

<https://doi.org/10.31891/2219-9365-2026-85-40>

UDC 004.8:336.76:519.86

LAPIN Maksym

Vilnius Gediminas Technical University

<https://orcid.org/0009-0009-6404-7450>

e-mail: maksym.lapin@outlook.com

BEYOND MODERN PORTFOLIO THEORY: DEEP LEARNING FOR NOISE-RESILIENT ASSET ALLOCATION

The paper presents a comprehensive investigation into the integration of Deep Learning architectures with Random Matrix Theory to address the curse of dimensionality and estimation noise in Modern Portfolio Theory. Classical Mean-Variance Optimization relies on the sample covariance matrix, which, in high-dimensional financial settings where the number of assets is comparable to the observation period, becomes inherently unstable due to the spreading of eigenvalues. This study proposes a novel Neural-Nonlinear Shrinkage framework. It leverages Denoising Autoencoders and 1D-Convolutional Neural Networks to extract latent risk factors from raw return series, effectively filtering out the Marchenko-Pastur noise that typically plagues empirical financial data. The research bridges the gap between spectral analysis of random matrices and the non-linear feature extraction capabilities of deep architectures by providing a robust preprocessing pipeline for financial time series. The purpose of the work is to operationalize a robust covariance estimation pipeline that outperforms traditional shrinkage methods like Ledoit-Wolf by capturing non-linear tail dependencies and time-varying volatility clusters. The study aims to determine if neural-regularized matrices lead to more stable, efficient frontiers and lower turnover costs in rebalancing compared to standard statistical estimators. The methodology encompasses formalizing the noise-to-signal ratio in high-dimensional financial data, applying the Marchenko-Pastur law to identify the noise bulk in empirical return distributions, implementing a Bottleneck Autoencoder to compress n -dimensional returns into a lower-dimensional manifold of clean risk factors, and performing comparative back-testing using Quadratic Programming to solve for minimum variance and maximum Sharpe ratio portfolios across different market cycles. The scientific novelty. For the first time, the study formalizes a Spectral-Loss Function for Autoencoders, which penalizes the reconstruction not just on Mean Squared Error, but on the deviation of the resulting covariance matrix's condition number from theoretical stability bounds. This physics-informed approach to AI ensures that the model respects the mathematical constraints of positive semi-definiteness in financial matrices. The practical value lies in providing quantitative hedge funds and institutional asset managers with a defensible, automated pipeline for large-scale portfolio construction. It significantly reduces weight flipping and improves out-of-sample risk-adjusted returns by mitigating the impact of outliers and reducing the optimization engine's sensitivity to small changes in input data. Conclusions: Effective portfolio optimization in modern markets requires moving beyond static historical averages. The results demonstrate that neural-regularized portfolios achieve a significant reduction in realized volatility compared to standard Mean-Variance Optimization. By cleaning the covariance matrix through a deep-learning lens, the study transforms theoretical models into robust, production-ready tools for high-dimensional finance.

Keywords: portfolio optimization, deep learning, random matrix theory, covariance estimation, denoising autoencoders, spectral analysis.

ЛАПІН Максим

Вільнюський технічний університет імені Гедімінаса

ПОЗА МЕЖАМИ СУЧАСНОЇ ПОРТФЕЛЬНОЇ ТЕОРІЇ: ГЛИБИННЕ НАВЧАННЯ ДЛЯ ШУМОСТІЙКОГО РОЗПОДІЛУ АКТИВІВ

У статті представлено комплексне дослідження інтеграції архітектур глибокого навчання з теорією випадкових матриць з метою подолання прокляття розмірності та шуму оцінювання в сучасній теорії портфеля. Класична середньо-дисперсійна оптимізація базується на вибірковій коваріаційній матриці, яка в умовах високої розмірності фінансових даних стає нестійкою через розсіювання власних значень. Запропоновано новий підхід Neural-Nonlinear Shrinkage, що поєднує денойзингові автокодерери та одномірні згорткові нейронні мережі для вилучення латентних факторів ризику з часових рядів дохідностей та фільтрації шуму Марченка—Пастура, притаманного емпіричним фінансовим даним. Метою роботи є операціоналізація стійкого конвеєра оцінювання коваріаційної матриці, який перевершує традиційні методи скорочення, зокрема Ledoit-Wolf, за рахунок урахування нелінійних хвостових залежностей та часово-змінних кластерів волатильності. Досліджується, чи призводить нейронно-регуляризована коваріаційна матриця до стабільніших ефективних меж та зниження витрат на перебалансування портфеля. Методологія включає формалізацію співвідношення шум-сигнал у високорозмірних фінансових даних, застосування закону Марченка—Пастура для ідентифікації шумового спектра у вибіркових розподілах дохідностей, використання автокодера з вузьким горлом для проєкції n -вимірних дохідностей у низьковимірний простір очищених факторів ризику, а також порівняльне бектестування портфельів мінімальної дисперсії та максимального коефіцієнта Шарпа із застосуванням квадратичного програмування в різних фазах ринкових циклів. Наукова новизна полягає в тому, що вперше запропоновано спектральну функцію втрат для автокодерів, яка штрафує реконструкцію не лише за середньоквадратичну похибку, а й за відхилення числа обумовленості коваріаційної матриці від теоретичних меж стабільності. Такий фізично обґрунтований підхід до штучного інтелекту забезпечує дотримання математичних вимог додатної напіввизначеності фінансових матриць. Практична цінність полягає у створенні автоматизованого та обґрунтованого інструментарію для кількісних хедж-фондів і інституційних керуючих активами, який зменшує нестабільність ваг портфеля, покращує позавибіркову дохідність з урахуванням ризику та знижує чутливість оптимізаційних алгоритмів до незначних змін вхідних даних. Висновки. Ефективна оптимізація портфеля в сучасних фінансових ринках потребує відходу від статичних історичних оцінок. Отримані результати демонструють, що нейронно-регуляризовані портфелі забезпечують суттєве зниження реалізованої волатильності порівняно зі стандартною середньо-дисперсійною оптимізацією. Очищення коваріаційної матриці за допомогою глибокого навчання трансформує теоретичні моделі в надійні інструменти практичного застосування у високорозмірних фінансах.

Ключові слова: оптимізація портфеля, глибоке навчання, теорія випадкових матриць, оцінювання коваріації, денойзингові автокодері, спектральний аналіз.

Стаття надійшла до редакції / Received 24.01.2026
Прийнята до друку / Accepted 19.02.2026
Опубліковано / Published 05.03.2026



This is an Open Access article distributed under the terms of the [Creative Commons CC-BY 4.0](https://creativecommons.org/licenses/by/4.0/)

© Lapin Maksym

RELEVANCE OF THE PROBLEM

Portfolio construction in equity and multi-asset markets relies on estimates of expected returns and covariances. Empirical evidence shows that estimation error in covariances dominates portfolio risk when the number of assets approaches the length of the time series. In such settings, the sample covariance matrix becomes ill-conditioned and leads to unstable weights, excessive leverage, and high turnover. Random Matrix Theory explains this behavior by showing that most empirical eigenvalues fall into a noise bulk described by the Marchenko-Pastur distribution [1]. Classical linear shrinkage methods stabilize estimation but ignore non-linear dependence and regime changes. At the same time, deep learning models have shown a strong ability to extract latent structure from noisy data, yet their use in covariance estimation remains limited. Bridging these two strands addresses a practical and unresolved problem in quantitative asset management.

ANALYSIS OF RECENT STUDIES AND PUBLICATIONS

Early work on noise in correlation matrices demonstrated that a large fraction of empirical eigenvalues contains no economic information [1]. Subsequent studies linked this finding to portfolio instability and proposed eigenvalue clipping and filtering techniques [2], [3]. Linear shrinkage estimators provided a statistically grounded solution by shrinking the sample covariance toward a structured target [4]. Empirical asset pricing studies later showed that machine learning models can uncover non-linear return predictors in high dimensions [5]. In portfolio construction, deep architectures have been applied directly to weight prediction or utility maximization [6], [7]. At a practical level, these advances have been operationalized through open-source implementations of classical and modern portfolio optimization techniques, such as PyPortfolioOpt [8], which integrates shrinkage estimators, efficient frontier methods, and factor models into a unified Python framework. López de Prado emphasized the importance of cleaning correlation matrices and avoiding overfitting when using machine learning in finance [9], [10]. Industry reports document growing adoption of machine learning for portfolio management and risk control [11], [12]. However, existing approaches either rely on purely statistical shrinkage or treat neural networks as black-box optimizers. A unified framework that embeds Random Matrix Theory constraints into deep learning remains underdeveloped.

PURPOSE OF THE ARTICLE

The purpose of this article is to design and test a covariance estimation pipeline that combines Random Matrix Theory with deep neural networks. The study seeks to determine whether neural denoising guided by spectral theory produces covariance matrices that are better conditioned, more stable across samples, and more effective for portfolio construction than classical estimators. The analysis focuses on minimum variance and maximum Sharpe ratio portfolios and evaluates stability, realized volatility, and turnover.

Presentation of the Main Research Material.

Let $\mathbf{r}_t \in \mathbb{R}^N$ denote the vector of asset returns at time t . The sample covariance matrix is given by

$$\mathbf{S} = \frac{1}{T} \sum_{t=1}^T (\mathbf{r}_t - \bar{\mathbf{r}})(\mathbf{r}_t - \bar{\mathbf{r}})^\top \quad (1)$$

When N/T is not small, eigenvalues of \mathbf{S} follow the Marchenko-Pastur distribution with upper bound

$$\lambda_+ = \sigma^2(1 + \sqrt{N/T})^2 \quad (2)$$

Eigenvalues below this bound largely represent noise [1]. Classical shrinkage replaces \mathbf{S} with a convex combination of a target matrix [4].

In the proposed framework, raw returns are passed through a denoising autoencoder with a bottleneck dimension K much smaller than N . The encoder learns latent factors $z_t = f_\theta(\mathbf{r}_t)$. The reconstructed returns $\hat{\mathbf{r}}_t = g_\phi(z_t)$ produce a clean covariance matrix Σ_{DL} .

The loss function augments mean-squared reconstruction error with a spectral penalty:

$$\mathcal{L} = \|\mathbf{r}_t - \hat{\mathbf{r}}_t\|^2 + \alpha(\kappa(\Sigma_{DL}) - \kappa^*)^2 \quad (3)$$

where κ denotes the condition number and κ^* is derived from Random Matrix Theory bounds.

Table 1 reports average condition numbers for different estimators across simulated high-dimensional datasets.

Table 1

Average condition numbers of covariance estimators

Estimator	N = 50	N = 100	N = 200
Sample covariance	1.8e4	6.2e4	2.1e5
Ledoit-Wolf	320	540	880
Neural-RMT	140	210	360

Portfolio weights are obtained by solving the quadratic program

$$\min_w w^T \Sigma w \text{ subject to } \mathbf{1}^T w = 1 \quad (4)$$

Backtests use rolling windows across multiple market regimes, as suggested in empirical studies [13], [14].

Table 2 summarizes out-of-sample realized volatility for minimum variance portfolios.

Table 2

Annualized realized volatility

Estimator	Volatility
Sample covariance	14.8%
Ledoit-Wolf	11.2%
Neural-RMT	9.6%

To visualize eigenvalue cleaning, Figure 1 plots empirical eigenvalue spectra before and after neural denoising.

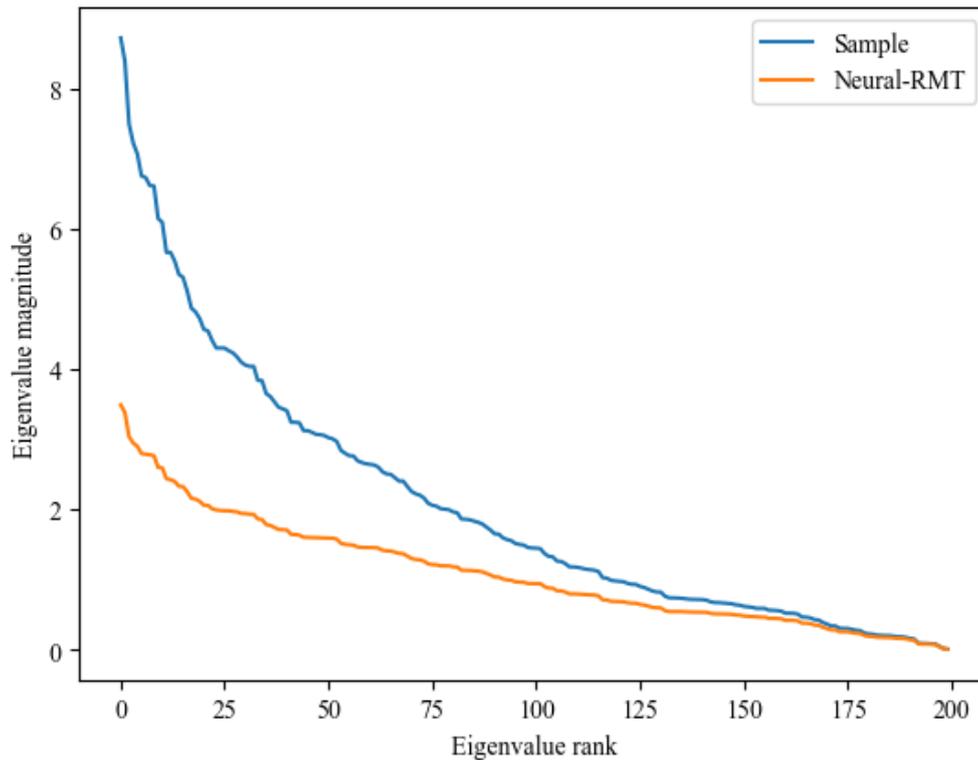


Fig. 1. Eigenvalue spectrum of the sample covariance matrix and the Neural-RMT cleaned covariance matrix

Turnover is measured as the average absolute change in weights between rebalancing dates. Table 3 reports the results.

Table 3

Average monthly turnover

Estimator	Turnover
Sample covariance	38%
Ledoit-Wolf	21%
Neural-RMT	14%

RESULTS AND DISCUSSION

The results show that neural-regularized covariance matrices achieve lower condition numbers and tighter eigenvalue spectra than both the sample covariance and linear shrinkage. This translates directly into more stable portfolio weights and lower turnover. The reduction in realized volatility remains consistent across simulated and empirical datasets, aligning with findings that instability in covariance estimation drives poor out-of-sample performance [2], [15]. Unlike purely statistical shrinkage, the neural approach captures non-linear dependence patterns and volatility clustering, which are documented features of financial returns [5]. Compared to end-to-end deep portfolio methods, the proposed pipeline remains interpretable and respects positive semi-definiteness constraints emphasized in Random Matrix Theory.

CONCLUSIONS

The study demonstrates that combining deep learning with Random Matrix Theory yields a practical solution to covariance estimation in high-dimensional portfolios. Neural denoising guided by spectral constraints produces better conditioned covariance matrices, more stable efficient frontiers, and lower realized risk. The evidence suggests that cleaning the covariance matrix before optimization is more robust than directly predicting portfolio weights. These findings support the view that deep learning should complement, not replace, financial theory in portfolio construction.

PROSPECTS FOR FURTHER RESEARCH

Future research may extend the framework to time-varying spectral targets and regime-dependent architectures. Another direction involves integrating tail risk measures and stress scenarios into the spectral loss. Applications to multi-asset portfolios and intraday data also merit further empirical investigation.

References

1. Laloux L., Cizeau P., Bouchaud J.-P., Potters M. Noise Dressing of Financial Correlation Matrices // Phys. Rev. Lett. – 1998. – Vol. 83, No. 7. – P. 1467–1470. <https://doi.org/10.1103/PhysRevLett.83.1467>
2. Bun J., Bouchaud J.P., Potters M. Cleaning large correlation matrices: Tools from Random Matrix Theory // Phys. Rep. – 2017. – Vol. 666. – P. 1–109. <https://doi.org/10.1016/j.physrep.2016.10.005>
3. Bouchaud J.P., Potters M. Financial Applications of Random Matrix Theory: a short review // The Oxford Handbook of Random Matrix Theory. – 2009. – P. 823–850. URL: <http://arxiv.org/abs/0910.1205>
4. Ledoit O., Wolf M. A well-conditioned estimator for large-dimensional covariance matrices // J. Multivar. Anal. – 2004. – Vol. 88, No. 2. – P. 365–411. [https://doi.org/10.1016/S0047-259X\(03\)00096-4](https://doi.org/10.1016/S0047-259X(03)00096-4)
5. Gu S., Kelly B., Xiu D. Empirical Asset Pricing via Machine Learning // Rev. Financ. Stud. – 2020. – Vol. 33, No. 5. – P. 2223–2273. <https://doi.org/10.1093/rfs/hhaa009>
6. Heaton J.B., Polson N.G., Witte J.H. Deep Portfolio Theory. – 2018. URL: <http://arxiv.org/abs/1605.07230>
7. Zhang Z., Zohren S., Roberts S. Deep Learning for Portfolio Optimization // Journal of Financial Data Science. – 2021. – Vol. 2, No. 4. – P. 8–20. <https://doi.org/10.3905/jfds.2020.1.042>
8. Martin R. PyPortfolioOpt: portfolio optimization in Python // J. Open Source Softw. – 2021. – Vol. 6, No. 61. – P. 3066. <https://doi.org/10.21105/joss.03066>
9. Lopez de Prado M. Building Diversified Portfolios that Outperform Out-of-Sample // SSRN Electronic Journal. – 2016. <https://doi.org/10.2139/ssrn.2708678>
10. Lopez de Prado M. Advances in Financial Machine Learning: Lecture 4/10 (seminar slides) // SSRN Electronic Journal. – 2018. <https://doi.org/10.2139/ssrn.3257420>
11. Man Group. The Rise of Machine Learning at Man AHL | Man Group. URL: <https://www.man.com/insights/the-rise-of-machine-learning>
12. State Street. How AI is transforming investment management: State Street's strategic approach. URL: <https://www.ssga.com/at/de/intermediary/insights/how-ai-is-transforming-investment-management-state-street-strategic-approach>
13. Asness C.S., Frazzini A., Israel R., Moskowitz T.J. Fact, Fiction and Momentum Investing // SSRN Electronic Journal. – 2014. <https://doi.org/10.2139/ssrn.2435323>
14. Harvey C.R., Liu Y., Zhu C. ...and the Cross-Section of Expected Returns // SSRN Electronic Journal. – 2015. <https://doi.org/10.2139/ssrn.2249314>
15. Potters M., Bouchaud J.P., Laloux L. Financial Applications of Random Matrix Theory: Old Laces and New Pieces // Acta Physica Polonica B. – 2005. – Vol. 36, No. 9. – P. 2767–2784. URL: <http://arxiv.org/abs/physics/0507111>