فصلنامهٔ پژوهش‌های پولی-بانکی
سال نوزدهم، شمارهٔ ۶۹-پاییز ۱۴۰۵
صفحات ۶۰۹-۶۴۴

سبد سهام برابری ریسک مبتنی بر شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت با رهیافت تجزیهٔ چولسکی

سیف الله حیدری [*]
امیرمحمدزاده [†]
سهیلا خویشتن‌دار [‡]

تاریخ دریافت: ۱۴۰۴/۱۱/۲۸ تاریخ پذیرش: ۱۴۰۵/۰۳/۱۱

چکیده

سبد سرمایه‌گذاری مبتنی بر مفهومِ برابری ریسک، به‌جای تخصیص وزن یکسان به دارایی‌ها، تلاش می‌کند سهم هریک از آن‌ها را در ریسک کل سبد متعادل سازد. چنین رویکردی می‌تواند از وابستگی بیش‌ازحد عملکرد سبد به یک دارایی یا مجموعه‌ای از دارایی‌ها جلوگیری کند و در شرایط نامساعد بازار، ظرفیت سبد را برای مواجهه با نوسانات و تکانه‌های مالی افزایش دهد. باوجوداین، دستیابی به تخصیص ریسک کارآمد، به برآورد دقیق و به‌روزرسانی مستمر ساختار وابستگی میان دارایی‌ها نیاز دارد، زیرا واریانس‌ها، کوواریانس‌ها، و ضرایب همبستگی در بازارهای مالی ثابت نیستند و در طول زمان دستخوش تغییر می‌شوند. در این مطالعه، به‌منظور پیش‌بینی رفتار آتی ماتریس کوواریانس، از شبکهٔ عصبی حافظهٔ بلندمدت-کوتاه‌مدت[§] بهره گرفته شده است. یکی از چالش‌های اساسی در این زمینه، احتمال نامعتبرشدن ماتریس کوواریانس حاصل از پیش‌بینی مدل ازنظر مثبت معین‌بودن است. برای برطرف‌کردن این مسئله، در این پژوهش از تجزیهٔ چولسکی استفاده شده است تا ماتریس پیش‌بینی‌شده ضمن حفظ اطلاعات مربوط به ساختار وابستگی دارایی‌ها، ویژگی مثبت معین‌بودن خود را نیز حفظ کند. چهارچوب پیشنهادی در بازار سهام ایران و بر روی سبدی شامل ۱۰ شاخص اصلی بورس تهران مورد آزمون قرار گرفته است. دورهٔ بررسی از

[*] دانشجوی دکترا، دانشگاه آزاد قزوین، دانشکده مدیریت و حسابداری 4051107663@iau.ac.ir
این مقاله برگرفته از رساله دکترا آقای سیف الله حیدری است.
[†] دانشیار، دانشگاه آزاد قزوین، دانشکده مدیریت و حسابداری (نویسنده مسئول) amir126@iau.ac.ir
[‡] استادیار، دانشگاه آزاد قزوین، دانشکده مدیریت و حسابداری، soheila.khishtandar@iau.ac.ir
[§] Long Short-Term Memory (LSTM)

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

ابتدای سال ۱۳۹۰ آغاز شده است و تا خرداد ۱۴۰۴ ادامه دارد. عملکرد روش مبتنی بر LSTM و تجزیهٔ چولسکی در چهارچوب راهبرد برابری ریسک، با دو رویکرد متداول دیگر، یعنی مدل پنهان مارکوف و مدل DCC-GARCH، مقایسه شده است.

نتایج حاصل از ارزیابی مدل‌ها حاکی از آن است که روش مبتنی بر LSTM در شاخص‌های عملکردی مورد بررسی، شامل متوسط بازده هفتگی، نسبت شارپ، بازده تجمعی، و حداکثر افت سرمایه، عملکرد مطلوب‌تری نسبت به دو روش رقیب داشته است. براساس این یافته‌ها، می‌توان برتری مدل LSTM را به قابلیت آن در استخراج و یادگیری روابط غیرخطی، الگوهای پیچیده، و تغییرات زمانی موجود در رفتار بازار سرمایهٔ ایران نسبت داد؛ ویژگی‌هایی که می‌توانند در پیش‌بینی پویای ساختار کوواریانس و درنتیجه، بهبود تصمیمات مربوط به تخصیص ریسک در سبد سهام مؤثر باشند.

واژه‌های کلیدی: سبد برابری ریسک، شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت، تجزیهٔ چولسکی، مدل پنهان مارکوف، مدل DCC-GARCH.
طبقه‌بندی JEL: G11, G17, C45

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

۱ مقدمه

سرمایه‌گذاری را می‌توان یکی از مهم‌ترین سازوکارهای شکل‌گیری ظرفیت‌های تولیدی و تحقق رشد پایدار اقتصادی دانست. در این میان، بازار سرمایه با فراهم‌کردن امکان انتقال منابع مالی از صاحبان وجوه به بخش‌های نیازمند سرمایه، نقش مهمی در فرایند تأمین‌مالی فعالیت‌های اقتصادی بر عهده دارد. بورس اوراق بهادار نیز با گردآوری سرمایه‌های پراکنده و هدایت آن‌ها به‌سمت فرصت‌های سرمایه‌گذاری، ازیک‌سو به توسعه و گسترش فعالیت بنگاه‌های اقتصادی کمک می‌کند و ازسوی‌دیگر، امکان مشارکت افراد در ایجاد ثروت و کسب بازده از فعالیت‌های اقتصادی را فراهم می‌سازد. از دیدگاه اقتصادی، سرمایه‌گذاری به معنای صرف‌نظرکردن از بخشی از مصرف در زمان حال با هدف دستیابی به منافع و سطح مصرف مطلوب‌تر در آینده است. ازآنجاکه تحقق بازده آتی با عدم‌اطمینان همراه است، پذیرش ریسکْ بخش جدایی‌ناپذیر تصمیمات سرمایه‌گذاری محسوب می‌شود و سرمایه‌گذار انتظار دارد در مقابل ریسک متحمل‌شده، بازدهی متناسب دریافت کند. در چنین شرایطی، مدیریت صحیح ریسک و نحوهٔ ترکیب دارایی‌ها اهمیت ویژه‌ای پیدا می‌کند. نظریهٔ مدرن سبد سهام نیز در همین راستا به‌عنوان یکی از چهارچوب‌های اصلی تصمیم‌گیری مالی شکل گرفته است و بر انتخاب ترکیبی از دارایی‌ها تأکید دارد که بتواند رابطهٔ میان ریسک و بازده سبد را به‌نحو مطلوب مدیریت کند.

در سال‌های اخیر، رویکردهای مبتنی بر تخصیص ریسک در حوزهٔ مدیریت دارایی مورد توجه گسترده‌تری قرار گرفته‌اند. یکی از مهم‌ترین این رویکردها، مدل برابری ریسک است که منطق تخصیص سرمایه را از تمرکز صِرف بر بازده مورد انتظار به‌سمت توزیع متوازن ریسک تغییر می‌دهد. برخلاف چهارچوب میانگین-واریانس مارکویتز که برای تعیین ترکیب بهینهٔ سبد به برآورد بازده مورد انتظار دارایی‌ها نیاز دارد، مدل برابری ریسک عمدتاً بر اطلاعات مربوط به ریسک و روابط متقابل میان دارایی‌ها تکیه می‌کند. در این چهارچوب، هدف آن است که هر دارایی سهمی متناسب و برابر از ریسک کل سبد داشته باشد؛ درنتیجه، وزن‌دهی دارایی‌ها صرفاً براساس میزان بازده پیش‌بینی‌شده انجام نمی‌شود. این ویژگی باعث می‌شود حساسیت روش در قبال خطاهای ناشی از پیش‌بینی بازده مورد انتظار کاهش یابد (سالاس و همکاران[1]، ۲۰۲۵).

[1] Salas et al.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

باوجود مزیت‌های نظری مدل برابری ریسک، کیفیت نتایج آن ارتباط مستقیمی با نحوهٔ تخمین ساختار وابستگی میان دارایی‌ها دارد. به بیان دیگر، چنانچه ماتریس کوواریانس به‌درستی برآورد نشود، وزن‌های حاصل از مدل نیز می‌توانند از تخصیص بهینه فاصله بگیرند. این موضوع در بازارهای مالی از اهمیت بیشتری برخوردار است، زیرا نوسانات، واریانس، و همبستگی میان دارایی‌ها در طول زمان ثابت باقی نمی‌مانند و تحت‌تأثیر شرایط مختلف اقتصادی و بازار تغییر می‌کنند؛ بنابراین، استفاده از برآوردهای ثابت و ایستا از ماتریس کوواریانس ممکن است نتواند تحولات واقعی ریسک و وابستگی میان دارایی‌ها را منعکس کند. همین مسئله موجب شده است که بخش قابل‌توجهی از مطالعات جدید به‌سمت روش‌های پویا و مبتنی بر داده برای پیش‌بینی ساختار کوواریانس حرکت کنند.

هم‌زمان با این تحولات، گسترش روش‌های هوش مصنوعی، به‌خصوص الگوریتم‌های یادگیری ماشین و یادگیری عمیق ، امکانات تازه‌ای برای تحلیل و پیش‌بینی متغیرهای مالی فراهم کرده است. بازارهای مالی به‌دلیل برخورداری از حجم بالای اطلاعات، وجود نویز، روابط غیرخطی میان متغیرها، و تغییرپذیری قابل‌توجه در طول زمان، ازجمله حوزه‌هایی هستند که استفاده از مدل‌های پیشرفتهٔ یادگیری می‌تواند در آن‌ها مزیت ایجاد کند. برخلاف بسیاری از مدل‌های سنتی که برای توصیف رفتار داده‌ها به مجموعه‌ای از فروض آماری ازپیش‌تعیین‌شده متکی‌اند، شبکه‌های عمیق این قابلیت را دارند که با استفاده از داده‌های تاریخی، روابط پیچیده و الگوهای نهفته را شناسایی کنند. این توانایی به‌ویژه در مسائلی که رفتار متغیرها دارای وابستگی زمانی و ساختار غیرخطی است، اهمیت بیشتری پیدا می‌کند.

بر همین اساس، این پژوهش با هدف ارتقای فرایند تخصیص ریسک در چهارچوب مدل برابری ریسک، از شبکهٔ LSTM برای پیش‌بینی پویای ماتریس کوواریانس استفاده می‌کند. نکتهٔ محوری در روش پیشنهادی، نحوهٔ مواجهه با یکی از محدودیت‌های مهم پیش‌بینی مستقیم ماتریس کوواریانس است، زیرا خروجی یک مدل پیش‌بینی‌کننده لزوماً ویژگی مثبت معین‌بودن موردِنیاز برای نوعی ماتریس کوواریانس معتبر را تضمین نمی‌کند. برای رفع این چالش، در این پژوهش از تجزیهٔ چولسکی استفاده شده است. این روش با تبدیل مسئلهٔ پیش‌بینی ماتریس کوواریانس به پیش‌بینی مؤلفه‌های ساختاری آن، امکان تولید ماتریسی معتبر و قابل‌استفاده در فرایند بهینه‌سازی سبد را فراهم می‌آورد و درعین‌حال می‌تواند پیچیدگی محاسباتی مسئله را کاهش دهد.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

در ادامه، کارایی چهارچوب پیشنهادی با استفاده از مدل‌های رقیب، ازجمله مدل پنهان مارکوف[1] (HMM) و مدل همبستگی شرطی پویا مبتنی بر GARCH[2] (DCC-GARCH) مقایسه می‌شود. این مقایسه با هدف بررسی میزان دقت پیش‌بینی، پایداری عملکرد، و توانایی مدل‌ها در مواجهه با تغییرات و نوسانات بازار سرمایهٔ ایران انجام می‌شود. از این طریق، پژوهش تلاش دارد مشخص کند ترکیب قابلیت‌های یادگیری زمانی LSTM با تجزیهٔ چولسکی می‌تواند در مقایسه با روش‌های متعارف‌تر، به تخصیص ریسک کارآمدتر و عملکرد مناسب‌تر سبد سهام منجر شود یا خیر.

۲ مبانی نظری و پیشینهٔ پژوهش

یکی از مهم‌ترین دستاوردهای اخیر در نظریهٔ سبد سهام، رویکرد سبد برابری ریسک است. برخلاف مدل کلاسیک مارکویتز که مبتنی بر بهینه‌سازی بازده مورد انتظار در برابر ریسک است، سبد برابری ریسک تنها بر تخصیص متوازن ریسک میان دارایی‌ها تمرکز دارد و از برآورد مستقیم بازده چشم‌پوشی می‌کند. در این چهارچوب، هدف اصلی به‌جای حداکثرسازی بازده، حداقل‌سازی تمرکز ریسک است؛ به‌گونه‌ای که هر دارایی سهم برابری از ریسک کل سبد سرمایه‌گذاری را به خود اختصاص دهد. این ویژگی باعث شده است سبدهای برابری ریسک نسبت به خطاهای برآورد پارامترها و شرایط غیرمنتظرهٔ بازار حساسیت پایین‌تری داشته باشند (دکوویچ و سیمویچ[3]، ۲۰۲۵). مطالعات تجربی بین‌المللی نشان داده‌اند که سبدهای برابری ریسک در مقایسه با سبدهای میانگین-واریانس در دوره‌های رکود و بحران‌های مالی پایدارترند و نسبت شارپ بالاتری را ارائه می‌دهند (سالاس و همکاران، ۲۰۲۵). این بدان معناست که سرمایه‌گذاران درازای واحدی از ریسک، بازدهی بیشتری کسب می‌کنند و هم‌زمان سبد سرمایهٔ آن‌ها در برابر ریزش‌های شدید بازار مقاومت بیشتری از خود نشان می‌دهد. به عبارتی، تعادل در تخصیص ریسک میان دارایی‌ها به کاهش نوسانات، هموارسازی بازده‌ها، و افزایش پایداری بازدهی در افق زمانی بلندمدت می‌انجامد. باوجود این مزایا، عملکرد دقیق مدل‌های برابری ریسک به دقت تخمین ماتریس کوواریانس دارایی‌ها وابسته است، زیرا این ماتریس بنیان محاسبهٔ سهم ریسک هر دارایی در سبد را تشکیل می‌دهد. در بسیاری از مدل‌های سنتی،

[1] Hidden Markof Model

[2] Generalized Autoregressive Conditional Heteroskedasticity

[3] Deković & Šimović

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

فرض می‌شود که ساختار همبستگی میان دارایی‌ها ایستاست، درحالی‌که واقعیت بازارهای مالی نشان می‌دهد کوواریانس‌ها به‌صورت پویا در زمان تغییر می‌کنند؛ ازاین‌رو، شناسایی و پیش‌بینی لحظه‌ای این پویایی اهمیت حیاتی دارد.

در سال‌های اخیر، درک پویایی رفتار بازارهای مالی و توسعهٔ راهبردهای بهینهٔ تخصیص دارایی یکی از چالش‌های اصلی پژوهشگران حوزهٔ مالی بوده است. مطالعات تجربی فراوان نشان داده‌اند که رفتار قیمتی سهام و دارایی‌های مالی به‌شدت غیرخطی، پویا، و پیچیده است و مدل‌های خطی کلاسیک، نظیر مدل‌های رگرسیونی سنتی، توانایی محدودی در پیش‌بینی چنین پویایی‌ای دارند. در مقابل، مدل‌های غیرخطی، به‌ویژه مدل‌های مبتنی بر یادگیری ماشین و شبکه‌های عصبی، قابلیت بالاتری در مدل‌سازی روابط پیچیده و تعاملات غیرخطی بین متغیرهای مالی از خود نشان می‌دهند (اقتصاد و محمدی، ۱۴۰۲). شبکه‌های عصبی، با الهام از ساختار عصبی مغز انسان و توانایی یادگیری از داده‌ها، ابزارهای قدرتمندی برای کشف الگوهای پنهان در سری‌های زمانی مالی به شمار می‌روند.

یک گسترش از شبکه‌های عصبی عمیق که برای پردازش داده‌های دنباله‌ای یا وابسته به زمان مورد استفاده قرار می‌گیرد، شبکه‌های بازگشتی[1] است. چالش مدل یادشده در این است که با زیادشدن تعداد داده‌های آموزشی، گذشتهٔ خود یا زمینهٔ بحث را فراموش می‌کنند. برای رفع این نقیصه، شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت به وجود آمده‌اند که توسط یک سلول حافظه، گذشته را به خاطر می‌سپارند یا بخشی از آن را فراموش می‌کنند. درمجموع، شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت رده‌ای از شبکه‌های عصبی عمیق‌اند که معمولاً برای پردازش بر روی ورودی‌های دنباله‌ای در یادگیری ماشین استفاده می‌شوند.

در این راستا، شبکه‌های عصبی حافظهٔ بلندمدت و کوتاه‌مدت به‌عنوان یکی از قدرتمندترین ابزارهای یادگیری عمیق برای مدل‌سازی داده‌های وابسته به زمان مورد استفاده قرار گرفته‌اند. این شبکه‌ها با قابلیت به‌خاطرسپاری وابستگی‌های بلندمدت در سری‌های زمانی، می‌توانند تغییرات ساختاری در کوواریانس دارایی‌ها را به‌دقت شناسایی کنند. ازآنجاکه ماتریس کوواریانس پیش‌بینی‌شده ممکن است به‌دلیل پیچیدگی مدل‌های یادگیری عمیق، خاصیت مثبت معین‌بودن خود را از دست بدهد، تلاش برای محاسبهٔ آن، ریسک‌های نامعتبر را به‌همراه خواهد داشت (لی و لیو[2]، ۲۰۲۳). این پژوهش برای مواجهه

[1] recurrent neural network

[2] Li & Liu

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

با این چالش از نوعی نوآوری استفاده خواهد کرد و آن رهیافت تجزیهٔ چولسکی ماتریس کوواریانس است. تجزیهٔ چولسکی روشی پایه‌ای در جبر خطی عددی است که ماتریس‌های متقارن و مثبت معین را به حاصل‌ضرب یک ماتریس مثلثی پایینی در ترانهاده‌اش تجزیه می‌کند؛ ازاین‌رو، به‌جای پیش‌بینی مستقیم ماتریس کوواریانس، ماتریس پایین‌مثلثی مورد پیش‌بینی قرار می‌گیرد و سپس ماتریس کوواریانس اصلی از حاصل‌ضرب پیش‌بینی ماتریس پایین‌مثلثی در ترانهادهٔ آن بازسازی می‌شود؛ بنابراین، تجزیهٔ چولسکی به‌عنوان نوعی فیلتر اعتبارسنجی اجباری عمل می‌کند؛ اگر ماتریسْ نامعتبر تشخیص داده شود، سامانه یک مرحلهٔ منظم‌سازی را برای بازیابی خاصیت مثبت معین‌بودن به‌کار می‌گیرد. بدین‌ترتیب، مدل اصلی پژوهش باتوجه‌به تاریخچهٔ ماتریس کوواریانس (به‌عنوان یک سری زمانی) از شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت برای پیش‌بینی ماتریس کوواریانس در افق زمانی آتی سبد سهام بهره می‌برد. با بهره‌گیری از تجزیهٔ چولسکی، سری زمانی ماتریس‌های کوواریانس ابتدا به سری ماتریس‌های پایین‌مثلثی تبدیل می‌شود و سپس با پیش‌بینی ماتریس پایین‌مثلثی، ماتریس کوواریانس بازیابی می‌شود. درنهایت، با پیش‌بینی ماتریس کوواریانس، سبد سهام بهینه برابری ریسک مورد بهینه‌سازی قرار می‌گیرد.

در این پژوهش، دو رویکرد پرکاربرد دیگر در زمینهٔ تخمین پارامتر کوواریانس، یعنی مدل پنهان مارکوف و DCC-GARCH نیز به‌کار خواهد رفت تا نتایج سودآوری سبدهای بهینهٔ حاصل از رویکرد پژوهش با آن دو مدل مقایسه شود. مدل مارکوف پنهان نوعی چهارچوب آماری قدرتمند است که برای مدل‌سازی سری‌های زمانی طراحی شده است که در آن مشاهداتِ قابل‌رؤیت، تابعی از یک فرایند حالت زیربنایی هستند که مستقیماً قابل اندازه‌گیری نیست. این مدل بر پایهٔ دو ایدهٔ کلیدی بنا شده است: نخست، اینکه سامانه در هر لحظه در یکی از N حالت مجزا قرار دارد؛ و دوم، خاصیت مارکوفی که بیان می‌کند حالت فعلی تنها به حالت بلافاصلهٔ قبلی وابسته است، نه کل تاریخچه. انتقال بین این حالت‌های پنهان توسط ماتریس احتمال کنترل می‌شود و هر حالت پنهان نیز نوعی توزیع احتمال مجزا برای تولید داده‌های مشاهده‌پذیر (مانند بازده سهام یا نوسانات بازار) فراهم می‌کند.

اهمیت مدل پنهان مارکوف در حوزهٔ مالی بسیار زیاد است، زیرا بازارهای مالی به ماهیت خود ایستا نیستند؛ به این معنا که میانگین بازده، واریانس، و همبستگی بین دارایی‌ها در طول زمان تغییر می‌کند. مدل پنهان مارکوف این واقعیت را به‌شکلی طبیعی مدل‌سازی می‌کند و به سرمایه‌گذاران این امکان را می‌دهد که رژیم‌های مختلف بازار را تشخیص دهند.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

این رژیم‌ها می‌توانند به‌صورت حالت‌های صعودی (با بازده بالا و ریسک کم) یا حالت‌های نزولی و بحرانی (با نوسان بالا) تفسیر شوند (ماجومدر و نیرچال[1]، ۲۰۲۴). این توانایی تشخیص حالت، امکان بهبود چشمگیری در بهینه‌سازی سبد سهام را فراهم می‌آورد. در روش‌های سنتی مانند مارکویتز، یک ماتریس کوواریانس واحد فرض می‌شود، اما مدل پنهان مارکوف به ما اجازه می‌دهد برای هر رژیم پارامترهای آماری متمایزی را تخمین بزنیم. این موضوع منجر به تخصیص دارایی پویا می‌شود.

مدل DCC-GARCH نیز که رابرت اِنگل[2] در سال ۲۰۰۲ معرفی کرد، رویکردی قدرتمند و انعطاف‌پذیر برای مدل‌سازی ماتریس کوواریانس شرطی در سبدهای مالی است. این مدل که توسعه‌ای از مدل‌های GARCH استاندارد و CCC-GARCH به شمار می‌رود، توانایی قابل‌توجهی در ثبت و تحلیل پویایی همبستگی‌ها بین دارایی‌های مالی در طول زمان دارد. مزیت کلیدی مدل DCC-GARCH در این است که واریانس (نوسان‌پذیری) شرطی هر دارایی را به‌صورت مجزا مدل‌سازی و سپس همبستگی شرطی بین دارایی‌ها را به‌عنوان مدلی مستقل و پویا پیاده‌سازی می‌کند. این تفکیکْ مدل را هم ازنظر محاسباتی مدیریت‌پذیر می‌سازد و هم به آن امکان ثبت پدیده‌های پیچیدهٔ بازار، مانند افزایش ناگهانی همبستگی در زمان بحران‌ها، را می‌دهد (کوین و یوگوپوسیتو[3]، ۲۰۲۵).

در ادامه به پیشینهٔ برخی از پژوهش‌هایی پرداخته می‌شود که در آن از ابزارهای هوش مصنوعی و یادگیری عمیق در خلال پیش‌بینی و بهینه‌سازی سبد سهام استفاده شده است. هراتی‌زاده و رضایی (۱۴۰۲) در پژوهشی با عنوان «ارائهٔ روشی جدید برای بهره‌گیری از یادگیری ماشین در فرایند بهینه‌سازی سبد سهام»، بر دو مرحله به‌طور مجزا اما متوالی تأکید کرده‌اند. آن‌ها چهارچوب نوآورانهٔ «Per-Learner» را معرفی کردند که از دو مدل یادگیری ماشین مجزا استفاده می‌نماید: مدل اول وظیفهٔ انتخاب بهینهٔ سهام را بر عهده دارد؛ و مدل دوم، با پیش‌بینی‌های خود، تخصیص وزن‌های بهینه برای سرمایه را در سبد منتخب تعیین می‌کند. این رویکرد دومرحله‌ای در ارزیابی‌ها نشان داد که بازده تجمعی سبد سهام را به‌طور قابل‌توجهی نسبت به سایر روش‌های موجود ارتقا می‌دهد. کیانی‌زاده، باغانی، و حمیدیان (۱۴۰۲) در پژوهشی با تمرکز بر روش داده‌کاوی به مقایسهٔ دقت

[1] Majumder & Neerchal
[2] Robert Engle
[3] Kevin & Yugopuspito

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

مدل‌های منتخب یادگیری ماشین شامل شبکهٔ عصبی، رگرسیون لجستیک، نزدیک‌ترین همسایه، ماشین بردار پشتیبان، و اعتبارسنجی ضربدری جهت پیش‌بینی قیمت سهام برای ۱۲ شرکت منتخب بورس اوراق بهادار تهران که از طریق روش حذف سیستماتیک انتخاب شده‌اند در قالب مدل‌های یادگیری ماشین پرداختند و نتایج نشان داد از بین الگوریتم‌های یادگیری ماشین، الگوریتم ماشین بردار پشتیبان بیشترین قدرت پیش‌بینی‌کنندگی در قیمت سهام را به خود اختصاص داده است.

اقتصاد و محمدی (۱۴۰۲) در پژوهش خود با عنوان «بهینه‌سازی سبد سرمایه‌گذاری به کمک پیش‌بینی بازده مورد انتظار با استفاده از روش‌های شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت، جنگل تصادفی، و آریما»، ایده‌ای نوآورانه را مطرح ساختند. آن‌ها استدلال می‌کنند که تأکید بر پیش‌بینی‌پذیری گزینه‌های سرمایه‌گذاری (علاوه‌بر سود و ریسک سنتی) برای سرمایه‌گذاران حیاتی است. نتایج تجربی آن‌ها که براساس داده‌های پنج‌سالهٔ پنج صنعت بورسی (بانکی، خودرویی، دارویی، فلزی، و نفتی) انجام شد، نشان داد مدل‌های بهینه‌سازی میانگین-واریانس زمانی که بازده مورد انتظار با استفاده از مدل جنگل تصادفی پیش‌بینی شده باشد، عملکرد بهتری نسبت به استفاده از سایر مدل‌های پیش‌بینی مانند آریما یا شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت از خود نشان می‌دهند. این پژوهش برتری مدل‌های یادگیری ماشین بر مدل‌های سری زمانی سنتی را در حوزهٔ پیش‌بینی برای بهینه‌سازی اثبات می‌کند. اسفندیار، کرامتی، و غلامی جمکرانی (۱۴۰۱) با تمرکز بر رویکرد یادگیری تقویتی به بهینه‌سازی سبد سهام پرداختند. یافته‌های پژوهش در دوره‌های صعودی و نزولی بازار نشان داد که رویکرد یادگیری تقویتی در بازارهای صعودی و نزولی به‌صورت معناداری بر رویکرد خرید و نگهداری برتری دارد و عملکرد بهتری ارائه داده است و نتایج با عملکرد الگوریتم‌ها در بازارهای بورس سازگار است. نتایج آشکار کرد که از دیدگاه سودآوری، رویکرد یادگیری تقویتی نسبت به رهیافت خرید و نگهداری، عملکرد بهتر و مؤثرتری داشته است؛ بنابراین، به‌کارگیری روش یادگیری تقویتی پیشنهاد می‌شود.

سالاس و همکاران (۲۰۲۵) به بررسی رویکرد ریسک برابری سلسله‌مراتبی به‌عنوان راه‌حلی برای مشکلاتی مانند بی‌ثباتی و تمرکز بالا در تخصیص دارایی پرداختند. آن‌ها با استفاده از روش‌های یادگیری ماشین و خوشه‌بندی مبتنی بر ماتریس کوواریانس، ساختار سلسله‌مراتبی بین دارایی‌ها را مدل کردند و نشان دادند که نسخه‌های مبتنی بر همبستگی HRP در سناریوهای مختلف بازار نسبت بازده به ریسک بهتری دارند و در بیشتر شرایط از روش‌های کلاسیک بهینه‌سازی عملکرد پایدارتر و منعطف‌تری ارائه می‌دهند. دکوویچ و سیمویچ (۲۰۲۵) نیز به پیاده‌سازی کارآمد الگوریتم HRP برای کاربردهای بلادرنگ

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

پرداختند. آن‌ها با بهینه‌سازی زمان محاسبات و استفاده از داده‌های تاریخی P&S 500 طی سال‌های ۲۰۰۵ تا ۲۰۲۳، عملکرد HRP را با روش تخصیص مساوی (N/۱) مقایسه کردند. نتایج نشان داد هرچند روش N/۱ بازدهی بیشتری دارد، HRP دارای نوسان کمتر (حدود ۱ درصد کمتر) است، که آن را در شرایطی با اولویت کنترل ریسک، به گزینه‌ای برتر تبدیل می‌کند.

آگال و رالجی و اوددلا[1] (۲۰۲۵) نوعی چهارچوب یادگیری ماشین برای تخصیص دارایی مبتنی بر ریسک در بهینه‌سازی سبد سهام ارائه کردند که از شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت برای پیش‌بینی نوسان و لایه‌های بودجه‌ریزی ریسک قابل‌مشتق بهره می‌برد تا وزن‌های سبد را به‌صورت پویا تحت قیود ریسک تنظیم کند. این روش باتوجه‌به شاخص‌های واقعی بازار مانند انتظارات نوسان و اسپردهای اعتباری، ریسک هدف را به‌روز می‌کند و فراتر از رویکردهای سنتیْ با کوواریانس ثابت عمل می‌کند. نتایج آزمایش‌های تجربی نشان داد چهارچوب پیشنهادی نسبت شارپ بهتری را نسبت به راهبردهای سنتی و روش‌های یادگیری عمیق موجود ارائه می‌دهد، به‌خصوص در شرایط بازار پرنوسان. کوین و یوگوپوسیتو (۲۰۲۵) روش ترکیبی جدیدی را با ادغام پیش‌بینی‌های شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت و الگوریتم یادگیری تقویتی برای بهینه‌سازی پویای سبد سهام معرفی کردند. هدف این مطالعه افزایش قابلیت تطبیقی مدل در فضاهای اعمال پیوسته و بهره‌گیری از وابستگی‌های زمانی داده‌های مالی بود. در این روش، شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت وابستگی‌های زمانی قیمت‌ها را پیش‌بینی و عامل الگوریتم یادگیری تقویتی وزن‌های دارایی را تنظیم می‌کند. ارزیابی مدل در داده‌های دارایی‌های مختلف نشان داد که این معماری ترکیبی نسبت به روش‌های مرجع، بازده سالانهٔ بالاتر و مقاومت بیشتری در برابر رژیم‌های بازار غیرایستا دارد.

لی[2] (۲۰۲۵) نشان داد استفاده از مدل شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت برای پیش‌بینی قیمت و نوسان می‌تواند به تعیین وزن‌های سبد سهام کمک کند و بازده تجمعی قابل‌توجهی در دوره‌های آزمایشی به‌دست آورد. این مطالعه به طور مستقیم مدل شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت را با دو راهبرد کمینه‌سازی واریانس و بیشینه‌سازی نسبت شارپ ترکیب کرد و نتایج نشان داد که رویکرد مبتنی بر شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت بازدهی بسیار بیشتری نسبت به شاخص‌های بازار پایه ارائه می‌دهد. این

[1] Agal, Raulji, & Odedra
[2] Li

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

نشان‌دهندهٔ ارزش‌افزودهٔ این روش‌های یادگیری عمیق در ساخت سبد سهام است. فن[1] (۲۰۲۵) نوعی رویکرد ترکیبی از مدل شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت و مدل میانگین-واریانس را برای بهینه‌سازی سبد سهام معرفی کرد. در این مطالعه، مدل شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت برای پیش‌بینی بازده‌های آینده با بهره‌گیری از داده‌های تاریخی استفاده شد و سپس این پیش‌بینی‌ها به مدل سنتی میانگین-واریانس داده شد تا سبد بهینه ساخته شود. نتایج نشان می‌دهد که این روشِ ترکیبی در طول داده‌های طولانی‌مدت FTSE 100 نسبت به مدل‌های مرجع عملکرد بهتری دارد، که اهمیت تلفیق روش‌های یادگیری عمیق با نظریهٔ سبد کلاسیک را برجسته می‌کند.

تالیارد[2] (۲۰۲۵) از مدل پنهان مارکوف برای شناسایی رژیم‌های نوسان در بازار اوراق بهادار با درآمد ثابت استفاده کرد تا به تخصیص بهینهٔ دارایی‌ها در طی بازارهای با نوسان بالا و پایین بپردازد. این روش نشان داد که مدیریت رژیم‌های بازار می‌تواند منجر به بهبود بازده تعدیل‌شده با ریسک نسبت به روش‌های بدون درنظرگرفتن رژیم شود، که اهمیت کاربرد مدل پنهان مارکوف در بازارهای متنوع مالی را افزایش می‌دهد. ماجومدر و نیرچال (۲۰۲۴) به توسعهٔ نوعی مدل مارکوف پنهان چندمتغیره برای انتخاب سبد سهام پرداختند. هدف آن‌ها شناسایی رژیم‌های بازار (مانند دوره‌های گاوی و خرسی) در داده‌های تاریخی سهام S&P 500 با استفاده از مدل پنهان مارکوف‌های مرتبط بود تا بتوانند سبد بهینه‌ای باتوجه‌به این رژیم‌ها بسازند. نتایج نشان داد که سبدهای به‌دست‌آمده از مدل مارکوف پنهان چندمتغیره می‌توانند بازده سالانه‌ای مشابه یا بهتر از شاخص بازار ارائه کنند، که نشان‌دهندهٔ توانایی مدل پنهان مارکوف در استفاده از ساختارهای پنهان بازار برای تصمیم‌گیری تخصیص دارایی است.

فرناندز، گارسیا سانچز و اوردیرس مره [3] (۲۰۲۴) به بررسی سیستماتیک کاربرد الگوریتم‌های یادگیری تقویتی در بهینه‌سازی سبد سهام پرداختند. هدف پژوهش مقایسهٔ ساختارهای مختلف عامل یادگیری تقویتی مانند DQN، DDPG، PPO، و SAC بود تا تأثیر آن‌ها بر بهره‌وری سبد سهام در دوره‌های زمانی و سیگنال‌های مختلف بازار سنجیده شود. نتایج این مطالعه نشان داد که مدل‌های یادگیری تقویتی عمیق توانایی بهتری در یادگیری سیاست‌های تخصیص پویا و تطبیق با تغییرات بازار نسبت به روش‌های آماری

[1] Fan

[2] Taljaard

[3] Fernández, García Sánchez, & Ordieres Meré

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

سنتی دارند و می‌توانند ریسک-بازده سبد را بهبود دهند. لی و لیو (۲۰۲۳) تلاش کردند تا مدل شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت را برای پیش‌بینی بازده سهام به‌کار ببرند و سپس نتایج پیش‌بینی را در مدل بهینه‌سازی میانگین-واریانس وارد کنند تا وزن‌های بهینهٔ سبد را تعیین کنند. آن‌ها مشاهده کردند که سبد بهینه‌شده با کمک پیش‌بینی‌های شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت عملکرد بهتری در مقایسه با شاخص S&P 500 ازنظر بازده و ریسک دارد، که نشان‌دهندهٔ توانایی این ترکیب یادگیری عمیق و روش‌های کلاسیک برای بهبود ساخت سبد است.

۳ مدل پژوهش

در این بخش، در گام نخست، صورت‌بندی سبد سرمایه‌گذاری مبتنی بر برابری ریسک ارائه می‌شود. در چهارچوب این مدل، تلاش می‌شود تا توزیع متوازن ریسک میان دارایی‌های مختلف موجود در سبد سرمایه‌گذاری تحقق یابد؛ به‌گونه‌ای که هر دارایی سهمی برابر از ریسک کلی سبد را بر عهده داشته باشد. یکی از مفاهیم بنیادینی که در این زمینه نقشی کلیدی ایفا می‌کند، قضیهٔ اویلر[1] برای توابع همگن است. این قضیه به ما این امکان را می‌دهد که به‌صورت دقیق و ریاضیاتی، سهم نسبی هر دارایی را از ریسک کل تعیین کنیم و از این طریق ساختاری متعادل و قابل‌کنترل برای سبد سرمایه‌گذاری ایجاد نماییم. قضیهٔ اویلر بیان می‌کند که برای تابع همگن f رابطهٔ (۱) برقرار است.

$$f(x=(x_1,x_2,\dots,x_n)) = x_1\frac{\partial f(x)}{\partial x_1} + x_2\frac{\partial f(x)}{\partial x_2} + \dots + x_n\frac{\partial f(x)}{\partial x_n} \qquad (۱)$$

درصورتی‌که تابع f نشان‌دهندهٔ ریسک سبد سهام باشد، آنگاه رابطهٔ (۱) را می‌توان به این صورت تأویل کرد که $x_i\frac{\partial f(x)}{\partial x_i}$ سهم ریسک دارایی iام از ریسک کل سبد سهام است. فرض کنیم n دارایی با بردار وزن x تشکیل سبد سهام بدهد. آنگاه انحراف معیار بازده سبد سهام به‌عنوان سنجه‌ای برای اندازه‌گیری ریسک σ_i برابر $\sigma_p = \sqrt{x^t \Sigma x}$ خواهد بود که Σ ماتریس کوواریانس دارایی‌هاست. درصورتی‌که $1 \le i \le n$ سهم ریسک هر دارایی از ریسک سبد سهام باشد (σ_i در اینجا نشان‌دهندهٔ انحراف معیار نیست)، آنگاه می‌توان نوشت:

[1] Euler

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

$$\sigma_p = \sqrt{x^t \Sigma x} = \sum_{i=1}^{n} \sigma_i. \quad (۲)$$

ازطرفی مطابق رابطهٔ اویلر، سهم ریسک دارای iام برابر $\sigma_i = x_i \frac{(\Sigma x)_i}{\sqrt{x^t \Sigma x}}$ است. مدل برابری ریسک به‌دنبال یکسان‌سازی سهم ریسک دارایی‌ها از ریسک کل سبد است و برای این منظور به بهینه‌سازی مدل رابطهٔ (۳) اقدام می‌کند. در مدل (۳)، باتوجه‌به مثبت‌بودن عواملی که در تابع هدف وجود دارد، برای کمینه‌شدن باید تمامی عوامل تا حد ممکن به هم نزدیک شوند و این یعنی تمام سهم ریسک‌ها یا σ_iها باید تا حد ممکن نزدیک به هم شود.

$$\begin{aligned} min \quad & \sum_{i=1}^{n} \sum_{j=1}^{n} (x_i \frac{(\Sigma x)_i}{\sqrt{x^t \Sigma x}} - \frac{1}{n})^2 \quad (۳) \\ & 1^t x = 1 \\ & x \geq 0 \end{aligned}$$

همان‌طور که در رابطهٔ (۳) دیده می‌شود، پارامتر اصلی در مدل برابری ریسک، ماتریس کوواریانس بازده دارایی‌های تشکیل‌دهندهٔ سبد سهام است. هدف این پژوهش برآورد پویای این پارامتر به کمک شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت با رهیافت تجزیهٔ چولسکی است. شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت گسترش‌یافته از شبکه‌های بازگشتی هستند که در آن برای رفع مشکل محوشوندگی گرادیان[1] از مفهوم حافظه به‌همراه تعدادی گیت[2] استفاده می‌شود. محوشوندگی گرادیان بیان می‌کند که با بزرگ‌ترشدن دنبالهٔ شبکه‌های متصل به هم در شبکه‌های بازگشتی، الگوریتم گرادیان نزولی که درجهت آموزش شبکه مورد استفاده قرار می‌گیرد، توانایی به‌روزرسانی اوزان را به‌صورت مؤثر از دست می‌دهد. برای رفع این مشکل واحد حافظه به شبکه‌های بازگشتی اضافه شده است و شبکه‌های حافظهٔ بلندمدت-کوتاه‌مدت شکل گرفته‌اند. واحد حافظه می‌تواند اطلاعات زمینه را حفظ کند، اطلاعاتی را به حافظه بسپارد، و/ یا اطلاعاتی را فراموش نماید. در ادامه، ساختار نوعی شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت و پارامترهای قابل‌آموزش آن بیان می‌شود. در هر شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت از c_t به‌عنوان بردار نشان‌دهندهٔ حافظه یا زمینه استفاده می‌شود. اطلاعات لایهٔ پنهانِ هر بخش از شبکه با بردار h_t و اطلاعات ورودی با x_t

[1] graidient vanishing

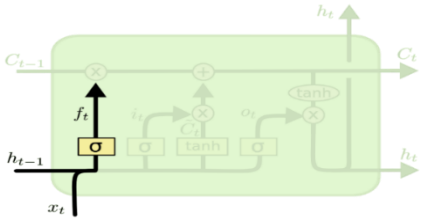
[2] Gate

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

نشان داده می‌شود. در لحظهٔ t، اطلاعات h_{t-1} (مربوط به گذشتهٔ سیستم) و x_t (اطلاعات جدید) در اختیار شبکه قرار می‌گیرد و مطابق رابطهٔ (۴)، اطلاعات گذشتهٔ سیستم به h_t تغییر پیدا می‌کند و خروجی سیستم o_t محاسبه می‌شود.

$$h_t = \sigma(Wx_t + Uh_{t-1} + b), o_t = \sigma(Vh_t + b) \quad (۴)$$

ماتریس‌های W,U,V,b شامل پارامترهای قابل‌آموزش سیستم هستند و σ نشان‌دهندهٔ تابع سیگموئید[1] است. در ادامه، بخشی از اطلاعات در اختیار، یعنی $[x_t, h_{t-1}]$، مطابق شکل ۱ مورد فراموشی قرار می‌گیرد. در این رابطه نیز W_f و b به‌ترتیب ماتریس و بردارهایی قابل‌آموزش‌اند.



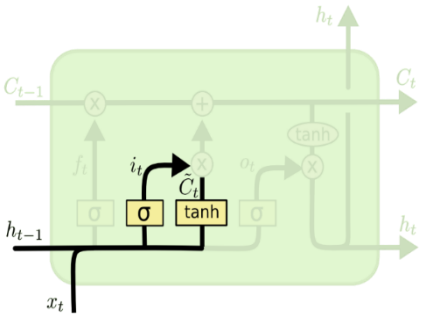
$$f_t = \sigma\left(W_f \cdot [h_{t-1}, x_t] \; + \; b_f\right)$$

شکل ۱. نحوهٔ فراموشی در شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت

بخشی از اطلاعات در دسترس مطابق شکل ۲ حفظ می‌شود.

[1] sigmoid function

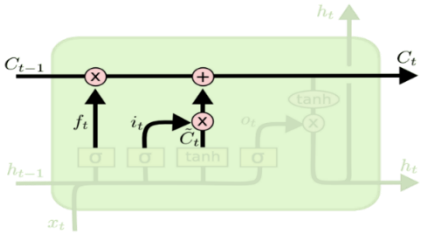
[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]



$$i_t = \sigma\left(W_i \cdot [h_{t-1}, x_t] \; + \; b_i\right)$$
$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] \; + \; b_C)$$

شکل ۲. نحوهٔ یادسپاری در ساختار شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت

درنهایت، حافظهٔ سیستم براساس بخشی از اطلاعات که باید فراموش شوند و بخشی از اطلاعات که باید به حافظه سپرده شوند به‌صورت شکل ۳ به‌روزرسانی می‌شود.

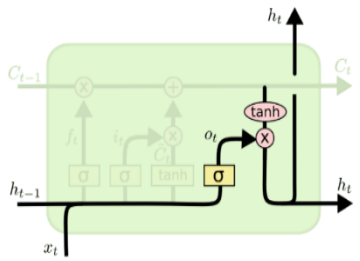


$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

شکل ۳. به‌روزرسانی حافظه در شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت

درنهایت، خروجی و لایهٔ پنهان شبکه (که ورودی شبکهٔ بعدی است) در گام یا زمان t به‌صورت شکل ۴ به‌روزرسانی می‌گردد.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]



$$o_t = \sigma\left(W_o\left[h_{t-1}, x_t\right] + b_o\right)$$
$$h_t = o_t * \tanh\left(C_t\right)$$

شکل ۴. به‌روزرسانی خروجی در شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت

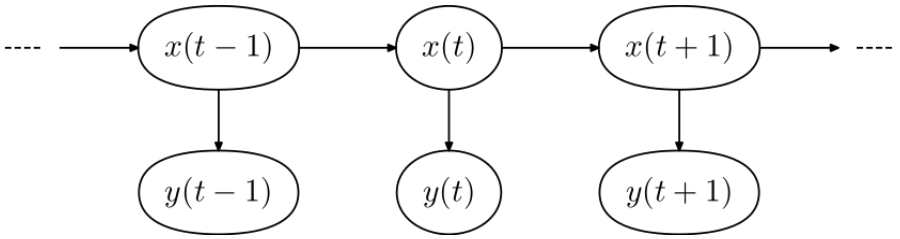
ماتریس کوواریانس بازده دارایی‌های تشکیل‌دهندهٔ سبد سهام در مدل برابری ریسک، نوعی ماتریس متقارن و مثبت معین است و استفاده از رویکرد شبکه‌های حافظهٔ بلندمدت و کوتاه‌مدت برای تخمین آن، تضمینی را برای شرط مثبت معین‌بودن خروجی شبکه ارائه نمی‌دهد. نوآوری این پژوهش استفاده از تجزیهٔ چولسکی است. تجزیهٔ چولسکی روشی پایه‌ای در جبر خطی عددی است که ماتریس‌های متقارن و معین مثبت را به حاصل‌ضرب یک ماتریس پایین‌مثلثی در ترانهاده‌اش تجزیه می‌کند. این روش به‌دلیل سرعت و پایداری عددی بیشتر نسبت به روش‌های عمومی‌تر مانند تجزیهٔ LU، کاربرد فراوانی دارد.

براین‌اساس، درصورتی‌که $\Sigma_1, \Sigma_2, \ldots, \Sigma_n$ دنباله‌ای از ماتریس‌های کوواریانس تاریخی باشد، ابتدا هر ماتریس با استفاده از تجزیهٔ چولسکی $\Sigma_i = L_i L_i^T$ به حاصل‌ضربی از ماتریس پایین‌مثلثی در ترانهادهٔ خودش تبدیل می‌شود. بدین صورت، به‌جای سری زمانی ماتریس کوواریانس‌ها از سری زمانی $L_1, L_2, \ldots, L_n$ استفاده می‌شود و شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت با این داده‌ها و درنظرگرفتن وقفهٔ زمانی مورد آموزش قرار می‌گیرد. خروجی شبکه نوعی ماتریس پایین‌مثلثی است که بار دیگر با فرمول بازسازی $\Sigma_i = L_i L_i^T$ به ماتریس کوواریانس تبدیل می‌شود. در داده‌های آزمون، ابتدا ماتریس کوواریانس توسط شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت پیش‌بینی می‌شود و سپس در مدل برابری جایگزین می‌شود و توسط الگوریتم فراابتکاریِ تجمعیْ ذرات مورد بهینه‌سازی قرار می‌گیرد.

در این پژوهش، برای بررسی عملکرد مدل پژوهش از دو رویکرد دیگر شامل مدل پنهان مارکوف و مدل گارچ نیز برای پیش‌بینی ماتریس کوواریانس و سپس بهینه‌سازی سبد سهام استفاده گردید که در ادامه معرفی می‌شود. شکل ۵ معماری کلی یک نمونه مدل مارکوف را نشان می‌دهد. هر شکل بیضی یک متغیر تصادفی است. متغیر تصادفی $x(t)$ یک حالت و متغیر تصادفی $y(t)$ مشاهده در زمان t است. فلش‌ها به معنای وابستگی‌های شرطی هستند. از شکل مشخص است که توزیع احتمال شرطی متغیر پنهان $x(t)$ فقط به مقدار

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

متغیر پنهان $x(t-1)$ وابسته است که این مشخصهٔ مارکوف نامیده می‌شود. به‌طور مشابه، مقدار متغیر مشاهدهٔ $y(t)$ تنها به مقدار متغیر حالت $x(t)$ بستگی دارد.



شکل ۵. نمودار مدل پنهان مارکوف

در مدل مارکوف دو نوع پارامتر وجود دارد: احتمال جابه‌جایی‌ها بین حالات و احتمال خروجی‌ها (یا مشاهدات). وظیفهٔ یادگیری در مدل مارکوف، یافتن بهترین احتمالات جابه‌جایی‌ها و خروجی‌ها براساس یک دنباله یا دنباله‌هایی از خروجی‌هاست. معمولاً این پارامترها به‌وسیلهٔ روش حداکثر درست‌نمایی براساس خروجی داده‌شده تخمین زده می‌شوند. هیچ الگوریتم قطعی برای حل این مسئله وجود ندارد، ولی برای پیداکردن حداکثر درست‌نمایی محلی می‌توان از الگوریتم‌های کارایی مانند بام ولچ[1] یا بالدی چاوین[2] استفاده کرد.

مدل دوم، مدل DCC-GARCH است که رویکردی قدرتمند و انعطاف‌پذیر برای مدل‌سازی ماتریس کوواریانس شرطی در سبدهای مالی است. این مدل که توسعه‌ای از مدل‌های GARCH استاندارد و CCC-GARCH به شمار می‌رود، توانایی قابل‌توجهی در ثبت و تحلیل پویایی همبستگی‌ها بین دارایی‌های مالی در طول زمان دارد. مزیت کلیدی مدل DCC-GARCH در این است که واریانس (نوسان‌پذیری) شرطی هر دارایی را به‌صورت مجزا مدل‌سازی و سپس همبستگی شرطی بین دارایی‌ها را به‌عنوان یک مدل مستقل و پویا پیاده‌سازی می‌کند. مدل DCC-GARCH را می‌توان به دو بخش اصلی تقسیم کرد. در مرحلهٔ اول، فرض می‌شود که واریانس شرطی هر دارایی i در زمان t، یعنی $\sigma_{i,t}^2$، از مدل GARCH استاندارد تبعیت می‌کند:

[1] Baum-Welch (BW)

[2] Baldi-Chauvin (BC)

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

$$\sigma_{i,t}^2 = \omega_i + \alpha_{i,1}\varepsilon_{i,t-1}^2 + \beta_{i,1}\sigma_{i,t-1}^2 \quad (۵)$$

مرحلهٔ دوم، مدل‌سازی همبستگی شرطی یا DCC است که پس از به‌دست‌آوردن واریانس‌های شرطی $\sigma_{i,t}^2$، یک ماتریس نرمال‌شده از باقی‌مانده‌ها مطابق رابطهٔ (۶) ایجاد می‌شود.

$$z_{i,t} = \frac{\varepsilon_{i,t}}{\sigma_{i,t}} \quad (۶)$$

مدل DCC فرض می‌کند که ماتریس همبستگی شرطی R_t نیز از فرایند GARCH پیروی می‌کند.

$$R_t = \mathrm{diag}(Q_t)^{-1/2} Q_t \mathrm{diag}(Q_t)^{-1/2} \quad (۷)$$

که در آن، Q_t ماتریس کوواریانس شرطی باقی‌مانده‌های نرمال‌شده است و از رابطهٔ (۸) تبعیت می‌کند.

$$Q_t = (1 - \lambda_1 - \lambda_2)\bar{Q} + \lambda_1 \eta_{t-1} + \lambda_2 Q_{t-1} \quad (۸)$$

در این رابطه، $\bar{Q}$ ماتریس کوواریانس میانگین بلندمدت باقی‌مانده‌های نرمال‌شده است و η_{t-1}. ماتریس کوواریانس خارجی باقی‌مانده‌های نرمال‌شدهٔ $z_{t-1}z_{t-1}^{\top}$ است و λ_1 و λ_2 پارامترهای DCC هستند که پویایی همبستگی را کنترل می‌کنند. λ_1 به تکانه‌های اخیر و λ_2 به همبستگی دورهٔ قبل وابستگی دارد. با دراختیارداشتن واریانس‌های شرطی $\sigma_{i,t}^2$ و ماتریس همبستگی شرطی R_t، ماتریس کوواریانس شرطی جامع Σ_t برای سبد به‌شکل رابطهٔ (۹) ساخته می‌شود.

$$\Sigma_t = D_t R_t D_t \quad (۹)$$

که در آن، D_t نوعی ماتریس قطری است و درایه‌های آن، انحرافات استاندارد شرطی $\sigma_{i,t}$ دارایی‌های مختلف در زمان t را شامل می‌شوند.

۴ یافته‌های پژوهش

دارایی‌های مورد استفاده در سبدهای برابری ریسک پژوهش که در ادامه معرفی می‌شود، شامل ۱۰ شاخص عمده از بورس اوراق بهادار تهران در بازهٔ زمانی ۱۳۹۰ تا پایان خرداد ۱۴۰۴ است. انتخاب شاخص به مفهوم یک سبد سهامِ متنوع از سهام زیرمجموعهٔ آن

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

شاخص است. بدین صورت، تنوع‌پذیری که از اصول مهم در تشکیل سبد سهام است، رعایت می‌گردد. باتوجه‌به دورهٔ پژوهش، تعداد داده‌های روزانه برابر ۳۵۹۱ داده است. فهرست شاخص‌های مورد استفاده در سبد پژوهش مطابق جدول ۱ است. انتخاب دارایی‌ها در مطالعات مربوط به بهینه‌سازی سبد سهام، صرفاً مرحله‌ای مقدماتی در فرایند پژوهش نیست، بلکه می‌تواند بر نتایج حاصل از برآورد ریسک، ساختار ماتریس کوواریانس، و درنهایت، ترکیب بهینهٔ سبد اثرگذار باشد. موضوع یادشده در این پژوهش که هدف آن پیش‌بینی پویای ماتریس کوواریانس و استفاده از آن در چهارچوب راهبرد برابری ریسک است، اهمیت بیشتری دارد. ازآنجاکه عملکرد مدل برابری ریسک به‌شدت به روابط متقابل میان دارایی‌ها وابسته است، انتخاب مجموعه‌ای از شاخص‌ها که ازنظر ماهیت فعالیت اقتصادی، عوامل اثرگذار بر بازده، و الگوی نوسانات تفاوت قابل‌توجهی داشته باشند، می‌تواند امکان ارزیابی مناسب‌تر مدل پیشنهادی را فراهم کند.

براین‌اساس، در این پژوهش به‌جای انتخاب تعداد زیادی از شاخص‌های صنعت، مجموعه‌ای متشکل از ۱۰ شاخص منتخب شامل سیمان، کاشی، فراورده‌های نفتی، قند و شکر، مواد دارویی، کانی‌های فلزی، کانی‌های غیرفلزی، خودرو، محصولات شیمیایی، و ماشین‌آلات به‌عنوان دارایی‌های سبد در نظر گرفته شده است. انتخاب این مجموعه بر مبنای چند ملاحظهٔ نظری و روش‌شناختی صورت گرفته است.

نخستین مبنای انتخاب، ایجاد تنوع در معرض ریسک‌های اقتصادی است. صنایع انتخاب‌شده ازنظر عوامل تعیین‌کنندهٔ سودآوری و رفتار قیمتی یکسان نیستند؛ برای مثال، عملکرد صنایع فراورده‌های نفتی، کانی‌های فلزی، و محصولات شیمیایی تا حد زیادی تحت‌تأثیر متغیرهایی مانند قیمت کالاهای پایه، نرخ ارز، و شرایط تجارت خارجی قرار می‌گیرد، درحالی‌که صنایعی نظیر خودرو، دارویی و ماشین‌آلات بیشتر تحت‌تأثیر عواملی همچون تقاضای داخلی، سیاست‌های صنعتی، هزینهٔ تأمین‌مالی، مقررات، و شرایط تولید داخلی قرار دارند. همچنین، صنایعی مانند سیمان، کاشی، و کانی‌های غیرفلزی ارتباط بیشتری با فعالیت‌های ساختمانی و عمرانی دارند؛ بنابراین، قراردادن این گروه‌ها در یک سبد واحد، مجموعه‌ای از دارایی‌ها با منشأهای متفاوت ریسک ایجاد می‌کند و امکان بررسی توان مدل برابری ریسک در توزیع ریسک میان بخش‌های ناهمگون اقتصادی را افزایش می‌دهد.

دومین ملاحظه، اهمیت بخش‌های تولیدی و صنعتی در ساختار بازار سرمایهٔ ایران است. شاخص‌های صنعتی در بورس تهران امکان بررسی عملکرد گروه‌های مختلف اقتصادی را فراهم می‌کنند و گزارش‌های بازار نیز به‌طور مستمر شاخص‌ها و عملکرد صنایع

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

مختلف را به‌تفکیک ارائه می‌کنند؛ برای نمونه، گزارش‌های بازار سرمایه، صنایعی مانند محصولات شیمیایی، فلزات، فراورده‌های نفتی، کانی‌های فلزی، دارویی، خودرو، سیمان، قند و شکر، و ماشین‌آلات را به‌صورت مجزا در طبقه‌بندی صنایع بازار نشان می‌دهند.

ملاحظهٔ سوم به اهمیت تنوع در ساختار همبستگی دارایی‌ها مربوط است. در این پژوهش، هدف صرفاً مقایسهٔ بازده شاخص‌های مختلف نیست، بلکه یکی از مسائل اصلی، پیش‌بینی ماتریس کوواریانس برای استفاده در فرایند تخصیص ریسک است؛ ازاین‌رو، دارایی‌هایی که واکنش مشابهی نسبت به یک عامل اقتصادی دارند، اطلاعات محدودی برای آزمون توانایی مدل در شناسایی ساختار پیچیدهٔ وابستگی فراهم می‌کنند. انتخاب صنایعی با ماهیت فعالیت متفاوت، این امکان را فراهم می‌سازد که مدل LSTM در مواجهه با روابط هم‌زمان، وابستگی‌های زمانی، و تغییرات همبستگی میان گروه‌های مختلف بازار مورد ارزیابی قرار گیرد.

چهارمین دلیل، کاهش ابعاد مسئله و کنترل پیچیدگی محاسباتی است. در مدل برابری ریسک، با افزایش تعداد دارایی‌ها تعداد عناصر موجود در ماتریس کوواریانس به‌صورت قابل‌توجهی افزایش می‌یابد. برای N دارایی، ماتریس کوواریانس دارای $(N(N+1)/2)$ عنصر مستقل است؛ بنابراین، افزایش تعداد شاخص‌ها نه‌تنها فرایند تخمین و پیش‌بینی ماتریس کوواریانس را دشوارتر می‌کند، بلکه پیچیدگی مرحلهٔ بهینه‌سازی وزن‌ها را نیز افزایش می‌دهد. این موضوع در مدل‌های یادگیری عمیق اهمیت بیشتری دارد، زیرا افزایش تعداد متغیرهای ورودی و خروجی می‌تواند نیاز به داده و محاسبات بیشتری ایجاد کند؛ درنتیجه، انتخاب ۱۰ شاخص، نوعی مصالحه میان تنوع دارایی‌ها و قابلیت اجرای پایدار مدل ایجاد می‌کند.

پنجمین مبنای انتخاب، امکان ایجاد مجموعه‌ای از داده‌های نسبتاً همگن ازنظر سطح شاخص‌سازی و دسترسی به داده‌های تاریخی است. استفاده از شاخص‌های صنعت به‌جای انتخاب تعداد زیادی سهم منفرد، می‌تواند بخشی از نویز و ویژگی‌های خاص شرکت‌ها را کاهش دهد و تمرکز تحلیل را از ریسک‌های مختص یک شرکت به رفتار کلی یک گروه صنعتی منتقل کند. این ویژگی برای پژوهشی که قصد دارد ساختار ریسک بین صنایع را بررسی کند، اهمیت دارد، زیرا هدف اصلی پیش‌بینی روابط میان گروه‌های اقتصادی است و نه پیش‌بینی عملکرد شرکتی خاص.

ازسوی‌دیگر، طول دورهٔ زمانی پژوهش نیز در انتخاب تعداد دارایی‌ها مؤثر است. دورهٔ مورد بررسی از ابتدای سال ۱۳۹۰ تا خرداد ۱۴۰۴ را در بر می‌گیرد و بنابراین، مجموعهٔ داده‌ها ازنظر زمانی نسبتاً گسترده است؛ بااین‌حال، افزایش بیش‌ازحد تعداد دارایی‌ها

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

موجب افزایش تعداد پارامترهای موردِنیاز برای تخمین ساختار کوواریانس می‌شود؛ درنتیجه، انتخاب ۱۰ شاخص این امکان را فراهم می‌کند که در کنار بهره‌گیری از یک دورهٔ زمانی طولانی، مسئلهٔ پیش‌بینی ماتریس کوواریانس در ابعادی قابل‌کنترل باقی بماند.

ملاحظهٔ ششم، نمایندگی طیف متنوعی از فعالیت‌های اقتصادی است. فهرست انتخاب‌شده را می‌توان به چند گروه کلی تقسیم کرد. فراورده‌های نفتی، کانی‌های فلزی، و محصولات شیمیایی عمدتاً نمایندهٔ بخش‌هایی هستند که ارتباط بیشتری با بازار کالاها، نرخ ارز، و متغیرهای بین‌المللی دارند. خودرو و ماشین‌آلات بیشتر منعکس‌کنندهٔ شرایط تولید صنعتی و تقاضای داخلی هستند. سیمان، کاشی، و کانی‌های غیرفلزی به فعالیت‌های ساختمانی و عمرانی وابستگی بیشتری دارند و درنهایت، قند و شکر و مواد دارویی ازجمله صنایعی هستند که ساختار تقاضا و عوامل تنظیمی متفاوتی دارند؛ درنتیجه، این ترکیب صرفاً مجموعه‌ای از صنایع بزرگ نیست، بلکه مجموعه‌ای از صنایع با منشأهای متفاوت ریسک و رفتار اقتصادی متفاوت را در بر می‌گیرد.

از منظر روش‌شناختی، انتخاب شاخص‌های صنعتی به‌جای تعداد زیادی از سهام شرکت‌ها همچنین باعث می‌شود اثر ریسک‌های خاص شرکت تا حدی کاهش یابد و تمرکز مطالعه بر ریسک و همبستگی در سطح صنعت قرار گیرد. این مسئله با هدف این پژوهش سازگار است، زیرا مسئلهٔ اصلی بررسی عملکرد مدل‌های مختلف در تخمین و پیش‌بینی پویای کوواریانس و سپس استفاده از آن در تخصیص ریسک است؛ بنابراین، شاخص صنعت می‌تواند به‌عنوان نماینده‌ای از رفتار مجموعه‌ای از شرکت‌های فعال در یک حوزهٔ اقتصادی مورد استفاده قرار گیرد.

تأکید می‌شود که انتخاب این ۱۰ شاخص به معنای بی‌اهمیت‌بودن سایر صنایع بازار سرمایه نیست. بازار سرمایهٔ ایران دارای گروه‌های صنعتی متعدد دیگری نیز هست و در مقاطع مختلف، صنایع گوناگون ازنظر ارزش بازار، حجم معاملات، و تعداد شرکت‌های فعال اهمیت متفاوتی داشته‌اند؛ برای مثال، داده‌های منتشرشده دربارهٔ ساختار بازار سرمایه نشان می‌دهد که در سال‌های اخیر، علاوه‌بر صنایع حاضر در نمونهٔ پژوهش، گروه‌هایی مانند بانک‌ها و مؤسسات اعتباری، شرکت‌های چندرشته‌ای صنعتی، و سایر صنایع نیز سهم قابل‌توجهی از بازار داشته‌اند؛ بنابراین، محدودکردن نمونه به ۱۰ شاخص منتخب باید به‌مثابهٔ نوعی تصمیم طراحی پژوهش با هدف ایجاد توازن میان نمایندگی اقتصادی، تنوع ریسک، کیفیت داده، و پیچیدگی محاسباتی تفسیر شود، نه به‌عنوان ادعایی مبنی بر برتری مطلق این صنایع نسبت به سایر گروه‌ها.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

درمجموع، می‌توان منطق انتخاب دارایی‌های پژوهش را بر چهار محور اصلی خلاصه کرد: نخست، ایجاد تنوع اقتصادی و ریسک بین دارایی‌ها؛ دوم، فراهم‌کردن ساختار همبستگی مناسب برای آزمون مدل پیش‌بینی کوواریانس؛ سوم، برخورداری از داده‌های تاریخی قابل استفاده در دورهٔ مورد مطالعه؛ و چهارم، کنترل ابعاد ماتریس کوواریانس و پیچیدگی محاسباتی مدل. براین‌اساس، مجموعهٔ ۱۰ شاخص منتخب، محیط مناسبی برای بررسی توانایی LSTM در یادگیری پویایی‌های زمانی و روابط متقابل میان صنایع و مقایسهٔ آن با روش‌های HMM و DCC-GARCH فراهم می‌کند.

جدول ۱. *فهرست دارایی‌های سبدهای سهام پژوهش*

عنوان شاخص	شمارهٔ دارایی	عنوان شاخص	شمارهٔ دارایی
سیمان	۱	کانی فلزی	۶
کاشی	۲	کانی غیرفلزی	۷
فراورده‌های نفتی	۳	خودرو	۸
قند و شکر	٤	شیمیایی	۹
مواد دارویی	٥	ماشین‌آلات	۱۰

افق زمانی سبدهای سهام پژوهش، هفتگی و هر هفته ۵ روز کاری در نظر گرفته شده است. براین‌اساس، ۷۱۸ بازده هفتگی به‌دست آمد. در ادامه و در تمام مدل‌های بهینه‌سازی سبد سهام مورد بحث، از ۷۵ درصد از داده‌ها برای آموزش مدل و از ۲۵ درصد برای آزمون عملکرد سودآوری استفاده شده است. همچنین، برای بهینه‌سازی تمام سبدها، از الگوریتم ازدحام ذرات[1] استفاده خواهد شد. الگوریتم ازدحام ذرات نوعی الگوریتم بهینه‌سازی الهام‌گرفته از رفتار اجتماعی دسته‌ای از پرندگان یا ماهیان است که برای یافتن راه‌حل بهینه برای مسائل پیچیده به‌کار می‌رود. در این الگوریتم، هر «ذره» نمایندهٔ یک راه‌حل بالقوه در فضای جست‌وجو است و با حرکت در این فضا، به‌سمت بهترین موقعیت‌های کشف‌شده توسط خودش[2] و بهترین موقعیت کشف‌شده توسط کل جمعیت[3] حرکت می‌کند. در طول فرایند بهینه‌سازی، هر ذره موقعیت و سرعت خود را براساس بهترین موقعیت قبلی خود و

[1] Particle Swarm Optimization (PSO)

[2] pbest

[3] gbest

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

بهترین موقعیت کل جمعیت به‌روزرسانی می‌کند. این حرکت به‌گونه‌ای است که ذرات به‌تدریج به‌سمت نواحی امیدوارکننده در فضای جست‌وجو همگرا می‌شوند. تنظیمات الگوریتم ازدحام ذراتِ مورد استفاده در پژوهش به‌صورت جدول ۲ است.

جدول ۲. *تنظیمات پارامترهای PSO*

پارامتر	مقدار
تعداد راه‌حل‌های بالقوه در هر نسل	۲۰۰
حداکثر تعداد نسل‌هایی که الگوریتم اجرا می‌شود	۵۰۰
میزان تأثیر موقعیت قبلی ذره بر سرعت فعلی؛ کاهش آن باعث همگرایی سریع‌تر می‌شود	۰/۷
میزان تمایل ذره به بازگشت به بهترین موقعیت قبلی خود	۱/۵
میزان تمایل ذره به حرکت به‌سمت بهترین موقعیت کل جمعیت	۱/۵
بازهٔ مجاز برای هر متغیر در راه‌حل	[۰،۱]

۱.۴ رویکرد LSTM-چولسکی برای پیش‌بینی پویای ماتریس کوواریانس

در چهارچوب روش پیشنهادی، فرایند مدل‌سازی با استخراج ماتریس‌های کوواریانس از مجموعه داده‌های آموزشی آغاز می‌شود. این ماتریس‌ها با درنظرگرفتن پنجرهٔ زمانی مشخص محاسبه می‌شوند و به‌منظور اطمینان از مثبت معین‌بودن آن‌ها، تحت تجزیهٔ چولسکی قرار می‌گیرند. حاصل این مرحله، مجموعه‌ای از ماتریس‌های پایین‌مثلثی است که به‌عنوان سری زمانی ورودی برای مرحلهٔ یادگیری مورد استفاده قرار می‌گیرند. در مرحلهٔ بعد، با اعمال وقفهٔ زمانی مشخص، ارتباط میان مقادیر گذشته و ساختار آتی ماتریس کوواریانس به شبکهٔ عصبی LSTM ارائه می‌شود تا مدل بتواند الگوهای زمانی موجود در داده‌ها را فراگیرد. پس از پایان فرایند آموزش، شبکهٔ آموزش‌دیده برای پیش‌بینی ماتریس کوواریانس مربوط به هفتهٔ آینده بر روی داده‌های آزمون به‌کار گرفته می‌شود. بدین‌ترتیب، ماتریس کوواریانس پیش‌بینی‌شده به‌عنوان ورودی مرحلهٔ تخصیص دارایی مورد استفاده قرار می‌گیرد. در ادامه، با استفاده از ماتریس کوواریانس برآوردشده، وزن‌های بهینهٔ دارایی‌ها در چهارچوب راهبرد برابری ریسک تعیین می‌شوند. برای حل مسئلهٔ بهینه‌سازی وزن‌های سبد، از الگوریتم بهینه‌سازی ازدحام ذرات استفاده شده است. این فرایند درنهایت به تعیین ترکیبی از وزن دارایی‌ها منجر می‌شود که در آن سهم دارایی‌های مختلف از ریسک کل سبد تاحدامکان به یکدیگر نزدیک باشد. پیاده‌سازی محاسبات و آموزش شبکهٔ

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

عصبی با استفاده از کتابخانهٔ پای‌تورچ[1] در محیط برنامه‌نویسی پایتون انجام گرفته است. مقادیر مربوط به پارامترها و تنظیمات مورد استفاده در مدل، مطابق اطلاعات ارائه‌شده در جدول ۳ انتخاب شده‌اند. همچنین، باتوجه‌به وجود ۱۰ دارایی در سبد و استفاده از بخش پایین‌مثلثی ماتریس کوواریانس به‌عنوان ورودی شبکه، تعداد متغیرهای ورودی مدل با تعداد عناصر مستقل بخش پایین‌مثلثی این ماتریس برابر خواهد بود.

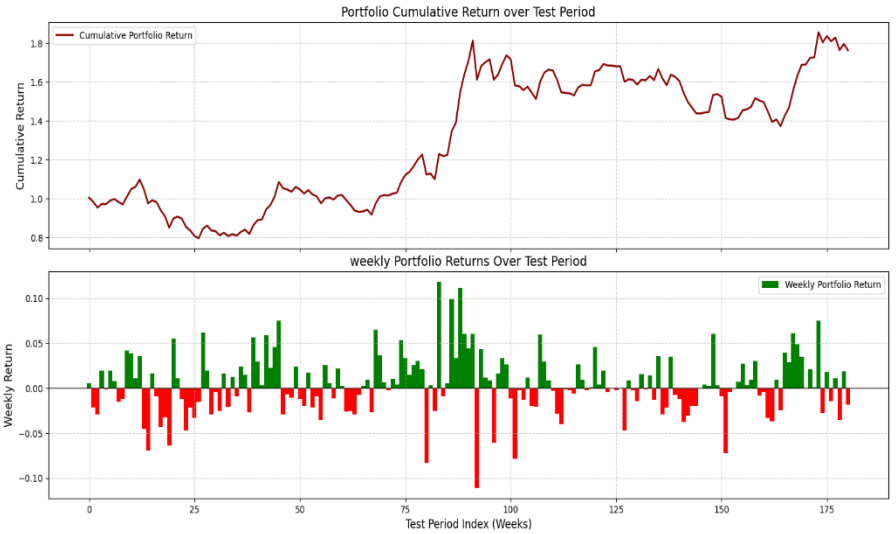
جدول ۳. *پارامترهای مورد استفاده در رویکرد اول*

پارامتر	**مقدار**
اندازهٔ پنجرهٔ زمانی برای محاسبهٔ ماتریس کوواریانس	۳۰
تأخیر (وقفهٔ زمانی)	۱۰
ابعاد ورودی	۵۵
اندازهٔ لایهٔ پنهان	٦٤
ابعاد خروجی	۵۵
تابع بهینه‌ساز	بهینه‌ساز آدام[2]
نرخ یادگیری	۰/۰۰۱
معیار آموزش	میانگین مربعات خطا[3]

عملکرد مدل اصلی پژوهش، یعنی شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت با رهیافت تجزیهٔ چولسکی، بر روی داده‌های آزمون در نمودار ۱ ارائه شده است. نمودار ذیل بازده‌های هفتگی کسب‌شده، و بازده تجمعی کسب‌شده بر روی داده‌های آزمون است.

[1] PyTorch
[2] Optim.Adam (OA)
[3] nn.MSELoss

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]



شکل ۶. بازده‌های هفتگی و بازده تجمعی بر روی داده‌های آزمون با رویکرد LSTM+CHOLOSKY

عملکرد مدل شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت با رهیافت تجزیهٔ چولسکی در جدول ۴ ارائه شده است.

جدول ۴. *عملکرد مدل شبکهٔ حافظهٔ بلندمدت و کوتاه‌مدت با رهیافت تجزیهٔ چولسکی*

معیار	مقدار
میانگین بازده هفتگی	۰/۰۰۳۸
ریسک (انحراف معیار)	۰/۰۳۲
نسبت شارپ	۰/۱۲
حداکثر افت سرمایه	٪ ۲۷
بازده تجمعی	۱/۷٤

بدین صورت، انتظار می‌رود به کمک این سبد بتوان به میانگین بازده هفتگی ۰/۰۰۳۸ با تحمل ریسک ۰/۰۳۳ دست یافت. نسبت پاداش به ریسک یا نسبت شارپ این رویکرد نیز ۰/۱۲ است. بازده تجمعی بر روی کل دورهٔ آزمون، یعنی ۱۷۹ هفته، برابر ۱/۷۴ است. همچنین، حداکثر افت سرمایهٔ سبد نشان می‌دهد که سبد نسبت به بلندترین قلهٔ خود دارای افت ۲۷ درصد بوده است.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

۲.۴ رویکرد مدل مارکوف پنهان در پیش‌بینی ماتریس کوواریانس

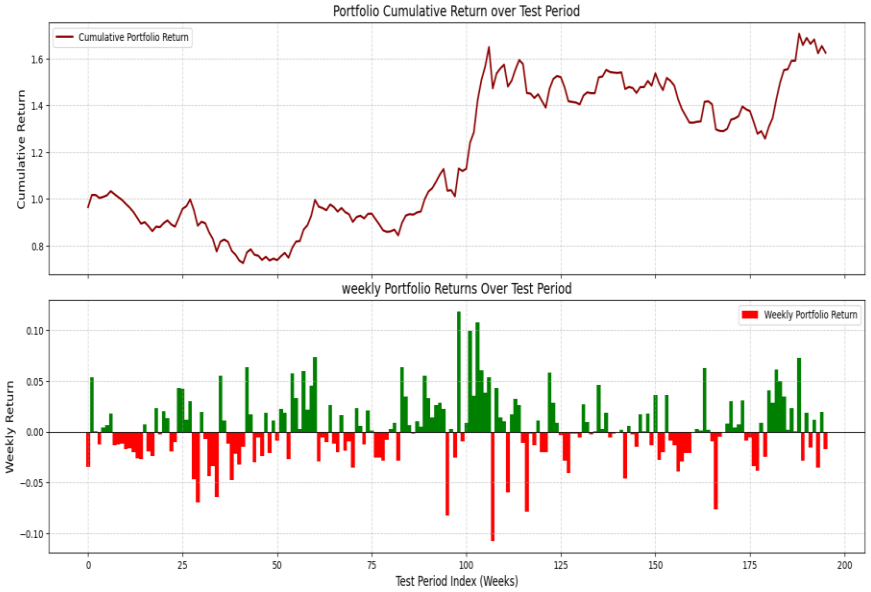
در رویکرد مبتنی بر مدل مارکوف پنهان، متغیرهای مشاهده‌شده به‌صورت توالی بازده‌های هفتگی مربوط به ۱۰ دارایی موجود در سبد تعریف می‌شوند. در این چهارچوب، فرض می‌شود بردار بازده‌های هفتگی از نوعی توزیع نرمال چندمتغیره پیروی می‌کند؛ ازاین‌رو، باتوجه‌به وجود ۱۰ دارایی، توزیع شرطی بازده‌ها به‌صورت نرمال چندمتغیره با ۱۰ مؤلفه در نظر گرفته می‌شود. این مدل با هدف شناسایی وضعیت‌های پنهان حاکم بر رفتار بازده دارایی‌ها و برآورد ویژگی‌های آماری مرتبط با هر وضعیت، بر روی داده‌های تاریخی آموزش داده می‌شود. برای پیاده‌سازی این مدل در محیط پایتون، از کتابخانهٔ Hmmlearn استفاده شده است. تنظیمات و پارامترهای مربوط به مدل مطابق مقادیر ارائه‌شده در جدول ۵ تعیین شده‌اند. ماتریس‌های کوواریانس و سایر پارامترهای مدل نیز براساس وضعیت‌های پنهان شناسایی‌شده در فرایند برآورد مدل استخراج و در مراحل بعدی پژوهش مورد استفاده قرار گرفته‌اند.

جدول ۵. *پارامترهای مورد استفاده در مدل پنهان مارکوف*

پارامتر	**مقدار**
نوع خروجی	توزیع نرمال چندمتغیره
نوع و تعداد فضای حالت	گسسته و شامل ۳ حالت
توزیع اولیهٔ حالات	$A = [0.33 \quad 0.33 \quad 0.33]$

در این مرحله، ابتدا ماتریس کوواریانس دارایی‌ها با استفاده از مدل مارکوف پنهان برآورد می‌شود. سپس ماتریس کوواریانس حاصل، در فرایند بهینه‌سازی سبد مورد استفاده قرار می‌گیرد و با بهره‌گیری از الگوریتم بهینه‌سازی ازدحام ذرات، وزن‌های بهینهٔ سبد در چهارچوب راهبرد برابری ریسک تعیین می‌گردد. به‌منظور ارزیابی عملکرد این رویکرد، نتایج حاصل از اجرای مدل بر روی مجموعه داده‌های آزمون در شکل ۷ ارائه شده است. در این نمودار، نمودار پایینی روند بازدهی هفتگی حاصل از سبد بهینه را در طول دورهٔ آزمون نشان می‌دهد، درحالی‌که نمودار بالایی مسیر بازده تجمعی سبد را در همین دوره به تصویر می‌کشد. بررسی هم‌زمان این دو نمودار امکان ارزیابی تغییرات کوتاه‌مدت بازده و همچنین روند کلی عملکرد سبد در دورهٔ آزمون را فراهم می‌کند.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]



شکل ۷. بازده‌های هفتگی و بازده تجمعی بر روی داده‌های آزمون با رویکرد پنهان مارکوف

عملکرد آماری مدل پنهان مارکوف در بهینه‌سازی سبد برابری ریسک در جدول ۶ ارائه شده است.

جدول ۶. *عملکرد مدل پنهان مارکوف*

معیار	مقدار
میانگین بازده هفتگی	۰/۰۰۳۲
ریسک (انحراف معیار)	۰/۰۳۲۷
نسبت شارپ	۰/۰۹۷
حداکثر افت سرمایه	۲۹٪
بازده تجمعی	۱/۶۷

مقایسهٔ نتایج ارائه‌شده در جدول ۶ با عملکرد رویکرد پیشنهادی پژوهش نشان می‌دهد که استفاده از مدل مارکوف پنهان به کاهش عملکرد سبد در اغلب شاخص‌های ارزیابی منجر شده است. به‌طور مشخص، میانگین بازده هفتگی در این روش حدود ۱۸ درصد و بازده تجمعی حدود ۴ درصد کمتر از رویکرد اصلی پژوهش بوده است. همچنین، نسبت

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

شارپ نیز کاهش ۲۴درصدی را تجربه کرده که نشان‌دهندهٔ عملکرد ضعیف‌تر مدل مارکوف پنهان از منظر بازده تعدیل‌شده براساس ریسک است. ازسوی‌دیگر، مقایسهٔ معیارهای ریسک نشان می‌دهد که ریسک سبد در دو رویکرد، با اغماض، تفاوت قابل‌توجهی نداشته و تقریباً در سطحی مشابه قرار گرفته است. بااین‌حال، شاخص حداکثر افت سرمایه در مدل مارکوف پنهان وضعیت نامطلوب‌تری دارد و مقدار آن نسبت به رویکرد پیشنهادی حدود ۰/۰۷ افزایش یافته است؛ بنابراین، اگرچه مدل مارکوف پنهان توانسته است سطح کلی ریسک سبد را تقریباً در محدودهٔ مشابهی حفظ کند، ازنظر ایجاد بازده و کنترل زیان‌های شدید، عملکرد ضعیف‌تری نسبت به رویکرد پیشنهادی نشان می‌دهد.

۳.۴ رویکرد DCC-GARCH

در رویکرد DCC-GARCH، به‌منظور مدل‌سازی و پیش‌بینی ساختار پویای کوواریانس میان بازده دارایی‌ها، از مدل GARCH (1,1) به‌عنوان مدل پایه استفاده شده است. این چهارچوب با درنظرگرفتن تغییرپذیری زمانی و وابستگی متقابل میان بازده دارایی‌ها، امکان برآورد ماتریس کوواریانس شرطی را فراهم می‌کند. پیاده‌سازی محاسبات و برآورد مدل در محیط برنامه‌نویسی پایتون و با بهره‌گیری از کتابخانهٔ ARCH انجام شده است. پس از برآورد ماتریس کوواریانس، این ماتریس در فرایند تعیین ترکیب بهینهٔ سبد براساس راهبرد برابری ریسک مورد استفاده قرار می‌گیرد. عملکرد حاصل از اجرای رویکرد DCC-GARCH بر روی مجموعه داده‌های آزمون در شکل ۸ ارائه شده است. در این شکل، بخش پایینی تغییرات بازده هفتگی سبد بهینه را در طول دورهٔ آزمون نشان می‌دهد، درحالی‌که بخش بالایی روند بازده تجمعی سبد را طی همین دوره نمایش می‌دهد. این دو شکل امکان بررسی رفتار کوتاه‌مدت سبد و روند کلی عملکرد آن در دورهٔ آزمون را فراهم می‌کنند.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]



شکل ۸. بازده‌های هفتگی و بازده تجمعی بر روی داده‌های آزمون با رویکرد پنهان مارکوف

عملکرد آماری مدل پنهان مارکوف در بهینه‌سازی سبد برابری ریسک در جدول ۷ ارائه شده است.

جدول ۷. عملکرد مدل *DCC-GARCH*

معیار	مقدار
میانگین بازده هفتگی	۰/۰۰۳۰
ریسک (انحراف معیار)	۰/۰۳۲۹
نسبت شارپ	۰/۰۹۱
حداکثر افت سرمایه	۳۱٪
بازده تجمعی	۱/۶۳

بررسی نتایج گزارش‌شده در جدول ۷ و مقایسهٔ آن با دو روش مورد بررسی پیشین نشان می‌دهد که مدل DCC-GARCH درمجموع نامطلوب‌ترین نتایج را در میان رویکردهای مورد ارزیابی داشته است. این مدل در تمامی معیارهای عملکردی بررسی‌شده، نسبت به دو

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

رویکرد دیگر عملکرد ضعیف‌تری نشان داده و ازنظر شاخص‌های ارزیابی، در رتبهٔ آخر قرار گرفته است.

۵ نتیجه‌گیری و پیشنهادها

راهبرد برابری ریسک یکی از رویکردهای تخصیص دارایی است که در آن، مبنای تعیین وزن دارایی‌ها میزان مشارکت آن‌ها در ریسک کل سبد است، نه ارزش اسمی سرمایه‌گذاری در هر دارایی. در این چهارچوب، دارایی‌هایی که نوسان پایین‌تری دارند معمولاً ظرفیت دریافت وزن بیشتری پیدا می‌کنند، درحالی‌که سهم دارایی‌های پرنوسان محدودتر می‌شود. هدف نهایی آن است که مشارکت نسبی دارایی‌های مختلف در ریسک کل سبد تاحدامکان متوازن باشد. تحقق این هدف به شناخت دقیق ساختار ریسک و وابستگی میان دارایی‌ها وابسته است و در این میان، ماتریس کوواریانس یکی از مهم‌ترین ورودی‌های مدل محسوب می‌شود. عناصر روی قطر اصلی این ماتریس، اطلاعات مربوط به واریانس یا میزان پراکندگی هر دارایی را در بر می‌گیرند و عناصر خارج از قطر، شدت و جهت وابستگی میان دارایی‌ها را نشان می‌دهند؛ ازاین‌رو، هرگونه خطا در برآورد ماتریس کوواریانس می‌تواند به‌طور مستقیم بر محاسبهٔ سهم ریسک دارایی‌ها، وزن‌های تخصیص‌یافته، و درنهایت، عملکرد سبد اثر بگذارد.

یکی از مسائل اساسی در برآورد ریسک دارایی‌های مالی، ماهیت متغیر و غیرایستای بازارهاست. ویژگی‌های آماری بازده‌ها در طول زمان ثابت نمی‌مانند و عواملی نظیر تغییر شرایط اقتصادی، تحولات سیاسی، نوسانات نرخ ارز، تغییر انتظارات سرمایه‌گذاران، و تکانه‌های بازار می‌توانند ساختار واریانس و همبستگی میان دارایی‌ها را دستخوش تغییر کنند. در چنین شرایطی، استفاده از نوعی ماتریس کوواریانس ثابت که صرفاً بر مبنای مشاهدات تاریخی برآورد شده باشد، ممکن است تصویر دقیقی از وضعیت جاری بازار ارائه نکند؛ به‌عنوان‌مثال، رابطهٔ همبستگی میان دو دارایی ممکن است در یک دوره شدید باشد، اما با تغییر شرایط بازار کاهش یابد یا بالعکس، رابطه‌ای جدید میان آن‌ها شکل بگیرد که در برآوردهای تاریخی مشاهده‌پذیر نباشد؛ درنتیجه، استفاده از برآوردهای ایستا می‌تواند به تعیین وزن‌های نامتناسب، افزایش مواجههٔ سبد با ریسک‌های پیش‌بینی‌نشده، و کاهش کیفیت عملکرد سرمایه‌گذاری منجر شود؛ بنابراین، برای اجرای مؤثر راهبرد برابری ریسک، به‌کارگیری روشی که بتواند تغییرات زمانی ساختار کوواریانس را دنبال کند، ضروری است. بر همین اساس، در این پژوهش ماتریس کوواریانس به‌صورت پویا و با استفاده از شبکهٔ عصبی حافظهٔ بلندمدت و کوتاه‌مدت پیش‌بینی شده است.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

انتخاب LSTM ازاین‌جهت صورت گرفته است که این معماری برای تحلیل داده‌های دارای ساختار زمانی طراحی شده است و توانایی مناسبی در شناسایی وابستگی‌هایی دارد که در فواصل زمانی مختلف میان مشاهدات شکل می‌گیرند. سازوکار داخلی این شبکه از طریق مجموعه‌ای از دروازه‌ها، نحوهٔ ورود، نگهداری، و حذف اطلاعات را کنترل می‌کند و به مدل اجازه می‌دهد اطلاعات مؤثر مربوط به گذشته را برای استفاده در پیش‌بینی‌های آتی حفظ کند. این قابلیت در داده‌های مالی اهمیتی ویژه دارد، زیرا رفتار متغیرهای مالی معمولاً تنها به مشاهدات نزدیک به زمان حال وابسته نیست و ممکن است اثر وقایع و الگوهای گذشته با وقفهٔ زمانی در داده‌ها باقی بماند؛ بنابراین، استفاده از LSTM می‌تواند امکان شناسایی روابط غیرخطی و الگوهای زمانی پیچیدهٔ موجود در رفتار بازده دارایی‌ها و ساختار کوواریانس را فراهم سازد. افزون‌بر این، با ورود مشاهدات جدید، مدل قادر است برآوردهای خود را متناسب با اطلاعات تازه به‌روزرسانی کند و درنتیجه، تخمین پویاتری از شرایط ریسک بازار ارائه دهد.

باوجود مزایای LSTM، پیش‌بینی مستقیم تمامی عناصر ماتریس کوواریانس با محدودیتی مهم مواجه است. ماتریس حاصل از پیش‌بینی شبکه الزاماً شرایط ریاضی لازم برای یک ماتریس کوواریانس معتبر، به‌ویژه ویژگی مثبت معین‌بودن، را برآورده نمی‌کند. درصورتی‌که این ویژگی نقض شود، استفاده از ماتریس پیش‌بینی‌شده در محاسبات ریسک و فرایند بهینه‌سازی سبد می‌تواند با مشکلات عددی و محاسباتی همراه شود. برای رفع این مسئله، در این پژوهش از تجزیهٔ چولسکی استفاده شده است. براساس این تجزیه، نوعی ماتریس کوواریانس مثبت معین را می‌توان به حاصل‌ضرب یک ماتریس پایین‌مثلثی و ترانهادهٔ آن تبدیل کرد؛ درنتیجه، به‌جای آنکه شبکهٔ عصبی مستقیماً تمامی عناصر ماتریس کوواریانس را پیش‌بینی کند، پارامترهای ساختاری ماتریس پایین‌مثلثی مورد پیش‌بینی قرار می‌گیرند و سپس ماتریس کوواریانس از طریق بازسازی حاصل می‌شود. این سازوکار، علاوه‌بر فراهم‌کردن چهارچوبی مناسب برای یادگیری ساختار کوواریانس، احتمال تولید ماتریس‌های نامعتبر را نیز کاهش می‌دهد.

برای ارزیابی رویکرد پیشنهادی، مجموعه‌ای شامل ۱۰ شاخص منتخب از صنایع مختلف بورس اوراق بهادار تهران در بازهٔ زمانی ابتدای سال ۱۳۹۰ تا پایان خرداد ۱۴۰۴ مورد استفاده قرار گرفت. باتوجه‌به انتخاب بازهٔ زمانی هفتگی، درمجموع ۷۱۸ مشاهدهٔ بازده برای آموزش، ارزیابی، و آزمون مدل‌ها محاسبه شد. عملکرد چهارچوب پیشنهادی متشکل از LSTM و تجزیهٔ چولسکی با دو روش دیگر، یعنی مدل مارکوف پنهان و DCC-GARCH، مورد مقایسه قرار گرفت. در هر سه رویکرد، ماتریس کوواریانس

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

برآوردشده در مرحلهٔ تخصیص دارایی مورد استفاده قرار گرفت و وزن‌های سبد برابری ریسک با بهره‌گیری از الگوریتم بهینه‌سازی ازدحام ذرات تعیین شد.

نتایج تجربی نشان داد که رویکرد مبتنی بر LSTM و تجزیهٔ چولسکی درمجموع توانسته است عملکرد مطلوب‌تری نسبت به دو روش مقایسه‌ای ایجاد کند. براساس نتایج به‌دست‌آمده، متوسط بازده هفتگی سبد حاصل از این روش برابر با ۰/۰۰۳۸، میزان ریسک برابر با ۰/۰۳۲، نسبت شارپ برابر با ۰/۱۲ و بازده تجمعی برابر با ۱/۷۴ بوده است. مقایسهٔ این شاخص‌ها با نتایج مدل مارکوف پنهان و DCC-GARCH نشان می‌دهد که چهارچوب پیشنهادی از منظر ترکیب بازده و ریسک و همچنین عملکرد تعدیل‌شده براساس ریسک، نتایج مناسب‌تری ارائه کرده است. این یافته را می‌توان تا حدی به قابلیت LSTM در استخراج وابستگی‌های زمانی و روابط غیرخطی موجود در داده‌های مالی و همچنین استفاده از تجزیهٔ چولسکی برای حفظ ساختار معتبر ماتریس کوواریانس نسبت داد.

به‌طورکلی، نتایج این مطالعه نشان می‌دهد که در محیطی مانند بازار سرمایهٔ ایران، که تغییرات ساختاری، نوسانات قابل‌توجه، و تغییر در روابط میان صنایع از ویژگی‌های مهم آن محسوب می‌شود، استفاده از مدل‌های پویا می‌تواند نسبت به رویکردهای مبتنی بر برآوردهای ثابت مزیت داشته باشد. ترکیب یادگیری عمیق با یک روش ریاضی برای تضمین ویژگی‌های ساختاری ماتریس کوواریانس، چهارچوبی فراهم می‌کند که می‌تواند هم‌زمان از ظرفیت یادگیری الگوهای پیچیده و الزامات محاسباتی مسئلهٔ تخصیص ریسک بهره ببرد.

بااین‌حال، نتایج به‌دست‌آمده را نباید به معنای برتری مطلق LSTM در تمامی شرایط بازار تلقی کرد. عملکرد مدل‌های پیش‌بینی مالی می‌تواند به انتخاب دورهٔ زمانی، نوع دارایی‌ها، افق پیش‌بینی، مشخصات داده‌ها، و نحوهٔ تنظیم پارامترهای مدل وابسته باشد؛ ازاین‌رو، توسعهٔ این پژوهش در چند مسیر می‌تواند ارزشمند باشد. استفاده از معماری‌های جدیدتر یادگیری عمیق، ازجمله مدل‌های مبتنی بر ترنسفورمر،[1] می‌تواند برای بررسی وابستگی‌های طولانی‌مدت و پیچیده‌تر مورد توجه قرار گیرد. همچنین، ترکیب مدل CNN و LSTM می‌تواند امکان استخراج هم‌زمان ویژگی‌های محلی و زمانی داده‌ها را فراهم کند. در کنار اطلاعات قیمتی، واردکردن متغیرهای اقتصاد کلان، شاخص‌های احساسات و رفتار سرمایه‌گذاران، و سایر متغیرهای اثرگذار بر بازار نیز می‌تواند به غنی‌ترشدن اطلاعات ورودی مدل و ارتقای کیفیت پیش‌بینی ماتریس کوواریانس کمک کند.

[1] transformer

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

در مطالعات آتی، همچنین پیشنهاد می‌شود عملکرد مدل‌ها در افق‌های زمانی متفاوت بررسی شود تا مشخص گردد آیا مزیت روش پیشنهادی در مقیاس‌های روزانه، ماهانه، یا سایر دوره‌های زمانی نیز حفظ می‌شود یا خیر. ازسوی‌دیگر، لحاظ‌کردن هزینه‌های معاملاتی، کارمزدها، محدودیت‌های نقدشوندگی، و سایر اصطکاک‌های بازار می‌تواند فاصلهٔ میان نتایج نظری و بازده قابل‌تحقق در شرایط واقعی را کاهش دهد. درمجموع، گسترش این چهارچوب به سایر بازارها، دوره‌های زمانی، و مجموعه‌های دارایی می‌تواند شناخت دقیق‌تری از قابلیت روش‌های یادگیری عمیق در پیش‌بینی ساختار ریسک و طراحی سبدهای سرمایه‌گذاری مقاوم در بازارهای نوظهور فراهم کند.

فهرست منابع

اسفندیار، م.، کرامتی، م. ع.، و غلامی جمکرانی، ر. (۱۴۰۱). بهینه‌سازی پورتفوی سهام در بورس اوراق بهادار تهران (کاربرد رهیافت یادگیری تقویتی). *مدل‌سازی اقتصادی*، ۱۶ (۵۸)، ۵۱-۶۶.

اقتصاد، ا. ع.، و محمدی، ع. (۱۴۰۲). بهینه‌سازی سبد سرمایه‌گذاری به‌کمک پیش‌بینی بازده مورد انتظار با استفاده از روش‌های شبکهٔ عصبی LSTM، جنگل تصادفی، و ARIMA. *چشم‌انداز مدیریت مالی*، ۱۳ (۴۳)، ۹-۲۸.

کیانی‌زاده، ح.، باغانی، ع.، و حمیدیان، م. (۱۴۰۲). مقایسهٔ دقت مدل‌های منتخب یادگیری ماشین جهت پیش‌بینی قیمت سهام در بورس اوراق بهادار. *بورس اوراق بهادار*، ۱۶ (۶۲)، ۷۵-۱۰۲.

هراتی‌زاده، س.، و رضایی، ف. (۱۴۰۲). ارائهٔ روشی جدید برای بهره‌گیری از یادگیری ماشین در فرایند بهینه‌سازی سبد سهام. *تصمیم‌گیری و تحقیق در عملیات*، ۸ (۲)، ۵۲۷-۵۳۹.

Agal, S., Raulji, K., & Odedra, N. D. (2025). A machine learning approach to risk based asset allocation in portfolio optimization. *Scientific Reports*, 15, 42263.

Deković, D., & Šimović, P. P. (2025). Hierarchical risk parity: Efficient implementation and real world analysis. *Future Generation Computer Systems*, 107744.

Espiga-Fernández, F., García-Sánchez, Á., & Ordieres-Meré, J. (2024). A systematic approach to portfolio optimization: A comparative study of reinforcement learning agents, market signals, and investment horizons. *Algorithms*, 17(12), 570.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

Fan, Y. (2025). Enhancing Investment Strategies with LSTM-based Stock Prediction and Mean-Variance Portfolio Optimization. *Advances in Economics, Management and Political Sciences*, 182, 110–117.

Haratizadeh, S., & Rezaee, F. (2023). A novel machine learning approach for portfolio optimization. *Journal of Decisions and Operations Research, 8*(2), 527–539. https://doi.org/10.22105/dmor.2022.307005.1488

Kevin, J., & Yugopuspito, P. (2025). Hybrid LSTM and PPO Networks for Dynamic Portfolio Optimization. *arXiv*.

Li, H., & Liu, T. (2023). Portfolio Optimization Based on the LSTM Forecasting Model. *Advances in Economics, Management and Political Sciences*, 48, 97–106.

Li, X. (2025). LSTM-based Portfolio Optimization Strategy. *Highlights in Business, Economics and Management*, 50, 347–354.

Majumder, R., Ji, Q., & Neerchal, N. K. (2024). Optimal Stock Portfolio Selection with a Multivariate Hidden Markov Model. *arXiv*.

Salas-Molina, F., Pla-Santamaria, D., Garcia-Bernabeu, A., & Hilario-Caballero, A. (2025). An Empirical Evaluation of Distance Metrics in Hierarchical Risk Parity Methods for Asset Allocation. *Computational Economics,* 1-18.

Taljaard, B. (2025). Regime-based portfolio optimisation: A Hidden Markov Model approach for fixed income portfolios. *European Stability Mechanism Working Paper*.

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

Journal of Monetary & Banking Research
Vol. 19, No. 69, spring 2026
pages 609-644

Risk Parity Portfolio Based on Long Short-Term Memory Networks with Cholesky Decomposition Approach

Seifollah Heidari[1] **Amirmohammad Zadeh**[2]
Soheila Khishtandar[3]

Received: 17-Feb-2026 Accepted: 1-Jun-2026

Abstract

Risk parity portfolio, with balanced risk distribution among all assets in the portfolio, strives to prevent risk concentration on a specific asset or group, contributing to the stability and resilience of the investment portfolio against market shocks. However, the effective implementation of the risk parity strategy requires the dynamic understanding and management of the asset covariance matrix, as relationships and correlations among assets change over time. The present research utilizes Long Short-Term Memory (LSTM) networks for the dynamic prediction of the covariance matrix, with its innovation lying in addressing the issue of the predicted covariance matrix not being positive definite by employing the Cholesky decomposition approach. In this study, the risk parity approach was used to optimize a portfolio consisting of 10 major Tehran Stock Exchange indices over the period 1390 to 1404, comparing three models: LSTM networks with Cholesky decomposition, Hidden Markov, and DCC-GARCH. The results showed that the LSTM model has

[1] Ph.D. Candidate, Islamic Azad University, Qazvin, Faculty of Management and Accounting, 4051107663@iau.ac.ir
[2] Associate Professor, Islamic Azad University, Qazvin, Faculty of Management and Accounting, (*Corresponding Author)*, amir126@iau.ac.ir
[3] Assistant Professor, Islamic Azad University, Qazvin, Faculty of Management and Accounting, soheila.khishtandar@iau.ac.ir

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]

advantages over the other two models in terms of weekly average return, Sharpe ratio, cumulative return, and maximum drawdown. This superiority stems from LSTM's ability to model the complex and dynamic patterns of the Iranian capital market.

Keywords: Risk Parity Portfolio, Long Short-Term Memory Network, Cholesky Decomposition, Hidden Markov Model, DCC-GARCH Model
JEL Classification: G11, G17, C45

[Downloaded from jmbr.mbri.ac.ir on 2026-11-05]