

Научная статья
<https://doi.org/10.23672/SAE.2024.37.21.003>
УДК 330.322



ПОДХОДЫ К ОПРЕДЕЛЕНИЮ ИНВЕСТИЦИОННЫХ РИСКОВ НА ОСНОВЕ НЕЙРОНЕЧЕТКОГО МОДЕЛИРОВАНИЯ

Пыркин А.Г.
ООО «Дзен Платформа»

Аннотация. Измерение и управление инвестиционными рисками является одной из важных и актуальных проблем для менеджеров, аналитиков и экспертов. После мирового финансового кризиса, в современных условиях неопределенности и турбулентности оценка и анализ рисков инвестиционных портфелей приобрели большее значение, поэтому со стороны научно-экспертного сообщества пристальное внимание уделялось тому, как риски выявляются, измеряются, анализируются и управляются.

Цель: изучить подходы к определению инвестиционных рисков на основе нейронечеткого моделирования.

Методы: анализ, синтез, обобщение и систематизации научных источников по проблеме исследования.

Результаты. Отмечено, что особую популярность приобретают инструменты анализа на основе нейронечеткого моделирования и машинного обучения. Предложена и детализирована авторская блок-схема использования нейронных сетей для оценки инвестиционных рисков.

Выводы. Сделан вывод о том, что нейронечеткое моделирование позволяет существенно повысить точность прогнозирования инвестиционных рисков.

Ключевые слова: инвестиции, риск, оценка, нейронная сеть, финансовые данные, аналитика, прогноз.

APPROACHES TO DETERMINING INVESTMENT RISKS BASED ON NEURO-FUZZY MODELING

Alexey G. Pyrkin
Zen Platform LLC

Abstract. Measuring and managing investment risks is one of the important and pressing problems for managers, analysts and experts. After the global financial crisis, in modern conditions of uncertainty and turbulence, the assessment and analysis of risks of investment portfolios have become increasingly important, therefore, from the scientific and expert community, close attention has been paid to how risks are identified, measured, analyzed and managed.

Object: to study approaches to determining investment risks based on neuro-fuzzy modeling.

Methods: analysis, synthesis, generalization and systematization of scientific sources on the research problem.

Findings: It is noted that analysis tools based on neuro-fuzzy modeling and machine learning are becoming especially popular. The author's block diagram of the use of neural networks for assessing investment risks is proposed and detailed.

Conclusions. It is concluded that neuro-fuzzy modeling can significantly improve the accuracy of forecasting investment risks.

Keywords: investment, risk, assessment, neural network, financial data, analytics, forecast.

Введение.

В условиях глобализации и интеграции экономических систем, операции на финансовых рынках между странами, ТНК и обычными предприятиями происходят все чаще; при этом финансовая среда становится сложнее, а распро-

странение рисков - быстрее и масштабнее. Ситуация усугубляется текущим состоянием международной финансовой системы, для которой характерными являются большой кредитный леверидж, высокие цены на активы, значительная волатильность рынка и высокие риски [4]. Оче-

видно, что в таких условиях выбор и заключение инвестиционных сделок существенным образом усложняется.

Как известно, процесс формирования оптимальной инвестиционной политики включает в себя этап, который предусматривает предварительное рассмотрение проектов и обоснованный выбор наиболее выгодных из них для дальнейшего изучения и реализации. При этом за короткое время приходится оценивать большой объем проектов, степень проработанности которых, как правило, недостаточна, а в условиях высокой неопределенности сведения о перспективах их реализации и возможных последствиях, в некоторой степени, являются ограниченными, неполными и неточными. В подобных условиях недостаточно только проведения традиционного анализа инвестиционного проекта, который из-за недостатка адекватной и определенной информации является малоэффективным.

Задача существенно усложняется, если портфель содержит структурированные продукты или сложные страховые полисы, для которых не существует открытых формул оценки.

На первом этапе генерируются различные сценарии для определения того, как может функционировать инвестиционный портфель до горизонта риска, а на втором - моделируются денежные потоки, возникающие после горизонта риска, для оценки стоимости портфеля в зависимости от каждого сценария [5].

Однако, хотя вложенное моделирование демонстрирует хорошие результаты оценки инвестиционных рисков, оно часто занимает слишком много времени, чтобы быть полезным в практических приложениях.

Обсуждение.

Некоторые ученые считают, что более прагматичной альтернативой, обычно используемой для коротких горизонтов риска, является метод дельта-гаммы, который аппроксимирует потери портфеля полиномом Тейлора второго порядка [8].

Если доступны первая и вторая производные портфеля по базовым факторам риска, метод эффективен с вычислительной точки зрения, но его точность зависит от того, насколько хорошо полином Тейлора второго порядка аппроксимирует истинные потери портфеля.

В контексте вышеизложенного, очевидно, что, когда необходимо точно оценить риски инвестиционного портфеля, использование традиционных статистических методов уже не дает желаемого результата. Чтобы преодолеть недо-

статки классических подходов, в последнее время исследователи стали уделять больше внимания применению искусственного интеллекта, машинного обучения и методов глубокого обучения в решении вопросов предотвращения и контроля финансовых рисков. В данной ситуации для формализации факторов неопределенности с целью их дальнейшего учета в процессе оценки, как инвестиционных рисков, так и эффективности проекта в целом, оправданным является применение элементов теории нечетких множеств и искусственных нейронных сетей.

Таким образом, изучение возможностей алгоритмов нейронных сетей для анализа инвестиционных портфелей и прогнозирования различного рода рисков составляет важную научно-практическую задачу, которая и обусловила выбор темы данной статьи.

Проблемы выявления и оценки рисков инвестиционных проектов и принятия на основе этого инвестиционных решений находятся в центре внимания многих исследователей, из числа которых можно выделить: Будникову Н.С., Горбаткову Г.А., Кирюхину О.И., Черникову А.Р., Тамаева Т.Т., Chun Yan, Lin Wang, Wei Liu, Man Qi.

Особенности использования методов машинного обучения для прогнозирования ошибок и оптимизации параметров работы инвестиционных фондов раскрывают в своих трудах Пименов В.И., Боговид А.Е., Бакуменко Л.П., Васильева Н.С., Королева Д.А., Chiou-Jye Huang, Yamin Shen, Yung-Hsiang Chen, Hsin-Chuan Chen.

Различные подходы к применению нейронных сетей в исследованиях по созданию моделей раннего предупреждения для прогнозирования и оценки финансовых рисков разрабатывают Лetyгина Е.Н., Малов Д.Н., Погодина Т.В., Багаев Д.В., Тукумбетов А.Р., Задорожный Н.С., Mili Pathak, Prashant Pokhriyal, Irshad Gandhi, Sridevi Khambhampaty.

Анализ накопленного на сегодняшний день научного наследия позволяет утверждать, что большинство публикаций содержат глубокую степень разработки теоретических основ нечетко-множественных и нейросетевых методов, а также их приложений в технических областях знаний и отраслях производства. Однако, четко проявился недостаток комплексного использования подобных методов в инвестиционном анализе. Возможности оценки инвестиционных рисков с помощью теории нечетких множеств и нейронных сетей в литературе практически не представлены, что говорит о необходимо-

сти проведения дальнейших исследований в данном направлении.

Таким образом, **цель статьи** заключается в рассмотрении подходов к определению инвестиционных рисков на основе нейронечеткого моделирования.

Результаты.

Под рисками инвестиционных проектов понимается, как правило, возможное ухудшение итоговых показателей эффективности проекта, которое возникает под влиянием неопределенности. В количественном выражении риск определяется как изменение показателей проекта: чистой текущей стоимости, внутренней нормы доходности и срока окупаемости [6].

В свою очередь, нейронные сети — это форма технического анализа, которая использует широкий спектр точек данных для классификации информации и прогнозирования.

Используя нейронные сети для оценки инвестиционного риска и прогнозирования будущих показателей портфеля, инвесторы могут оперировать лучшими доступными данными для принятия решений на основе прогнозов искусственного интеллекта. Хотя эти данные должны сопровождаться человеческим принятием решений и анализом, нейронные сети могут оказать поддержку в разработке комплексной инвестиционной стратегии для достижения долгосрочных и краткосрочных инвестиционных целей на индивидуальном или институциональном уровне [9].

Ряд проблем, связанных с инвестиционными рисками, может быть решен с помощью нейронечеткого моделирования. Измерение риска и анализ ключевых факторов, в том числе изучение взаимосвязей между ними, могут быть реализованы с помощью машинного обучения.

Для разработки комплексного индекса риска, учитывающего все области и переменные финансового рынка, может быть применен генетический алгоритм. Методология «роя частиц» является эффективной для аппроксимации общей тенденции риска и определения наиболее влиятельных переменных риска.

Некоторые из последних исследований показали, что новые методы искусственного интеллекта, такие как дерево решений, машина опорных векторов, нейронные сети глубокого обучения превосходят статистические модели и методы оптимизации для оценки инвестиционных проектов. В отличие от статистических методов, методы искусственного интеллекта автоматически извлекают знания из обучающих вы-

борок и широкого набора данных. Согласно имеющимся на сегодняшний день экспертным отчетам, методы искусственного интеллекта превосходят статистические в процессе решения проблем оценки корпоративных инвестиционных рисков, особенно при классификации нелинейных закономерностей [7].

На рис. 1 в обобщенном виде приложена разработанная автором блок-схема использования нейронечеткого моделирования для оценки инвестиционных рисков.

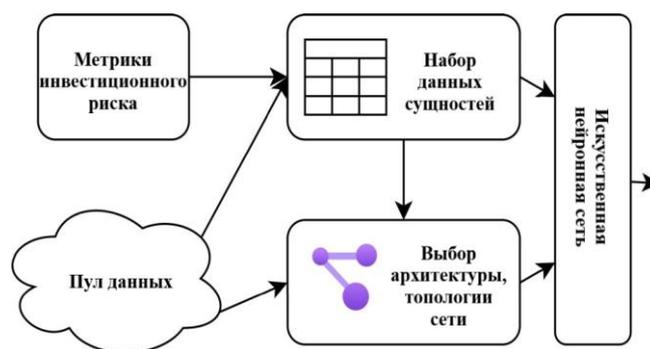


Рис. 1 Блок-схема использования нейронечеткого моделирования для оценки инвестиционных рисков (разработано автором).

Рассмотрим более подробно блоки, выделенные на рис. 1.

Набор данных сущностей. На первом этапе анализа определяется, какой инвестиционный портфель, из каких активов, инструментов и объектов необходимо смоделировать и оценить. Для этого следует установить отрасль приложения капитала, субъектную принадлежность (предприятия, фонды, частные компании), метрики, которые будут использоваться для измерения риска, а также состав информационных данных о характеристиках инвестиционных предложений, которые будут подаваться на вход нейронной сети.

Следует отметить, что одной из сильных сторон моделей нейронных сетей и используемого в процессе их построения машинного обучения, является их способность работать с высоко-размерными данными. Т.е., нейронные сети могут автоматически извлекать признаки из больших данных без необходимости явной разработки признаков. Это позволяет использовать широкий спектр признаков в качестве входных данных для моделирования выбранной метрики инвестиционного риска, что в свою очередь дает возможность выявлять и анализировать сложные взаимосвязи [10].

Метрики инвестиционного риска. Необходимо акцентировать внимание на том, что нет никаких особых ограничений в отношении метрик, используемых для инвестиционного риска, кроме того, что они являются функцией, возможно, нелинейной, от информации о характеристиках проекта, чтобы обеспечить возможность их моделирования.

В зависимости поставленных задач и особенностей проекта, метрика может быть непрерывной (например, Marginal Expected Shortfall или CoVaR) или дискретной (например, ранжирование или категориальная классификация), или даже требовать больших вычислительных затрат (например, метрики на основе моделирования, анализ данных высокой размерности, экспертные или качественные оценки). Поскольку оценка инвестиционного риска относится к классу задач, которые решаются под наблюдением, также необходимо предварительно пометить определенный процент сущностей, который будет передан в нейронную сеть для ее обучения.

В целом, в мире инвестиций существует множество различных показателей риска. Их можно разделить на две категории: фундаментальные и количественные. Фундаментальные метрики риска учитывают базовые активы и обязательства компании, в то время как количественные метрики риска фокусируются на цифрах, стоящих за этими активами и обязательствами. Фундаментальные показатели риска включают такие вещи, как соотношение цены к прибыли, соотношение долга к прибыли и отношение денежного потока к общим активам. Количественные показатели риска, такие как безрисковая ставка и бета, измеряют, насколько цена акций или долга компании отклоняется от среднего показателя для того же типа ценных

бумаг [3].

Пул данных. В последнее время, в связи с развитием цифровых финансов, ускорением темпов Четвертой промышленной революции, сквозным внедрением ИКТ в финансовую сферу в процессе инвестиционного анализа приходится использовать все больше и больше неструктурированной информации. Это означает, что финансовые данные становятся все более неоднородными.

Таким образом, в процессе оценки инвестиционных рисков аналитикам необходимо оперировать структурированными и неструктурированными данными [1].

В финансовой сфере ключевым источником структурированных данных являются данные бизнес-процессов, которые генерируются или собираются предприятиями и государственными организациями в процессе экономической деятельности. Как показано на рисунке 2, данные бизнес-процессов состоят из трех основных частей: данные о транзакциях, корпоративные данные и данные государственных органов. Большая часть транзакционных данных накапливается в ходе финансовых операций, купли-продажи акций, оформлении кредитов и т.д.

Корпоративные данные — это данные, хранящиеся в базах или являющиеся побочным продуктом процесса работы, такие как статистические отчеты, экспертные оценки, аналитические обзоры. Данные государственных учреждений, как правило, находятся в ведении правительственных ведомств и создаются в сотрудничестве с компаниями, занимающимися базами данных. Примером может служить национальная централизованная система коммерческой и потребительской кредитной отчетности.

Состав финансовых данных



Рис. 2 Финансовые структурированные и неструктурированные данные.

Каждый день в информационное про-

странство попадают огромные объемы неструктурированных финансовых данных: профильные телепередачи, сообщения на биржевых форумах, финансовые отчеты компаний, акции которых котируются на бирже, и даже карты распределе-

ния недвижимости, снятые спутниками. По оценкам некоторых аналитиков, большая часть финансовых данных (80-90 %) является неструктурированной. По сравнению со структурированными данными, неструктурированные данные более многочисленны и сложнее в обработке, поэтому они способны существенным образом влиять на все аспекты финансового мира.

Именно для извлечения ценной информации из неструктурированных данных критически важно использовать искусственные нейронные сети, которые применяют для этого алгоритмы обработки естественного языка (NLP). Например, такие факторы, как оценка склонности к событиям, индекс внимания и волатильность риска, извлекаются из текстовой информации социальных сетей. Например, Маозе Zhou применил анализ настроений для прогнозирования инвестиционных рисков. Исследователь использовал хорошо зарекомендовавший себя метод поиска данных, известный как *class-related pattern mining*, чтобы отфильтровать сведения, относящиеся к последствиям банкротства компании, из большого количества неструктурированного текста (отчетов об управлении бизнесом, финансовых новостей, потоковых твитов в реальном времени, финансовой отчетности, финансовых документов). Затем он использовал сверточные нейронные сети, чувствительные к зависимостям, для анализа отфильтрованных данных [9].

Выбор сети. Для корректной и всесторонней оценки инвестиционного риска критически важно использовать не только информативные метрики и собрать широкий спектр данных, но также выбрать правильную структуру нейронной сети. Структура сети важна, поскольку она позволит с необходимой степенью достоверности отразить взаимосвязанность и зависимость между инвестиционными предложениями/портфелями и рынками, которые могут усиливать и распространять шоки и сбои по всей финансовой системе [2].

Для оценки инвестиционного риска, по мнению автора, целесообразно использовать конволюционную нейронную сеть (CNN). Ее уникальная структура позволяет снизить риск чрезмерной подгонки, а также уменьшить объем памяти, занимаемой глубокой сетью, которая используется для определения сходства между

новыми признаками и исходными данными.

CNN состоит из слоев конволюций (conv), объединения (pool) и полных соединений (FC). Слои конволюции и объединения отвечают за извлечение признаков, а FC используется для классификационного распознавания. Структура сети показана на рисунке 3.

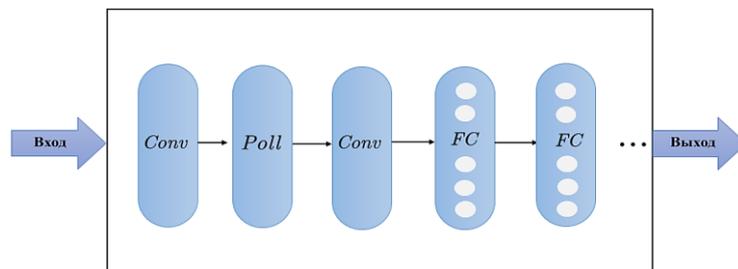


Рис. 3 Блок-схема одномерной CNN.

Уникальная структура CNN при обработке данных снижает вычислительные усилия и делает сеть простой и эффективной.

Слой свертки рассчитывается следующим образом:

$$X_j^L = f\left(\sum_{i \in M_j} X_i^{L-1} \times K_j^L + b_j^L\right)$$

где X_j^L, X_i^{L-1} - карта признаков L -го и $L-1$ -го слоев, соответственно; M_j - входная карта признаков; K - ядро свертки, соответствующее признаку; и b_j^L - единица смещения слоя.

$$X_j^L = f[\beta_j^L \text{down}(X_i^{L-1}) + b_j^L]$$

где $\text{down}(x)$ - понижающая дискретизация, а β_j^L, b_j^L - аддитивное и мультипликативное смещение L -го слоя.

Заключение.

Таким образом, в современных динамичных условиях, характеризующихся широким спектром неструктурированных данных, их разрозненностью, большим объемом различного рода финансовых показателей, традиционные подходы для оценки инвестиционных рисков не позволяют получить достоверные результаты. Перспективным инструментом, в данном случае, является нейронное моделирование, которое позволяет существенно повысить точность прогнозирования. С целью применения на практике данного подхода, в статье представлена авторская блок-схема использования нейронных сетей для оценки инвестиционных рисков.

Конфликт интересов

Conflict of Interest

Не указан.

None declared.

Рецензия

Review

Все статьи проходят рецензирование в формате double-blind peer review (рецензенту неизвестны имя и должность автора, автору неизвестны имя и должность рецензента). Рецензия может быть предоставлена заинтересованным лицам по запросу.

All articles are reviewed in the double-blind peer review format (the reviewer does not know the name and position of the author, the author does not know the name and position of the reviewer). The review can be provided to interested persons upon request.

Литература:

1. Бухтияров С.Е. Методы формирования инвестиционного портфеля на основе диверсификации, оценки доходности и риска инвестиций // *Russian Economic Bulletin*. 2023. Т. 6. № 6. С. 271-276.
2. Кутуев Т.Н. Модели теории игр в роли методов оценки риска в финансовой и инвестиционной деятельности // *Научный аспект*. 2023. Т. 1. № 3. С. 33-38.
3. Манохин Д.И. Оценка факторов риска в работе инвестиционных платформ // *Финансовая экономика*. 2022. № 5. С. 221-224.
4. Монгуш В.А. Качественная и количественная оценка основных типов рисков инвестиционных проектов // *Вестник науки*. 2023. Т. 5. № 12-1 (69). С. 48-51.
5. Тугушев Р.А. Методы оценки рисков инвестиционной деятельности // *Научно-исследовательский центр «Technical Innovations»*. 2021. № 7. С. 49-51.
6. Шарян Э.Г. Проблемы анализа и оценки рисков инвестиционных проектов // *Известия высших учебных заведений. Проблемы полиграфии и издательского дела*. 2021. № 2. С. 36-39.
7. Яшева Г.А. Оценка рисков инвестиционных проектов на основе программного приложения // *Материалы и технологии*. 2021. № 1. С. 69-74.
8. Anand Kumar Predicting the antecedents of consumers' intention toward purchase of mutual funds: A hybrid PLS-SEM-neural network approach // *International Journal of Consumer Studies*. 2022. Volume 47, Issue 2. P. 98-105.
9. Maoze Zhou Research on corporate financial performance prediction based on self-organizing and convolutional neural networks // *Expert Systems*. 2022. Volume 39, Issue 9. P. 34-39.
10. Zidi Gao Attention based hybrid parametric and neural network models for non-stationary time series prediction // *Expert Systems*. 2023. Volume 41. P. 15-23.

References:

1. Bukhtiyarov S.E. Methods for forming an investment portfolio based on diversification, assessing the profitability and risk of investments // *Russian Economic Bulletin*. 2023. T. 6. No. 6. Pp. 271-276.
2. Kutuev T.N. Game theory models in the role of risk assessment methods in financial and investment activities // *Scientific aspect*. 2023. T. 1. No. 3. P. 33-38.
3. Manokhin D.I. Assessment of risk factors in the operation of investment platforms // *Financial Economics*. 2022. No. 5. Pp. 221-224.
4. Mongush V.A. Qualitative and quantitative assessment of the main types of risks of investment projects // *Bulletin of Science*. 2023. T. 5. No. 12-1 (69). Pp. 48-51.
5. Tugushev R.A. Methods for assessing the risks of investment activities // *Scientific Research Center «Technical Innovations»*. 2021. No. 7. Pp. 49-51.
6. Sharyan E.G. Problems of analysis and risk assessment of investment projects // *News of higher educational institutions. Problems of printing and publishing*. 2021. No. 2. Pp. 36-39.
7. Yasheva G.A. Risk assessment of investment projects based on software applications // *Materials and Technologies*. 2021. No. 1. Pp. 69-74.
8. Anand Kumar Predicting the antecedents of consumers' intentions toward purchase of mutual funds: A hybrid PLS-SEM-neural network approach // *International Journal of Consumer Studies*. 2022. Volume 47, Issue 2. Pp. 98-105.
9. Maoze Zhou Research on corporate financial performance prediction based on self-organizing and convolutional neural networks // *Expert Systems*. 2022. Volume 39, Issue 9. Pp. 34-39.
10. Zidi Gao Attention based hybrid parametric and neural network models for non-stationary time series prediction // *Expert Systems*. 2023. Volume 41. Pp. 15-23.

Информация об авторе:

Пыркин Алексей Германович, финансовый директор, ООО «Дзен Платформа», г. Москва, e-mail: apyrkin@mail.ru

Alexey G. Pyrkin, Financial Director, Zen Platform LLC, Moscow