



فصلنامه علمی پژوهشی دانش سرمایه‌گذاری
سال دهم / شماره سی‌ونهم / پاییز ۱۴۰۰

محاسبه ارزش در معرض ریسک دنباله با استفاده از مدل EGARCH-Extreme Learning Machine و رویکرد پیش بینی بلندمدت در صنعت بیمه

رضا راعی

استاد گروه مدیریت مالی، دانشگاه تهران، تهران، ایران

اعظم هنردوست

دانشجوی دکتری مالی گرایش بیمه، دانشگاه تهران، تهران، ایران (نویسنده مسئول)
honardoust5594@yahoo.com

عزت‌اله عباسیان

دانشیار گروه مدیریت دولتی، دانشگاه تهران، تهران، ایران

تاریخ دریافت: ۹۸/۰۵/۰۹ تاریخ پذیرش: ۹۸/۰۵/۱۴

چکیده

یکی از مهم‌ترین روش‌های سنجش ریسک بازار استفاده از روش ارزش در معرض ریسک می‌باشد که نهادهای مالی نظیر بانک‌ها، بیمه‌ها و صندوق‌های سرمایه‌گذاری به طور گسترده‌ای از آن‌ها استفاده می‌نمایند. با مطرح شدن انتقادات معیار ارزش در معرض ریسک که در راس آن‌ها عدم تامین ویژگی زیر جمع‌پذیری است؛ تحقیقات به بررسی سنجه ارزش در معرض ریسک دنباله معطوف گردید و این سنجه در کمیته بازل در بانکداری و سیستم‌های توانگری مالی II اروپا و توانگری مالی سوئیس در صنعت بیمه مورد استفاده قرار گرفت؛ لذا در این پژوهش از این معیار جهت سنجش ریسک بازار سهام استفاده خواهد شد. با توجه به اینکه افق زمانی ریسک‌های یک بیمه‌گر بر خلاف بانک‌ها سالانه می‌باشد؛ لذا برای محاسبه ارزش در معرض ریسک دنباله از دو متد رویکرد واریانس-کوواریانس با بکارگیری مدل گارچ نمایی-ماشین فوق یادگیری برای پیش‌بینی نوسانات و استفاده از قاعده جذر زمان؛ و مدل شبیه‌سازی تاریخی با داده‌های فیلتر شده استفاده شده است. نتایج با استفاده از بازده‌های روزانه شاخص کل بورس اوراق بهادار تهران برای سال‌های ۱۳۸۸ تا ۱۳۹۶ حاکی از دقت بیشتر مدل گارچ نمایی-ماشین فوق یادگیری و بکارگیری قاعده جذر زمان می‌باشد.

واژه‌های کلیدی: ارزش در معرض ریسک دنباله، ریسک بازار سهام، سنجش ریسک سالانه، شبیه‌سازی تاریخی با داده‌های فیلتر شده، مدل گارچ نمایی-ماشین فوق یادگیری.

۱- مقدمه

ارزش در معرض ریسک به عنوان یک معیار ریسک مورد انتقادات بسیاری قرار گرفته است که از جمله مهم‌ترین این انتقادات، عدم تامین ویژگی زیر جمع پذیری است؛ بدین معنا که ریسک یک پرتفوی می‌تواند بیش از مجموع ریسک دارایی‌های آن زمانی که با معیار ارزش در معرض ریسک اندازه‌گیری شده‌اند؛ باشد. همچنین انتقاد دیگر وارد بر آن به عدم محاسبه شدت زیان‌های رخ داده اشاره دارد (آچربی و تاش، ۲۰۰۲). از همین رو آرتزرنر و همکاران (۱۹۹۹) ارزش در معرض ریسک دنباله^۱ را برای مدیریت ریسک کمی، به عنوان یک معیار ریسک منسجم به جای معیار ریسک نامنسجم ارزش در معرض ریسک معرفی نمودند (کاست، میلهات و مارسو، ۲۰۱۲).

در ماه می ۲۰۱۲، کمیته بازل در نظارت بانکی اعلام کرد که قصد جایگزینی ارزش در معرض ریسک دنباله با ارزش در معرض ریسک را در مدل‌های داخلی بانک‌ها برای تعیین الزامات قانونی سرمایه دارد (کراس و پائولا، ۲۰۱۴). پس از آن، در صنعت بیمه نیز توانگری مالی II اروپا و سیستم توانگری مالی سوئیس نیز از سنجه ارزش در معرض ریسک دنباله در اندازه‌گیری ریسک‌های خود استفاده نمودند. یکی از متغیرهای لازم جهت محاسبه ارزش در معرض ریسک دنباله، پیش‌بینی نوسانات بازدهی می‌باشد که بسیاری از تحقیقات ملی و بین‌المللی به یافتن مدلی مناسب جهت پیش‌بینی هر چه دقیق‌تر آن‌ها اختصاص یافته است. لذا در این پژوهش با استفاده از مدل گارچ نمای-ماشین فوق یادگیری^۲ که ترکیبی از مدل‌های واریانس شرطی و شبکه عصبی است به پیش‌بینی نوسانات بازدهی بازار بورس و اوراق بهادار تهران می‌پردازیم. استفاده از شبکه عصبی به افزایش قدرت پیش‌بینی مدل خواهد افزود.

از سوی دیگر بررسی تحقیقات انجام شده در حوزه مدیریت ریسک بازار نشان می‌دهد که در این پژوهش‌ها، عمدتاً بر ریسک کوتاه‌مدت (روزانه و هفتگی) تمرکز می‌شود. پر واضح است که در بعضی از موارد، تحلیل بلندمدت (مثلاً فصلی و سالانه) با اهمیت‌تر و مربوط‌تر می‌باشد. در حقیقت، سنجه‌های ریسک موسسات مالی نظیر بانک‌ها، عمدتاً برای افق‌های یک روزه تا دو هفته‌ای محاسبه می‌شوند. اما به عنوان مثال؛ در صنعت بیمه، ریسک‌های پیش رو می‌بایست در افق‌های زمانی طولانی‌تر (یعنی سالانه) محاسبه و مدیریت شوند. این در حالیست که مدل‌سازی با استفاده از داده‌های یک ساله شامل مشکلاتی از جمله؛ نامانایی مجموعه داده‌ها، فقدان بازده‌های یک ساله و تفاوت ویژگی‌های داده‌های سالانه از داده‌های روزانه است که قابلیت اتکای مدل را زیر سوال می‌برد (امبرشت، کافمن و پتی، ۲۰۰۵). لذا به منظور توجه به افق زمانی سالانه مورد بررسی در شرکت‌های بیمه، از روش شبیه‌سازی تاریخی با داده‌های فیلتر شده^۳ نیز برای محاسبه ارزش در معرض ریسک دنباله استفاده خواهد شد.

این پژوهش از جمله معدود مطالعاتی است که در خصوص اندازه‌گیری ریسک در افق‌های زمانی بلندمدت انجام شده است. اکثر تحقیقات صورت گرفته در زمینه اندازه‌گیری ریسک و به ویژه محاسبه ریسک بازار صرفاً به دنبال یافتن مدلی هستند که دقت این محاسبات را افزایش دهد؛ حال آن که مساله اندازه‌گیری ریسک در افق‌های زمانی بلندمدت که بالاخص در شرکت‌های بیمه مرسوم است؛ مغفول مانده است. لذا هدف پژوهش

حاضر، در کنار بهبود پیش‌بینی نوسانات، بررسی روش‌های سالانه نمودن ریسک بازار سهام با بکارگیری متد شبیه‌سازی نیز هست.

ارزش در معرض ریسک، حداکثر زیانی است که کاهش ارزش سبد دارایی برای دوره معینی در آینده، با ضریب اطمینان مشخصی، از آن بیشتر نمی‌شود. به عبارتی دیگر ارزش در معرض ریسک بدترین زیان مورد انتظار را تحت شرایط عادی بازار و طی یک دوره زمانی مشخص و در سطح اطمینان معین اندازه می‌گیرد (رادپور و عبده تبریزی، ۱۳۸۸؛ ۴۶).

پس از معرفی ارزش در معرض ریسک، نظریه سنج‌های منسجم ریسک توسط آرتزرنر و همکارانش (۱۹۹۹) پیشنهاد شد که اولین نظریه رسمی در زمینه ریسک مالی است. آن‌ها ویژگی‌های مطلوب سنج‌های ریسک را در قالب قواعد انسجام که شامل ویژگی‌های یکنوایی، زیرجمع‌پذیری، همگنی مثبت و عدم تغییر انتقالی است؛ ارائه نمودند (آرتزرنر، دلپاین، ابر و هس، ۱۹۹۹؛ آچربی و تاش، ۲۰۰۲). آرتزرنر و همکاران در نهایت روشی را برای تأمین عدم زیر جمع‌پذیری متدهای چارک محور پیشنهاد می‌دهند. نتایج مطالعه آن‌ها منجر به معرفی ریزش مورد انتظار تحت عناوین ES ، $TVaR$ و TCE شد؛ معیار ریسکی که ویژگی‌های انسجام و از جمله زیر جمع‌پذیری را دارا می‌باشد (کاست، میلیهات و مارسو، ۲۰۱۲):

$$TCE_{\alpha}(X) = -E_P \left[\frac{X}{r} \leq -VaR_{\alpha}(X) \right] \quad \text{رابطه ۱}$$

چنانچه توزیع بازدهی سبد دارایی، ملاک برآورد سنج‌های ریسک قرار گیرد. ابتدا ارزش در معرض ریسک آن را برآورد نموده سپس با استفاده از معادله زیر مقدار $TVaR$ محاسبه می‌گردد.

$$TVaR_{\alpha}(X) = \frac{1}{\alpha} \int_0^{\alpha} F^{-1}(p) dp \quad \text{رابطه ۲}$$

ارزش در معرض ریسک دنباله متوسط زیان‌های فراتر از ارزش در معرض ریسک می‌باشد. از آنجا که ارزش در معرض ریسک توسط کمیته بازل تایید شده بود لذا به عنوان یک معیار استاندارد برای ریسک بازار مالی مطرح گردید. ارزش در معرض ریسک دنباله بزرگی زیان‌های وارده را نیز بررسی می‌نماید در حالی که ارزش در معرض ریسک تنها چندک مورد نظر را بدست می‌آورد (ریگی و سرتا، ۲۰۱۵).

الینگ و پانکوک (۲۰۱۴) در مقاله‌ای به بررسی نقادانه طرح توانگری مالی II اتحادیه اروپا در محاسبه ریسک نوسانات قیمت سهام پرداختند. آن‌ها برای بدست آوردن ریسک نوسانات قیمت سهام، به تبعیت از آزمون مورد استفاده توانگری مالی سوییس، از ارزش در معرض ریسک دنباله در سطح اطمینان ۹۹٫۵ درصد استفاده نمودند و دریافته بکارگیری آن به جای ارزش در معرض ریسک منجر به نتایج قابل مقایسه‌تری با داده‌های واقعی می‌شود و ضریب ریسک نوسانات قیمت سهام در توانگری مالی II را در حدود ۶٫۵ درصد افزایش می‌دهد.

ریگی و سرتا (۲۰۱۵) در پژوهشی به مقایسه مدل‌های مختلف تخمین ارزش در معرض ریسک دنباله پرداختند. هدف پژوهش آن‌ها، یافتن بهترین مدل جهت تخمین ارزش در معرض ریسک دنباله در هر شرایطی

است. به این ترتیب دریافتند که مدل‌های شرطی، به استثنای بازار ارز، به ویژه روش‌های گارچ و FHS بر سایر مدل‌ها ارجح هستند. همچنین توزیع تی استیودنت چوله نقش مهمی را ایفا می‌نماید. در نتیجه آن‌ها دریافتند که توجه به حقایق بازارهای مالی از جمله خوشه‌بندی نوسانات، دنباله‌های پهن، عدم تقارن و مفروضات غیر واقعی پیشین نظیر نرمال بودن منجر به نتایج ضعیفی می‌شود.

کلنر و روش (۲۰۱۶) به مقایسه تجربی ارزش در معرض ریسک در سطح اطمینان ۹۹ درصد و ارزش در معرض ریسک دنباله در سطح اطمینان ۹۷٫۵ درصد با توجه به پیشنهاد کمیته بازل پرداختند. نتایج آن‌ها نشان می‌دهد که اثر بالقوه تغییر از ریزش مورد انتظار در سطح اطمینان ۹۷٫۵ درصد به ارزش در معرض ریسک در سطح اطمینان ۹۹ درصد در برآورد هم‌سنجی‌های ریسک و هم‌ریسک مدل قابل مشاهده است. ریسک‌های مالی معمولاً به خوبی توسط توزیع‌های دارای چولگی و کشیدگی درگیر می‌شوند. در نتیجه تخمین‌های ریزش مورد انتظار در سطح اطمینان ۹۷٫۵ درصد بیش از ارزش در معرض ریسک در سطح اطمینان ۹۹ درصد است که منجر به الزامات سرمایه‌ای بیشتری خواهد شد.

از آنجا که لازمه محاسبه ارزش در معرض ریسک دنباله محاسبه ارزش در معرض ریسک، و لازمه محاسبه ارزش در معرض ریسک، برآورد میانگین و واریانس است؛ در نتیجه یکی از مهمترین چالش‌هایی که مدل‌های پیش‌بینی ارزش در معرض ریسک با آن مواجه هستند، وجود پدیده واریانس شرطی در توزیع بازده داده‌های مالی است. طراحی مدل خود رگرسیونی مشروط بر ناهمسانی واریانس ابتدا توسط انگل در سال ۱۹۸۳ مطرح شد (فلاح شمس، ۱۳۸۹).

پینجامان و آرالاس (۲۰۱۵) در مطالعه‌ای به بررسی پویای بی‌ثباتی بازده سهام و عوامل کلان اقتصادی در مالزی با استفاده از مدل‌های گارچ نمایی پرداختند. برآورد بازده بی‌ثباتی پویا توسط ایشان نشان می‌دهد بازده سهام به طور مداوم متأثر از شوک‌های دوره‌های قبلی بازار است. همچنین نتایج مطالعه او نشان می‌دهد ارتباط معناداری بین متغیرهای کلان اقتصاد و بی‌ثباتی بازده سهام وجود دارد و علاوه بر این اثرات اهرمی در بازار سهام وجود دارد، بدین ترتیب که اخبار منفی تأثیر بیشتری نسبت به اخبار مثبت بر بی‌ثباتی بازده سهام دارند.

با توجه به اهمیت ویژه پیش‌بینی نوسانات، در سال‌های اخیر از شبکه عصبی برای تقویت قدرت پیش‌بینی این مدل‌ها استفاده می‌شود. شبکه عصبی مصنوعی تکنولوژی داده کاوی است که از پژوهش‌ها بر روی سیستم مغز و اعصاب الهام گرفته شده است. شبکه‌های عصبی پس انتشار از یک سری ورودی‌ها و واحدهای پردازش که به عنوان نورون شناخته می‌شوند، تشکیل شده‌اند. نورون‌ها در یک لایه به وسیله ارتباطاتی که وزن نامیده می‌شوند، به طور کامل با هم مرتبط هستند. مرسوم‌ترین معماری برای شبکه پس انتشار، شبکه عصبی پیشخور^۵ می‌باشد.

شبکه‌های عصبی پیشخور به طور گسترده‌ای در بسیاری از زمینه‌ها مورد استفاده قرار گرفته‌اند که علت آن توانایی آن‌ها در: (۱) تقریب مقادیر غیر خطی پیچیده به طور مستقیم از نمونه‌های ورودی؛ و (۲) ارائه مدل برای گروه بزرگی از پدیده‌های مصنوعی و طبیعی که رسیدگی به آن‌ها با استفاده از تکنیک‌های پارامتریک کلاسیک مشکل است؛ می‌باشد (هانگ، ژو و سیو، ۲۰۰۶).

هانگ و همکاران (۲۰۰۶) الگوریتم یادگیری ساده و کارآمدی را برای شبکه‌های عصبی پیش‌خور با یک لایه پنهان ارائه نمودند که ماشین فوق یادگیری نامیده می‌شود و بدین ترتیب تشریح می‌گردد:

با توجه به مجموعه داده‌ای حاوی نمونه‌های N تایی، نمونه‌های آموزش با (z_i, y_i) ، $i = 1, 2, \dots, N$ با m دسته نشان داده می‌شوند که $z_i = [z_{i1}, z_{i2}, \dots, z_{in}]^T$ بردار متغیرهای ورودی و $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T$ بردار خروجی است. شبکه عصبی پیش‌خور با یک لایه پنهان (SLFN) با V گره پنهان و تابع فعال‌سازی $f(z)$ به صورت ریاضی به شکل ذیل مدل‌سازی می‌شود:

$$\sum_{i=1}^V \beta_i f(a_i \cdot z_j + b_i) = y_j, \quad j = 1, \dots, N \quad \text{رابطه ۳}$$

بنابراین مدل ماشین فوق یادگیری به صورت دقیق‌تر با فرمت ماتریسی به صورت ذیل نوشته می‌شود:

$$H\beta = Y \quad \text{رابطه ۴}$$

که در آن،

$$H(a_1, \dots, a_V, b_1, \dots, b_V, z_1, \dots, z_N) = \begin{bmatrix} G(a_1 \cdot z_1 + b_1) & \dots & G(a_V \cdot z_1 + b_V) \\ \vdots & & \vdots \\ G(a_1 \cdot z_N + b_1) & \dots & G(a_V \cdot z_N + b_V) \end{bmatrix}_{N \times V} \quad \text{رابطه ۵}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_V^T \end{bmatrix}_{V \times m}, \quad Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{N \times m} \quad \text{رابطه ۶}$$

و $a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$ ، $i = 1, 2, \dots, V$ بردار وزنی است که بردار i امین نورون پنهان را به نورون‌های ورودی متصل می‌کند و b_i مقدار آستانه‌ای آمین نورون پنهان است. سپس β_i ، $i = 1, 2, \dots, V$ نشان دهنده بردار وزنی است که آمین نورون‌های پنهان را به نورون‌های خروجی متصل می‌کند. در این مدل، V نورون پنهان با تابع فعال‌سازی وجود دارد. توابع فعال‌سازی متنوعی می‌توانند در اینجا مورد استفاده قرار گیرند.

H ماتریس خروجی لایه پنهان شبکه عصبی نامیده می‌شود و ستون i ام H برای خروجی گره پنهان i ام با توجه به ورودی‌های z_1, z_2, \dots, z_n است. اجرای معمول ماشین فوق یادگیری برای اعمال تصادفی گره‌های محاسباتی در لایه پنهان است که ممکن است مستقل از آموزش داده‌ها باشد. برای ماشین فوق یادگیری، دستیابی به کوچکترین خطاهای آموزش، اصلی که وزن‌ها کوچکتر از حد معمول هستند؛ می‌تواند عملکرد تعمیم یافته بهتر شبکه‌ها را فراهم نماید. از آنجا که در ماشین فوق یادگیری، لایه پنهان نیازی به تنظیم ندارد و پارامترهای لایه پنهان می‌توانند ثابت باشند؛ لذا مدل می‌تواند وزن‌های خروجی را با استفاده از روش حداقل مربعات^۶ حل نماید. بنابراین وزن‌های خروجی β می‌توانند به صورت ذیل محاسبه شوند:

$$\hat{\beta} = H^+Y \quad \text{رابطه ۷}$$

که H^+ ماتریس معکوس تعمیم یافته مور-پن روز H^Y می‌باشد.

ژانگ و همکاران (۲۰۱۷) با ارائه یک مدل غیر خطی موسوم به GELM که از ترکیب مدل گارچ با مدل‌های ناپارامتریک شبکه عصبی حاصل می‌شود به پیش‌بینی نوسانات بازدهی شاخص CSI300 و سهم دیگر و همچنین تخمین ارزش در معرض ریسک آن‌ها پرداختند. آن‌ها در کنار مدل مزبور، از سایر مدل‌های واریانس شرطی، ELM و SVM^۴ استفاده نمودند؛ که در نهایت نتایج نشان می‌دهد عملکرد مدل GELM در میان مدل‌های مورد بررسی از کفایت بهتری برخوردار بوده و به طور قابل ملاحظه‌ای قدرت پیش‌بینی‌ها را بهبود می‌بخشد.

در حالی که ریسک‌های بازار برای بانک‌ها در یک افق زمانی روزانه یا هفتگی محاسبه می‌شود؛ افق زمانی ریسک بازار یک بیمه‌گر بهتر است که به صورت سالانه باشد. برای یک شرکت بیمه‌داری‌ها و بدهی‌ها به دلیل ماهیت آن‌ها نمی‌توانند پیوسته قیمت‌گذاری گردند در نتیجه عملاً امکان ارزیابی ریسک در افق‌های زمانی کوتاه‌مدت ممکن نیست. ساده‌ترین قاعده مقیاس‌دهی استفاده از قاعده جذر زمان است:

$$\sigma_{1 \text{ year}} \approx \sqrt{k} \cdot \sigma_{h \text{ days}} \quad k = \frac{261}{h} \quad \text{رابطه ۸}$$

مک نیل و همکاران (۲۰۰۵) و کافمن و پتی (۲۰۰۳) متدولوژی‌هایی را مطالعه کردند که مدلی را برای ارزیابی فاکتورهای ریسک در طول افق زمانی بلندمدت پیشنهاد می‌دهد. این مدل‌ها عبارتند از: مدل گشت تصادفی، AR(p)، GARCH(1,1)، و توزیع‌های دنباله پهن. قاعده جذر زمان با فروض توزیع نرمال مطرح گردیده است. فرض کنید که ارزش مورد انتظار لگاریتم بازدهی‌ها برابر صفر باشد و یک توزیع نرمال با نوسان σ در طول یک روز داشته باشد. همچنین فرض کنید که لگاریتم بازدهی‌ها iid هستند. این قیمت‌داری لگاریتمیک از یک فرآیند گشت تصادفی با دریفت^۹ صفر پیروی می‌کند. ترکیب کردن بیش از k روز یک متغیر با توزیع نرمال و میانگین صفر و نوسان $\sqrt{k}\sigma$ می‌دهد. لذا تحت فرض نرمال بودن، ارزش در معرض ریسک و TVaR بر مبنای این قانون می‌توانند مقیاس‌سازی شوند (سندستروم، ۲۰۱۱؛ ۲۵۱:۲۵۰):

$$Var^{(k)} = \sqrt{k}Var^{(1)} \quad \text{رابطه ۹}$$

$$TVaR^{(k)} = \sqrt{k}TVaR^{(1)} \quad \text{رابطه ۱۰}$$

با وجود آن که کمیته بازل استفاده از قاعده جذر زمان را برای پیش‌بینی ارزش در معرض ریسک ده روزه مجاز دانسته است؛ برخی از تحقیقات در این زمینه، مانند پژوهش کریستوفرسن، دیبالد و شورمن (۱۹۹۸)، داد، بلک و کنز (۲۰۰۳)، دنیلسون و زیگراند (۲۰۰۶) و اسکوگلاند، اردمن و چن (۲۰۱۱) این قاعده را با توجه به شرایط عادی بازار نقد کرده‌اند. بلک، کنز و داد (۲۰۰۰) بیان می‌دارند که این قاعده غیر قابل اعتماد است و به طور شایان توجهی به بیش برآوردی ارزش در معرض ریسک منجر می‌شود (گرچی و سجاد، ۱۳۹۵).

کافمن و پتی (۲۰۰۳) به بررسی ویژگی‌های آماری و رفتار سری‌های زمانی مالی در توأثرهای متفاوت پرداختند. و دقت مدل‌های مختلف با داده‌های با توأثرهای متفاوت را در پیش‌بینی ریزش مورد انتظار مورد آزمون قرار دادند. آن‌ها در این تحقیق ۳ مدل پویای گام تصادفی^{۱۱}، GARCH(1,1)، AR(p) و مدل ایستای توزیع‌های دنباله پهن^{۱۱} را ارائه و در دوره‌های زمانی h روزه آزمون نمودند. در مدل گشت تصادفی آن‌ها فرض می‌نمایند که بازده‌های لگاریتمی یک دوره‌ای مستقل و دارای توزیع نرمال بوده و میانگین و واریانس ثابت دارند. قاعده جذر زمان منجر می‌شود به:

$$\hat{\sigma}^k = \sqrt{k}\hat{\sigma} \quad \text{رابطه (۱۱)}$$

$$\hat{\mu}^k = k\hat{\mu} \quad \text{رابطه (۱۲)}$$

نتایج مطالعه آن‌ها نشان می‌دهد که از میان ۴ مدل مزبور، روش گام تصادفی روشی بهینه برای محاسبه ارزش در معرض ریسک و ریزش مورد انتظار با استفاده از داده‌های ماهانه در سطح خطای ۱ و ۵ درصد می‌باشد. مک نیل و همکاران (۲۰۰۵) از شبیه‌سازی مونت کارلو و استفاده از قاعده جذر زمان استفاده نمودند. نتایج نشان می‌دهد که قاعده جذر زمان به طور آشکاری منجر به بیش برآورد ارزش در معرض ریسک و ارزش در معرض ریسک دنباله می‌شود.

گرجی و سجاد (۱۳۹۵) ارزش در معرض ریسک چند دوره‌ای برای شاخص کل بورس اوراق بهادار تهران (TEPIX)، NASDAQ و FTSE را با استفاده از مدل شبیه‌سازی تاریخی فیلتر شده^{۱۲} (FHS) روزانه و پنج روزه برآورد نمودند. همچنین به منظور مقایسه نتایج از روش‌های شبیه‌سازی تاریخی موزون با واریانس^{۱۳} (HW^{۱۴})، روش هیبریدی^{۱۵} (BRW)، روش شبیه‌سازی تاریخی^{۱۶} (HS)، شبیه‌سازی تاریخی بوت استرپ شده^{۱۷} (BHS) و روش‌های پارامتریک برآورد ارزش در معرض ریسک بر پایه دو مدل GARCH و EGARCH، با توجه به وجود اثر اهرم مالی^{۱۸} در بازده دارایی‌های مالی و با فرض توزیع نرمال و تی-استیودنت استفاده نمودند.

آن‌ها پس از به کارگیری ۱۶ روش شبیه‌سازی تاریخی و مدل‌های پارامتریک در سه سطح اطمینان ۹۵، ۹۹ و ۹۹٫۵ درصد، دریافتند مدل شبیه‌سازی تاریخی بوت‌استرپ شده بهترین عملکرد را برای شاخص کل بورس تهران دارد. همچنین در سطح اطمینان ۹۵ درصد مدل پارامتریک گارچ نمایی با توزیع تی-استیودنت و در سطوح ۹۹ و ۹۹٫۵ درصد مدل گارچ نمایی با توزیع نرمال عملکرد مطلوب‌تری نسبت به سایر مدل‌ها در برآورد ارزش در معرض ریسک پنج روزه برای شاخص‌های NASDAQ و FTSE دارد.

۲- روش‌شناسی پژوهش

جامعه آماری مورد استفاده در این تحقیق، مقادیر شاخص کل بورس اوراق بهادار تهران از تاریخ ۱۳۷۱/۰۴/۰۸ تا تاریخ ۱۳۹۶/۱۲/۲۹ می‌باشد. در این پژوهش به دلیل نیاز به سری‌های زمانی طولانی مدت از متغیر مورد بررسی و از سوی دیگر تغییر روش محاسبه شاخص کل از اواسط سال ۱۳۸۷، از مقادیر شاخص طی ۹ سال گذشته استفاده شده است. به این ترتیب مقدار شاخص کل از تاریخ ۱۳۸۸/۰۱/۰۱ تا تاریخ ۱۳۹۶/۱۲/۲۹ به عنوان نمونه مورد

بررسی انتخاب شده‌اند. در این پژوهش به دلیل کمبود تعداد داده‌های سالانه که سبب کاهش داده‌های موجود برای پس‌آزمایی می‌شود؛ ملاک محاسبه ارزش در معرض ریسک دنباله سالانه را سال‌های شمسی قرار نداده به این ترتیب که هر ۳۶۵ روز تقویمی، که به صورت متحرک محاسبه می‌شود، معادل یک سال در نظر گرفته شده است.

فرضیه تحقیق

مدل گارچ نمایی - ماشین فوق یادگیری نسبت به شبیه‌سازی تاریخی با داده‌های فیلتر شده در پیش‌بینی ریسک نوسانات سالانه بازار سهام از دقت بیشتری برخوردار است.

مدل خودرگرسیون واریانس ناهمسانی شرطی تعمیم یافته نمایی (EGARCH):

مدل گارچ نمایی از جمله مدل‌های پیش‌بینی نوسان نامتقارن می‌باشد. علت ایجاد چنین مدل‌هایی آن است که در برخی سری‌های زمانی به دلایل مختلف، ممکن است نوسانات مثبت بیشتر یا کمتر از نوسانات منفی باشد. به طور مثال اثرات خبرهای خوب و بد در نوسانات بازده بازار متفاوت است. از جمله این مدل‌ها مدل نامتقارن EGARCH(p,q) است که شکل معادله آن به صورت زیر است (شهریار، ۱۳۹۵؛ ۴۸):

$$\log(\sigma_t^2) = w + \sum_{j=1}^q \beta_j \log \sigma_{t-j}^2 + \sum_{i=1}^p \alpha_i \left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| + \sum_{k=1}^r \gamma_k \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \quad \text{رابطه (۱۳)}$$

مدل گارچ نمایی - ماشین فوق یادگیری (EGELM)

مدل گارچ نمایی - ماشین فوق یادگیری (EGELM) در واقع از ترکیب مدل‌های شبکه عصبی و مدل‌های واریانس شرطی حاصل می‌شود. در این روش با ترکیب یک مدل پارامتریک با ناپارامتریک می‌توان به بهبود پیش‌بینی نوسانات کمک نمود. تابع تصمیم‌گیر مدل ماشین فوق یادگیری به شرح ذیل می‌باشد:

$$\sigma_{o_t} = f_V(\sigma_{z_t}) = \sum_{i=1}^V \beta_i g_i(\sigma_{z_t}) = \sum_{i=1}^V \beta_i G(a_i, b_i, \sigma_{z_t}), \sigma_{z_t} \in R^N, \beta_i \in R^M \quad \text{رابطه (۱۴)}$$

که a_i بردار وزنی ارتباط بین نورون‌های ورودی با نورون پنهان i ام، b_i تورش‌های نورون پنهان i ام، σ_{z_t} سری زمانی نوسانات تخمین زده شده اولیه، f تابع فعال سازی، β_i بردار وزن بین لایه نهان و لایه خروجی می‌باشد، V تعداد گره‌های لایه پنهان و g_i بیانگر تابع خروجی $G(a_i, b_i, \sigma_{z_t})$ از i امین گره پنهان می‌باشد. همچنین گره‌های با تابع فعال سازی g ، می‌توانند به صورت زیر تعریف شوند:

$$g_i = G(a_i, b_i, \sigma_{z_t}) = g(a_i \cdot \sigma_{z_t} + b_i), a_i \in R^N, b_i \in R^+ \quad \text{رابطه (۱۵)}$$

برخلاف روش‌های معمول یادگیری، مدل ماشین فوق یادگیری نه تنها سعی می‌کند خطای داده‌های آموزش را حداقل کند، سعی در حداقل کردن نرم وزن‌های خروجی نیز دارد. بر اساس تئوری بارتلت^{۱۹} برای SLFN-ها کاهش نرم وزن‌ها در کنار کاهش خطای آموزش به تعمیم‌پذیری بهتری می‌رسد. لذا مساله بهینه‌سازی مدل مزبور به شرح ذیل می‌باشد:

$$\text{Minimize: } L_{D_{GELM}} = \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \|\zeta_i\|^2 \quad (\text{رابطه ۱۶})$$

$$\text{Subject to: } h(\sigma_{z_t})\beta = \sigma_{y_t} - \zeta_i, i = 1, \dots, N$$

که C پارامتری کنترلی برای توازن بین بردار خطای آموزش (ζ) و نرم وزن‌های خروجی (β) است. در نهایت خروجی مدل گارچ نمایی- ماشین فوق یادگیری بردار انحراف معیارهای هدف می‌باشد که برای محاسبه ارزش در معرض ریسک و ارزش در معرض ریسک دنباله مورد استفاده قرار می‌گیرد. در این مطالعه جهت مدل‌سازی گارچ نمایی- ماشین فوق یادگیری از وقفه‌های مدل گارچ نمایی بر اساس یافته‌های تخمین همین مدل در این پژوهش استفاده شده است. همچنین الگوریتم مورد استفاده از این توبلاکس ORELM^{۲۱} و همراه با ۲۰ گره پنهان با تابع فعال‌سازی سیگموئید خواهد بود.

شبیه‌سازی تاریخی با داده‌های فیلتر شده (FHS)

در این روش فرض می‌شود که بازده‌ها از یک فرآیند ARMA(1,1) طبق معادله ۱۷ و نوسان از فرآیند GARCH(1,1) مطابق معادله ۱۸ پیروی می‌نمایند.

$$R_t = \mu + \beta R_{t-1} + \varepsilon_t + \alpha \varepsilon_{t-1} \quad (\text{رابطه ۱۷})$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (\text{رابطه ۱۸})$$

بعد از تخمین ضرایب معادلات بالا می‌توان بازده‌های برآورد شده را با تقسیم نمودن آن‌ها به تخمین نوسان شرطی هر دوره، استاندارد (فیلتر) نمود.

$$e_t = \varepsilon_t / \sigma_t \quad (\text{رابطه ۱۹})$$

اگر مدل صحیح باشد؛ این بازده‌های استاندارد شده iid خواهند بود و بنابراین می‌توان آن‌ها را برای شبیه‌سازی تاریخی بکار برد. درگام بعدی تکنیک بوتسترپینگ فیلتر شده را برای تولید داده‌های تصادفی از نمونه تاریخی استفاده می‌نماییم. سپس هر e_i (برای $i=1, \dots, N$) تولید شده از استخراج‌های تصادفی را در نوسان شرطی تخمینی دوره t+1 که خواهان تخمین ارزش در معرض ریسک در آن هستیم ضرب می‌کنیم. در این راه توزیع کل بازده‌های عوامل ریسک که با تاریخ گذشته و نیز نوسان جاری سازگار است، شبیه‌سازی می‌گردد.

بنابراین اگر اولین پسماند مستخرج را به صورت e_1 تعریف نماییم، اولین شوک شبیه‌سازی شده برای زمان $t+1$ با محاسبه جمله زیر بدست خواهد آمد:

$$\varepsilon_1 = e_1 \cdot \hat{\sigma}_{t+1} \quad \text{رابطه ۲۰}$$

که $\hat{\sigma}_{t+1}$ پیش‌بینی نوسان شرطی بدست آمده از مدل GARCH است. به طور مشابه، $\varepsilon_2, \varepsilon_3, \dots, \varepsilon_N$ نیز تولید می‌گردند. شاخص کل برای هر یک از ε_i ها برای بدست آوردن توزیع N ارزش آتی محتمل ارزش‌گذاری مجدد می‌گردد. در نهایت، ارزش در معرض ریسک با قطع این توزیع در صدک مورد نظر و محاسبه تفاوت میان این صدک و ارزش جاری پرتفوی بدست می‌آید (سارنج، ۱۳۹۶؛ ۲۷۳:۲۷۲).

پس‌آزمایی مدل‌ها

در نهایت برای پس‌آزمایی مدل‌ها از آزمون مک نیل و فری به منظور بررسی معناداری پیش‌بینی‌ها و همچنین از تابع زیان اولسن و رویه مجموعه اطمینان مدل به منظور رتبه‌بندی مدل‌ها به لحاظ میزان دقت پیش‌بینی‌ها استفاده خواهد شد. پس‌آزمایی مک نیل و فری مبتنی بر پسماندهای تخطی استاندارد شده می‌باشد و معناداری مدل‌ها به لحاظ قدرت پیش‌بینی را بررسی می‌نماید. آماره پس‌آزمایی مزبور بر اساس رابطه زیر تعریف می‌گردد:

$$y_{t+1} = \begin{cases} \frac{R_{t+1} - TVaR_{t+1|t}^{(1-p)}}{\hat{\sigma}_{t+1}} & \text{if } R_{t+1} < VaR_{t+1|t}^{(1-p)} \\ 0 & \text{if } R_{t+1} \geq VaR_{t+1|t}^{(1-p)} \end{cases} \quad \text{رابطه ۲۱}$$

همچنین تابع زیان اولسن به صورت زیر ارائه می‌شود:

$$\psi_{(TVaR)t+1} = \begin{cases} 1 + (R_{t+1} - TVaR_{t+1|t}^{(1-p)})^2 & \text{if } R_{t+1} < TVaR_{t+1|t}^{(1-p)} \\ (R_{t+1} - TVaR_{t+1|t}^{(1-p)})^2 & \text{if } TVaR_{t+1|t}^{(1-p)} < R_{t+1} < VaR_{t+1|t}^{(1-p)} \\ 0 & \text{if } R_{t+1} \geq VaR_{t+1|t}^{(1-p)} \end{cases} \quad \text{رابطه ۲۲}$$

رویه مجموعه اطمینان مدل (MCS) (تدوین شده توسط هانسن و همکاران (۲۰۱۱)) نیز با هدف مقایسه پیش‌بینی‌های ارزش در معرض ریسک دنباله به دست آمده توسط مدل‌های مختلف استفاده می‌شود. رویه هانسن شامل دنباله‌ای از آزمون‌های آماری است که در آن‌ها، مدل‌ها به لحاظ معنی‌داری آماری و با استفاده از آزمون‌های آماری توانایی پیش‌بینی برابر (EPA)^{۲۲} به صورت دو به دو مقایسه شده و در نهایت مجموعه‌ای از مدل‌های برتر که در آن‌ها فرضیه صفر آزمون EPA در سطح اطمینان α رد نشده‌اند، انتخاب می‌گردد (سارنج، ۱۳۹۶؛ ۳۶۳:۳۵۲).

۳- یافته‌های پژوهش

داده‌های استفاده شده در این پژوهش مربوط به شاخص کل بورس اوراق بهادار تهران (TEDPIX) در دوره زمانی ۱۳۸۸/۰۱/۰۵ تا ۱۳۹۶/۱۲/۲۹ و با تواتر روزانه است که به دو دسته دوره تخمین و دوره آزمون تقسیم می‌شوند. سطح اطمینان برای محاسبه ارزش در معرض ریسک دنباله سالانه، ۹۹٪ در نظر گرفته شده است و روش تخمین پارامترها روش حداکثر درست‌نمایی است. بعلاوه طول دوره تخمین را از ابتدای سال ۱۳۸۸ تا انتهای سال ۱۳۹۲ و طول دوره آزمون را از ابتدای سال ۱۳۹۳ تا انتهای سال ۱۳۹۶ در نظر می‌گیریم. متغیر استفاده شده در این پژوهش بازده لگاریتمی شاخص کل بورس اوراق بهادار تهران می‌باشد که نحوه محاسبه آن بدین طریق می‌باشد:

$$r_t = \ln\left(\frac{S_t}{S_{t-h}}\right) \quad \text{رابطه (۲۳)}$$

S_t شاخص کل در زمان t و S_{t-h} شاخص کل در زمان $t-h$ می‌باشد. که h معادل ۱ روز کاری است.

R_t : بازده سالانه شاخص کل می‌باشد.

برای بررسی دقیق ویزگی داده‌ها به انجام برخی آزمون‌های آماری می‌پردازیم که در جدول ۱ نشان داده شده است.

جدول ۱: آزمون‌های انجام شده برای بازدهی روزانه شاخص کل در سطح اطمینان ۹۵ درصد


P value	مقدار بحرانی	آماره آزمون	هدف آزمون	نوع آزمون
۰,۰۰۱	۵,۹۶	۲۸۹۹,۸۶	پیروی داده‌ها از توزیع نرمال استاندارد	چارک-برا ^{۲۳}
۰,۰۰۰	۰,۰۲۸۹	۰,۴۸۹	پیروی داده‌ها از توزیع نرمال استاندارد	کلموگروف-اسمیرنوف ^{۲۴}
۰,۰۰۰	۱۴,۱	۲۴۸,۲	بررسی اثر خود همبستگی بین بازده‌ها	لیونگ-باکس ^{۲۵}
۰,۰۰۰	۱۴,۱	۱۱۰,۹	بررسی اثر خود همبستگی بین مجذور بازده‌ها	لیونگ-باکس
۰,۰۰۰	۳,۸	۸۴,۶	بررسی وجود اثرات آرچ	آرچ ^{۲۶}
0.001	-1.94	-31.122	مانایی (عدم وجود ریشه واحد)	دیکی فولر افزوده

منبع: یافته‌های محقق

جدول ۱ نشان می‌دهد که آزمون‌های چارک-برا و کولموگروف-اسمیرنوف در سطح اطمینان ۹۵ درصد معنادار می‌باشند؛ لذا بازده‌های روزانه از توزیع نرمال پیروی نخواهند کرد. بعلاوه آزمون لیونگ-باکس که برای بررسی اثرات خودهمبستگی بین بازده‌ها به کار می‌رود؛ در سطح اطمینان مورد بررسی معنادار بوده که بیانگر وجود اثرات خودهمبستگی بین بازده‌ها و قابلیت پیش‌بینی آن‌ها می‌باشد. از طرف دیگر معناداری آزمون لیونگ-باکس برای مجذور بازده‌ها حاکی از وجود اثرات خود همبستگی و ناهمسانی واریانس است. همچنین با انجام آزمون آرچ فرضیه صفر مبنی بر عدم وجود اثرات آرچ رد شده و نتیجه گرفته می‌شود که ناهمسانی واریانس یکی از ویژگی‌های این دسته از داده‌ها می‌باشد. در نهایت نتایج آزمون دیکی فولر افزوده نیز حاکی از مانایی سری‌های زمانی تحت بررسی با الگوی بدون عرض از مبدا و روند است.

تشخیص مدل میانگین شرطی

با توجه به جدول ۱ و معناداری آزمون لیونگ باکس که حاکی از وجود فرایند AR در مدل است،



شکل ۱: معیار آکائیک برای مرتبه‌های مختلف مدل ARMA

منبع: یافته‌های محقق

در این مرحله به کمک معیار آکائیک و برآورد الگوهای مختلف از وقفه‌های AR و MA مدل مناسب میانگین شرطی برای پیش بینی بازده‌های آتی شناسایی می‌شود. به منظور شناسایی مدل بهینه، الگوهای مختلفی از ARMA طراحی و پارامترهای آن‌ها را برآورد کرده و معیار آکائیک هر یک محاسبه می‌شود. شکل ۱ معیارهای آکائیک برای الگوهای مختلف ARMA را نشان می‌دهد. همانگونه که قابل تشخیص است مدل ARMA(3,4) دارای کمترین میزان معیار آکائیک بوده و لذا در ادامه فرایند از این مدل استفاده خواهد شد. نتایج تخمین این مدل به شرح جدول ۲ می‌باشد.

جدول ۲: تخمین مدل ARMA(3,4) برای بازدهی روزانه شاخص کل

ARMA(3,4)	مقدار	خطای معیار	مقدار آماره t	PValue
Intercept	-0.00190	0.00047	-4.00590	0.00006
AR{1}	-0.43733	0.03896	-11.22600	0.00000
AR{2}	0.23754	0.05252	4.52320	0.00001
AR{3}	0.91507	0.03895	23.49600	0.00000
MA{1}	0.84181	0.04516	18.64300	0.00000
MA{2}	0.02365	0.08001	0.29557	0.76755
MA{3}	-0.90352	0.07576	-11.92700	0.00000
MA{4}	-0.29557	0.03374	-8.76100	0.00000
Variance	0.00005	0.00000	35.24400	0.00000

منبع: یافته‌های محقق

پس از تخمین مدل میانگین شرطی مناسب، به منظور بررسی کفایت مدل از آزمون لیونگ باکس استفاده می‌نماییم. نتایج نشان می‌دهد که فرض صفر مبنی بر عدم خودهمبستگی در حالت کلی رد نشده و در ناحیه H_0 قرار داریم. نتیجه آزمون آرچ نیز حاکی از واقع شدن در ناحیه H_1 با سطح معنی داری نزدیک به صفر و آماره آزمون 70.4 و سطح بحرانی 3.8 است. بنابراین همانگونه که مشاهده می‌شود این الگو مسئله خودهمبستگی ندارد ولی دارای مشکل وایانس ناهمسانی بوده و لذا استفاده از الگوهای خانواده ARCH اجتناب‌ناپذیر است.

جدول ۳: آزمون‌های انجام شده پس از اجرای فرآیند ARMA (سطح اطمینان ۹۵ درصد)


P value	مقدار بحرانی	آماره آزمون	نوع آزمون
0.7659	14.1	4.1	لیونگ-باکس
0.0000	3.8	70.4	آرچ

منبع: یافته‌های محقق

پس از یافتن و برآورد الگوی بهینه ARMA و این یافته که این مدل مسئله واریانس ناهمسانی دارد. در ادامه به برآورد مدل گارچ نمایی-ماشین فوق یادگیری برای پیش‌بینی نوسانات روزانه می‌پردازیم.

مدل گارچ نمایی-ماشین فوق یادگیری (EGELM)

در ابتدا بر اساس مقادیر مختلف معیار آکائیک به برآورد الگوهای مختلف گارچ نمایی با فرض توزیع تی-استیودنت و تا مرتبه ۴ می‌پردازیم.



شکل ۲: معیار آکائیک برای مرتبه‌های مختلف مدل ARMA(3,4)-EGARCH(1,1)

منبع: یافته‌های محقق

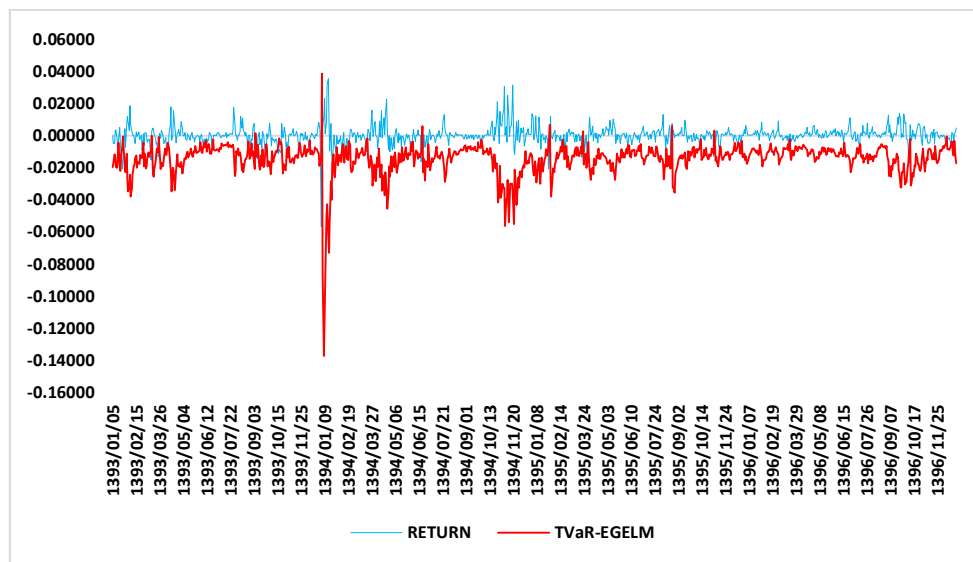
همانگونه که از شکل ۲ قابل ملاحظه است مدل نهایی ARMA(3,4) با EGARCH(1,1) می‌باشد که ضرایب آن به شرح جدول ۴ است.

جدول ۴: تخمین مدل ARMA(3,4)-EGARCH(1,1) برای بازدهی روزانه شاخص کل

پارامتر	مقدار	خطای معیار	مقدار آماره t	PValue
ARMA(3,4) (t Distribution):				
Constant	-0.00047	0.00024	-1.95240	0.05089
AR{1}	0.07465	0.11554	0.64606	0.51824
AR{2}	-0.32424	0.03355	-9.66490	0.00000
AR{3}	0.84411	0.06611	12.76900	0.00000
MA{1}	0.36938	0.11028	3.34950	0.00081
MA{2}	0.35184	0.07075	4.97330	0.00000
MA{3}	-0.62864	0.09686	-6.49030	0.00000
MA{4}	-0.40707	0.05709	-7.12990	0.00000
DoF	6.07040	1.05360	5.76160	0.00000
(t Distribution): (1, 1)EGARCH				
Constant	-0.22205	0.09351	-2.37470	0.01757
GARCH{1}	0.97792	0.00921	106.24000	0.00000
ARCH{1}	0.19348	0.03612	5.35730	0.00000
Leverage{1}	-0.03699	0.01775	-2.08400	0.03716
DoF	6.07040	1.05360	5.76160	0.00000

منبع: یافته‌های محقق

با توجه به نتایج فوق‌الگویی مورد استفاده در این بخش ELM-EGARCH(1,1) خواهد بود. همچنین الگوریتم مورد استفاده جهت مدل‌سازی شبکه عصبی ماشین فوق یادگیری^{۲۷} ORELM و همراه با ۲۰ گره پنهان با تابع فعال‌سازی سیگموئید می‌باشد. در نهایت شکل ۳ نتیجه پیش‌بینی برون نمونه‌ای مقدار ارزش در معرض ریسک دنباله با تواتر روزانه بر اساس مدل گارچ نمایی-ماشین فوق یادگیری را نشان می‌دهد.




شکل ۳: نمودار آزمون باز خورد ارزش در معرض ریسک دنباله روزانه در دوره پیش بینی با استفاده از مدل EGELM
منبع: یافته‌های محقق

همانطور که مشخص است به‌طور شهودی می‌توان در خصوص تعداد استثنائات بیان داشت که این تعداد تقریباً کمتر یا مساوی از حد مجاز در دوره آزمون می‌باشد.

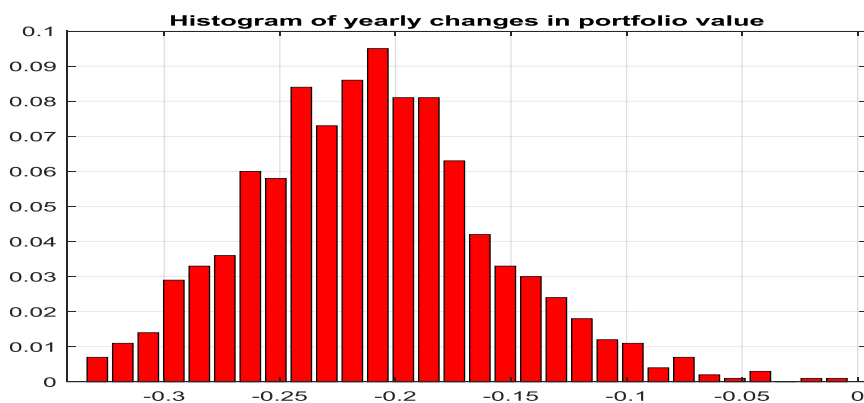
شبیه‌سازی تاریخی با داده‌های فیلتر شده (FHS)

در این روش برای محاسبه ارزش در معرض ریسک دنباله سالانه، پنجره تخمین را حرکت داده و بازدهی شاخص کل را برای یک سال پس از انتهای دوره تخمین بدست می‌آوریم. با تکرار این فرآیند به میزان ۱۰۰۰ بار، ۱۰۰۰ مسیر برای پیش‌بینی بازدهی شاخص کل در یک سال آتی بدست آمده که شکل ۴ مربوط به سال ۱۳۹۶ می‌باشد.



شکل ۴: مسیرهای متعدد به وجود آمده برای محاسبه TVaR سال ۱۳۹۶
منبع: یافته‌های محقق

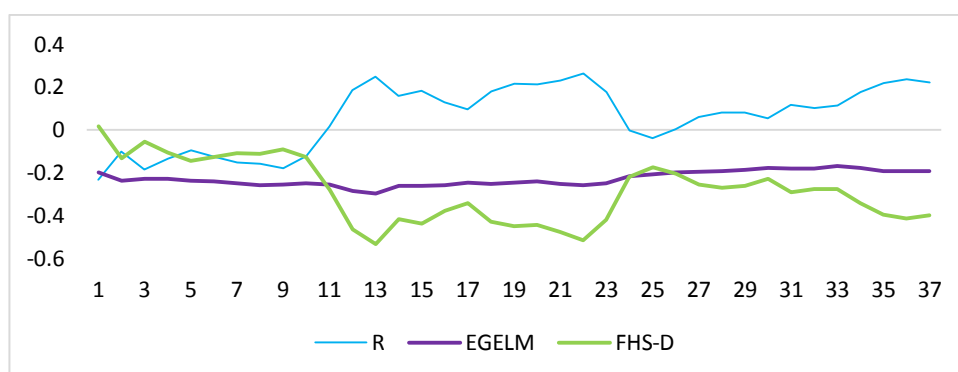
سپس نمودار هیستوگرام مقادیر بدست آمده از مسیرهای متعدد را رسم نموده و صدک نود و نهم آن را محاسبه می‌نماییم. در نهایت متوسط زیان‌های بعد از صدک مزبور را به عنوان ارزش در معرض ریسک دنباله محاسبه می‌کنیم. شکل ۵ نمودار هیستوگرام سال ۱۳۹۶ می‌باشد.



شکل ۵: نمودار هیستوگرام رسم شده برای محاسبه TVaR سال ۱۳۹۶
منبع: یافته‌های محقق

۳-۱- محاسبه ارزش در معرض ریسک دنباله سالانه شده

با توجه به اینکه در الگوی گارچ نمایی-ماشین فوق یادگیری مقادیر انحراف معیار، ارزش در معرض ریسک و ارزش در معرض ریسک دنباله به صورت روزانه محاسبه گردید؛ لذا در این مرحله با استفاده از قاعده جذر زمان به تخمین مقادیر سالانه متغیرهای مزبور خواهیم پرداخت. اما در روش شبیه‌سازی تاریخی با داده‌های فیلتر شده این مقادیر مستقیماً به صورت سالانه محاسبه شده‌اند.



شکل ۶: نمودار مقایسه‌ای پیش‌بینی ارزش در معرض ریسک دنباله سالانه دو مدل و بازدهی سالانه شاخص کل
منبع: یافته‌های محقق

شکل ۶ مقایسه ارزش در معرض ریسک دنباله سالانه شده دو مدل را با بازدهی سالانه شاخص کل نشان می‌دهد. بر اساس شکل، ارزش در معرض ریسک دنباله بدست آمده از مدل گارچ نمایی-ماشین فوق یادگیری هموارتر و نزدیک‌تر به بازدهی‌های محقق سالانه می‌باشد؛ اما برای روش شبیه‌سازی تفاوت قابل ملاحظه‌ای مشاهده می‌گردد. همچنین در روش شبیه‌سازی استثنائاتی دیده می‌شود که این استثنائات در مدل گارچ نمایی-ماشین فوق یادگیری دیده نمی‌شود. اگرچه عدم وجود هیچ‌گونه استثنائی ممکن است این مساله را در ذهن متبادر نماید که ارزش در معرض ریسک دنباله محاسبه شده در این الگو نسبت به روش شبیه‌سازی که حاوی استثنائاتی می‌باشند؛ بیش برآورد شده است. اما با مشاهده نمودار فوق در می‌یابیم که ارزش در معرض ریسک بدست آمده در شبیه‌سازی دچار بیش برآورد شده به طوری که از مشاهدات شماره ۱۰ به بعد فاصله آن‌ها با بازدهی شاخص کل بیشتر شده است.

برای اینکه بر اساس روش‌های شهودی به تصمیم‌گیری نپردازیم؛ از آزمون‌های آماری تعیین شده برای این مساله استفاده خواهیم نمود. آزمون مورد استفاده برای معناداری ارزش در معرض ریسک دنباله بدست آمده، آزمون مک‌نیل و فری بوده که نشان می‌دهد آیا مقادیر ارزش در معرض ریسک دنباله بدست آمده از قابلیت اتکای لازم برخوردار هستند یا خیر. جدول ۵ نتایج آزمون مک‌نیل و فری را برای دو مدل نشان می‌دهد. نتایج نشان می‌دهد تنها روش گارچ نمایی-ماشین فوق یادگیری از قابلیت اتکا برخوردار می‌باشد.

جدول ۵: نتایج نهایی معناداری و رتبه‌بندی مدل‌ها در قدرت پیش‌بینی ارزش در معرض ریسک دنباله (سطح اطمینان ۹۵ درصد)

رتبه بر اساس تابع زیان اولسن	TVaR سال ۹۶	VaR سال ۹۶	p-value	مقدار آماره t	مدل‌ها
۲	0.1921	0.14	*0.0798	0.8462	گارچ نمایی-ماشین فوق یادگیری
1	0.3987	0.3752	0.0137	1.5612	شبیه سازی تاریخی با داده های فیلتر شده

منبع: یافته‌های محقق

در این مرحله می‌بایست بر اساس تابع زیان اولسن و استفاده از رویه مجموعه اطمینان مدل به رتبه‌بندی روش‌های مزبور به لحاظ توانایی پیش‌بینی ارزش در معرض ریسک دنباله پرداخته شود اما با توجه به اینکه تنها یک مدل در آزمون مک نیل و فری انتخاب شد؛ لذا رتبه‌بندی معنایی نداشته اما برای آگاهی بیشتر نسبت به رتبه مدل‌ها در صورتی که معنادار می‌بودند؛ این آزمون برای دو مدل استفاده شده است که نتایج آن در جدول ۵ قابل ملاحظه است. بر اساس تابع زیان اولسن، مدل شبیه‌سازی تاریخی با داده‌های فیلتر شده در رتبه ۱ و گارچ نمایی-ماشین فوق یادگیری در رتبه ۲ قرار دارد اما همان‌طور که عنوان گردید؛ مدل گارچ نمایی-ماشین فوق یادگیری بر اساس آزمون مک نیل و فری از قابلیت اتکای بیشتری برخوردار می‌باشد.

۴- نتیجه‌گیری و پیشنهادها

در حالی که ریسک‌های بازار برای بانک‌ها در یک افق زمانی روزانه یا هفتگی محاسبه می‌شود؛ برای یک شرکت بیمه، دارایی‌ها و بدهی‌ها به دلیل ماهیت آن‌ها نمی‌توانند پیوسته قیمت‌گذاری گردند در نتیجه عملاً امکان ارزیابی ریسک در افق‌های زمانی کوتاه مدت ممکن نیست لذا افق زمانی ریسک بازار یک بیمه‌گر بهتر است که به صورت سالانه باشد. بنابراین در این پژوهش با دو مساله پیش‌بینی دقیق نوسانات که لازمه برآورد ارزش در معرض ریسک و ارزش در معرض ریسک دنباله در رویکردهای پارامتریک است؛ و نحوه سالانه نمودن ریسک بازار مواجهیم. لذا برای پیش‌بینی نوسانات از روش گارچ نمایی-ماشین فوق یادگیری و برای سالانه نمودن آن از قاعده جذر زمان استفاده شد؛ همچنین به منظور توجه به مساله سالانه نمودن ریسک استفاده از مزیت‌های روش‌های شبیه‌سازی نیز لحاظ گردید. نتایج نشان می‌دهد که در روش شبیه‌سازی تاریخی با داده‌های فیلتر شده دچار بیش برآورد مقدار ارزش در معرض ریسک دنباله هستیم به همین دلیل علیرغم اینکه بر اساس تابع زیان اولسن و بکارگیری رویه مجموعه اطمینان مدل در رتبه اول قرار دارد ولی بر اساس آزمون مک نیل و فری معنادار نبوده لذا از قابلیت اتکای لازم در پیش‌بینی برخوردار نیست. در نتیجه در این پژوهش استفاده از مدل گارچ نمایی-ماشین فوق یادگیری برای پیش‌بینی نوسانات و سپس استفاده از قاعده جذر زمان برای سالانه نمودن ریسک‌ها به نتایج بهتری منجر گردیده است. لذا در مقایسه صورت گرفته در این مطالعه قاعده جذر زمان عملکرد بهتری داشته هر چند که مطالعات صورت گرفته بر مزیت روش‌های شبیه‌سازی تأکید نموده بودند. این مساله به علت بلندمدت بودن افق زمانی پیش‌بینی است که سالانه در نظر گرفته شده است. در

تحقیقاتی که روش شبیه‌سازی را برای پیش‌بینی ارزش در معرض ریسک دنباله بیش از یک روزه مطلوب دانستند؛ افق زمانی پیش‌بینی یک ساله نبوده؛ نظیر مطالعه گرجی و سجاد (۱۳۹۵) که به برآورد ارزش در معرض ریسک ۵ روزه پرداختند و دریافتند که روش شبیه‌سازی تاریخی بوت‌استرپ شده برای شاخص کل بورس اوراق بهادار تهران بهترین عملکرد را داشته است. همچنین می‌توان به مطالعه کافمن و پتی (۲۰۰۳) از معدود مطالعات صورت پذیرفته در خصوص برآورد ریسک در صنعت بیمه اشاره نمود که با بررسی ۴ روش مختلف برای برآورد ارزش در معرض ریسک در افق سالانه دریافتند که مدل گام تصادفی که در عمل همانند قاعده جذر زمان عمل می‌نمود بهترین روش می‌باشد.

در خاتمه با توجه به اهمیت مساله سالانه نمودن ریسک‌ها در صنعت بیمه، توصیه می‌گردد تحقیقات بیشتری به بررسی این مقوله پرداخته شود تا راهنمایی برای سنجش انواع ریسک‌ها به ویژه در محاسبات مربوط به نسبت توانگری مالی شرکت‌های بیمه باشد. از آنجا که نسبت توانگری مالی موسسه بیمه و اقدامات پیرو آن می‌تواند بر تمامی جوانب شرکت‌های بیمه اثرگذار باشد. لذا تعیین میزان دقیق این نسبت در صنعت بیمه از اهمیت فوق العاده‌ای برخوردار است که لزوم تحقیقات فراوانی در این راستا را فراهم می‌کند.

فهرست منابع

- * رادپور میثم، عیده تبریزی حسین (۱۳۸۸)، اندازه‌گیری و مدیریت ریسک بازار: رویکرد ارزش در معرض ریسک. اول تدوین تهران: آگاه.
- * سارنج علیرضا (۱۳۹۶)، تجزیه و تحلیل ریسک بازار از تئوری تا عمل (به همراه کاربردها در MATLAB و Excel). اول تدوین تهران: نگاه دانش.
- * شهریار بهنام (۱۳۹۵)، مدل آیین نامه نحوه محاسبه و نظارت بر توانگری مالی موسسات بیمه (آیین نامه ۹۶ شورای عالی بیمه)، تهران: طرح‌های پژوهشی سفارشی بیمه مرکزی ج.ا.ایران.
- * فلاح شمس میرفیض (۱۳۸۹)، بررسی مقایسه‌ای کارایی مدل ریسک سنجی و مدل اقتصادسنجی گارچ در پیش‌بینی ریسک بازار در بورس اوراق بهادار تهران. مجله مهندسی مالی و مدیریت پرتفوی، ۱(۵).
- * گرجی مهسا، سجاد رسول (۱۳۹۵)، «برآورد ارزش در معرض خطر چند دوره‌ای بر پایه روش‌های شبیه‌سازی و پارامتریک»، تحقیقات مالی، ۱۸(۱).
- * Acerbi, C. & Tasche, D., 2002. On the coherence of expected shortfall. *Journal of Banking & Finance*, Volume 26.
- * Artzner, P., Delbaen, F., Eber, J.-M. & Heath, D., 1999. Coherent Measures of Risk. *Mathematical Finance*, 9(3).
- * Cossette, H., Mailhot, M. & Marceau, É., 2012. TVaR-based capital allocation for multivariate compound distributions with positive continuous claim amounts. *Insurance: Mathematics and Economics*, Volume 50.
- * Eling, M. & Pankoke, D., 2014. Basis Risk, Procyclicality, and Systemic Risk in the Solvency II Equity Risk Module. *Journal of Insurance Regulation*, 33(1).
- * Embrechts, P., Kaufmann, R. & Patie, P., 2005. Strategic Long-Term Financial Risks: Single Risk Factors. *Computational Optimization and Applications*, 32(1-2).
- * Huang, G.-B., Zhu, Q.-Y. & Siew, C.-K., 2006. Extreme learning machine: Theory and applications. *Neurocomputing*, Volume 70.

- * Kaufmann, R. & Patie, P., 2003. Strategic Long-Term Financial Risks: The One-Dimensional Case. Research Report, RiskLab, ETH Zurich.
- * Kellner, R. & Rösch, D., 2016. Quantifying market risk with Value-at-Risk or Expected Shortfall? Consequences for capital requirements and model risk. Journal of Economic Dynamics & Control, Volume 68.
- * Krause, J. & Paoletta, M., 2014. A fast, accurate method for value-at-risk and expected shortfall. Econometrics, 2(2).
- * McNeil, A. J., Frey, R. & Embrechts, P., 2005. Quantitative Risk Management: Concepts, Techniques and Tools. 1st ed. Princeton: Princeton University Press.
- * Pinjaman, S. B. & Aralas, S. B., 2015. the dynamic stock returns volatility and macroeconomic factors in Malaysia: a Sectoral Study. South East Asia Journal of Contemporary Business, Economics and Law, 8(3).
- * Righi, M. B. & Ceretta, P. S., 2015. A comparison of Expected Shortfall estimation models. Journal of Economics and Business, Volume 78.
- * Sandstrom, A., 2011. Handbook of Solvency for Actuaries and Risk Managers: Theory and Practice. New York: Taylor & Francis Group.
- * Zhang, H.-G. et al., 2017. Calculating Value-at-Risk for high-dimensional time series using a nonlinear random mapping model. Economic Modelling, Volume 67.

یادداشت‌ها

TVaR (Tail Value at Risk)¹ که در ادبیات مالی همچنین با عنوان Expected Shortfall یا ریزش مورد انتظار نیز شناخته شده است.

² EGARCH-Extreme Learning Machine (EGELM)

³ Filtered Historical Simulation (FHS)

⁴ Tail Conditional Expectation

⁵ Feedforward Neural Network

⁶ Least-squares method

⁷ the Moore-Penrose generalized inverse of matrix H

⁸ Support vector machine

⁹ drift

¹⁰ Random Walk

¹¹ Heavy Tailed Distributions

¹² Filtered Historical Simulation

¹³ Volatility-weighted Historical Simulation

¹⁴ Hull & White

¹⁵ Boudoukh, Richardson & Whitelaw (BRW)

¹⁶ Historical Simulation

¹⁷ Bootstrapped Historical Simulation

¹⁸ Leverage Effect

¹⁹ Bartlett's Theory

²⁰ Single-hidden layer feedforward neural network

²¹ outlier robustness problems ELM

²² Equal Predictive Ability

²³ Jarque Bera

²⁴ Kolmogorov-Smirnov

²⁵ Liung Box

²⁶ ARCH(Autoregressive Conditional Heteroscedasticity)

²⁷ outlier robustness problems ELM