



A Machine Learning-Based Hierarchical Risk Parity Approach: A Case Study of Portfolio Consisting of Stocks of the Top 30 Companies on the Tehran Stock Exchange

Marziyeh Nourahmadi 

Ph.D., Department of Financial Engineering, Faculty of Economic, Management and Accounting, Yazd University, Yazd, Iran. E-mail: mnourahmadi@ut.ac.com

Hojjatollah Sadeqi * 

*Corresponding Author, Associate Prof., Department of Financial Management, Faculty of Economic, Management and Accounting, Yazd University, Yazd, Iran. E-mail: sadeqi@yazd.ac.ir

Abstract

Objective: The problem of securities optimization is a significant financial problem, and the issue of choosing the optimal stock portfolio has long occupied the minds of investment professionals. Under uncertain conditions, it is essential to determine asset allocation. The creation of a portfolio of investments is one of the most common financial challenges faced by investors. For them, building a portfolio of investments that yields the highest level of profit is imperative. Various methods have been introduced to construct a portfolio, the most famous of which is the Markowitz approach. There are numerous shortcomings with mean-variance theory due to its difficulty in estimating expected returns and covariances for different asset classes. The problem with the Markowitz variance-mean method, estimation errors, and inconsistencies led to the development of several other academics' attempts to find possible portfolio solutions that would lead to optimal asset allocation. To overcome this problem, Marcos Lopez de Prado was the first researcher to propose a hierarchical model for portfolio construction in his famous paper "Building Diversified Portfolios that outperform out-of-sample", in 2016.

Methods: The present study is applied in terms of purpose, quantitative in terms of the implementation process, and retrospective and post-event in terms of time. This research focuses on the application of machine learning in selecting the optimal portfolio and its purpose is to find a stock portfolio optimization method that has superior performance in prototype simulation for the Tehran Stock Exchange. In this study, we use the Hierarchical Risk Parity (HRP) machine learning technique and compare the results with the minimum variance approach. The concept of HRP is based on graph theory and machine learning techniques and can be divided into three main stages including tree clustering, quasi-diagonalization, and recursive bisection. To conduct this research, the

adjusted closing prices of 30 listed companies for 760 trading days from 2018 to 2020 were used. Missing values were filled by propagating the last valid observation forward

Results: To evaluate portfolio performance, the Sharpe ratio was measured for both in-sample and out-of-sample periods. The results of in-sample and out-of-sample analyses showed that the Hierarchical Risk Parity approach performs better than the minimum variance approach.

Conclusion: In this study, the researchers employed a novel asset allocation method – Hierarchical Risk Parity (HRP) which has the most desirable diversification properties. HRP provides a meaningful alternative to traditional asset allocation approaches and an important risk management tool for investors. Therefore, portfolio managers should have an active approach in evaluating each method according to the conditions and situations in which they are.

Keywords: Portfolio optimization, Minimum-variance, Hierarchical risk parity, Machine learning, Portfolio performance.

Citation: Nourahmadi, Marziyeh & Sadeqi, Hojjatollah (2022). A Machine Learning-Based Hierarchical Risk Parity Approach: A Case Study of Portfolio Consisting of Stocks of the Top 30 Companies on the Tehran Stock Exchange. *Financial Research Journal*, 24(2), 236-256. <https://doi.org/10.22059/FRJ.2021.319092.1007146> (in Persian)

Financial Research Journal, 2022, Vol. 24, No.2, pp. 236-256
Published by University of Tehran, Faculty of Management
<https://doi.org/10.22059/FRJ.2021.319092.1007146>
Article Type: Research Paper
© Authors

Received: February 15, 2021
Received in revised form: July 24, 2021
Accepted: January 2, 2022
Published online: August 30, 2022



پژوهشگاه علوم انسانی و مطالعات فرهنگی
رتال جامع علوم انسانی

یادگیری ماشین مبتنی بر رویکرد سلسله‌مراتبی برابری ریسک (مطالعه موردی: پرتفولیو

سهام متشکل از ۳۰ شرکت برتر بورس اوراق بهادار تهران)

مرضیه نوراحمدی

دکتری، گروه مهندسی مالی، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران. رایانامه: mnourahmadi@ut.ac.com

حجت‌الله صادقی*

* نویسنده مسئول، دانشیار، گروه مدیریت مالی، دانشکده اقتصاد، مدیریت و حسابداری، دانشگاه یزد، یزد، ایران. رایانامه: sadeqi@yazd.ac.ir

چکیده

هدف: مسئله تخصیص دارایی‌ها، به تصمیم‌گیری تحت شرایط عدم اطمینان نیاز دارد. تشکیل پرتفوی سرمایه‌گذاری، یکی از مشکلات مالی بسیار رایج است. همواره سرمایه‌گذاران در تکاپوی تشکیل بهترین پرتفوی برای سرمایه‌گذاری هستند تا بتوانند بیشترین سود را کسب کنند. تاکنون روش‌های زیادی برای تشکیل پرتفوی معرفی شده است که مشهورترین آن، رویکرد مارکویتز است. تئوری میانگین - واریانس، به دلیل دشواری در تخمین بازده مورد انتظار و کواریانس برای طبقات مختلف دارایی، اشکال‌های عملی زیادی دارد. هدف از اجرای این پژوهش، یافتن روشی برای بهینه‌سازی سبد سهام است که در شبیه‌سازی برون‌نمونه برای بازار سهام ایران، عملکرد برتری داشته باشد.

روش: در این پژوهش، از تکنیک یادگیری ماشین برابری ریسک سلسله‌مراتبی استفاده شده و نتایج آن با رویکرد مینیمم واریانس مقایسه شده است. برای اجرای این پژوهش، از قیمت پایانی تعدیل شده ۳۰ شرکت بورسی برای ۷۶۰ روز معاملاتی در دوره زمانی ۱۳۹۷ تا ۱۳۹۹ استفاده شده است.

یافته‌ها: برای ارزیابی عملکرد پرتفولیو از نسبت شارپ برای هر دو دوره درون‌نمونه و برون‌نمونه استفاده شد. نتایج به‌دست‌آمده از تحلیل درون‌نمونه و برون‌نمونه نشان داد که رویکرد برابری ریسک سلسله‌مراتبی، در مقایسه با رویکرد مینیمم واریانس، عملکرد بهتری دارد.

نتیجه‌گیری: رویکرد برابری ریسک سلسله‌مراتبی، جایگزین معناداری برای رویکردهای سنتی تخصیص دارایی، از جمله رویکرد مینیمم واریانس است و برای سرمایه‌گذاران، ابزار مهم مدیریت ریسک محسوب می‌شود. مدیران سبگ‌گردان و سرمایه‌گذاران نیز می‌توانند از این روش برای تخصیص وزن به سبد خود استفاده کنند.

کلیدواژه‌ها: بهینه‌سازی پرتفولیو، مینیمم واریانس، سلسله‌مراتبی برابری ریسک، یادگیری ماشین، عملکرد پرتفولیو.

استناد: نوراحمدی، مرضیه و صادقی، حجت‌الله (۱۴۰۱). یادگیری ماشین مبتنی بر رویکرد سلسله‌مراتبی برابری ریسک (مطالعه موردی: پرتفولیو سهام متشکل از ۳۰ شرکت برتر بورس اوراق بهادار تهران). *تحقیقات مالی*، ۲۴(۳)، ۲۳۶-۲۵۶.

مقدمه

مشکل بهینه‌سازی اوراق بهادار یک مشکل اساسی در مالی است و بحث انتخاب سبد سهام بهینه از گذشته ذهن متخصصان سرمایه‌گذاری را به خود مشغول کرده است. یکی از مفروضات اساسی در مالی این است که به دلیل کمبود منابع، همه گزینه‌های اقتصادی با نوعی مبادله مواجهند. مسئله مهمی که سرمایه‌گذار منطقی هنگام تصمیم‌گیری در خصوص سرمایه‌گذاری با آن روبه‌رو می‌شود، انتخاب بین میزان بازدهی‌ای است که می‌خواهد به دست آورد و میزان ریسکی که مایل است با توجه به آن بازده بپذیرد. در نتیجه، مرحله مهم فرایند سرمایه‌گذاری، این است که تشخیص دهد چطور منابع مالی خود را به نحو بهینه تخصیص دهد (بچیس، کری و والپیان، ۲۰۲۰).

در دهه ۱۹۵۰، مارکوویتز، پدر نظریه مدرن پرتفولیو (MPT) تئوری خود را ارائه نمود که بیان می‌کند که سرمایه‌گذاران هنگام تصمیم‌گیری در خصوص کارآمدترین روش تخصیص منابع، عقلایی عمل می‌کنند. اگرچه نمی‌توانند ریسک پرتفولیو را به طور کامل حذف کنند؛ قانونی وجود دارد که طبق آن سرمایه‌گذاران وجوه خود را میان تمام اوراق بهاداری که حداکثر بازده مورد انتظار را دارند، متنوع‌سازی می‌نمایند. این قانون فرض می‌کند که سبد سهام بهینه دارای حداکثر بازده مورد انتظار و حداقل واریانس است.

نظریه مارکوویتز امروزه به عنوان تئوری پرتفولیو مدرن شناخته می‌شود و پایه کلیه ادبیات سرمایه‌گذاری و روش‌های بهینه‌سازی اوراق بهادار است. این روش موفق شد در جایی که مردم فقط به میانگین و واریانس بازده سبد سهام علاقه‌مند بودند، رویکردی بهینه برای تخصیص منابع در میان اوراق بهادار ریسکی فرموله کند. MPT یک روش رسمی و در عین حال قابل قبول برای یافتن پرتفولیوهای بهینه فراهم می‌کند که مرز کارا نامیده می‌شود که بیشترین بازده مورد انتظار برای یک سطح معین از ریسک یا کمترین ریسک را به ازای یک سطح معین از بازده مورد انتظار نشان می‌دهد (بچیس و همکاران، ۲۰۲۰).

مشکل روش واریانس - میانگین مارکوویتز، خطاهای تخمین و ناسازگاری، سبب شد که تلاش‌های دیگری برای یافتن راه‌حل‌های ممکن پرتفولیو که به تخصیص بهینه‌تری منجر شود، توسعه یابد. تئوری میانگین - واریانس، به دلیل دشواری در تخمین بازده مورد انتظار و کواریانس برای طبقات مختلف دارایی، اشکالات عملی زیادی دارد. متنوع‌سازی پرتفولیو و عملکرد اوراق بهادار طی بحران مالی اعتباری ۲۰۰۸، نیاز به صنعت مدیریت دارایی برای ایجاد چارچوب‌های نظری جدید با نتایج تجربی قوی را آشکار کرد. مدل‌های جدید مبتنی بر ریسک هستند، به این معنی که آنها سعی می‌کنند عوامل ریسک را به جای بازده مورد انتظار که پیش‌بینی‌پذیر نیستند، تخمین بزنند. وزن پرتفوی جدید، بازده مورد انتظار را در نظر نمی‌گیرد و فقط به عوامل ریسک خاص مؤثر بر هر ورق بهادار در پرتفولیو بستگی دارد.

با وجود دیدگاه رایج مبنی بر شکست متنوع‌سازی در بحران اعتباری اخیر، استراتژی‌های برابری ریسک، عملکرد خوبی نسبت به پرتفولیو سنتی از خود نشان دادند.

روشی که معمولاً مورد استفاده قرار می‌گرفت، اختصاص ۶۰ درصد از سبد به سهم و ۴۰ درصد از آن به اوراق قرضه بود. با این حال این استراتژی به دلیل عدم تنوع‌بخشی، به عملکرد بسیار ضعیف منجر می‌شود (بچیس و همکاران، ۲۰۲۰). بنابراین پرتفولیو برابری ریسک سعی کرد تا با سرمایه‌گذاری در کلاس‌های مختلف دارایی، شکاف را پر کند و کل ریسک بازار را به‌طور مساوی به هر گروه منتقل کند. از مصادیق تخصیص دارایی جدید، می‌توان به اوراق قرضه، سهام، املاک و مستغلات، کالاها و صندوق‌های پوششی و... اشاره کرد. دلیل اصلی رویکردهای برابری ریسک، تقسیم درصد ریسک هر کلاس دارایی است؛ اما چرا سرمایه‌گذاران باید به سهم مشارکت هر کلاس دارایی علاقه داشته باشند. از نظر تجربی نشان داده شده است که ریسک سهم، شاخص بسیار دقیقی برای سنجش ضرر سهم است.

نکته اصلی برابری ریسک، تنوع بخشیدن به کلاس‌های دارایی است که در محیط‌های اقتصادی رفتار متفاوتی دارند. به‌طور کلی، سهام در محیط‌های با رشد بالا و تورم کم خوب عمل می‌کند، اوراق قرضه در تورم یا رکود اقتصادی به خوبی عمل می‌کند و کالاها معمولاً در شرایط تورمی بهترین عملکرد را دارند. بنابراین، ایجاد یک سبد متعادل می‌تواند به بازدهی بسیار قوی‌تر منجر شود. پرتفولیو برابری ریسک، معمولاً بیشتر از استراتژی‌های سنتی تخصیص دارایی، در اوراق بهادار با نوسان کم سرمایه‌گذاری می‌کنند. برخی از مهم‌ترین مدل‌های مبتنی بر ریسک عبارت‌اند از: پرتفولیو با مشارکت مقدار برابر در ریسک (ERC)^۱، پرتفولیو برابری ریسک (RP)^۲، مینی‌م واریانس کلی (GMV)^۳، پرتفولیو با حداکثر تنوع‌سازی (MDP)^۴، پرتفولیو با حداکثر نسبت شارپ (MSP)^۵، استراتژی نوسان معکوس (IV)^۶ و پرتفولیو با وزن بازار سهام (MCWP)^۷.

به دلیل دشواری در تخمین بازده مورد انتظار و کواریانس برای طبقات مختلف دارایی، رویکرد میانگین - واریانس (MVP) دارای اشکالات عملی زیادی است. به‌منظور برطرف نمودن این اشکالات، دپردو^۸ اولین محقق بود که مدل سلسله‌مراتبی را برای ساخت پرتفولیو در سال ۲۰۱۶ پیشنهاد نمود. این محقق اسپانیایی، از تئوری شبکه و یادگیری ماشینی برای ساخت یک پرتفولیو متنوع با رویکرد برابری ریسک سلسله‌مراتبی (HRP) استفاده کرد که با مدل‌های بهینه‌سازی پرتفولیو مبتنی بر ریسک تفاوت شایان توجهی دارد. روش HRP از وارونگی ماتریس کواریانس جلوگیری می‌کند. همچنین دپردو در پژوهش خود ثابت کرد که پذیرش الگوریتم HRP به تولید پرتفولیوهایی با استحکام بیشتر منجر می‌شود که نسبت به سایر استراتژی‌های تخصیص، نوسان‌های کمتری دارد. در این پژوهش، رویکرد برابری ریسک سلسله‌مراتبی، بر اساس روش‌های خوشه‌بندی، پیاده‌سازی شده و با روش بهینه‌سازی مینی‌م - واریانس

1. Equal Risk Contribution Portfolio
2. Risk Parity Portfolio
3. Global Minimum Variance
4. Maximum Diversification Portfolio
5. Maximum Sharpe Ratio Portfolio
6. Inverse Volatility Strategy
7. Market-Capitalization-Weighted Portfolio
8. Marcos Lopez de Prado

(MVP)^۱ مقایسه شده است. مجموعه داده مورد استفاده برای این پژوهش، ۳۰ شرکت برتر بورس اوراق بهادار تهران است.

در بخش بعدی به ادبیات نظری و پژوهش‌های انجام شده در این خصوص پرداخته می‌شود و در بخش سوم، تئوری HRP توضیح و شرح داده می‌شود. در نهایت به پیاده‌سازی پرتفوی با استفاده از این رویکرد برای ۳۰ شرکت برتر بورس اوراق بهادار تهران در دو دوره درون‌نمونه و برون‌نمونه پرداخته و نتایج هر دو روش با استفاده از معیار شارپ ارزیابی خواهد شد.

پیشینه پژوهش

پرتفولیو فرایندی است که در آن سرمایه‌گذاران نحوه تخصیص دارایی را انتخاب می‌نمایند. نظریه پرتفولیو مارکویتز، نه تنها عوامل تعیین‌کننده ریسک پرتفولیو را آشکار می‌نماید، بلکه مهم‌تر از آن، این نتیجه‌گیری مهم را نشان می‌دهد که «بازده مورد انتظار یک دارایی توسط ریسک خود تعیین می‌شود»؛ یعنی قیمت دارایی، دارایی‌ها با توجه به اندازه ریسک آنها قیمت‌گذاری می‌شوند. قیمت یک دارایی متناسب با واریانس یا انحراف معیار آن تعیین می‌شود.

مدیران سرمایه‌گذاری می‌توانند عملکرد پرتفوی سرمایه‌گذاری را در سه فعالیتی به‌دست آورند که روند مدیریت پرتفوی را تشکیل می‌دهد: سیاست سرمایه‌گذاری، انتخاب سبد و زمان‌بندی بازار. مطالعات انجام شده در مورد برنامه‌های بزرگ بازنشت‌نگی ایالات متحده نشان می‌دهد که کل بازده سیاست سرمایه‌گذاری ۹۳/۶ درصد است؛ از این رو سیاست سرمایه‌گذاری مهم‌ترین بخش در مدیریت پرتفوی به حساب می‌آید و اغلب به آن تخصیص استراتژیک گفته می‌شود (برینسون، هود و بریبور،^۲ ۱۹۸۶). سیاست سرمایه‌گذاری یا تخصیص استراتژیک، تعیین می‌کند که کدام دسته از دارایی‌ها و با چه وزنی برای رسیدن به هدف سرمایه‌گذاری انتخاب شوند (برینسون و همکاران، ۱۹۸۶). با توجه به کلاس دارایی و وزن آن، از آنجا که هر کلاس دارایی با ریسک و بازده خود مرتبط است، مدیر سرمایه‌گذاری باید در مورد تحمل ریسک، افق سرمایه‌گذاری و سطح ریسک سرمایه‌گذاری تصمیم بگیرد (کوهرنس،^۳ ۱۹۹۹).

برای درک بهتر موضوع، کلیدواژه «Diversified Portfolios» در تاریخ ۲۲ ژانویه ۲۰۲۱ در اسکپوس جست‌وجو شد و با استفاده از bibliometrix در نرم‌افزار R خروجی‌های مندرج در جدول ۱ به‌دست آمد.

با توجه به نتایج به‌دست‌آمده از درگاه اسکپوس، تاکنون ۷۵۷ پژوهش بین دوره زمانی ۱۹۹۵ تا ۲۰۲۱ انجام شده است که از بین آنها، ۵۹۲ پژوهش در قالب مقاله گزارش شده است. در جدول ۱ آمار توصیفی پژوهش‌های انجام شده درج شده است. همچنین، شکل ۱ سیر پژوهش‌های انجام شده طی دوره‌های زمانی مختلف را نشان می‌دهد.

1. Minimum-Variance Portfolio
2. Brinson, Hood & Beebower
3. Cochrane

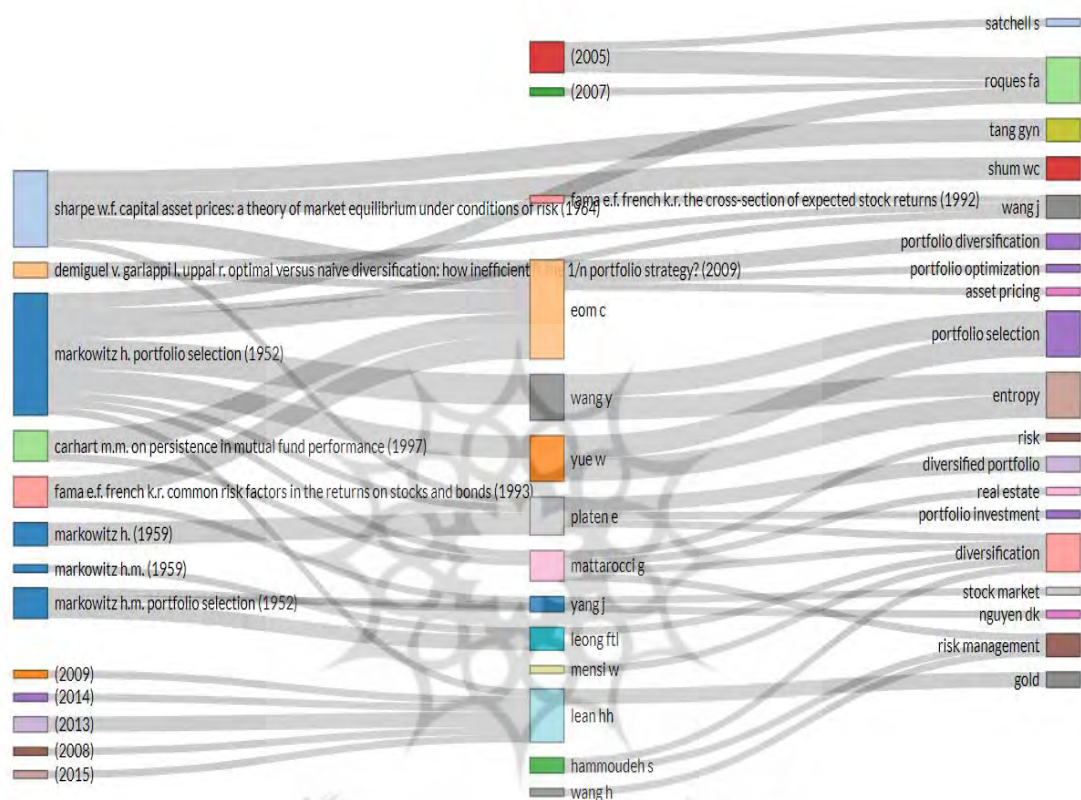
جدول ۱. آمار توصیفی پژوهش‌های انجام شده

نتایج	توصیف
اطلاعات اصلی در خصوص داده‌ها	
۱۹۵۷:۲۰۲۱	دوره زمانی
۴۷۰	منابع (مقاله، کتاب و ...)
۷۵۷	اسناد
۱۰/۵	میانگین انتشار در هر سال
۱۸/۴۳	میانگین استناددهی در هر سال
۲۳۵۵۱	منابع
نوع اسناد	
۵۹۲	مقاله
۲	مقالات در دست انتشار
۳	کتاب
۴۵	فصل کتاب
۴	مقالات کسب و کار
۵۷	مقاله کنفرانسی
۲	مقاله مروری
محتوای اسناد	
۱۷۲۹	کلمات کلیدی
۱۵۶۹	نویسندگان



شکل ۱. تعداد پژوهش‌های انجام شده در هر سال

در شکل ۲ اهمیت تنوع بخشی پرتفولیو در تحقیقات انجام گرفته نشان داده شده است. در این شبکه ارتباط بین نویسندگان، واژگان کلیدی و همچنین موضوع پژوهش انجام گرفته مورد بررسی قرار گرفته است. با بررسی این شکل می توان به زمینه های پژوهشی مورد علاقه پژوهشگران دست پیدا نمود. انتخاب پرتفوی، متنوع سازی پرتفوی، مدیریت ریسک از جمله کلیدواژه های مهم در این پژوهش ها است.



شکل ۲. اهمیت تنوع بخشی پرتفولیو در تحقیقات انجام گرفته

ساختار سلسله مراتبی سیستم های پیچیده مالی برای اولین بار توسط هربرت سایمون برنده جایزه نوبل در سال ۱۹۹۱ بررسی شد (سایمون، ۱۹۹۱). در مقاله معروف «معماری پیچیدگی» نویسنده اظهار می کند که «سیستم پیچیده، یعنی سیستمی که از قسمت های زیادی تشکیل شده است و به روشی دشوار با یکدیگر تعامل غیرساده ای دارند». در چنین سیستم هایی، کل بیشتر از مجموع اجزا است.

وی معتقد است که سیستم های پیچیده مالی، از ساختار سلسله مراتبی برخوردارند که به موجب آن، کل سیستم به زیرگروه های مختلف متمایز تجزیه می شود که می توان آنها را با سهولت بیشتری تجزیه و تحلیل نمود. سیستم سلسله مراتبی، به سیستمی گفته می شود که از سیستم های به هم پیوسته ای تشکیل شده باشد و هر یک از آنها، خود دارای ساختار سلسله مراتبی است تا هنگامی که به پایین ترین سطح از زیرسیستم اولیه برسیم. بنابراین ساختار سلسله مراتبی

می‌تواند به حل مشکلات پیچیده کمک کند و آنها را به زیرگروه‌های کوچک‌تر و ساده‌تری دسته‌بندی کند که در انتها، همهٔ راه‌حل‌ها با هم در یک گروه جمع می‌شوند.

با وجود این، استنباط روابط سلسله‌مراتبی بین اوراق بهادار در طی فرایند تخصیص سبد سهام، چالش‌های بسیاری را به همراه دارد. در واقع ماتریس‌های هم‌بستگی مورد استفاده از پایداری پرتفولیو، ساختار سلسله‌مراتبی را نشان نمی‌دهد. این مسئله در ماتریس‌های بزرگ کواریانس بیشتر مشهود است.

به‌منظور پیش‌بینی ماتریس کواریانس به اندازه N ، حداقل به $\frac{N(N+1)}{2}$ بازده مورد انتظار iid (دارای توزیع یکسان و مستقل) نیاز داریم. با این حال، اثبات شده است که بازده‌های دارای‌ها، نوسان‌های خوشه‌ای و ناهم‌سانی واریانس دارند، از ساختار هم‌بستگی ناپایدار در طول دوره‌های زمانی بلندمدت تشکیل شده‌اند و به خطاهای جدی منجر می‌شوند که می‌تواند مزایای متنوع‌سازی پرتفوی را از بین ببرد.

برای غلبه بر این مشکل، دپردو^۱ اولین محققى بود که مدل سلسله‌مراتبی را برای ساخت پرتفولیو پیشنهاد کرد. این محقق اسپانیایی، از تئوری شبکه و یادگیری ماشینی برای ساخت یک پرتفولیو متنوع با رویکرد برابری ریسک سلسله‌مراتبی بهره برد که با مدل‌های بهینه‌سازی پرتفولیو مبتنی بر ریسک تفاوت‌های چشمگیری دارد. روش HRP از وارونگی ماتریس کواریانس جلوگیری می‌کند. رابطه اوراق بهادار در پرتفوی، به‌عنوان یک سلسله مراتب سازمان یافته است که در آن خوشه‌های دارای مشابه با استفاده از ضریب هم‌بستگی ایجاد می‌شود. جایگزینی ساختار کواریانس سنتی با یک ساختار سلسله‌مراتبی سه هدف اصلی را امکان‌پذیر می‌کند: اول، به‌طور کامل از اطلاعات ماتریس کواریانس استفاده می‌کند؛ دوم، پایداری وزن‌ها را پوشش می‌دهد؛ سوم، برخلاف بیشتر روش‌های سنتی تخصیص‌دهی مبتنی بر ریسک، نیازی به وارونگی ماتریس کواریانس ندارد (بچیس و همکاران، ۲۰۲۰). در جدول ۲ پژوهش‌های انجام شده در خصوص پرتفوی مرور شده است.

جدول ۲. پیشینه پژوهش‌های انجام شده

نکات کلیدی	نویسندگان	عنوان مقاله
استراتژی‌های متنوع‌سازی بر اساس خوشه‌بندی سلسله‌مراتبی بررسی شده است.	لوهره، روتر و اسچافر ^۲ ، ۲۰۲۰	برابری ریسک سلسله‌مراتبی: حسابداری وابستگی‌های ناشی از تخصیص چند عاملی چند‌دارایی.
جنبه‌های فنی وابستگی اندازه پنجره و جنبه متنوع‌سازی پرتفولیو بهینه بررسی شده است.	اونلا، چاکرابورتی، کاسکی، کرتز و کانتو ^۳ ، ۲۰۰۳	پویایی‌های هم‌بستگی بازار: طبقه‌بندی و تجزیه و تحلیل پرتفولیو
استراتژی پرتفولیوی پویا مبتنی بر ساختارهای متغیر شبکه‌های MST در بازار سهام چین ارائه شده است.	رن و همکاران ^۴ ، ۲۰۱۷	استراتژی پرتفولیو پویا با استفاده از رویکرد خوشه‌بندی

1. Marcos Lopez de Prado
2. Lohre, Rother & Schäfer
3. Onnela, Chakraborti, Kaski, Kertesz & Kanto
4. Ren et al.

ادامه جدول ۲

عنوان مقاله	نویسندگان	نکات کلیدی
رویکرد شبکه‌ای برای انتخاب پرتفولیو	پرالتا و زارعی ^۱ ، ۲۰۱۶	هدف عمده این مقاله، به‌کارگیری شبکه‌های مالی به‌عنوان ابزاری مفید برای انتخاب پرتفولیو با هدف قراردادن گروهی از دارایی‌ها با توجه معیار مرکزیت آنهاست.
خوشه‌بندی سری‌های زمانی مالی با کاربرد آن در افزایش رديابی شاخص پرتفولیو	داز و سینکوتی ^۲ ، ۲۰۰۵	نتایج مبتنی بر خوشه‌بندی با نتایج تکنیک‌های تصادفی مقایسه می‌شود و اهمیت خوشه‌بندی را در کاهش نویز و پایداری روش‌های پیش‌بینی، به‌ویژه برای رديابی شاخص پیشرفته نشان می‌دهد.
ریسک ارتباط متقابل و مدیریت پرتفولیو فعال	باتینگر و پاپنبروک ^۳ ، ۲۰۱۶	در این پژوهش، به‌طور تجربی مطالعات بررسی شده است تا مشخص شود که چگونه امتیازهای معیار مرکزیت مختلف با یکدیگر و با ورودی‌های بهینه‌سازی پرتفولیو ارتباط دارند. سپس چگونگی تلفیق مرکزیت در یک چارچوب مبتنی بر ریسک مانند چارچوب مبتنی بر بازده و ریسک بیان شده است.
الگوریتم‌های خوشه‌بندی برای ساخت پرتفولیو ریسک تعدیل شده	لئون و همکاران ^۴ ، ۲۰۱۷	این مقاله، عملکرد هفت پرتفولیو ایجاد شده با استفاده از تکنیک‌های تجزیه و تحلیل خوشه‌بندی برای طبقه‌بندی دارایی‌ها به دسته‌ها را بررسی می‌کند. همچنین، استفاده از بهینه‌سازی کلاسیک در داخل هر خوشه را برای انتخاب بهترین دارایی‌ها در داخل هر طبقه بررسی کرده است.
انتخاب دارایی مبتنی بر خوشه‌بندی سلسله‌مراتبی	رافینوت ^۵ ، ۲۰۱۷	این مقاله یک روش تخصیص دارایی مبتنی بر خوشه‌بندی سلسله‌مراتبی پیشنهاد می‌نماید که از تئوری شبکه و تکنیک‌های یادگیری ماشین استفاده می‌نماید. نتایج تجربی آنها نشان می‌دهد که پرتفولیو مبتنی بر خوشه‌بندی سلسله‌مراتبی پایدار و واقعاً متنوع است و نسبت به تکنیک‌های معمول بهینه‌سازی، از نظر آماری عملکرد بهتری برای تعدیل ریسک دارد.
ریسک برابر سلسله‌مراتبی برای ساخت پرتفولیو	رافینوت، ۲۰۱۸	نتایج نشان می‌دهد که پرتفولیو HERC ^۶ مبتنی بر معیارهای ریسک نزولی، از نظر آماری عملکرد بهتری نسبت به معیارهای CdaR برای تعدیل ریسک به‌دست می‌آورد.
ساخت پرتفولیو متنوع‌سازی شده که در مقایسه با نمونه عملکرد بهتری دارد	دپرادو ^۷ ، ۲۰۱۶	در این مقاله، نویسنده رویکرد HRP ^۸ را برای جلوگیری از سه‌نگرانی عمده در بهینه‌سازی و CLA ^۹ به‌ویژه بی‌ثباتی، تمرکز و عملکرد پایین معرفی می‌کند.
آیا پرتفولیو مبتنی بر روش‌های یادگیری ماشینی می‌تواند از پرتفولیوهای مبتنی بر ریسک سنتی بهتر عمل کند؟	جین و جین ^{۱۰} ، ۲۰۱۹	در این مقاله به بررسی تأثیر انتخاب غلط ماتریس کواریانس بر عملکرد روش‌های مختلف تخصیص پرداخته شده است. همچنین بررسی می‌کند که آیا عملکرد HRP ^۸ مبتنی بر روش‌های یادگیری ماشین، بهتر از پرتفولیوهای مبتنی بر روش‌های تعدیل ریسک سنتی است یا نه؟

1. Peralta & Zareei

2. Dose & Cincotti

3. Baitinger & Papenbrock

4. León et al.

5. Raffinot

6. Hierarchical Equal Risk Contribution Portfolio (HERC)

7. De Prado

8. Hierarchical Risk Parity (HRP)

9. Critical Line Algorithm (CLA)

10. Jain & Jain

در ایران نیز پژوهش‌هایی در خصوص بهینه‌سازی سبد سهام صورت گرفته که به چند نمونه از آنها اشاره شده است. کریمی (۱۴۰۰) در پژوهش خود به بررسی الگوریتم ژنتیک چند هدفه (NSGA-II) تحت معیار ریسک ارزش در معرض خطر مشروط پرداخت. وی از داده‌های ۱۳ شرکت در دوره زمانی ۱۳۹۰ تا ۱۳۹۷ برای تشکیل سبد استفاده کرد. نتایج نشان داد که در روش الگوریتم ژنتیک چند هدفه (NSGA-II) سهامی که کمترین ارزش در معرض خطر را دارد، بیشترین وزن را در سبد بهینه به دست می‌آورد. همچنین سبد بهینه شده به روش الگوریتم ژنتیک چند هدفه (NSGA-II) بازده بیشتر و در عین حال ریسک کمتری دارد. نبی‌زاده، قره باغی و بهزادی (۱۳۹۶) در پژوهش خود به بررسی عملکرد پرتفوی ردیاب شاخص با رویکرد نامتقارن و وارد کردن بتای نامطلوب در مدل ردیاب شاخص برای بهبود عملکرد آن پرداختند. نتایج پژوهش آنها نشان داد مدلی که بر مبنای بتای نامطلوب ارائه شده و توسط الگوریتم تکامل دیفرانسیلی حل شده است، کارایی بیشتری دارد. تقی‌زاده یزدی، فلاح‌پور و احمدی مقدم (۱۳۹۵) در پژوهش خود به انتخاب پرتفوی بهینه سهام با استفاده از تکنیک‌های نوین برنامه‌ریزی آرمانی، یعنی دو تکنیک برنامه‌ریزی فراآرمانی (Meta-GP) و برنامه‌ریزی آرمانی ترتیبی توسعه‌یافته (ELGP) پرداختند. هر دو مدل به دنبال حداکثرسازی بازدهی و نقدشوندگی و همچنین به حداقل رساندن بتا و ریسک سهام شرکت‌ها برای تشکیل پرتفوی بهینه‌اند. در نهایت دو پرتفوی به دست آمده با مقدار بازدهی هر یک مقایسه شد.

روش بهینه‌سازی به کاررفته در این پژوهش، رویکرد برابری ریسک سلسله‌مراتبی است که با روش بهینه‌سازی مینیم - واریانس مقایسه می‌شود. در ادامه به روش‌شناسی موضوع و معرفی این روش پرداخته شده است.

روش‌شناسی پژوهش

این پژوهش از نظر نوع، مدل‌سازی و از نظر روش، توصیفی و از نظر هدف، کاربردی است. قلمرو موضوعی این تحقیق کاربرد یادگیری ماشین در انتخاب پرتفوی بهینه است. اولین مرحله از فرایند آماده‌سازی داده‌ها استخراج داده است. جامعه آماری این پژوهش ۳۰ شرکت برتر شاخص بورس است که از طریق نرم‌افزار نوآوران امین استخراج شده و کلیه پردازش داده‌ها از طریق نرم‌افزار پایتون انجام شده است. دومین مرحله از فرایند آماده‌سازی داده‌ها، پیش‌پردازش داده‌ها است. در ابتدای این مرحله، لازم است داده‌ها از عواملی همچون نویز، داده‌های پرت و داده‌های گم‌شده که کیفیت داده‌ها را به مخاطره می‌اندازند، پاک‌سازی شود. در این پژوهش، ابتدا تعداد روز معاملاتی همه سهام بررسی شد و با توجه به تعداد روزهای معاملاتی و همچنین، با توجه به اینکه برخی از این شرکت‌ها عرضه اولیه بودند و داده کافی نداشتند، تعداد پنج شرکت از آنها حذف و ۲۵ نمونه برای تجزیه و تحلیل انتخاب شد. کلیه شرکت‌ها برای دوره زمانی از ۱۰ تیر ۱۳۹۷ تا ۸ مرداد ۱۳۹۹ معادل با ۱ ژوئیه ۲۰۱۸ تا ۲۹ ژوئیه ۲۰۲۰ (۷۶۰ روز معاملاتی) مورد بررسی قرار گرفتند. ۸۰ درصد داده‌ها (۶۰۸ روز) به عنوان درون‌نمونه (۱۳۹۷/۱۰/۰۴ تا ۱۳۹۸/۱۲/۰۹) و ۲۰ درصد داده‌ها معادل (۱۵۲ روز) به عنوان برون‌نمونه (۱۳۹۸/۱۲/۱۰ تا ۱۳۹۹/۰۵/۰۸) در نظر گرفته شده است. کلیه محاسبات این پژوهش، در نسخه ۳/۸ نرم‌افزار پایتون انجام شده است. در جدول ۳ آمار توصیفی داده‌ها درج شده است.

جدول ۳. آمار توصیفی داده‌ها

نام شرکت	میانگین	انحراف معیار	مینیمم	%۲۵	%۵۰	%۷۵	ماکزیمم
اخابر	۴۸۲۶/۲۸	۴۹۳۹/۵	۱۴۶۳	۱۹۱۲	۲۹۹۳/۵	۵۷۱۱	۱۷۶۳۰
فارس	۶۰۳۵/۵۷	۶۱۲۲/۰۱۲	۱۸۳۲	۲۷۴۸/۵	۳۵۶۱	۶۲۴۹/۷۵	۳۳۳۰۰
فملی	۵۹۱۳/۱۱	۷۰۶۶/۶۹	۱۳۹۶	۲۳۷۵	۳۳۲۹	۵۸۱۱/۷۵	۳۶۹۱۲
فولاد	۳۹۳۹/۹۹	۴۱۷۷/۳۲۷	۱۱۷۰	۱۸۲۸/۲۵	۲۵۰۸	۳۸۱۰/۲۵	۲۳۰۲۰
همراه	۱۴۲۵۶/۹۵	۱۰۳۲۶/۲۹	۵۷۲۰	۷۸۳۱/۷۵	۱۰۹۱۵	۱۵۵۹۰/۵	۶۴۹۹۰
حکشتی	۸۸۲۵/۹۴	۱۱۵۷۷/۸۳	۲۳۹۱	۳۳۴۹/۲۵	۴۱۰۶	۶۶۷۸/۵	۷۴۵۲۶
جم	۱۴۷۱۰/۶۱۴	۹۲۴۴/۰۵۸	۶۱۸۸	۱۰۱۶۰	۱۱۴۸۲	۱۳۸۴۸	۵۳۸۳۰
کچاد	۵۵۸۸/۳۵۳	۴۹۱۹/۸۰۸	۱۵۹۴	۲۹۷۶	۳۹۰۹	۵۲۲۱/۷۵	۲۵۲۹۰
کگل	۵۶۹۲/۴۲	۴۴۷۲/۸۲۸	۱۹۶۲	۳۳۳۱	۴۳۴۱	۵۰۷۸/۵	۲۴۱۱۰
خودرو	۶۱۶/۳۰۵	۱۱۶۵/۵۰۲	۱۰۰	۱۴۰	۲۶۹/۵	۵۲۵	۷۵۰۰
خسپا	۵۹۸/۱۸	۸۳۲/۶۷۴	۱۵۵	۲۴۴	۳۱۸	۵۸۰/۷۵	۵۲۲۰
پارس	۵۱۵۲۷/۹۰۳	۳۶۲۰۷/۵۱۶	۱۵۴۵۶	۲۷۳۷۵	۳۶۸۶۷/۵	۵۹۵۳۱/۵	۱۷۳۲۶۹
پارسان	۷۱۴۵/۲۹	۷۰۷۶/۵۴	۲۰۷۰	۳۵۰۱/۵	۴۳۳۹/۵	۶۹۴۱	۳۹۶۹۰
رمپنا	۷۲۶۲/۳۳۹	۶۹۲۶/۹۳۱	۱۳۶۷	۲۷۶۲/۷۵	۴۷۶۵	۸۳۳۳/۷۵	۳۳۸۹۳
شپدیس	۲۵۷۰/۳۷	۲۳۱۸۲/۵۶	۶۸۶۹	۱۲۵۹۵/۵	۱۶۶۹۴	۲۴۱۷۲/۷۵	۱۱۷۸۹۰
شپنا	۴۱۷۱/۸۱	۴۸۶۶/۲۵۵	۹۵۹	۲۰۲۱/۲۵	۲۷۸۲/۵	۳۷۸۰	۳۳۵۱۹
شبندر	۹۷۰۱/۷۳۸	۹۲۹۰/۲۷	۲۷۵۹	۴۹۸۸	۶۷۶۵	۹۷۲۹/۲۵	۵۹۳۹۰
شتران	۳۷۹۰/۴۲۸	۴۱۹۲/۰۲۸۶	۸۵۵	۱۶۹۱/۲۵	۲۴۴۱	۳۵۹۶/۲۵	۲۹۹۶۷
تاپیکو	۳۸۴۰/۰۳	۳۹۷۵/۷	۱۰۹۸	۱۷۷۴	۲۲۴۸	۴۰۷۳/۲۵	۲۲۱۰۶
وبملت	۱۵۲۸/۰۹۶	۱۵۴۲/۶۷	۲۱۷	۶۱۰	۱۰۱۱	۱۶۷۹/۲۵	۶۵۹۴
وبصادر	۷۴۵/۷۰	۸۱۵/۲۸	۲۴۸	۳۹۳	۴۴۰	۶۳۳	۴۸۴۰
وغدیر	۳۶۷۳/۴۸	۳۸۰۳/۲۱	۹۷۹	۱۵۲۷/۵	۲۱۹۲	۳۷۴۳/۷۵	۱۹۳۶۰
ومعادن	۴۵۳۷/۵۰	۳۸۱۵/۲۳۹	۱۱۹۴	۲۷۱۳	۳۱۸۸	۴۲۵۹/۷۵	۱۹۷۰۰
وامید	۸۸۳۰/۰۹	۹۰۱۱/۰۲۵	۲۳۱۱	۴۲۳۵/۷۵	۵۷۰۰	۸۲۸۴/۵	۴۷۳۰۰
ویپارس	۶۵۹/۴۹	۹۹۹/۳۳۳	۱۴۳	۱۷۵	۳۶۳	۵۳۵	۵۱۵۰

در جدول ۳، آمار توصیفی داده‌های سهام شرکت‌های مختلف در دوره زمانی منتخب ارائه شده است. مینیمم قیمت سهام برای خودرو معادل ۱۰۰ و ماکزیمم قیمت سهام برای سهام شرکت پارس معادل ۱۷۳۲۶۹ است. در این پژوهش قیمت پایانی تعدیل شده، به عنوان متغیر اصلی ایجاد خوشه استفاده شده است. شروع آن با سری قیمت‌های خام P_{it} است که قیمت سهام شرکت i در روز t را نشان می‌دهد، همچنین P_{it-1} نشان دهنده قیمت سهام شرکت i در روز $t-1$ است. با توجه به اینکه توزیع قیمت سهام، به توزیع لاگ‌نرمال^۱ نزدیک است، برای محاسبه بازده داده‌ها از فرمول بازده لگاریتمی، از رابطه ۱ استفاده می‌شود.

$$R_{it} = \ln \frac{P_{it}}{P_{it-1}} \quad \text{رابطه ۱}$$

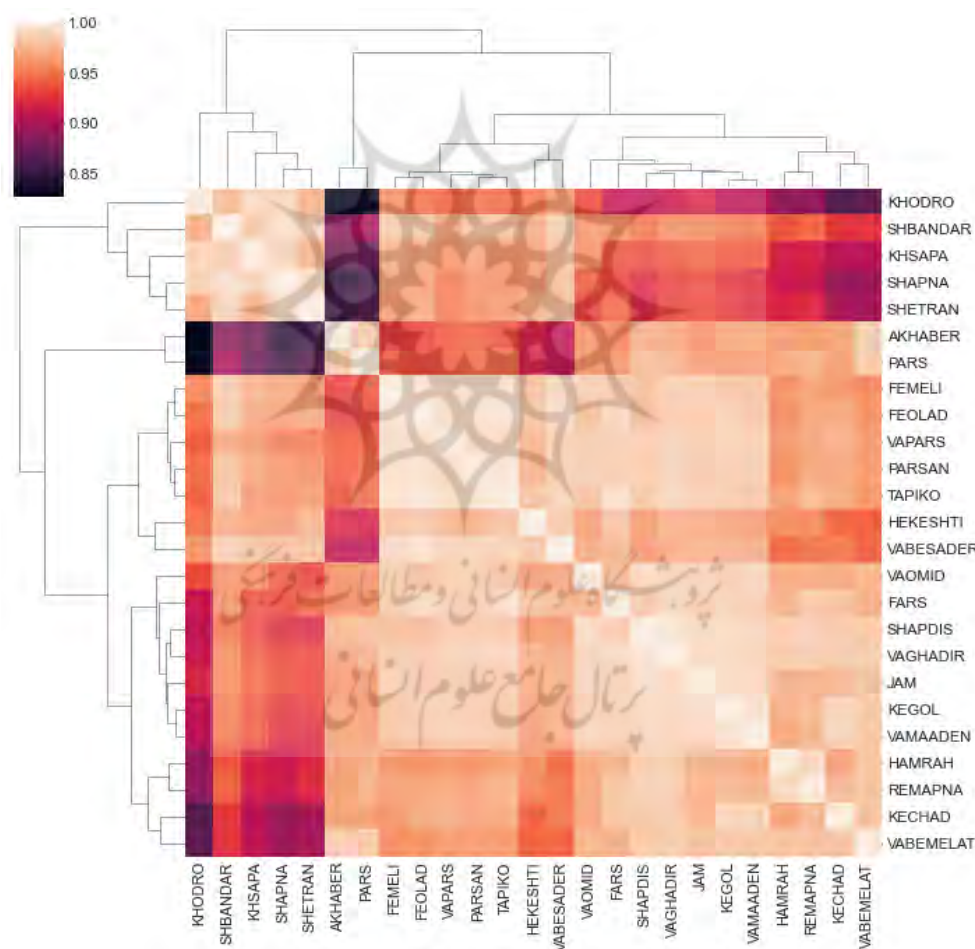
در ادامه به توضیح مدل اصلی کار، یعنی روش HRP پرداخته می‌شود.

1. Lognormal

مفهوم HRP مبتنی بر تئوری گراف و تکنیک‌های یادگیری ماشین است و می‌تواند به سه مرحله اصلی دسته‌بندی شود: خوشه‌بندی درخت^۱، شبه قطری^۲ و تقسیم بازگشتی^۳. در ادامه، هر مرحله را با جزئیات بیشتری شرح می‌دهیم. مرحله اول شامل تجزیه دارایی‌های پرتفولیو به خوشه‌های مختلف با استفاده از الگوریتم خوشه‌بندی درخت سلسله‌مراتبی^۴ است. برای دو دارایی i و j ، ماتریس هم‌بستگی به ماتریس هم‌بستگی - فاصله D به شکل رابطه ۲ تبدیل می‌شود (بارگرافت^۵، ۲۰۲۰):

$$D(X_i, X_j) = \sqrt{\frac{1}{2}(1 - \rho_{i,j})} \quad \text{رابطه ۲}$$

در شکل ۳ ماتریس خوشه‌بندی هم‌بستگی ترسیم شده است.



شکل ۳. ماتریس خوشه‌بندی هم‌بستگی

1. Tree clustering
2. Quasi-diagonalization
3. Recursive bisection
4. Hierarchical Tree Clustering algorithm
5. Burggraf

مرحله دوم، مرحله خوشه‌بندی درخت شامل محاسبه فاصله اقلیدسی بین بردارهای دو ستون D است که ماتریس فاصله \bar{D} را به ما می‌دهد:

$$\bar{D}(i, j) = \sqrt{\sum_{k=1}^N (D(k, i) - D(k, j))^2} \quad \text{رابطه ۳}$$

تفاوت اصلی بین رابطه ۳ و رابطه ۲ که در بخش قبلی محاسبه کردیم، این است که اولی فاصله بین دو اوراق بهادار i و j را در پرتفولیو محاسبه می‌کند، در حالی که دومی فاصله بین آن جفت دارایی‌ها را محاسبه می‌کند. $\bar{D}(i, j)$ تابع کل ماتریس هم‌بستگی است. مرحله بعدی، ایجاد اولین خوشه (i^*, j^*) است. می‌توان جفت‌هایی را برگرداند که حداقل فاصله را دارند:

$$U[1] = \arg \min_{i, j} \bar{D}(i, j) \quad \text{رابطه ۴}$$

U مجموعه خوشه‌هاست. بعد از آن، باید ماتریس \bar{D} را از طریق مسیر «linkage criterion» به‌روزرسانی کنیم. فاصله بین خوشه اول $U[1]$ و دیگر خوشه‌های i به صورت رابطه ۵ محاسبه می‌شود:

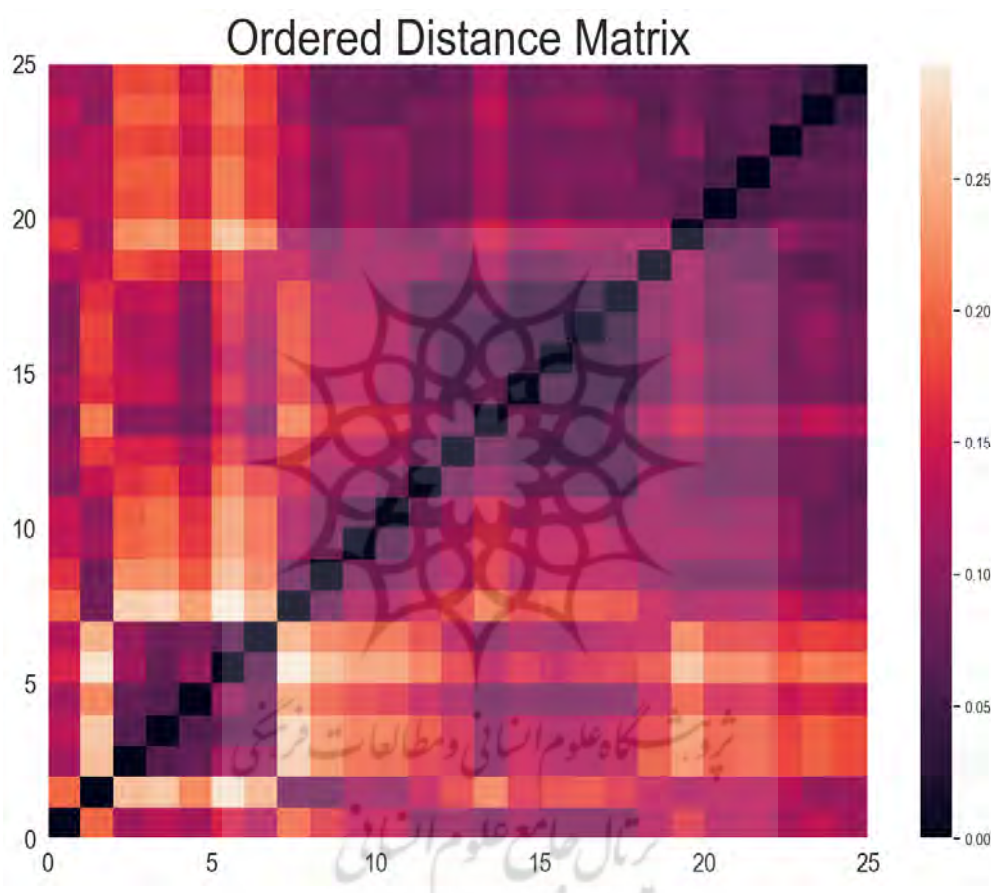
$$\bar{D}(i, U[1]) = \min(\bar{D}(i, i^*), \bar{D}(i, j^*)) \quad \text{رابطه ۵}$$

این مرحله برای هر سهامی در پرتفولیو تکرار می‌شود. هر بار، یک خوشه جدید از دارایی‌ها تشکیل می‌شود، الگوریتم ماتریس فاصله را آپدیت می‌کند، تا زمانی که فقط یک خوشه باقی بماند (بچیس و همکاران، ۲۰۲۰). نتایج در شکل ۴ مشاهده می‌شود.



شکل ۴. نمودار خوشه‌بندی

در مرحله بعد، ماتریس کواریانس quasi-diagonalization استفاده می‌شود که داده‌ها را برای مرتب‌سازی خوشه‌های ذاتی به وضوح مرتب می‌کند. ردیف‌ها و ستون‌های ماتریس کواریانس به گونه‌ای سازمان‌دهی می‌شوند که دارایی‌های مشابه کنار هم قرار گیرند و سرمایه‌گذاری‌های متفاوت از هم جدا شوند. به این ترتیب، کواریانس‌های بزرگ در امتداد مورب ماتریس کواریانس قرار می‌گیرند، در حالی که کواریانس‌های کوچک‌تر در اطراف این مورب قرار می‌گیرند، از این رو quasi-diagonal نامیده می‌شود. نتیجه در شکل ۵ ترسیم شده است.



شکل ۵. ماتریس کواریانس

bisection آخرین و مهم‌ترین مرحله از الگوریتم HRP است؛ زیرا وزن نهایی به اوراق بهادار در سید سهام را تعریف می‌کند. در اینجا از مزیت ویژگی پرتفولیو استفاده می‌کند که تخصیص معکوس برای ماتریس کواریانس قطری بهینه است.

به دنبال فرایند خوشه‌بندی، الگوریتم هر خوشه را به دو زیر خوشه V_1 و V_2 تقسیم می‌کند. از خوشه نهایی $U[N]$ شروع می‌شود. با توجه به وزن داده شده به پرتفولیو $w_i, \forall i = 1, \dots, N$ ، واریانس هر زیر خوشه به صورت روابط ۶ و ۷ محاسبه می‌شود:

$$V_{1,2} = w^T V w \quad \text{رابطه ۶}$$

که:

$$w = \frac{\text{diag}(V)^{-1}}{\text{trace}(\text{diag}(V)^{-1})} \quad \text{رابطه ۷}$$

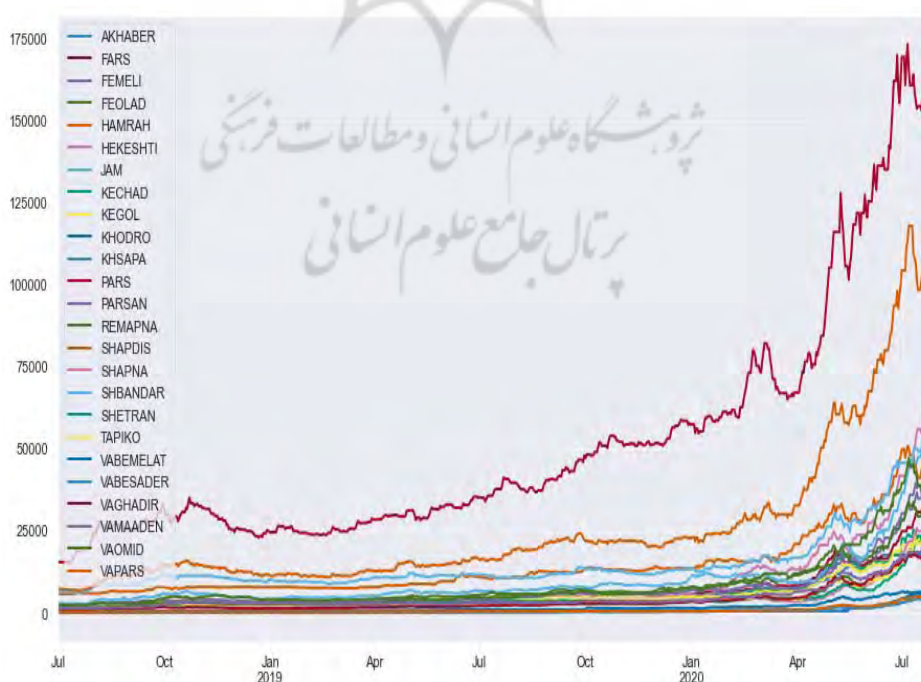
با توجه به این دو عامل وزن، الگوریتم وزن پرتفولیوها را برای هر زیر خوشه به روز می کند. بنابراین، فقط دارایی های موجود در هر خوشه برای تخصیص پرتفولیو نهایی در نظر گرفته می شود. وزن w_1 و w_2 برای این دو زیر خوشه به صورت رابطه ۸ است:

$$w_1 = a_1 * w_1, w_2 = a_2 * w_2 \quad \text{رابطه ۸}$$

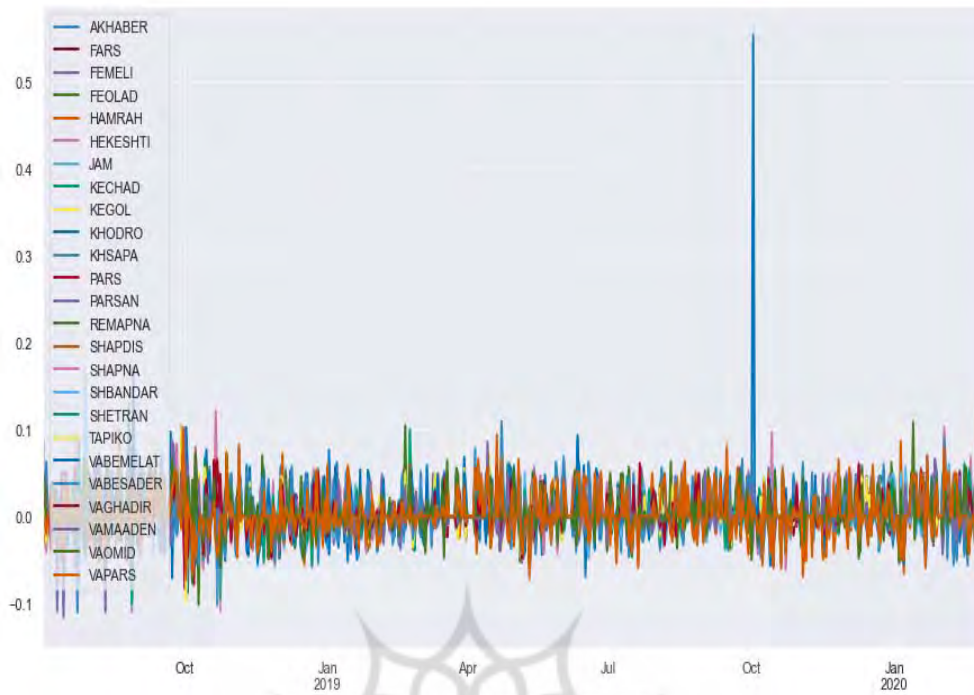
روش تعیین وزن از پایین به بالا، یکی از مزایای HRP نسبت به الگوریتم های تخصیص دیگر است. به جای اینکه همه دارایی های پرتفولیو با هم رقابت کنند، فقط دارایی های یک گروه برای تخصیص با یکدیگر رقابت می کنند. الگوریتم تضمین می کند که $\sum_{i=1}^N w_i = 1$ و $0 \leq w_i \leq 1, \forall i = 1, \dots, N$.

یافته های پژوهش

در شکل های ۶ و ۷، به ترتیب قیمت و بازده داده ها ترسیم شده است.




شکل ۶. قیمت سهام



شکل ۷. بازده سهام

نمودار دندروگرام شرکت‌ها به صورت شکل ۸ است.




شکل ۸. دندروگرام

تمرکز اصلی پژوهش ما، ایجاد جایگزینی خوشه‌بندی HRP به جای بهینه‌سازی سبد سهام با استفاده از رویکرد MVP است. در ادامه با استفاده از دو روش HRP و MVP وزن بهینه پرتفوی را محاسبه نموده و با استفاده از داده‌های درون‌نمونه و برون‌نمونه به ارزیابی این دو روش می‌پردازیم. نتایج در شکل ۹ نشان داده شده است. همچنین، نتایج وزن سهام بر اساس دو روش در جدول ۴ نمایش داده شده است.

جدول ۴. وزن سهام بر اساس دو رویکرد HRP و MVP

HRP	MVP	نام شرکت
۰/۰۵۵۷۱	۰/۰۰۵۷۵	اخابر
۰/۰۴۱۰۱	۰/۰۹۱۹۵۵	فارس
۰/۰۲۶۰۹۰	۰/۰۳۳۶۸	فملی
۰/۰۲۹۵۸	۰/۰۱۱۹۷	فولاد
۰/۱۱۱۸۴۵	۰/۴۱۱۹۴	همراه
۰/۰۳۳۳۷	۰/۰۲۹۰۲	حکشتی
۰/۰۵۹۷	۰/۱۱۸۶	جم
۰/۰۲۷۵۳	۰/۰۰۱۹۹۵	کچاد
۰/۰۴۸۵۶	۰/۰۲۷۲	کگل
۰/۰۳۳۱۸۹	۰/۰۲۱۸۲	خودرو
۰/۰۲۵۳۱	۰/۰۱۷۶۲۸	خسپا
۰/۰۳۵۲	۰/۰۷۱۹۶	پارس
۰/۰۵۷۹۲	۰/۰۰۱۵۱	پارسان
۰/۰۳۵۲۷	۰/۰۱۸۰۷	رمپنا
۰/۰۳۹۵۳	۰/۰۰۳۳۶	شپدیس
۰/۰۳۱۹۲۲	۰/۰۰۶۵۶	شپنا
۰/۰۲۴۷۷۴۵	۰/۰۰۲۲۷	شبندر
۰/۰۲۲۳۶۳	۰/۰۰۹۶۷	شتران
۰/۰۲۷۷۱	۰/۰۰۱۰۷۹	تاپیکو
۰/۰۱۷۲۲	۰/۰۱۵۲۱۳	وبملت
۰/۰۳۴۵۰	۰/۰۵۲۸۱۷	وبصادر
۰/۰۴۴۰	۰/۰۰۱۴۸۸۲	وغدیر
۰/۰۳۸۰۰	۰/۰۲۰۲۷۷۵	ومعادن
۰/۰۷۳۷۵	۰/۰۱۷۹۷۴	وامید
۰/۰۲۶۷۱۱۲	۰/۰۰۶۰۸۷	وپارس



شکل ۹. وزن سهام بر اساس دو روش

همان‌گونه که در جدول ۴ و شکل ۹ ملاحظه می‌شود، بیشترین وزن به همراه اول و کمترین وزن نیز به وبملت اختصاص دارد.


بحث

همان‌گونه که در قسمت قبلی توضیح داده شد، ۸۰ درصد داده‌ها (۶۰۸ روز) به‌عنوان درون‌نمونه و ۲۰ درصد داده‌ها (۱۵۲ روز) به‌عنوان برون‌نمونه در نظر گرفته شده است. در ادامه عملکرد پرتفوی تولید شده توسط هر دو روش با بررسی نتایج داخل نمونه و خارج از نمونه، ارزیابی می‌شود.



شکل ۱۰. درون‌نمونه

همان گونه که ملاحظه می‌شود، عملکرد روش HRP نسبت به MVP در هر دو دوره زمانی درون نمونه و برون نمونه بهتر است. همچنین، هر دو روش نسبت به شاخص کل در هر دو دوره زمانی عملکرد بهتری دارد.



شکل ۱۱. برون نمونه

نسبت شارپ معیار عملکردی است که ویلیام شارپ آن را در سال ۱۹۶۶ معرفی کرد. این نسبت معمولاً توسط سرمایه‌گذاران برای ارزیابی مدیران صندوق و پرتفوی اتخاذ می‌شود که بازده بیشتر از نرخ بدون ریسک در هر واحد نوسان را به دست می‌دهد؛ بنابراین، ابزار مهمی در تخصیص دارایی محسوب می‌شود. در ادامه پس از محاسبه وزن‌ها، با استفاده از معیار شارپ به ارزیابی عملکرد سبد سرمایه‌گذاری برای هر دو روش پرداخته می‌شود. معیار شارپ یا نسبت بازده به تغییرپذیری، بازده را نسبت به ریسک کل سبد سرمایه‌گذاری اندازه‌گیری می‌کند. جدول ۵ خلاصه نتایج ارزیابی هر دو روش MVP و HRP در درون نمونه و برون نمونه را نشان می‌دهد.

جدول ۵. ارزیابی درون نمونه و برون نمونه

نسبت شارپ	انحراف معیار	مدل	
۳/۴۰۷	۰/۱۵۹۱۵	MVP	درون نمونه
۳/۴۰۲	۰/۱۸۲۸۳	HRP	
۷/۶۷۸	۰/۳۱۷۴۷	MVP	برون نمونه
۸/۷۳۱	۰/۲۹۲۲	HRP	

با توجه به نتایج جدول ۵، ملاحظه می‌شود که نسبت شارپ برای الگوریتم HRP در هر دو درون نمونه و برون نمونه بالاتر است و نشان‌دهنده برتری این روش نسبت به رویکرد MVP است.

نتیجه‌گیری و پیشنهادها

از دیرباز، تصمیم‌گیری درباره انتخاب صحیح دارایی‌های مالی و سهام برای ایجاد سبد سرمایه‌گذاری، همیشه با تردید همراه بوده است و یکی از دغدغه‌های اساسی مدیران سرمایه‌گذاری و سرمایه‌گذاران بوده است. مدیریت سبد سرمایه‌گذاری سهام که شامل تجزیه و تحلیل ترکیب سرمایه‌گذاری‌ها و انتخاب و مدیریت نگهداری مجموعه‌ای از سرمایه‌گذاری‌هاست، فرایند پیچیده‌ای است و اغلب از ساختار خاصی تبعیت نمی‌کند. بازارهای سرمایه باعث می‌شوند تا سرمایه‌گذاران منابع مالی مازاد خود را در یک یا چند دارایی سرمایه‌گذاری کنند و از این طریق سود به‌دست آورند. سرمایه‌گذاران، همواره در پی یافتن سبدهای با بیشترین بازده و کمترین ریسک هستند و امروزه با پیچیده‌تر شدن شرایط بازار، اهمیت این موضوع بیشتر شده است. در اصل، فرد سرمایه‌گذار در زمان سرمایه‌گذاری ترجیح می‌دهد تا دارایی یا ترکیبی از دارایی‌ها را انتخاب کند که در آینده با ریسک معین، بیشترین بازده را داشته باشد؛ بنابراین سرمایه‌گذاران و تحلیلگران به دنبال دانستن قیمت آینده دارایی‌ها و عوامل مؤثر بر آن و ریسک سرمایه‌ها هستند. تجزیه و تحلیل بازارهای مالی و ریسک‌های اساسی صنعت بسیار مهم است و تأثیر آن در توسعه و طراحی سبد سرمایه‌گذاری و استراتژی‌های سرمایه‌گذاری بسیار مهم و شایان توجه است. روش‌های بسیاری در رابطه با نحوه انتخاب سبد سرمایه‌گذاری مطرح و معرفی شده است. دپردو^۱ نخستین محقق بود که مدل سلسله‌مراتبی را برای ایجاد پرتفولیوی سهام پیشنهاد نمود. این محقق اسپانیایی، از تئوری شبکه و یادگیری ماشینی برای ساخت یک پرتفولیو متنوع با رویکرد برابری ریسک سلسله‌مراتبی (HRP) استفاده کرد که با مدل‌های بهینه‌سازی پرتفولیو مبتنی بر ریسک تفاوت چشمگیری دارد. روش HRP از وارونگی ماتریس کواریانس جلوگیری می‌کند. با توجه به آنکه روش میانگین - واریانس مارکوویتز، سنگ بنای نظریات انتخاب پرتفولیو است، روش‌های جدیدی که معرفی شده، در گام نخست با محک و معیار روش مارکوویتز مقایسه می‌شوند. بنابراین، در این پژوهش از دو تکنیک یادگیری ماشین HRP و MVP در دو دوره زمانی درون‌نمونه و برون‌نمونه برای ۳۰ شرکت برتر بورس اوراق بهادار استفاده شد. به‌منظور ارزیابی نتایج نیز، از نسبت شارپ بهره‌برده شد. نتایج حاکی از آن است که رویکرد HRP نسبت به MVP عملکرد بهتری در هر دو دوره درون‌نمونه و برون‌نمونه دارد. خاطر نشان می‌شود که در پژوهش حاضر، به بهینه‌سازی پرتفوی روی ۳۰ شرکت برتر اقدام شده است و پژوهشگران می‌توانند در کارهای آتی هم دوره زمانی و هم تعداد سهام منتخب برای بهینه‌سازی را بسط داده و به تجزیه و تحلیل نتایج بپردازند. همچنین می‌توانند این روش‌ها را با سایر روش‌های بهینه‌سازی سهام مقایسه نمایند.

یکی از محدودیت‌هایی که در اغلب پژوهش‌های سری زمانی وجود دارد، این مسئله است که گاهی به دلایلی چون توقف طولانی مدت نماد یا زیاد بودن داده‌های مفقوده، برخی از نمادها از مطالعه به ناچار حذف می‌شوند؛ اما الزاماً بدین معنا نیست که آن سهام‌ها برای پرتفوی سبد سهام مناسب نیستند. همان‌گونه که در روش‌شناسی نیز توضیح داده شد، در این پژوهش ۳۰ شرکت انتخاب شد که به دلیل کمبود داده، ۵ شرکت حذف و با ۲۵ شرکت باقی‌مانده سبد سهام تشکیل شد. بنابراین پژوهشگران می‌توانند در مطالعات آتی، به بررسی نحوه برخورد با چنین داده‌هایی بپردازند. برای این منظور

می‌توانید به پژوهش نوراحمدی و صادقی (۱۳۹۹) که در خصوص مروری بر روش‌های مدیریت مقادیر گمشده در سری‌های زمانی مالی است، مراجعه کنید.

منابع

- کریمی، آرزو (۱۴۰۰). بهینه‌سازی سبد سهام با استفاده از الگوریتم ژنتیک چند هدفه (NSGA II) و ماکزیمم نسبت شارپ. *مهندسی مالی و مدیریت اوراق بهادار*، ۱۲(۴۶)، ۳۸۹-۴۱۰.
- تقی‌زاده یزدی، محمدرضا؛ فلاح‌پور، سعید؛ احمدی مقدم، محمد (۱۳۹۵). انتخاب پرتفوی بهینه با استفاده از برنامه‌ریزی فراآرمانی و برنامه‌ریزی آرمانی ترتیبی توسعه‌یافته. *تحقیقات مالی*، ۱۸(۴)، ۵۹۱-۶۱۲.
- نبی‌زاده، احمد؛ قره‌باغی، هادی؛ بهزادی، عادل (۱۳۹۶). بهینه‌سازی پرتفوی ردیابی شاخص بر اساس بتای نامطلوب مبتنی بر الگوریتم‌های تکاملی. *تحقیقات مالی*، ۱۹(۲)، ۳۱۹-۳۴۰.
- نوراحمدی، مرضیه؛ صادقی، حجت‌الله (۱۳۹۹). مروری بر روش‌های مدیریت مقادیر گمشده در سری‌های زمانی، ششمین همایش ریاضیات و علوم انسانی (ریاضیات مالی). <http://femath6.atu.ac.ir/paper?manu=107697>.

References

- Baitinger, E., & Papenbrock, J. (2016). Interconnectedness risk and active portfolio management. *Journal of Investment Strategies, Forthcoming*. Available at SSRN: <https://ssrn.com/abstract=2909839>
- Bechis, L., Cerri, F., & Vulpiani, M. (n.d.). (2020). *Machine Learning Portfolio Optimization: Hierarchical Risk Parity and Modern Portfolio Theory*.
- Brinson, G. P., Hood, L. R., & Beebower, G. L. (1986). Determinants of portfolio performance. *Financial Analysts Journal*, 42(4), 39-44.
- Burggraf, T. (2020). Beyond Risk Parity—A Machine Learning-based Hierarchical Risk Parity Approach on Cryptocurrencies. *Finance Research Letters*, 101523.
- Cochrane, J. H. (1999). *Portfolio advice for a multifactor world*. National Bureau of Economic Research.
- De Prado, M. L. (2016). Building diversified portfolios that outperform out of sample. *The Journal of Portfolio Management*, 42(4), 59-69.
- Dose, C., & Cincotti, S. (2005). Clustering of financial time series with application to index and enhanced index tracking portfolio. *Physica A: Statistical Mechanics and Its Applications*, 355(1), 145-151.
- Hüttner, A., Mai, J.-F., & Mineo, S. (2018). Portfolio selection based on graphs: Does it align with Markowitz-optimal portfolios? *Dependence Modeling*, 6(1), 63-87.
- Jain, P., & Jain, S. (2019). Can machine learning-based portfolios outperform traditional risk-based portfolios? the need to account for covariance misspecification. *Risks*, 7(3), 74.

- León, D., Aragón, A., Sandoval, J., Hernández, G. J., Arévalo, A., & Niño, J. (2017). Clustering algorithms for Risk-Adjusted Portfolio Construction. *ICCS*, 1334–1343.
- Lohre, H., Rother, C., & Schäfer, K. A. (2020). Hierarchical risk parity: Accounting for tail dependencies in multi-asset multi-factor allocations. *Machine Learning and Asset Management, Forthcoming*.
- Simon, H. A. (1991). The Architecture of Complexity. In *Facets of Systems Science*, 457–76. Springer.
- Onnela, J.-P., Chakraborti, A., Kaski, K., Kertesz, J., & Kanto, A. (2003). Dynamics of market correlations: Taxonomy and portfolio analysis. *Physical Review E*, 68(5), 56110.
- Peralta, G., & Zareei, A. (2016). A network approach to portfolio selection. *Journal of Empirical Finance*, 38, 157–180.
- Raffinot, T. (2017). Hierarchical clustering-based asset allocation. *The Journal of Portfolio Management*, 44(2), 89–99.
- Raffinot, T. (2018). The hierarchical equal risk contribution portfolio. Available at SSRN 3237540.
- Ren, F., Lu, Y.N., Li, S.P., Jiang, X.F., Zhong, L.X., & Qiu, T. (2017). Dynamic portfolio strategy using clustering approach. *PloS One*, 12(1), e0169299.
- Karimi, A. (2021). Stock portfolio optimization using multi-objective genetic algorithm (NSGA II) and maximum Sharp ratio. *FEJ*, 12(46), 389–410. (in Persian)
- Nabizade, A., Gharehbaghi, H., & Behzadi, A. (2017). Index Tracking Optimization under down Side Beta and Evolutionary Based Algorithms. *Financial Research Journal*, 19(2), 319–340. <https://doi.org/10.22059/jfr.2017.226501.1006374>. (in Persian)
- Noorahmadi, M., Sadeghi, H., (2019), a review of missing value management methods in time series. *6th Mathematics and Humanities Seminar (Financial Mathematics)*. <https://femath6.atu.ac.ir/paper?manu=107697> (in Persian)
- Taghizadeh Yazdi, M. R., Fallahpour, S., & Ahmadi Moghaddam, M. (2017). Portfolio selection by means of Meta-goal programming and extended lexicograph goal programming approaches. *Financial Research Journal*, 18(4), 591–612. <https://doi.org/10.22059/jfr.2017.62580>. (in Persian)