرهای بازاری در ANN بدون اعمال برخی تعدیلات، لزوماً منجر به نتایج بهتری نمی‌شود. علاوه بر این، آزمون فرضیه که در مدل‌های عادی رگرسیونی و مدل‌های سری زمانی قابل انجام است، در مدل‌های شبکه عصبی آسان نبوده و در مواردی چندان دقیق نیست.

از سوی دیگر در پاسخ به اهمیت موضوع تغییر پذیری، مدل‌های اقتصادسنجی فراوانی توسط محققین اقتصاد مالی در این خصوص ارائه شده است که این مهم از نیاز به مدل‌سازی شرایط عدم اطمینان و لزوم مدیریت ریسک نهفته در دارایی‌های مالی ناشی می‌شود. بازدهی دارایی‌های مالی معمولاً دارای سه ویژگی مهم است: نوسان خوشه‌ای^۱، رابطه نامتقارن^۲ (اهرم) و غیر خطی بودن^۳. مدل‌های ناهمسانی واریانس شرطی به دلیل انطباق با این ویژگی‌ها، در تحقیقات مالی کاربرد فراوانی پیدا کرده‌اند (Bildirici, et al., 2009).

به این ترتیب مدل‌هایی نظیر مدل ناهمسانی واریانس شرطی یا ARCH توسط انگل (Engle, 1982) به دنبال آن مدل تعمیم یافته آرچ یا GARCH توسط بولرزلرف (Bollersler, 1986) گسترش پیدا نمود. نلسون (Nelson, 1991) مدل گارچ نمایی یا EGARCH را معرفی نمود و در سال‌های ۱۹۹۳ تا ۱۹۹۴ گروهی از محققان بطور مستقل مدل ارتقا یافته دیگری از این خانواده با نام GJR-GARCH را معرفی کردند. زاکاین (Zakain, 1994) مدل حدی گارچ یا TGARCH و سنتانا (Sentana, 1995) مدل گارچ درجه دو یا QGARCH را معرفی نمود. مدل دیگری از این گروه توسط دینگ و همکاران (Ding, et al., 1993) تحت عنوان گارچ توانی یا PGARCH ارائه شد و مطالعه این محققان را می‌توان پایه و اساس APGARCH دانست که توسط تس و همکاران (Tes, et al., 2002) معرفی گردید (Roh, 2007). همان‌طور که اشاره شد، نقطه قوت مدل‌های فوق در این است که پایه‌های تئوریک مالی و اقتصادی قوی دارند. اما به هر حال شرایط متغیر بازار، همواره اجزاء اختلال فراوانی ایجاد می‌نماید و لذا برای ارتقای مدل باید مدام بر تعداد متغیرهای توضیح دهنده افزود. از سوی دیگر مدل‌های سری زمانی مقید به فروض محدود کننده‌ای در رابطه با نوع توزیع سری

-
1. Volatility Clustering
 2. Asymmetric Relation
 3. Nonlinearity Property

زمانی می‌باشند. بنابراین در بسیاری از موارد تکیه بر خروجی‌های خام این مدل‌ها، منطقی به نظر نمی‌رسد و منجر به نتیجه‌گیری‌هایی به دور از واقع می‌شود.

به این ترتیب استفاده از مدل‌های اقتصادسنجی ناهمسانی واریانس شرطی و نیز استفاده از شبکه عصبی مصنوعی در پیش‌بینی نوسان‌پذیری، هر یک دارای نقاط ضعف و قوتی هستند. در این پژوهش برای مرتفع نمودن کمبودهای هر یک از روش‌های یاد شده، یک مدل دوگانه سری زمانی - شبکه عصبی پیشنهاد شده که انتظار می‌رود ضمن برطرف نمودن اشکالات شبکه عصبی در فرآیند یادگیری، در افزایش توان پیش‌بینی مدل‌های گروه ناهمسانی واریانس شرطی موثر افتد.

مروری بر پیشینه پژوهش

در این مقاله کوشش می‌شود با بکارگیری ابزار ناپارامتریک شبکه عصبی مصنوعی و تکنیک داده-کاوی^۱، بر میزان دقت پیش‌بینی نوسان افزوده شود. در دو دهه اخیر ANN کاربرد بسیار وسیعی به خصوص در مدل‌سازی و پیش‌بینی مالی پیدا نموده است. نخستین مطالعات صورت گرفته از این دست، بر تخمین سطح بازدهی شاخص بازار سهام متمرکز بود. از آن جمله می‌توان به مطالعه کیموتو، آساکو، یادا و تاکنوکا اشاره داشت (Kimoto, et al, 1990). این پژوهش‌گران الگوریتم‌های یادگیری و پیش‌بینی فراوانی را در جهت رسیدن به سیستم پیش‌بینی کننده‌ای کارآمد و مطلوب برای شاخص بازار بورس نیویورک، مورد آزمون قرار دادند. حاصل این پژوهش این واقعیت را مورد تأیید قرار می‌داد که ضریب همبستگی بین متغیرهای مختلف با بکارگیری ANN برای یادگیری، به مراتب بهتر از روش رگرسیون چندگانه می‌باشد. در همین رابطه برخی دیگر از پژوهشگران از جمله تریپی و دسینو به پیش‌بینی جهت تغییرات در بازدهی روزانه S&P با بکارگیری ANN پرداختند (Trippi, et al., 1992). روش به کار رفته توسط آنها ترکیب خروجی شبکه‌ها با استفاده از عملگرهای منطقی (Boolean) بود که به تنظیم مجموعه الگوهای بهینه‌سازی شده برای پیش‌بینی سری‌های زمانی مالی منجر گردید. در مطالعات بعدی، رویکرد اصلی مبتنی بر تکنیک‌های هوش مصنوعی (AI) بوده است. برای نمونه دو پژوهش‌گر با نام‌های نیکولوپولوس و فلراث سیستم هوشمند دوگانه‌ای را معرفی نمودند که در آن از الگوریتم ژنتیک برای ایجاد معماری و آموزش شبکه عصبی سرمایه‌گذاری تلفیقی استفاده می‌شود (Nikolopoulos, et al., 1994). پرمینگر و همکاران (Preminger, et al., 2007) از خودرگرسیو خطی^۲ و نیز مدل شبکه عصبی برای بهبود در پیش‌بینی

1. Data Mining Technique

2 Linear Autoregressive

نرخ ارز استفاده نمودند. مدل پیشنهادی آنها از مدل‌های کلاسیک بهتر عمل می‌کرد ولی هنوز از گام تصادفی^۱ بهتر نبود.

ژنگ و همکاران (Zhang, et al., 2007) معماری جدیدی تحت عنوان شبکه عصبی فازی بازه-ای تصادفی ایجاد نمودند که پایه آن شبکه عصبی فازی بود. دو پژوهش‌گر نامبرده از شبکه عصبی فوق برای پیش‌بینی نرخ ارز استفاده نمودند. شبکه مذکور نرخ ارز را بصورت بازه‌ای، و نه در نقطه‌ای از زمان، پیش‌بینی می‌کند. حسن و همکاران (Hassan, et al., 2007) از مدلی چندگانه متشکل از مدل مارکوف، ANN و الگوریتم ژنتیک استفاده نمودند. این مدل که برای پیش‌بینی بازده بازار بورس بکار بسته شده بود اثبات نمود که مدل‌های چندگانه بهتر از مدل‌های شبیه‌سازی می‌باشند. همچنین دو محقق با نام‌های یو و همکاران (Yu, et al., 2008). شبکه‌های عصبی دوتایی^۲، شبکه‌های عصبی دوتایی مبتنی بر سری زمانی فازی^۳ و شبکه عصبی مصنوعی مبتنی بر سری‌های زمانی فازی با جایگذاری^۴ را مورد استفاده قرار دادند و به این نتیجه رسیدند که شبکه اخیر دارای بهترین عملکرد است. از سوی دیگر همزاسی و همکاران (Hamzacebi, et al., 2009) روش ARIMA و ANN را مقایسه کردند و این طور نتیجه گرفتند که پیش‌بینی مستقیم شبکه عصبی انطباق بیشتری با واقع دارد. ولی در عین حال تصریح نمودند که قبل از تعمیم نتایج این تحقیق، لازم است مطالعات تکمیلی صورت پذیرد.

لذا با توجه به پژوهش‌های یاد شده و دیگر مطالعات مشابهی که برای رعایت اختصار از ذکر آن خودداری شده است، می‌توان گفت ایده ترکیب تکنیک‌های پیش‌بینی سری‌های زمانی، حوزه وسیعی از تحقیقات مالی و سرمایه‌گذاری را به خود اختصاص داده است. در این میان از جمله مطالعاتی که نزدیکی بیشتری با این تحقیق دارد مطالعه رو می‌باشد (Roh, 2007). وی مدل کلاسیک ANN، مدل میانگین موزون متحرک نمایی (EWMA)، GARCH و EGARCH را به همراه ANN بکار برد. مدل NN-EGARCH در بازه‌های زمانی ۱۰ روزه بهترین عملکرد را نشان داد به طوری که ضریب برخورد برای این مدل ترکیبی برای دوره‌های کوتاه مدت ۱۰ روزه به ۱۰۰٪ می‌رسید. بیلدیریکی و همکاران (Bildirici, et al., 2009) شبکه‌های عصبی را با مدل‌های ناهمسانی واریانس شرطی (GARCH, EGARCH, TGARCH, PGARCH, APGARCH و...) ترکیب نمودند و به این

-
1. Random Walk (RW)
 2. Bivariate Neural Networks
 3. Bivariate Neural Network-based Fuzzy Time Series
 4. Bivariate Neural Network-based Fuzzy Time Series Model With Substitute

نتیجه رسیدند که مدل ترکیبی، پیش‌بینی بهتری نسبت به تک‌تک مدل‌ها به تنهایی دارد. همچنین گورسن و همکاران (Guresen, et al, 2011) کارایی مدل‌های شبکه عصبی مصنوعی پرسترون چند لایه، شبکه عصبی مصنوعی پویا و مدل‌های ترکیبی گارچ با شبکه عصبی را از نقطه نظر دو معیار MAD و MSE بر روی شاخص بورس نزدیک مورد مطالعه قرار دادند. پژوهش این محققین، نتایج به-دست آمده توسط رو (Roh, 2007) را مورد تأیید قرار نمی‌داد و توجه آن‌ها استفاده رو از متغیرهای بنیادی بازار (بازده تا سررسید اوراق قرضه، قیمت اوراق قرضه و ...) در کنار متغیرهای خروجی مدل گارچ بود. در واقع آن‌ها بهبود پیش‌بینی مدل‌های ترکیبی را نتیجه استفاده از این متغیرهای بنیادی تعبیر نمودند.

اما در مجموع، نتایج حاصل از این تحقیقات بیانگر این واقعیت می‌باشد که پردازش بیشتر بر روی خروجی‌های یک سیستم پیش‌بینی کننده مثل مدل‌های ناهمسانی واریانس شرطی، توسط سایر ابزارها همانند شبکه عصبی، می‌تواند در شرایطی منجر به بهبود خروجی‌ها و بالاتر رفتن درجه انطباق آن با واقعیت شود. در رابطه با مدل‌سازی نوسانات بازار، از جمله مطالعات صورت گرفته در ایران می‌توان به تحقیق تهرانی و همکاران در سال ۱۳۸۹ اشاره داشت. در این مطالعه عملکرد مدل‌های شرطی و غیر شرطی مورد مقایسه قرار گرفته و نتایج حاکی از آنست که در میان مدل‌های بررسی شده عملکرد مدل میانگین متحرک ۲۵۰ روزه، هموارسازی نمایی و CGARCH از دیگر مدل‌ها بهتر است. ضمن آنکه بر مبنای نتایج این پژوهش، در کل، مدل‌های غیر شرطی عملکرد بهتری نسبت به مدل‌های شرطی داشته‌اند. ابونوری و مؤتمنی در تحقیقی بازخور نوسانات را با استفاده از اطلاعات سری زمانی روزانه شاخص بورس تهران مورد آزمون قرار دادند. آن‌ها با استفاده از مدل گارچ نمایی - میانگین^۱ به این نتیجه رسیدند بین نوسانات بازدهی پیش‌بینی نشده و بازده بازار رابطه معنا دار وجود داشته است. در رابطه با پیش‌بینی متغیرهای گوناگون با استفاده از شبکه عصبی نیز مطالعات گوناگونی در ایران صورت پذیرفته که از آن جمله به مطالعه عرب مازار و قاسمی در سال ۱۳۸۸ اشاره می‌شود. آن‌ها به این نتیجه رسیدند که ترکیب شبکه‌های عصبی با الگوریتم ژنتیک به منظور انتخاب متغیرهای بهینه، توانایی پیش‌بینی را به‌طور محسوسی افزایش می‌دهد.

1. Exponential GARCH in Mean

مدل‌های پژوهش

شبکه عصبی پیش‌خور^۱ با تابع فعال‌سازی پرسپترون^۲ (که نوعی تابع فعال‌سازی آستانه‌ای^۳ است) در سال ۱۹۶۲ توسط روزنبلات (Rosenblatt, 1962) معرفی شد و همچنان جزء کاراترین و رایج‌ترین مدل‌های شبکه عصبی به خصوص در حوزه مطالعات مالی می‌باشد. پرسترون چند لایه یا MPL از ترکیب وزنی خطی d متغیر ورودی به شکل زیر حاصل می‌شود:

$$a_j = \sum_{i=0}^d w_{ji}^{(1)} x_i \quad (1)$$

که x_i متغیر ورودی i ام و w_{ji} اوزان شبکه می‌باشند. اگر g تابع فعال‌سازی باشد و $z_j = g(a_j)$ ، شبکه با تخصیص توابع فعال‌سازی لایه‌های پنهان به لایه دوم، ایجاد می‌شود. برای هر واحد خروجی k داریم:

$$a_j = \sum_{j=0}^M w_{kj}^{(2)} z_j \quad (2)$$

با به کار بستن تابع فعال‌سازی $y_k \equiv g(a_k)$ و ترکیب عبارت‌های

(۱) و (۲) داریم:

$$MPL: y_k = \tilde{g} \left(\sum_{j=0}^M w_{kj}^{(2)} g \left(\sum_{i=0}^d w_{ji}^{(1)} x_i \right) \right)$$

چندین روش برای آموزش شبکه وجود دارد که معروف‌ترین آن الگوریتم پس انتشار^۴ می‌باشد و این الگوریتم را می‌توان تعمیمی از الگوریتم حداقل میانگین مربعات خطا^۵ دانست (Rumelhart, 1995). در این پژوهش طیف وسیعی از مدل‌های گروه ناهمسانی واریانس شرطی مورد بررسی قرار گرفته‌اند و خروجی آن‌ها توسط شبکه عصبی با ساختار مذکور بازآموزی شده است. مدل‌های ترکیبی گارچ - شبکه عصبی یا ANN-GARCH و در واقع مدل تقویت شده گارچ^۶ با یک لایه پنهان و s نرون، بشکل ذیل تعریف می‌شوند:

$$\sigma^2 = GARCH + \sum_{h=1}^s \xi_h \psi(z_t, \lambda_h) \quad , \quad \psi(z_t, \lambda_h) = \left[1 + \exp \left(\lambda_{h,d,w} + \sum_{w=1}^m \left[\sum_{l=1}^m \lambda_{h,d,w} z_{t-d}^w \right] \right) \right]^{-1}$$

1. Feed forward
2. Perceptron
3. Threshold Activation Function
4. Backpropagation
5. Least mean square error
6. Augmented GARCH(p,q) Model

$$z_{t-d} = [\varepsilon_{t-d} - E(\varepsilon)] / \sqrt{E(\varepsilon^2)}, \quad \lambda_{h,d,w} \sim \text{uniform}[-1, +1]$$

که در این عبارات GARCH معرف مجموعه مدل‌های ناهمسانی واریانس شرطی است که در ادامه به آنها اشاره خواهد شد. $\psi(z_t, \lambda_h)$ تابع فعال ساز و λ_h بردار اوزان و z_t متغیرهای ورودی می‌باشند. بسیاری از سری‌های زمانی مالی به سادگی توسط GARCH(1,1) مدل‌سازی می‌شوند. لذا در اولین قدم به استخراج متغیرهای ورودی به شبکه از مدل پایه‌ای GARCH(1,1)، که بصورت زیر تعریف شده است، خواهیم پرداخت.

$$y_t = \hat{\mu} + \varepsilon_t \quad \sigma^2_t = \hat{\alpha}_0 + \hat{\alpha}_1 \varepsilon^2_{t-1} + \hat{\beta}_1 \sigma^2_{t-1}$$

پس از تخمین ضرایب α_1 و β_1 ، متغیرهای زیر به عنوان ورودی شبکه عصبی تعریف می‌شوند (Roh, 2007):

$$\sigma'^2_{t-1} = \hat{\beta}_1 \sigma^2_{t-1} \quad \varepsilon'^2_{t-1} = \hat{\alpha}_1 \varepsilon^2_{t-1}$$

علاوه بر این برای مدل‌های خانواده گارچ، مدل میانگین نیز مورد بررسی قرار گرفته است. به پیشنهاد انگل و همکاران^۱ در سال ۱۹۸۷، و به منظور تعیین رابطه ریسک و بازده، عبارت انحراف معیار شرطی در معادله اصلی وارد گردید:

$$y_t = \hat{\mu} + \hat{\alpha}_0 \sigma_{t-1} + \varepsilon_t \quad \sigma^2_t = \hat{\alpha}_1 + \hat{\alpha}_2 \varepsilon^2_{t-1} + \hat{\beta}_1 \sigma^2_{t-1}$$

چنانچه α_0 مثبت و از لحاظ آماری معنی‌دار باشد، می‌توان نتیجه گرفت افزایش میزان ریسک با افزایش در میانگین بازدهی همراه می‌باشد و در این شرایط α_0 را می‌توان صرف ریسک تعبیر نمود (Brooks, 2008).

سایر مدل‌ها عبارتند از EGARCH، GJR-GARCH، CGARCH، JGARCH، APGARCH، NPGARCH و PGARCH که با احتساب مدل میانگین در هر مورد، در کل ۱۶ مدل مورد بررسی قرار خواهند گرفت. برای جلوگیری از طولانی شدن بحث از تشریح مدل‌ها صرف نظر می‌شود و به بیان این نکته اکتفا می‌گردد که برای استخراج داده‌های ورودی به شبکه از انواع مدل‌ها، مشابه روش ذکر شده برای GARCH(1,1) عمل خواهد شد. در واقع هریک از اجزای تشکیل دهنده مدل‌های گارچ، یک گروه از متغیرهای ورودی شبکه را فراهم می‌نمایند و انتظار می‌رود فرآیند آموزش شبکه منجر به افزایش قدرت توضیح دهنده مدل‌ها شود.

1. Engle, Lilien and Robins

نکته دیگر گزینش متغیر هدف^۱ است. برای انتخاب این متغیر ناظر جهت استفاده در آموزش شبکه، واریانس متحرک بازدهی مورد توجه قرار گرفته است. هرچند به خاطر ماهیت شرطی بودن واریانس در مدل‌های گارچ نمی‌توان بطور مستقیم (مستقل از مدل‌ها) این متغیر را محاسبه نمود اما مطابق روش استفاده شده توسط رو (Roh, 2007) و برخی دیگر از مطالعات مشابه، از واریانس متحرک بهره برده شده است. با آزمون افق‌های زمانی گوناگون، مشاهده گردید واریانس متحرک هفتگی (پنج روزه) با خروجی مدل‌های گارچ همخوانی بالایی دارد.

روش ارزیابی پیش‌بینی‌ها

ارزیابی نتایج پیش‌بینی، و در واقع گزینش معیار ارزیابی و یا تابع زیان^۲ مناسب از نکات حائز اهمیت در مسأله پیش‌بینی است. در ادبیات پژوهشی این حوزه عمدتاً از سه معیار الف - ریشه میانگین مجذور خطاها^۳ (RMSE)، ب - میانگین قدر مطلق خطاها^۴ (MAE) و ج - میانگین قدرمطلق درصد خطاها^۵ (MAPE) استفاده شده است:

$$RMSE = \sqrt{\frac{1}{N} \sum (\hat{Y} - Y)^2} \quad MAE = \frac{1}{N} \sum |\hat{Y} - Y| \quad MAPE = \frac{1}{N} \sum \left| \frac{\hat{Y} - Y}{Y} \right|$$

دو معیار نخست کاربرد بیشتری در زمینه سنجش میزان دقت پیش‌بینی دارند. معیار نخست از خانواده محاسبات میانگین خطای استاندارد و معیار دوم و سوم در مورد خطای مطلق است. معیار سوم با وجود برخی ضعف‌ها (مثلاً Y ها الزاماً باید غیر صفر باشند) در سایر پژوهش‌ها کما بیش کاربرد داشته است. آزمون‌های متعددی برای اندازه‌گیری میزان دقت روش‌های مختلف پیش‌بینی وجود دارد که از آن جمله می‌توان به آزمون مورگان-گرنجر-نیوبولد^۶ و یا آزمون میس-روگوف^۷ اشاره داشت. اما یکی از آزمون‌های مطرح در این زمینه آزمون دیبولد - ماریانو^۸ است که در این مطالعه برای تشخیص معنی داری آماری تفاوت در پیش‌بینی‌های مدل‌های گارچ و مدل‌های تلفیقی گارچ - شبکه عصبی از آن استفاده شده است. برای اجرای این آزمون، بطور خلاصه دو مقدار پیش‌بینی رقیب

1. Target Variable
2. Loss Function
3. Root Mean Square Deviation
4. Mean Absolute Error
5. Mean Absolute Percentage Error
6. Morgan - Granger - Newbold Test (1999)
7. Meese - Rogoff Test (1988)
8. Diebold - Mariano Test (1995)

یعنی Y_{T+H}^1 و Y_{T+H}^2 را در نظر می‌گیریم. سپس با استفاده خطای پیش‌بینی تابع زیان L را بشکل زیر محاسبه می‌نماییم:

$$L(\varepsilon_{T+H}^i) = (\varepsilon_{T+H}^i)^2 \quad \text{و} \quad \varepsilon_{T+H}^2 = Y_{T+H} - Y_{T+H}^2 \quad \text{و} \quad \varepsilon_{T+H}^1 = Y_{T+H} - Y_{T+H}^1$$

در ادامه، دنباله d_t که بشکل ذیل تعریف می‌شود را از لحاظ همبستگی مورد آزمون قرار می‌دهیم:

$$d_t = L(\varepsilon_{T+H}^1) - L(\varepsilon_{T+H}^2)$$

اگر \bar{d} و λ_i را به ترتیب میانگین و واریانس نمونه‌ای دنباله d_t در نظر بگیریم و H اندازه نمونه، و اگر این دنباله همبسته نباشد، آماره دیبولد - ماریانو DM_1 و اگر دنباله مذکور همبسته باشد با این فرض که q مقدار λ_i (کوواریانس) غیر صفر باشد، آماره بشکل DM_2 تعریف خواهد شد:

$$DM_1 = \frac{\bar{d}}{\sqrt{\frac{\lambda_0}{H-1}}} \quad DM_2 = \frac{\bar{d}}{\sqrt{\frac{(\lambda_0 + 2\lambda_1 + \dots + 2\lambda_q)}{H-1}}}$$

این آماره دارای توزیع t با درجه آزادی $H-1$ ، و فرض صفر برابری قدرت پیش‌بینی دو روش رقیب خواهد بود (Mariano, 2002). همچنین برای بررسی بیشتر موضوع نسبت برخورد^۱ (HR) برای پیش‌بینی مدل‌های گارچ و مدل‌های ترکیبی محاسبه شده است. این نسبت در واقع فراوانی نسبی است برای سنجش میزان صحت جهت افزایش‌ها یا کاهش‌های نوسان در مقایسه با واقعیت. نسبت برخورد را می‌توان به صورت زیر محاسبه نمود:

$$HR = \frac{1}{N} \sum_{t=1}^N \theta_t, \quad \theta_t = \begin{cases} 1 & : (\hat{\sigma}_{t+1}^2 - \sigma_t^2)(\sigma_{t+1}^2 - \sigma_t^2) \geq 0 \\ 0 & : \text{else} \end{cases}$$

نسبت برخورد عددی بین صفر و یک است به نحوی که مقدار ۰.۵ برای این نسبت نشان‌دهنده آن خواهد بود که نتیجه، چیزی بهتر از پیش‌بینی تصادفی نیست (Schittenkopf, et al., 1999). لازم به ذکر است مدل‌هایی در این پژوهش در پیش‌بینی موفق به شمار می‌روند که از نظر معیارهای مذکور، توان توضیح دهندگی نوسان بازدهی را بهبود بخشند.

1. Hit Ratio

ساختار داده‌ها و آزمون‌های اولیه آن

بازده شاخص بازار یا بازده کل، پراکسی^۱ یا نمایده‌ای برای پژوهش در خصوص ویژگی‌های بازدهی دارایی‌های مالی است که در سایر تحقیقات مشابه نیز از آن استفاده شده است. در این مطالعه نیز شاخص کل بورس اوراق بهادار تهران در بین سالهای ۱۳۸۰ تا پایان ۱۳۹۰ مورد توجه قرار گرفته که مشتمل بر ۲۵۶۷ مشاهده است. بازده شاخص در تاریخ t از طریق گرفتن لوگاریتم طبیعی از حاصل تقسیم عدد شاخص در تاریخ t بر این عدد در تاریخ $t-1$ به دست آمده است. در نمونه ذکر شده تعداد ۲۴۶۲ مشاهده (از ۱۳۸۰/۱/۲۱ تا ۱۳۹۰/۶/۳۰) برای ایجاد مدل‌ها و آموزش شبکه‌ها و تعداد ۱۰۰ مشاهده (از ۱۳۹۰/۷/۳ تا ۱۳۹۰/۱۲/۲) برای سنجش میزان دقت پیش‌بینی‌ها به عنوان پیش‌بینی برون نمونه‌ای استفاده شده است. برای تعیین مدل موفق‌تر در پیش‌بینی، افق زمانی ۱۰۰ روزه به پنج بازه مساوی تقسیم و تغییرات دقت پیش‌بینی در این بازه‌ها بررسی می‌شود. جدول (۱) آمار توصیفی داده‌ها را نمایش می‌دهد.

جدول (۱): آمار توصیفی داده‌ها

احتمال	آماره جاراک - برا	کشیدگی	چولگی	انحراف معیار	کمینه	بیشینه	میانه	میانگین
۰.۰۰۰	۱۸۸۷۲.۶	۱۶.۵۴۶۵	۰.۳۴۰۸	۰.۰۰۵۹	٪-۵.۴۵	٪۵.۲۶	٪۰.۰۶	٪۰.۰۹

در استفاده از مدل‌های ناهمسانی واریانس شرطی (گارچ) پیش از هر چیز باید از ثابت و یا متغیر بودن واریانس جمله خطا آگاهی یافت. به این منظور آزمون ضریب لاگرانژ^۲ بر روی پسماندها برای سری زمانی بازده روزانه شاخص با اعمال پنج وقفه انجام شد که نتایج آن در جدول (۲) مشاهده می‌شود.


جدول (۲): آزمون ضریب لاگرانژ آرچ

F-statistic	5/011083	Prob. F(5,2451)	0/0001
Obs*R-squared	24/86259	Prob. Chi-Square(5)	0/0001

بنابراین فرض صفر مبنی بر ثابت بودن واریانس در طول نمونه رد می‌شود و لذا بازده شاخص دارای اثرات آرچ است. در نمودار (۱)، که نمایش دهنده نوسان بازدهی شاخص در بازه زمانی مورد مطالعه است، می‌توان آثاری از آرچ، به خصوص نوسان خوشه‌ای را ملاحظه کرد. هر چند در این نمودار به نظر می‌رسد شوک‌های مثبت نوسان بیشتری را نسبت به شوک‌های منفی ایجاد می‌نمایند، اما به هر حال این ویژگی بازده شاخص را باید دقیق‌تر مورد مطالعه قرار داد.

1. Proxy
2. LM ARCH Test, Angle (1982)

نمودار (۱): نوسان بازده در شاخص کل بورس تهران



همچنین داده‌ها باید از لحاظ وجود یا نبود ریشه واحد آزمون شوند. ریشه واحد موجب نامانایی سری زمانی می‌شود و این بدان معنی خواهد بود که گشتاورهای ثابتی برای بازده‌ها وجود ندارد. در این شرایط اعتبار آزمون‌های انجام شده خدشه دار خواهد شد.

جدول (۳): آزمون ریشه واحد با ۹ وقفه

احتمال	آماره t	فرض صفر: بازده دارای ریشه واحد است	
۰.۰۰۰	-۹۸۲۱۴	آماره آزمون دیکي فولر افزوده	
-	-۳.۴۳۲۸	%۱	مقادیر بحرانی آزمون در سطح:
-	-۲.۸۶۲۵	%۵	
-	-۲.۵۶۷۳	%۱۰	

در این پژوهش دو آزمون مرسوم برای تشخیص نامایی یعنی آزمون دیکي - فولر افزوده و فیلیپس - پرون انجام شد که هر دو آزمون فرض صفر مبنی بر وجود ریشه واحد را رد نمودند. نتایج آزمون دیکي - فولر در جدول (۳) منعکس گردیده است.

یکی از نکات مهم در ساختار داده‌های این پژوهش، تغییر شاخص قیمت به شاخص قیمت و بازده نقدی در آذر ماه ۱۳۸۷ است که از این تاریخ، شاخص قیمت محاسبه و منتشر نشده است. این مسأله پیوستگی داده‌ها را تا حدودی خدشه‌دار می‌کند و آن را می‌توان از محدودیت‌های پژوهش دانست. با این وجود مانا بودن سری زمانی مورد مطالعه می‌تواند نشان‌دهنده اعتبار آزمون‌ها و نتایج به دست آمده باشد.

تخمین مدل‌ها و آموزش شبکه‌های عصبی

در جدول (۴) نتایج حاصل از تخمین مدل‌ها نمایش داده شده و پارامترهای هر یک از مدل‌ها و نیز مقدار آماره Z هر یک از پارامترها (در ذیل آن) درج شده است. مرتبه مدل‌ها یک در نظر گرفته شده است ($p=q=1$)

جدول (۴): تخمین مدل‌های گارچ

مدل‌های گارچ	پارامترها			
	Arch	Garch	c	
GARCH	0.4971	0.3824	6.72E-06	
	22.8635	32.3533	32.5693	
GARCH-M	0.4974	0.3914	6.48E-06	
	21.8851	27.4395	26.3042	
IGARCH	0.0577	0.9423		
	43.4004	708.8598		
IGARCH-M	0.0674	0.9326		
	38.7004	535.8222		
GJR-GARCH	0.5236	-0.0703	0.3873	6.66E-06
	21.3538	-1.9345	24.8283	29.0165
GJR-GARCH-M	0.6845	-0.4145	0.4435	5.64E-06
	17.4339	-10.8112	26.2094	19.4125
EGARCH	0.6926	0.0429	0.6523	-4.1632
	29.6543	3.6513	45.6358	-25.1686
EGARCH-M	0.6524	0.1708	0.7604	-3.0158
	33.9543	13.1635	53.1733	-18.8540
APGARCH	0.5822	-0.0423	0.2785	2.8983
	15.9421	-2.2069	11.1827	15.6841
APGARCH-M	0.4470	-0.2328	0.4527	1.9337
	21.2873	-12.9922	19.4047	14.9514
NPGARCH	0.5957	0.2768	2.8611	6.73E-08
	17.0269	11.1873	16.8456	1.0894
NPGARCH-M	0.5805	0.2933	2.7623	1.13E-07
	17.5236	11.5043	16.1407	1.0868

مدل‌های گارچ	پارامترها				
	Parch	Aparch-e	Pgarch	c	
PGARCH	0.3203	-0.0362	0.5238	0.0013	
	26.0767	-1.6168	33.3474	25.3680	
PGARCH-M	Parch	Aparch-e	Pgarch	c	
	0.3285	-0.3015	0.5689	0.0010	
	26.7218	-15.4405	30.4389	14.2390	
CGARCH	Carch-Q1	Carch-Q2	Carch	Cgarch	c
	0.9991	0.0270	0.5033	0.3395	2.23E-04
	3172.2490	3.7075	33.8263	40.3239	2.3081
CGARCH-M	Carch-Q1	Carch-Q2	Carch	Cgarch	c
	8.85E-01	0.4580	0.1072	-0.4522	5.38E-05
	60.1702	17.5136	11.6120	-12.30132	7.8695

توضیح: در این جدول، ضرایب تخمین زده شده مربوط به هر پارامتر، و در ذیل آن آماره Z مربوطه درج شده است. تمام ضرایب به جز ضرایبی که با رنگ کدر مشخص شده‌اند معنی دار می‌باشند.

همانطور که از آماره‌های Z پیداست، پارامترها در اغلب مدل‌ها در سطح اطمینان ۹۹ درصد و ۹۵ درصد معنی دارند، به جز پنج پارامتر که در این سطح معنی دار نیستند و با رنگ کدر متمایز شده‌اند. عمده‌ی مدل‌های گروه ناهمسانی واریانس شرطی، در راستای انعکاس بهتر اثر اهرم یا همان اثر نامتقارن شوک‌ها ارتقاء پیدا نموده‌اند. از لحاظ نظری انتظار می‌رود شوک منفی، صاحب اثر قوی‌تری بر روی نوسان بازدهی باشد. اما با نگاه به جدول، نتیجه دیگری حاصل می‌شود. پارامترهای Tarch و Aparch-e که اثر اهرم را منعکس می‌نمایند از لحاظ علامت منفی‌اند. هرچند اثر اهرم در مدل EGARCH در مرتبه اول مثبت است ولی با تخمین مرتبه دوم EGARCH(1,1)، مشاهده گردید ضریب اهرم در وقفه دوم منفی است. بنابراین به عنوان یک نتیجه کلی می‌توان گفت پس از بروز شوک منفی در شاخص کل بورس تهران، نوسان کمتری در روزهای آتی بر بازده این شاخص تحمیل می‌شود و بالعکس.

جدول (۵): ضریب انحراف معیار شرطی در معادله اصلی

معادلات گارچ - میانگین	σ		
	ضریب	آماره Z	احتمال
GARCH-M	۰.۳۱۶	۵.۴۷۴	۰.۰۰۰
IGARCH-M	-۰.۲۱۹	-۶.۶۸۴	۰.۰۰۰
CGARCH-M	۰.۲۷۲	۵.۰۲۶	۰.۰۰۰
GJR-GARCH-M	۰.۶۷۹	۱۰.۶۲۸	۰.۰۰۰
EGARCH-M	۰.۷۷۶	۱۴.۴۴۶	۰.۰۰۰
APGARCH-M	۰.۶۹۲	۱۰.۶۳۰	۰.۰۰۰
NPGARCH-M	۰.۲۴۱	۳.۶۵۱	۰.۰۰۰
PGARCH-M	۰.۹۱۳	۱۵.۹۳۹	۰.۰۰۰

از نکات قابل توجه در نتایج به دست آمده، مدل‌های گارچ - میانگین می‌باشند. جدول (۵) ضریب انحراف معیار بازدهی در معادله اصلی (میانگین) این مدل‌ها را نمایش می‌دهد. ضرایب در بیشتر موارد مثبت و معنی دارند و لذا رابطه مستقیم ریسک و بازده قابل مشاهده است.

در مرحله بعد با استفاده از پارامترهای تخمین زده شده، داده‌های ورودی یک به یک و برای هر مدل محاسبه و سپس شبکه‌ها آموزش داده شده‌اند. برای آموزش شبکه‌ها از تابع یادگیری TRAINLM^۱ و دو لایه پنهان با تابع انتقال سیگموئید تانژانت هایپربولیک^۲ استفاده شده است. برای تعیین تعداد نرون‌ها بسته به هر مدل، ۵ تا ۲۵ نرون در نظر گرفته شده و مطابق روش به کار گرفته شده توسط بیلدیریکی و همکاران (Bildirici, et al., 2009)، شبکه عصبی دارای کمترین خطا در نتیجه ده اجرای شبکه، انتخاب گردیده است.

جدول (۶): عملکرد آموزش و آزمون شبکه عصبی مصنوعی

مدل‌های ترکیبی	عملکرد آموزش شبکه			عملکرد آزمون شبکه		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
APGARCH	1.3E-04	5.1E-05	0.795	3.7E-05	2.7E-05	0.719
APGARCH-M	7.9E-05	4.3E-05	1.098	4.2E-05	3.0E-05	0.544
CGARCH	2.7E-05	2.9E-05	1.423	1.6E-07	2.7E-05	0.675
CGARCH-M	8.6E-05	6.0E-05	0.997	1.2E-05	3.1E-05	0.763
EGARCH	5.1E-05	3.9E-05	0.951	3.8E-05	2.8E-05	0.637
EGARCH-M	6.3E-05	4.5E-05	0.755	3.5E-05	2.5E-05	0.466
GARCH	1.3E-04	4.8E-05	0.639	3.7E-05	2.6E-05	0.611
GARCH-M	1.4E-04	4.7E-05	0.633	3.7E-05	2.7E-05	0.541
GJR-GARCH	7.6E-05	6.7E-05	0.897	3.6E-05	2.6E-05	0.586
GJR-GARCH-M	9.6E-05	9.8E-05	1.598	6.6E-05	3.8E-05	0.924

1. Levenberg-Marquardt Backpropagation
2. Hyperbolic Tangent Sigmoid Transfer Function

مدل‌های ترکیبی	عملکرد آموزش شبکه			عملکرد آزمون شبکه		
	RMSE	MAE	MAPE	RMSE	MAE	MAPE
IGARCH	3.4E-05	4.2E-05	0.942	4.7E-05	3.4E-05	0.888
IGARCH-M	5.9E-05	5.9E-05	1.618	3.8E-05	2.9E-05	0.906
NPGARCH	1.5E-05	3.3E-05	1.236	3.8E-05	2.7E-05	0.653
NPGARCH-M	2.3E-05	3.5E-05	2.646	4.2E-05	3.0E-05	0.647
PGARCH	9.5E-05	4.3E-05	0.986	4.1E-05	2.7E-05	0.735
PGARCH-M	1.9E-04	7.8E-05	0.63	3.0E-05	2.2E-05	0.634

از سوی دیگر عموماً در ورود داده‌ها به شبکه عصبی، برای کاهش نوسان نتایج، داده‌ها نرمال‌سازی می‌شوند. نرمال‌سازی مذکور در افق زمانی بلند مدت معمولاً موجب پیش‌بینی بهتر می‌شود ولی در کوتاه مدت خطا را بالا می‌برد و در برخی موارد به پیش‌بینی‌های ضعیف‌تر منجر می‌گردد. لذا در این پژوهش، فرآیند آموزش شبکه هم با داده‌های نرمال و هم با داده‌های غیر نرمال طی شد. در جدول (۶) نتایج حاصل از آموزش و آزمون شبکه درج شده است (برای رعایت اختصار تنها به ذکر نتایج آموزش و آزمون شبکه با داده‌های غیر نرمال بسنده شده است).

هرچند هدف اصلی از اجرای این پژوهش بررسی دقت پیش‌بینی مدل‌های ترکیبی در مقایسه مدل‌های خانواده گارچ است اما می‌توان مدل‌های دقیق‌تر را به طور مطلق نیز تعیین کرد. طبیعی است که سه معیار مختلف ارزیابی، به نتیجه‌گیری‌های گوناگونی منتهی شود و از طرفی دو گروه نتیجه نرمال شده و غیر نرمال نیز به پیچیدگی کار بیافزاید. ولی با توجه به جدول (۶) و نیز بررسی نتایج کلی پژوهش می‌توان نزدیکی تقریبی نتایج از لحاظ معیارهای سه‌گانه را مشاهده کرد. جدول (۷) بهترین مدل‌های ترکیبی از نظر هر یک از معیارها و به ترتیب کمترین خطا را منعکس کرده است که مدل‌های مشترک زیادی در صدر این جدول مشاهده می‌شود.

جدول (۷): بهترین مدل‌های ترکیبی در پیش‌بینی از نظر معیارهای سه‌گانه

	RMSE	MAE	MAPE
1	CGARCH	PGARCH-M	EGARCH-M
2	CGARCH-M	EGARCH-M	GARCH-M
3	PGARCH-M	GJR-GARCH	APGARCH-M
4	EGARCH-M	GARCH	GJR-GARCH
5	GJR-GARCH	APGARCH	GARCH
6	APGARCH	GARCH-M	PGARCH-M
7	GARCH-M	PGARCH	EGARCH
8	GARCH	NPGARCH	NPGARCH-M

همچنین افزایش ناگهانی در سطح بازدهی شاخص در ۲۰ روزه سوم موجب افزایش شدید خطای پیش‌بینی شده است (به جز مدل گارچ مولفه‌ای). این امر را می‌توان در جدول ۸ مشاهده نمود. پس از

این دوره زمانی، سطح خطا دوباره رو به کاهش گذارده است. بنابراین یکی دیگر از محدودیت‌های این مطالعه که موجب انحراف نسبی نتایج شده است را می‌توان همین تغییر غیر منتظره در سطح بازده دانست.

جدول (۸): درصد افزایش و کاهش خطای پیش‌بینی (RMSE) در افق‌های زمانی

مدل‌های ترکیبی	$\% \Delta(T+40)$	$\% \Delta(T+60)$	$\% \Delta(T+80)$	$\% \Delta(T+100)$
APGARCH	-16.6%	30.4%	-1.3%	-3.2%
APGARCH-M	-9.7%	13.8%	-0.6%	-2.7%
CGARCH	-41.5%	-63.9%	-74.2%	-68.9%
CGARCH-M	-45.4%	14.6%	44.7%	-8.4%
EGARCH	-16.2%	27.9%	0.1%	0.0%
EGARCH-M	-9.4%	18.3%	-0.2%	-1.9%
GARCH	-17.0%	37.5%	-3.6%	-2.9%
GARCH-M	-16.4%	35.4%	-2.4%	-3.5%
GJR-GARCH	-17.1%	34.1%	-3.2%	-2.9%
GJR-GARCH-M	-7.8%	68.8%	-11.5%	-5.1%
IGARCH	-14.0%	31.0%	0.7%	-2.4%
IGARCH-M	-7.2%	26.0%	5.1%	-4.9%
NPGARCH	-15.7%	30.2%	-0.5%	-2.8%
NPGARCH-M	-13.0%	25.3%	2.6%	-3.4%
PGARCH	-14.3%	46.2%	0.0%	-5.9%
PGARCH-M	-8.8%	11.6%	2.8%	-3.4%

به منظور بررسی معنی‌داری تفاوت‌ها، آماره دیبولد - ماریانو برای دو پیش‌بینی رقیب گارچ و گارچ - شبکه عصبی، برای هر کدام از مدل‌ها محاسبه و در جدول (۱۰) درج شده است. در جدول (۹) نسبت برخورد مدل‌های ترکیبی با مدل‌های پایه‌ای گارچ مورد مقایسه قرار گرفته و اولین نتیجه این مقایسه این است که نرمال کردن داده‌ها قبل از ورود به شبکه موجب کاهش میزان همسویی نتایج پیش‌بینی می‌شود و این موضوع را می‌توان در کاهش نسبت در ستون آخر این جدول مشاهده نمود. لذا نرمال سازی از این نظر، نتیجه پیش‌بینی را مخدوش می‌کند.

جدول (۹): مقایسه نسبت‌های برخورد (Hit Ratio)

مدل‌ها	مدل‌های گارچ	مدل‌های ترکیبی (غیر نرمال)	مدل‌های ترکیبی (نرمال شده)
APGARCH	0.72	0.62 ↓	0.56 ↓
APGARCH-M	0.66	0.63 ↓	0.60 ↓
CGARCH	0.65	0.65 -	0.63 ↓
CGARCH-M	0.63	0.67 ↑	0.62 ↓
EGARCH	0.62	0.67 ↑	0.60 ↓
EGARCH-M	0.68	0.71 ↑	0.62 ↓
GARCH	0.70	0.69 ↓	0.59 ↓
GARCH-M	0.69	0.59 ↓	0.61 ↓
GJR-GARCH	0.68	0.68 -	0.63 ↓
GJR-GARCH-M	0.70	0.71 ↑	0.48 ↓
IGARCH	0.55	0.62 ↑	0.59 ↑
IGARCH-M	0.55	0.60 ↑	0.63 ↑
NPGARCH	0.71	0.62 ↓	0.63 ↓
NPGARCH-M	0.70	0.60 ↓	0.57 ↓
PGARCH	0.59	0.62 ↑	0.63 ↑
PGARCH-M	0.65	0.66 ↑	0.62 ↓

اما در صورتی که داده‌های ورودی خام یا غیر نرمال مورد استفاده قرار گیرند، همسویی تغییرات نوسانات برآورد شده توسط مدل‌های ترکیبی در مقایسه با نوسانات واقعی، در مجموع بیشتر می‌شود و این نتیجه‌گیری با یافته‌های رو (Roh, 2007) مطابقت دارد.

جدول (۱۰) مقایسه‌ای از نتایج نهایی مدل‌های ترکیبی و مدل‌های پایه‌ای گارچ را ارائه می‌نماید. در این جدول، درصد کاهش یا افزایش در خطای پیش‌بینی به همراه مقدار آماره آزمون دیبولد - ماریانو متناظر با هر مدل ذکر شده است.

همان‌گونه که نتایج نشان می‌دهد، در نتیجه ترکیب سه مدل گارچ توانی نامتقارن (APGARCH)، گارچ نمایی - میانگین (EGARCH-M) و گارچ توانی - میانگین (PGARCH-M) با شبکه عصبی مصنوعی، خطای پیش‌بینی به شکل موفقیت‌آمیزی کاهش یافته است. اما در برخی از مدل‌ها نرمال‌سازی و یا عدم نرمال‌سازی داده‌های ورودی به شبکه، در نتیجه نهایی تأثیراتی داشته است. مدل GARCH-M و به خصوص مدل IGARCH-M با داده‌های غیر نرمال کار می‌کنند. از طرف دیگر مدل EGARCH با وجود نتیجه ضعیف با به کارگیری داده‌های غیر نرمال، با استفاده از داده‌های نرمال کارآمدی نشان می‌دهد. همچنین مدل PGARCH با داده‌های نرمال شده از لحاظ معیارهای خطای مطلق پیش‌بینی، موفق عمل کرده است. جدول ۹ نشان می‌دهد این مدل‌ها عمدتاً در اصلاح جهت تغییرات نوسان نیز موفق عمل کرده‌اند.



جدول (۱۰): تغییرات در خطای پیش‌بینی و آماره آزمون دیبولد - ماریانو

مدل‌های ترکیبی	تغییرات (داده‌های غیر نرمال)			آماره دیبولد - ماریانو	تغییرات (داده‌های نرمال شده)			آماره دیبولد - ماریانو
	RMSE	MAE	MAPE		RMSE	MAE	MAPE	
APGARCH *	-14.5%	-42.3%	-8.9%	2.8030***	-17.9%	-42.8%	-32.7%	2.2264**
APGARCH-M	2.8%	-31.2%	-26.5%	-0.8605	-7.8%	-40.0%	-32.1%	1.5853
CGARCH	-98.8%	-6.2%	-9.0%	0.3217	75.7%	-4.5%	-32.0%	0.3159
CGARCH-M	61.8%	-6.4%	-11.6%	1.4463	343.1%	5.6%	-29.4%	0.0846
EGARCH *	-7.3%	-3.7%	2.1%	1.2488	-9.7%	-3.9%	-7.3%	-4.4013***
EGARCH-M *	-13.6%	-11.8%	-14.1%	2.3395**	-11.8%	-6.1%	-8.4%	2.2145**
GARCH	-9.0%	-11.6%	-0.6%	-0.9506	5.4%	7.3%	-5.4%	1.5114
GARCH-M *	-10.5%	-8.1%	-10.3%	-2.1847**	-1.8%	3.0%	-11.8%	-0.2687
GJRGARCH	-12.2%	-11.4%	-3.4%	1.7576*	-5.7%	-5.7%	-12.0%	-1.0978
GJRGARCH-M	-4.2%	3.4%	9.5%	0.2817	447.7%	534.4%	672.1%	0.2897
IGARCH	12.4%	4.3%	-9.5%	-1.2251	10.7%	6.5%	-33.3%	2.5546
IGARCH-M *	-10.0%	-10.1%	-2.2%	2.6919***	19.2%	15.6%	-28.0%	-3.9009***
NPGARCH	-13.8%	-41.2%	-17.3%	2.3597	-2.0%	-32.3%	-29.6%	0.4175
NPGARCH-M	-5.8%	-33.3%	-16.0%	0.6916	-4.9%	-31.4%	-26.8%	0.6164
PGARCH *	6.3%	-41.6%	-8.2%	-0.4556	15.7%	-29.3%	-26.6%	-3.1736***
PGARCH-M *	-26.1%	-49.8%	-13.1%	2.9822***	-14.7%	-41.1%	-31.3%	2.0053**

توضیح: در این جدول درصد تغییرات خطای پیش‌بینی در نتیجه ترکیب مدل‌های گارچ با شبکه عصبی و نیز آماره دیبولد - ماریانو برای دو روش رقیب درج شده است. سه، دو و یک ستاره معرف معنی‌داری آماره مذکور با درجه اطمینان ۹۹، ۹۵ و ۹۰ درصد است.

به این ترتیب هفت مدل ترکیبی، که در جدول ۱۰ با ستاره مشخص شده‌اند را می‌توان چارچوب-هایی مناسب برای پیش‌بینی نوسان بازده دانست که می‌توان در تحقیقات آتی توانایی این مدل‌ها در پیش‌بینی نوسان بازده سهام را نیز مورد بررسی قرار داد. در نمودار ۲، پیش‌بینی نوسان بازدهی شاخص توسط مدل EGARCH-M و نیز مدل ANN-EGARCH-M در مقایسه با نوسان بازدهی واقعی ترسیم شده است. مقایسه این دو نمودار، که به عنوان نمونه ارائه شده است، می‌تواند نزدیک‌تر شدن پیش‌بینی به واقع را به صورت شهودی‌تر، به نمایش بگذارد.

نمودار (۲): مقایسه پیش‌بینی مدل گارچ نمای- میانگین و مدل ترکیبی آن با نوسان واقعی



بحث و نتیجه‌گیری

با توجه به اهمیت موضوع نوسان بازدهی که به گوشه‌ای از آن در قسمت‌های قبل اشاره شد، در این مطالعه سعی گردید با پی‌گیری ایده ترکیب روش‌های پیش‌بینی و با به‌کارگیری انعطاف و قدرت شبکه‌های عصبی در این مورد، بر دقت پیش‌بینی مدل‌های گروه ناهمسانی واریانس شرطی خودرگرسیون (گارچ) افزوده شود. نتایج به‌دست آمده نشان می‌دهد ترکیب مزبور موجب کاهش خطای پیش‌بینی و افزایش همسویی آن با نتایج واقعی می‌شود. از میان طیف وسیعی از مدل‌های گارچ که مورد مطالعه قرار گرفته است، مدل‌های ترکیبی ANN-APGARCH، ANN-EGARCH-M، ANN-PGARCH-M و ANN- PGARCH-M بهترین پیش‌بینی را انجام می‌دهند. علاوه بر این مدل‌ها، ANN- GARCH-M، ANN-IGARCH-M، ANN-EGARCH و ANN-PGARCH نیز مدل‌های مناسبی تشخیص داده شده‌اند. بنابراین بر اساس نتایج کلی حاصل از این پژوهش، نوسان پیش‌بینی شده توسط مدل‌های ترکیبی نسبت به خروجی خام مدل‌های پایه‌ای گارچ، از دقت بالاتری برخوردار است و می‌توان از این ترکیب برای تخمین نوسان یا تغییرپذیری، در قیمت‌گذاری مشتقات، محاسبه ارزش در معرض ریسک و ... استفاده نمود.

منابع و مأخذ:

۱. ابونوری اسماعیل، مومنی مانی (۱۳۸۵)، بررسی هم‌زمان اثر اهرمی و بازخورد نوسانات در بازار سهام تهران، تحقیقات اقتصادی، شماره ۷۶، صص ۱۰۱ تا ۱۱۷.
۲. تهرانی رضا، محمدی شاپور، پورابراهیمی محمد رضا (۱۳۸۹)، مدل سازی و پیش‌بینی نوسانات بازده در بورس اوراق بهادار تهران، تحقیقات مالی دوره ۱۲ شماره ۳۰ صص ۲۳ تا ۳۴.
۳. عرب مازار یزدی محمد، قاسمی مهسا (۱۳۸۸)، قیمت‌گذاری عرضه‌های عمومی اولیه: ترکیب شبکه‌های عصبی مصنوعی و الگوریتم ژنتیک، بررسی‌های حسابداری و حسابرسی، دوره ۱۶، شماره ۵۸، صص ۸۷ تا ۱۰۲.
4. Bildirici, M., Ersin, O. O. (2009). "Improving forecasts of GARCH family models with the artificial neural networks: An application to the daily returns in Istanbul stock exchange" *Expert Systems with Applications*, 36: 7355–7362.
5. Brooks, C. (2008). "Introductory Econometrics for Finance" second edition, Cambridge University Press, 410
6. Guresen, E., Kayakutlu, G., Daim, U. D. (2011). "Using artificial neural network models in stock market index prediction", *Expert Systems with Applications*, 38: 10389–10397
7. Hamzacebi, C., Akay, D., Kutay, F. (2009). "Comparison of direct and iterative artificial neural network forecast approaches in multi-periodic time series forecasting", *Expert Systems with Applications*, 36: 3839–3844. Springer.
8. Hassan, M. R., Nath, B., Kirley, M. (2007). "A fusion model of HMM, ANN and GA for stock market forecasting", *Expert Systems with Applications*, 33: 171–180.
9. Kimoto, T., Asakawa, K., Yoda, M., Takeoka, M. (1990). "Stock market prediction system with modular neural network", In *Proceedings of the international joint conference on neural networks*, San Diego, California: 1–6.
10. Mariano, R. S. (2002). "Econometrics Forecasting", Chapter 13: Testing Forecast Accuracy, Blackwell Publishing Ltd
11. Nikolopoulos, C., Fellrath, P. (1994). "A hybrid expert system for investment advising", *Expert Systems*, 11(4): 245–250.
12. Preminger, A., Franck, R. (2007). "Forecasting exchange rates: A robust regression approach", *International Journal of Forecasting*, 23: 71–84.
13. Roh, T. H. (2007). "Forecasting the volatility of stock price index", *Expert Systems with Applications*, 33: 916–922.
14. Rosenblatt, F. (1962). *Principles of neuro-dynamics: Perceptrons and the theory of brain mechanisms* (1st ed.). Washington, DC: Spartan.
15. Rumelhart, D. E., Rubin, R., Golden, R., Chauvin, Y. (1995). "Back propagation: The basic theory", In Chauvin Y. Rumelhart D. E. (Eds.), "Back propagation: Theory, architectures, and applications": 1–34. Hillsdale NJ: Lawrence Erlbaum.

16. Schittenkopf, C., Dorffner, G., Dockner, E. J. (1999). "Forecasting Time-dependent Conditional Densities: A Semi nonparametric Neural Network Approach", *Adaptive Information Systems and Modeling in Economics and Management Science*.
17. Trippi, R. R., DeSieno, D. (1992). "Trading equity index futures with a neural network", *The Journal of Portfolio Management*, 19: 27–33.
18. Yu, T. H., Huarng, K. (2008). "A bivariate fuzzy time series model to forecast the TAIEX", *Expert Systems with Applications*, 34: 2945–2952.
19. Zhang, Y., Wan, X. (2007). "Statistical fuzzy interval neural networks for currency exchange rate time series prediction", *Applied Soft Computing*, 7:1149–1156.

Archive of SID