

УДК 33

Н.Э. Гребенников

Санкт-Петербургский политехнический университет, Москва,
email: grebennikoff.nikita@yandex.ru

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ОПТИМИЗАЦИИ ПОРТФЕЛЯ ЦЕННЫХ БУМАГ

Ключевые слова: машинное обучение, оптимизация портфеля, финансовые рынки, риск-менеджмент, прогнозирование доходности, алгоритмическое инвестирование.

В статье проводится обзор и анализ перспективного направления портфельного анализа, основанного на использовании методов машинного обучения. Рассмотрены проблемы традиционных подходов к управлению портфелем и их ограничения, а также преимущества методов машинного обучения в анализе больших объемов данных и построении нелинейных моделей. Представлена классификация алгоритмов машинного обучения для оптимизации портфелей ценных бумаг, выделены три типа алгоритмов: надзорное обучение для предсказания доходности активов, безнадзорное обучение для кластеризации рисков и усиленное обучение для адаптации портфеля в реальном времени. Представлены ключевые ограничения и риски использования алгоритмов машинного обучения в рамках анализа портфелей ценных бумаг. Рассмотрены такие перспективные разработки в области алгоритмов машинного обучения, как глубокие нейронные сети, графовые модели и байесовская статистика, для оптимизации портфелей ценных бумаг.

N.E. Grebennikov

St. Petersburg Polytechnic University, Moscow, email: grebennikoff.nikita@yandex.ru

APPLICATION OF MACHINE LEARNING ALGORITHMS FOR SECURITIES PORTFOLIO OPTIMIZATION

Keywords: machine learning, portfolio optimization, financial markets, risk management, profitability forecasting, algorithmic investing.

The article provides an overview and analysis of a promising area of portfolio analysis based on the use of machine learning methods. The problems of traditional approaches to portfolio management and their limitations are considered, as well as the advantages of machine learning methods in analyzing large amounts of data and building nonlinear models. A classification of machine learning algorithms for optimizing securities portfolios is presented, and three types of algorithms are identified: supervised learning for predicting asset returns, unsupervised learning for risk clustering, and enhanced learning for real-time portfolio adaptation. The key limitations and risks of using machine learning algorithms in the framework of securities portfolio analysis are presented. Promising developments in the field of machine learning algorithms such as deep neural networks, graph models, and Bayesian statistics for optimizing securities portfolios are considered.

Сложность современных финансовых рынков возрастает под влиянием глобальной экономической интеграции, изменчивости макроэкономических показателей и многообразия инвестиционных инструментов, что порождает возникновение вызовов для традиционных методов оптимизации портфеля. Глобальные изменения экономической среды приводят к необходимости разработки инновационных инструментов, которые способны адекватно отражать динамические взаимосвязи между активами, что открывает возможности применения алгоритмов машинного обучения (далее – МО) в рамках оптимизации портфеля.

В контексте цифровизации и цифровой трансформации бизнеса классические модели оптимизации портфеля (средняя дисперсия Марковица (модель «риск-доходность»), среднее абсолютное отклонение, минимакс, дисперсия с учётом асимметрии (скошенности), меньший частичный момент, условная стоимость под риском и др. [1]) оказываются ограничены и зачастую уже не могут учитывать сложные взаимозависимости, обусловленные статичностью исходных предположений и линейной структурой аналитических инструментов. Трудность их интеграции приводит к снижению эффективности

распределения ресурсов, что обуславливает потребность внедрения методов, способных своевременно учитывать изменчивость финансовой среды. Современные тенденции финансовой аналитики отражают потенциал алгоритмов машинного обучения в анализе рисков и доходности, что служит основой для совершенствования стратегий управления инвестиционными портфелями. Многие исследователи в области экономики и МО сходятся во мнении, что внедрение основанных на МО алгоритмов в экономические процессы будет расширяться в будущем. При этом этот рост будет происходить быстрее, чем в других сферах, что обусловлено спецификой экономического анализа, в его основе которой лежит применение статистических и эконометрических методов [2].

Результаты и обсуждение

Методы экономического анализа традиционно основываются на предположении о линейности связей и равновесном состоянии рынка, что упрощает вычисления, однако снижает точность в условиях сложной и изменчивой среды. Фиксированные модели, использующие статичные данные, не всегда отражают реальную динамику процессов, поскольку экономические показатели подвержены постоянным колебаниям под воздействием множества факторов. Рост объёмов информации и усложнение взаимосвязей между экономическими агентами требуют инструментов, способных учитывать нелинейные зависимости и адаптироваться к изменениям. В рамках повышения точности анализа в настоящее время имеется потребность в динамических и адаптивных решениях.

Всё более широкое применение в финансовой аналитике находят алгоритмы МО, поскольку они способны адаптироваться к быстро меняющимся рыночным условиям. Одной из ключевых областей их использования является прогнозирование цен финансовых активов, основанное на применении нелинейных моделей. Алгоритмы МО способны выявлять скрытые зависимости в больших массивах данных, поэтому они особенно эффективны в рамках анализа ха-

рактеризующихся высокой волатильностью рынков. Основанные на алгоритмах модели улучшают точность предсказаний и повышают устойчивость анализа к неопределённости внешней среды. Кроме того, за счёт способности идентифицировать аномальные явления и предсказывать возможные кризисные ситуации алгоритмы МО оказываются чрезвычайно полезными для идентификации и учёта рисков: они позволяют строить адаптивные модели, которые обновляются на основе поступающих данных, обеспечивая актуальность прогнозов и повышая их практическую значимость. Способность МО эффективно работать с неструктурированными данными и учитывать их временные изменения открывает новые возможности для управления сложными финансовыми процессами, особенно когда традиционные методы оказываются недостаточно результативными.

Оптимизация портфельных стратегий традиционно основывается на математических методах нахождения экстремума при наличии ограничений, среди которых наиболее распространённым является принцип Лагранжа. В рамках этого метода вводится функция Лагранжа, включающая в себя представленные с помощью множителей целевую функцию и ограничения. Принцип Лагранжа позволяет преобразовывать задачу с ограничениями в эквивалентную систему уравнений, решение которой даёт оптимальные веса активов. Также условия Каруша–Куна–Таккера, формализующие необходимость выполнения ограничений неравенств в оптимизационных задачах, что обеспечивает корректность найденного решения, особенно при наличии жёстких требований к структуре портфеля. Несмотря на широкое применение таких методов, их эффективность может снижаться при усложнении рыночных условий, когда линейные или квадратичные предположения о зависимости доходности и риска не обеспечивают достаточно адекватной точности. В связи с этим изучению влияния МО на оптимизацию портфеля ценных бумаг (далее – ПЦБ) в научной литературе уделяется небольшое внимание (табл. 1). Обзор зарубежных

исследований позволяет установить, что ПЦБ в основном рассматривается в рамках анализа МО для оптимизации общих портфелей. В последнее время эффективность алгоритмов МО активно эмпирически проверяется в рамках общей оптимизации распределения портфеля, многозадачного изучения риска и доходности, прогнозирования цен на активы, выбора и прогнозирования портфеля акций и др. В целом, вне зависимости от выбранных алгоритмов МО и основанных на их различном сочетании гибридных моделей, в новейшей литературе устанавливается эффективность использования алгоритмов МО по сравнению с классическими подходами [3].

Следует отметить, что в российской научной литературе стратегии управления ПЦБ встречаются часто [10], [11], однако применение МО для оптимизации ПЦБ в российских статьях практически не раскрывается. Тем не менее, в ряде работ установлены любопытные выводы (табл. 2).

В целом, в научной литературе выделяется довольно большое количество вариантов применения алгоритмов МО для оптимизации портфеля: в каждой работе встречается собственный авторский подход на примере исторических данных. Это связано с тем, что возможности построения алгоритмов МО достаточно широки. В связи с этим целесообразно структурировать основные направления применения алгоритмов МО для оптимизации портфелей. В данной работе рассматривается классификация, включающая в себя три общие категории: надзорное обучение, безнадзорное обучение и усиленное обучение.

Надзорное обучение для предсказания доходности активов (Supervised learning, далее – SL) – это алгоритм МО, основанный на использовании размеченных данных для формирования зависимостей между входными характеристиками активов и их будущими финансовыми показателями. В моделях SL используются метрики, отражающие поведенческие и фундаментальные характеристики активов, что позволяет строить прогнозы с учётом как макроэкономических факторов, так и специфики отдельных инструмен-

тов. Достоверность таких предсказаний во многом определяется качеством исходных данных и выбором моделей МО, способных учитывать нелинейные зависимости в динамике цен. Эффективность алгоритмов SL в финансовой аналитике определяется способностью адаптироваться к меняющимся рыночным условиям, для чего требуется постоянное обновление параметров моделей. При этом нельзя не отметить, что предсказания, основанные на исторических данных, могут сталкиваться с проблемой смещения оценок в периоды резких структурных изменений. Для повышения устойчивости методов применяются техники регуляризации, снижающие вероятность переобучения, а также ансамблевые методы МО, позволяющие учитывать разнообразные сценарии развития рынка.

Безнадзорное обучение (Unsupervised learning, далее – UL) для кластеризации рисков – это алгоритм МО, предназначенный для обнаружения скрытых структур в данных и формирования групп активов с однородными характеристиками риска. Кластеризация рисков с использованием UL направлена на выявление схожих по характеристикам активов и формирование групп, обладающих общими свойствами с точки зрения волатильности, корреляционных зависимостей и иных параметров. Основанный на использовании UL анализ позволяет проводить диверсификацию с учётом неочевидных взаимосвязей между инструментами, в результате чего становится возможным снижение совокупного риска портфеля, при том, что необходимость жёсткого ограничения структуры активов отсутствует. Использование методов кластеризации в рамках анализа рисков позволяет адаптировать портфельные стратегии к различным фазам рыночного цикла, а также выявлять изменения в группировке активов во время появления новых рыночных тенденций. Следует отметить, что подходы, основанные на сегментации данных, могут дополнять традиционные методы риск-менеджмента, что позволяет учитывать сложные структурные особенности рыночных активов и повышать точность оценки их потенциальной доходности.

Таблица 1

Обзор релевантных исследований в области изучения влияния МО на оптимизацию ПЦБ

Статья	Методология	Ключевой вывод
[4]	Используются модель МО (случайный лес (далее – RF), регрессия опорных векторов (далее – SVR)) и 3 модели глубокого обучения (далее – DL)	Расширенные модели средней дисперсии Марковица (далее – MV) и омега работают лучше, чем иные модели
[5]	Используются модели МО (SVR, RF и сеть долгой краткосрочной памяти (далее – LSTM))	Построение более прибыльного портфеля MV для коинтегрированных акций, чем на основе обычных моделей МО
[6]	Используется гибридная модель МО (свёрточные нейронные сети (далее – CNN) и LSTM	Интеграция предварительного отбора акций может улучшить производительность MV
[7]	Используется гибридная модель МО с улучшенным алгоритмом светлячка (далее – FA)	Модель превосходит традиционные способы (без прогнозирования акций) и показатели доходности и рисков
[8]	Литературный обзор МО для оптимизации портфеля	Основанные на оценке параметров и оптимизации модели МО превосходят традиционный подход «предсказать – затем оптимизировать»
[9]	Используется новая гиперэвристическая структура модели DL с подкреплением (далее – DRL)	Установлен потенциал прироста производительности по сравнению с традиционным базовым методом DRL

И с т о ч н и к : составлено автором по источникам, представленным в таблице 1.

Таблица 2

Российские исследования в области изучения влияния МО на оптимизацию ПЦБ

Статья	Методология	Ключевой вывод
[12]	Анализ портфелей известных инвесторов с оценкой их применимости к российскому рынку	Оптимальная структура портфеля определяется индивидуальными целями инвестора; универсального решения не существует
[13]	Оптимизация портфеля с использованием распределения Леви и генетического алгоритма	Подход эффективен на небольших выборках, но ограничен в применении к крупным массивам данных
[14]	Иерархическая кластеризация для снижения размерности данных перед оптимизацией портфеля Марковица	Авторский метод позволяет представить активы в виде многоуровневой структуры, упрощая последующую обработку
[15]	Сравнение классической модели Марковица с портфелем, построенным с декомпозицией риска	Разделение риска на систематическую и несистематическую компоненты позволяет улучшить прогнозируемость модели
[16]	Сравнение нейросетевых и деревообразных моделей для выбора оптимального портфеля	Лучшие результаты показала рекуррентная нейросеть, учитывающая макроэкономические и технические индикаторы

И с т о ч н и к : составлено автором по источникам, представленным в таблице 2.

Усиленное обучение (Reinforcement learning, далее – RL) для адаптации портфеля в реальном времени – это алгоритм МО, основанный на оценке эффективности последовательных решений, когда выбор стратегий инвестирования определяется накопленным вознаграждением за предыдущие действия. Адаптив-

ное управление портфелем с использованием алгоритмов RL основано на концепции поэтапного принятия решений в условиях неопределённости, когда модель последовательно оценивает эффективность различных стратегий. В отличие от методов, работающих на основе фиксированных данных, применение

RL позволяет алгоритму корректировать распределение активов с учётом новых рыночных условий, что особенно актуально при высокой волатильности рынков. Для использования методов RL требуется разработка такой системы оценки состояния рынка, когда алгоритм получает информацию о текущей структуре портфеля и внешних факторах, влияющих на его динамику. В рамках разработки системы необходимо определить метрики, позволяющие измерять эффективность выбранной стратегии, а также внедрить механизмы, предотвращающие переобучение модели на локальных паттернах для более устойчивого управления портфельными рисками в долгосрочной перспективе. Разнообразие методов МО в задачах оптимизации портфеля обусловлено спецификой решаемых проблем, в связи с чем представляется целесообразным структурировать алгоритмы МО, имеющие практическое применение в задачах оптимального распределения активов (табл. 3).

Далее целесообразно сосредоточиться на ключевых математических формулах, которые непосредственно связаны с применением МО в оптимизации ПЦБ, в отличие от классических формул оптимизации портфелей, которые и так являются хорошо известными (например, MV, коэффициент Шарпа, модель CAPM, подверженная риску стоимость (Value-at-Risk), модель Блэка-Литтермана и мн. др.). Так, можно указать общее уравнение современной теории портфеля (MPT), которая предполагает, что цена ценной бумаги учитывает всю доступную информацию и отражает ее экономическую стоимости [8]. Как правило, это уравнение ожидаемой доходности портфеля (формула (1)):

$$E(r_p) = \sum_{i=1}^n \omega_i E(r_i) \quad (1)$$

где $E(r_p)$ – ожидаемая доходность портфеля; ω_i – вес; i – актив в портфеле; $E(r_i)$ – ожидаемая доходность i -го актива; n – количество активов в портфеле.

В MPT ожидаемый риск портфеля зависит от взаимозависимости активов в портфеле, которая фиксируется их парными корреляциями: чем выше парные корреляции между активами в портфеле, тем выше ожидаемый риск портфе-

ля. Для улучшения классических методов портфельного анализа в рамках SL чаще всего используется формула функции потерь среднеквадратичной ошибки (формула (2)):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

где: y_i – истинное значение доходности актива; $\hat{y}_i$ – предсказанное моделью значение; n – количество наблюдений.

Основная цель использования данной формулы заключается в уменьшении ошибки модели на обучающих данных. Формула активно используется в таких регрессионных моделях, как линейная регрессия, RF, XGBoost, LSTM и др.

Для улучшения классических методов портфельного анализа в рамках UL чаще всего используется формула кластеризации, в частности, k-means (формула (3)):

$$J = \sum_{i=1}^k \sum_{j \in C_i} x_j - \mu_i^2 \quad (3)$$

где k – количество кластеров; C_i – множество объектов в кластере i ; x_j – объект, принадлежащий кластеру; μ_i – центр кластера (среднее значение векторов активов в кластере).

В рамках данной формулы алгоритм уменьшает сумму квадратов расстояний от каждой точки до центра своего кластера. Формула описывает суть использования k-means, однако похожие принципы используются в DBSCAN, методе главных компонент (PCA) и иных методах кластеризации для выявления групп активов с похожей динамикой. В частности, PCA применяется для снижения размерности данных и улучшения визуализации ПЦБ. Данный метод исключает избыточную информацию и выделяет наиболее значимые факторы, влияющие на доходность активов. В рамках PCA многомерные данные преобразуются в новое пространство, в котором переменные становятся ортогональными и упорядоченными по степени объяснённой дисперсии, что предоставляет возможность визуализировать структуру портфеля в сжатом виде, выявлять основные направления изменчивости рыночных активов и упрощать последующий анализ.

Таблица 3

Классификация наиболее применяемых алгоритмов МО, применяемых для оптимизации портфеля

Тип обучения	Алгоритмы (на английском)	Аббревиатура
Надзорное обучение (SL)	Линейная регрессия для оценки доходности	LR
	Случайный лес для прогнозирования доходности активов	RF
	Градиентный бустинг для моделирования рыночных процессов	XGBoost
	Метод опорных векторов для временных рядов	SVR
	Долгая краткосрочная память для предсказания доходности	LSTM
Безнадзорное обучение (UL)	Алгоритм К-средних для группировки активов по характеристикам	K-Means
	Алгоритм кластеризации, основанный на плотности данных, для выявления аномалий	DBSCAN
	Метод главных компонент для снижения размерности данных	PCA
Усиленное обучение (RL)	Q-обучение для динамического управления портфелем	Q-Learning
	Глубокое Q-обучение для адаптивных инвестиционных стратегий	DQN
	Проксимальная политика оптимизации для балансировки активов	PPO
	Глубокое детерминированное градиентное обучение для оптимизации портфеля	DDPG

Источник: составлено автором на базе [8].

Так, недавно отечественными учёными [14] был предложен простой метод понижения размерности (формула (4)):

$$X_i = \frac{W_j}{S_j} \quad (4)$$

где j – кластер, в который входит ценная бумага j ; S_j – число ценных бумаг в кластере j .

Предложенный метод основан на предварительной иерархической кластеризации активов с использованием коэффициента парной корреляции Пирсона, его использование позволяет сгруппировать ценные бумаги по схожести их доходностей, что уменьшает число параметров в задаче оптимизации и при этом сохранить основные характеристики исходных данных.

Для улучшения классических методов портфельного анализа в рамках RL чаще всего используется формула Q-функции, которая оценивает ценность состояния и действия (формула (5)):

$$Q(s, a) \leftarrow Q(s, a) + \alpha [r + \lambda \max_{a'} Q(s', a') - Q(s, a)] \quad (5)$$

где $Q(s, a)$ – оценка ценности действия a в состоянии s ; r – полученное вознаграждение (например, доходность портфеля за период); α – скорость обучения; λ – коэффициент дисконтирования будущих наград; s' , a' – следующее состояние и действие.

В рамках RL агент принимает решения по изменению структуры портфеля и получает вознаграждение за каждое действие. Данная формула лежит в основе Q-Learning, DQN, PPO и иных методов RL, которые позволяют адаптировать портфель с учётом динамики. Также нельзя не отметить роль таких методов обработки временных данных, как ARIMA и GRU, поскольку анализ временных рядов играет важнейшую роль в прогнозировании финансовых показателей, а данные модели способны учитывать как линейные, так и сложные нелинейные зависимости. В этом контексте метод ARIMA (англ. AutoRegressive Integrated Moving Average) используется для изучения временной структуры данных, основанной на автокорреляции и скользящем среднем. Суть применения метода ARIMA заключа-

ется в представлении временного ряда в виде комбинации авторегрессионных компонентов и сглаженных средних значений, что позволяет выявлять систематические паттерны и устранять влияние случайных флуктуаций. За счёт интегрированного механизма разностей модель ARIMA адаптируется к нестационарным данным и обеспечивает более точное прогнозирование, однако нельзя не отметить, что её применимость ограничивается гипотезами о линейности процессов и стационарности преобразованного ряда.

Развитие методов анализа временных данных привело к появлению архитектур, способных учитывать долгосрочные зависимости без жёстких предположений о форме распределения. Так появился метод GRU (англ. Gated Recurrent Unit), который представляет собой модифицированную версию рекуррентных нейронных сетей, позволяющую учитывать историческую информацию при сохранении вычислительной эффективности. В отличие от традиционных рекуррентных моделей, метод GRU регулирует процесс обновления состояния с помощью специальных механизмов, которые контролируют, какие данные сохраняются в памяти, а какие игнорируются. Структура позволяет эффективно работать с последовательностями данных, когда присутствуют нелинейные зависимости, в связи с чем метод GRU является особенно полезным в задачах прогнозирования финансовых временных рядов с учётом сложных динамических закономерностей. Нельзя не упомянуть и про метод HRP (англ. Hierarchical Risk Parity) – альтернативный подход к распределению активов, который устраняет характерные для классической оптимизации ПЦБ ограничения. В отличие от традиционной модели Марковица, которая требует вычисления обратной ковариационной матрицы, метод HRP использует методы кластеризации на основе деревьев для построения иерархической структуры взаимосвязей между активами, что способствует повышению стабильности распределения весов и снижению риска чрезмерной концентрации ка-

питала в отдельных активах. Так, недавнее исследование показывает, что использование основанного на корреляционных метриках HRP помогло установить лучшую эффективность по сравнению с квадратичными оптимизаторами в условиях растущего рынка, а также обеспечить более сбалансированное соотношение риска и доходности в различных рыночных сценариях [17].

Однако анализ финансовых данных с использованием алгоритмов МО сопровождается рядом методологических ограничений, среди которых важное место занимает проблема интерпретируемости моделей. Так, прогностические алгоритмы, основанные на глубоких нейронных сетях и ансамблевых методах, формируют сложные зависимости, представленные в виде многомерных нелинейных функций, что затрудняет их анализ. В отличие от классических методов, предполагающих достаточно чёткую структуру входных параметров и детерминированные зависимости, модели МО адаптируются к скрытым закономерностям в данных, однако при этом не всегда позволяют установить причинно-следственные связи между переменными. В рамках управления ПЦБ отсутствие прозрачности в механизмах принятия решений ограничивает возможности регулирования рисков и оценки устойчивости стратегий. Взаимосвязи между факторами, на основе которых строятся прогнозы, могут меняться в зависимости от рыночных условий, что ещё больше усложняет интерпретацию моделей и потому актуализирует необходимость применения методов, позволяющих уточнять степень влияния отдельных переменных.

Кроме того, точность прогнозирования финансовых показателей во многом определяется качеством исходных данных, на которых обучаются модели, а также корректностью процедуры их предобработки. Исторические выборки содержат шумы, выбросы и возможные структурные изменения, что приводит к ошибкам в прогнозах и снижению устойчивости алгоритмов. При ограниченном

объёме обучающих данных модели МО склонны к переобучению, в рамках которого они запоминают частные закономерности конкретной выборки, однако теряют способность к обобщению на новых данных. Вместе с тем используемые для настройки параметров моделей оптимизационные процедуры могут приводить к локальным минимумам функции ошибки, что затрудняет поиск наиболее эффективных решений. Как итог – полученные предсказания могут показывать высокую точность на исторических данных, но при этом не соответствовать реальным рыночным условиям при изменении макроэкономических факторов. Поэтому на практике нужна балансировка сложности моделей и их способности адаптироваться к нестабильным рыночным процессам.

Тем не менее, применение алгоритмов МО в управлении ПЦБ обусловлено их способностью адаптироваться к изменяющейся рыночной среде, что отличает их от традиционных финансовых моделей. В отличие от методов, основанных на статических предположениях, модели МО учитывают сложные нелинейные зависимости и анализируют широкий спектр факторов, влияющих на стоимость активов. Благодаря гибкости таких алгоритмов возможно своевременно реагировать на нестабильность рынков и выявлять скрытые закономерности в динамике финансовых данных. Однако точность прогнозов, получаемых на основе МО, зависит от качества исходных данных и корректности выбранных параметров, что не лишает исследователей и практиков рисков, связанных с интерпретацией результатов и возможностью переобучения моделей. Высокая вычислительная сложность алгоритмов МО представляет собой значительное ограничение, особенно при анализе больших массивов данных и применении сложных нейросетевых архитектур. Для реализации алгоритмов МО требуются значительные вычислительные мощности, что увеличивает время обработки и усложняет их практическую реализацию. В финансовых приложениях в контексте высокой скорости торговых операций

это может создавать проблемы при необходимости оперативного принятия решений. Снижению издержек вычислений способствует оптимизация структуры моделей и применение методов регуляризации, однако это полностью не устраняет проблему ресурсоёмкости, что ограничивает возможности использования сложных моделей в реальном времени. В целом можно выделить следующие ключевые риски использования алгоритмов МО в рамках оценки ПЦБ (табл. 4).

Несмотря на имеющиеся ограничения, активное развитие методов МО привело к активному внедрению глубоких нейронных сетей в анализе финансовых данных, что расширяет возможности прогнозирования и автоматизированного управления ПЦБ. Так, в настоящее время архитектуры, использующие многослойные нейронные сети, позволяют моделировать сложные нелинейные зависимости и учитывать скрытые закономерности рынка. Интеграция трансформеров и специализированных рекуррентных сетей также улучшает работу с временными рядами посредством повышения точности предсказаний и обработки последовательностей данных. Однако адаптация таких моделей в задачах оптимизации ПЦБ сопровождается необходимостью масштабных вычислений. Использование графовых моделей также открывает широкие перспективы для анализа взаимосвязей между активами и структурными характеристиками финансовых систем.

Графовые нейросети могут выявлять топологические особенности различных взаимодействий на рынке и проводить анализ динамических изменений структуры финансовых потоков. В условиях высокой рыночной нестабильности представление данных в виде графов упрощает задачу кластеризации активов и построения стратегий управления рисками; тем не менее вследствие того, что на результаты прогнозов влияет выбор метрик, используемых для оценки связей между финансовыми инструментами, для использования графовых методов на практике необходима тонкая настройка.

Таблица 4

Ключевые риски реализации алгоритмов МО в рамках оптимизации ПЦБ

Риск	Методы МО	Последствия
Недостаточная интерпретируемость	Глубокие нейронные сети (LSTM, DQN, PPO), ансамблевые методы (XGBoost, RF)	Сложность оценки факторов, влияющих на предсказания, отсутствие прозрачности в принятии решений, ограниченная применимость в регулировании рисков
Зависимость от качества данных	Надзорное обучение (SL), временные ряды (ARIMA, GRU), графовые модели	Ошибки прогнозов при наличии шумов и выбросов, снижение устойчивости моделей, ухудшение адаптации к новым рыночным условиям
Переобучение на исторических данных	Нейросетевые модели (LSTM, GRU), алгоритмы усиленного обучения (Q-Learning, DQN, PPO)	Потеря способности к обобщению, снижение точности прогнозов на новых данных, высокая чувствительность к рыночным изменениям
Ошибки оптимизации	Градиентный бустинг (XGBoost), кластеризация (K-Means, DBSCAN), байесовские методы	Поиск локальных минимумов функции ошибки, неправильное распределение весов активов, нестабильность стратегий при изменении рыночных условий
Высокие вычислительные затраты	Глубокие нейросети (LSTM, DQN), графовые модели	Длительное время обработки данных, трудности в применении для оперативного управления портфелем, необходимость масштабных вычислительных ресурсов

Источник составлено автором по [1], [8].

Условия для более точной оценки рисков и прогнозирования доходности на основе байесовских методов формирует интеграция вероятностных моделей с алгоритмами МО. Так, включение адаптивных вероятностных оценок в процесс оптимизации ПЦБ позволяет корректировать модели с учётом изменения рыночных условий и неопределённости данных. Вместе с тем в настоящее время активно изучаются возможности квантового машинного обучения, теоретически способного ускорить вычисления для оптимизации ПЦБ и снизить тем самым сложность обработки больших массивов данных. Однако практическое применение квантовых алгоритмов в финансовом анализе пока ещё остаётся сильно ограниченным вследствие очевидных технологических барьеров.

Выводы

Использование алгоритмов МО в оптимизации ПЦБ представляет собой одно из наиболее перспективных направлений современной финансовой аналитики. Гибкость методов МО позволяет учитывать сложные зависи-

мости между активами, анализировать рыночные тенденции в реальном времени и адаптироваться к изменениям макроэкономической среды. В отличие от основанных на статических предположениях традиционных моделей алгоритмы МО способны выявлять скрытые закономерности в данных и формировать стратегии управления активами с учётом динамики рынка. Включение в анализ методов прогнозирования, кластеризации и усиленного обучения формирует условия для более точного определения оптимальных параметров ПЦБ. Однако значительными барьерами, ограничивающими повсеместное применение МО в задачах портфельного управления, остаются высокая вычислительная сложность и требования к качеству данных.

Развитие технологий обработки данных и совершенствование архитектур моделей формируют предпосылки для дальнейшего расширения возможностей алгоритмов МО в сфере финансов. В частности, интеграция методов глубокого обучения, графовых моделей и вероятностных подходов открывает новые

горизонты в оценке рыночных рисков и оптимизации ПЦБ. Несмотря на существующие ограничения, алгоритмы МО уже показывают свою эффективность

в анализе финансовых данных, а их дальнейшее развитие может привести к значительным изменениям в подходах к управлению инвестициями.

Библиографический список

1. Gunjan A., Bhattacharyya S. A brief review of portfolio optimization techniques // *Artificial Intelligence Review*. 2023. Vol. 56. No 5. P. 3847-3886.
2. Долгов А.М., Люкевич И.Н., Долгов В.М. Применение методов машинного обучения в ценообразовании // *Вестник Алтайской академии экономики и права*. 2022. № 4-1. С. 52-59.
3. Habbab F.Z., Kampouridis M. An in-depth investigation of five machine learning algorithms for optimizing mixed-asset portfolios including REITs // *Expert Systems with Applications*. 2024. Vol. 235. P. 1-20.
4. Родин Д.Я., Паршин А.Б., Терпицкая К.И. Стратегии управления портфелем ценных бумаг // *Вестник Академии знаний*. 2022. № 3 (50). С. 455-464.
5. Плахин А.Е., Гусева Т.И., Селезнева М.В. Стратегия управления портфелем ценных бумаг // *Фундаментальные исследования*. 2024. № 12. С. 61-68.
6. Ma Y., Han R., Wang W. Portfolio optimization with return prediction using deep learning and machine learning // *Expert Systems with Applications*. 2021. Vol. 165. P. 1-12.
7. Du J. Mean–variance portfolio optimization with deep learning based-forecasts for cointegrated stocks // *Expert Systems with Applications*. 2022. Vol. 201. P. 1-14.
8. Chaweewanchon A., Chaysiri R. Markowitz mean-variance portfolio optimization with predictive stock selection using machine learning // *International Journal of Financial Studies*. 2022. Vol. 10. No 3. P. 1-19.
9. Chen W. et al. Mean–variance portfolio optimization using machine learning-based stock price prediction // *Applied Soft Computing*. 2021. Vol. 100. P. 1-22.
10. Lee Y. et al. An Overview of Machine Learning for Portfolio Optimization // *Journal of Portfolio Management*. 2024. Vol. 51. No 2. P. 1-31.
11. Cui T. et al. Multi-period portfolio optimization using a deep reinforcement learning hyper-heuristic approach // *Technological Forecasting and Social Change*. 2024. Vol. 198. P. 1-11.
12. Батракина Т.Н. и др. К вопросу о формировании структуры личного инвестиционного портфеля // *Вестник Алтайской академии экономики и права*. 2021. № 4-1. С. 14-20.
13. Каваленя Л.Н. Применение устойчивых распределений Леви и генетических алгоритмов для оптимизации портфеля ценных бумаг // *Математическое и компьютерное моделирование в экономике, страховании и управлении рисками*. 2023. Т. 8. С. 58-71.
14. Полетаев А.Ю., Спиридонова Е.М. Иерархическая кластеризация как метод снижения размерности в задаче оптимизации инвестиционного портфеля Марковица // *Моделирование и анализ информационных систем*. 2020. Т. 27. № 1. С. 62-71.
15. Асатуров К.Г. Оптимизация инвестиционного портфеля с декомпозицией риска // *Вестник Московского университета. Серия 6. Экономика*. 2017. № 5. С. 61-85.
16. Buyanova E.A., Sarkisov A.R. Constructing of an Optimal Portfolio on the Russian Stock Market Using a Nonparametric Method–Artificial Neural Network // *Корпоративные финансы*. 2017. Vol. 11. No 3. P. 100-110.
17. Salas-Molina F. et al. An Empirical Evaluation of Distance Metrics in Hierarchical Risk Parity Methods for Asset Allocation // *Computational Economics*. 2025. P. 1-18.

Дата поступления статьи в редакцию: 10.03.2025

Дата принятия статьи в печать: 03.04.2025