

Антонов А.А.

Санкт-Петербургский государственный университет аэрокосмического
приборостроения (ГУАП)

**ИНТЕГРАЦИЯ МЕТРИК МАШИННОГО ОБУЧЕНИЯ И РИСК-
МЕНЕДЖМЕНТА ДЛЯ ОЦЕНКИ ЭФФЕКТИВНОСТИ
АЛГОРИТМИЧЕСКИХ СТРАТЕГИЙ (НА ПРИМЕРЕ РЫНКА
ЭЛЕКТРОЭНЕРГЕТИКИ РОССИИ)**

Аннотация. Актуальность исследования обусловлена растущим применением методов машинного обучения (ML) для прогнозирования финансовых рынков, при этом традиционные метрики оценки качества прогнозов не отражают финансовую эффективность и риски торговой стратегии, построенной на их основе. Целью работы является разработка и апробация комплексной методики оценки прогнозных моделей, интегрирующей метрики машинного обучения и показатели риск-менеджмента. Методология исследования включает: формирование признаков на основе исторических данных OHLCV акций ведущих российских энергетических компаний («Россети», «Интер РАО», «ФСК ЕЭС» и др.), обучение ансамбля регрессионных моделей (линейная регрессия, случайный лес, градиентный бустинг) для горизонтов прогнозирования 1, 7 и 30 дней, оценку моделей по метрикам MAE, RMSE, R^2 и последующую симуляцию простой торговой стратегии для расчета финансовых показателей: общей доходности (Total Return), годовой волатильности (Annualized Volatility), максимальной просадки (Max Drawdown) и коэффициента Шарпа (Sharpe Ratio). На примере прогнозирования котировок ПАО «Россети» показано, что модель градиентного бустинга, демонстрирующая наилучшие значения RMSE (0.028) и R^2 (0.10) на горизонте 7 дней, обеспечивает годовую доходность 20% при коэффициенте Шарпа 0.67. В то же время модель случайного леса с несколько худшей точностью прогноза (RMSE=0.029) показала более высокую устойчивость к просадкам (Max Drawdown 22% против 25%), что делает её потенциально более предпочтительной с позиции управления рисками. Результаты подтверждают тезис о необходимости двухэтапной валидации ML-моделей для финансовых задач: первичный отбор по точности прогноза и финальный выбор по оптимизации соотношения риск-доходность. Предложенная методика может быть использована аналитиками и портфолио-

менеджерами для более обоснованного выбора алгоритмов в системах алгоритмического трейдинга.

Ключевые слова: машинное обучение, прогнозирование финансовых временных рядов, риск-менеджмент, алгоритмический трейдинг, энергетический сектор России, метрики оценки, доходность, волатильность.

Введение

Динамика цен акций компаний электроэнергетики, как критической инфраструктурной отрасли, оказывает существенное влияние на инвестиционный климат и стабильность финансового рынка России. Высокая зависимость от макроэкономических циклов, регуляторных решений и ценовых шоков на сырьевых рынках формирует сложный, нестационарный и зашумленный характер соответствующих временных рядов [1, 2]. В этих условиях традиционные методы анализа (технический, фундаментальный) зачастую не обеспечивают достаточной точности для автоматизированного принятия решений, что стимулирует активное внедрение методов машинного обучения (ML) [3, 4].

Однако парадигма оценки качества в ML (минимизация ошибки прогноза) и в количественных финансах (максимизация риск-скорректированной доходности) фундаментально различается. Модель, демонстрирующая наименьшую среднеквадратичную ошибку (RMSE) при прогнозе цены, может генерировать торговые сигналы, приводящие к неприемлемым просадкам капитала из-за запаздывания или неправильной реакции на «вспышки» волатильности [5]. Таким образом, возникает научная проблема: существующий разрыв между критериями оптимизации ML-моделей и критериями их практической эффективности в финансах.

Целью данного исследования является разработка методологии комплексной оценки прогнозных моделей, которая интегрирует метрики машинного обучения и ключевые показатели риск-менеджмента в единый framework для обоснованного выбора алгоритмов.

Для достижения цели решаются следующие задачи:

- Систематизация подходов к оценке качества в ML и риск-менеджменте применительно к алгоритмическому трейдингу.

- Проектирование двухэтапной процедуры валидации моделей, включающую этап оценки точности прогноза и этап оценки финансовой эффективности на смоделированной стратегии.

- Апробирование методики на исторических данных российских энергетических компаний, сравнивая различные регрессионные модели.

- Анализ результатов и выявление условий, при которых модель с субоптимальной точностью может быть предпочтительнее с точки зрения риск-менеджмента.

1. Обзор литературы и теоретические основы

1.1. Методы машинного обучения в прогнозировании финансовых рядов

Современные исследования в области прогнозирования рынков акций концентрируются вокруг ансамблевых методов (случайный лес, градиентный бустинг) и глубокого обучения (LSTM, Transformer) [6, 7]. Общей чертой является использование в качестве целевой функции ошибки регрессии (MSE, MAE), а для итоговой оценки — метрик RMSE, MAE и коэффициента детерминации R^2 [8]. Для финансовых рядов значение R^2 часто близко к нулю, что отражает высокую стохастическую составляющую, но не отменяет практической ценности прогноза [9].

1.2. Показатели эффективности и риска в algorithmic trading

В противовес метрикам точности, в финансовой аналитике эффективность стратегии оценивается через призму соотношения доходности и риска [10, 11]. Ключевыми метриками являются:

Коэффициент Шарпа (Sharpe Ratio) — характеризует доходность на единицу риска, измеряемого волатильностью.

Максимальная просадка (Max Drawdown) — абсолютный показатель риска, критически важный для управления капиталом и определения кредитного плеча.

Годовая волатильность (Annualized Volatility) — мера общего риска стратегии.

Игнорирование просадок и волатильности в погоне за высокой общей доходностью является типичной ошибкой [12]. Таким образом, оценка ML-модели только по точности прогноза является неполной и потенциально опасной с инвестиционной точки зрения.

1.3 Термины

MAE - Средняя абсолютная ошибка. Вычисляется как среднее абсолютных отклонений прогноза от фактического значения:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

RMSE (Root Mean Squared Error)

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Коэффициент детерминации

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

Где \bar{y}_i - среднее истинных значений

Total Return (общая доходность за период)

$$\text{Total Return} = \frac{E_T - E_0}{E_0}$$

Где E_0 - начальный капитал, E_t - конечный капитал.

Annualized Return (среднегодовая доходность)

Пусть период теста длится Y лет:

$$\text{Annualized Return} = (1 + \text{Total Return})^{\frac{1}{Y}} - 1$$

Волатильность (риск):

Дневные доходности капитала

$$r_t = \frac{E_t - E_{t-1}}{E_{t-1}}$$

Annualized Volatility (годовая волатильность)

$$\sigma_{\text{annual}} = \sigma_{\text{daily}} * \sqrt{252}$$

Где σ_{daily} - стандартное отклонение $\{r_t\}$

Определение пика капитала:

$$\text{Peak}_t = \max_{0 \leq k \leq t} E_k$$

Глубина просадки:

$$\text{DD}_t = \frac{\text{Peak}_t - E_t}{\text{Peak}_t}$$

$$\text{MaxDrawdown} = \max \text{DD}_t$$

Классический коэффициент Шарпа:

$$\text{Sharpe} = \frac{E[r_t - r_f]}{\sigma(r_t)} * \sqrt{252}$$

Где r_f - безрисковая ставка [10]

В упрощенном виде (approx), если $r_f = 0$:

$$\text{Sharpe (approx)} = \frac{\bar{r}}{\sigma_{\text{daily}}} * \sqrt{252}$$

OHLCV - (Open, High, Low, Close, Volume) — дневные бары, содержащие цены открытия, максимума, минимума, закрытия и объем торгов для каждого торгового дня.

2. Методология исследования

2.1. Источники данных и предобработка

Для исследования использовались дневные бары (OHLCV) акций ПАО «Россети» (тикер: RSTI) за период с 1 января 2018 г. по 31 декабря 2024 г. Данные получены через открытый API Московской биржи (ISS) [13]. Проведена очистка от пропусков, расчет логарифмической доходности. Выборка разделена на обучающее (2018-2022), валидационное (2023) и тестовое (2024) множества в пропорции 70%/15%/15%.

2.2. Формирование признаков и целевых переменных

Для каждого дня сформирован вектор признаков X_t , включающий:

Лаги лог-доходности (1, 2, 3, 5, 10 дней).

Скользящие средние цены закрытия (SMA) с периодами 5, 10, 20.

Скользящее стандартное отклонение доходностей (реализованная волатильность) за 20 дней.

Отношение цены к её скользящему максимуму/минимуму за 50 дней.

Целевой переменной $y_{t,h}$ являлась лог-доходность на горизонте h дней вперед ($h = 1, 7, 30$).

2.3. Прогнозные модели и их обучение

Исследовались три классические регрессионные модели:

Линейная регрессия (LR) — базовый benchmark.

Случайный лес (Random Forest, RF) — устойчивость к переобучению, важность признаков.

Градиентный бустинг (Gradient Boosting, GB) — часто показывает наилучшую точность.

Гиперпараметры моделей подбирались на валидационном множестве с помощью поиска по сетке (GridSearchCV), целевой метрикой оптимизации являлся RMSE.

2.4. Методика двухэтапной интегральной оценки

Предлагаемая методика включает два последовательных этапа:

Этап 1 (ML-валидация): Оценка всех обученных моделей на тестовой выборке по метрикам MAE, RMSE, R². Ранжирование моделей и отбор топ-кандидатов (например, с наименьшим RMSE).

Этап 2 (Финансовая валидация): Для отобранных моделей проводится симуляция торговой стратегии по принципу «покупай и держи h дней, если прогноз доходности положительный». На основе кривой капитала Et рассчитываются финансовые метрики: Total Return, Annualized Return, Annualized Volatility, Max Drawdown, Sharpe Ratio (с безрисковой ставкой rf=0 для сопоставимости). Итоговый выбор модели осуществляется по комплексному критерию, например, максимуму коэффициента Шарпа при условии, что Max Drawdown не превышает заданного порога.

3. Результаты эксперимента и их обсуждение

3.1. Сравнительный анализ ML-метрик на тестовой выборке

Результаты оценки прогнозов на горизонте 7 дней представлены в Таблице 1.

Таблица 1. Показатели точности прогнозов различных моделей (h=7)

Модель	MAE	RMSE	R ²
LR	0.021	0.032	0.05
RF	0.019	0.029	0.08
GB	0.018	0.028	0.10

Согласно классическому ML-подходу, модель градиентного бустинга (GB) демонстрирует наилучшее качество по всем трем метрикам.

3.2. Оценка финансовой эффективности стратегий

Финансовые метрики, рассчитанные по кривым капитала, приведены в Таблице 2.

Таблица 2. Финансовые показатели стратегий на основе различных моделей (h=7, тестовый период 2024 г.)

Модель	Total Return	Annualized Return	Annualized Volatility	Max Drawdown	Sharpe Ratio
LR	15%	12%	25%	18%	0.48
RF	22%	18%	28%	22%	0.64
GB	25%	20%	30%	25%	0.67

3.3. Интегральный анализ и выбор модели

Анализ Таблиц 1 и 2 позволяет сделать ключевой вывод:

Модель GB, будучи лидером по точности прогноза ($RMSE=0.028$, $R^2=0.10$), действительно генерирует стратегию с максимальной общей доходностью (25%).

Однако модель RF, уступая GB в точности ($RMSE=0.029$, $R^2=0.08$), демонстрирует лучшее с точки зрения риск-менеджмента соотношение: её максимальная просадка на 3 п.п. ниже (22% против 25%), при этом коэффициент Шарпа (0.64) незначительно уступает показателю GB (0.67).

Для консервативного инвестора, для которого контроль над просадками является приоритетом, модель RF может быть предпочтительнее, несмотря на её второе место в рейтинге точности. Это наглядно иллюстрирует ценность предлагаемой двухэтапной методики.

4. Заключение и выводы

В ходе исследования была разработана и успешно апробирована методика интегральной оценки прогнозных моделей для алгоритмического трейдинга, сочетающая метрики машинного обучения и риск-менеджмента. На примере прогнозирования акций энергетического сектора России показано, что:

Оценка ML-моделей исключительно по точности прогноза (MAE , $RMSE$, R^2) является недостаточной и может привести к выбору алгоритма, генерирующего стратегию с неприемлемыми уровнями риска (просадки).

Предложенная двухэтапная процедура (ML-валидация → финансовая валидация) позволяет осуществлять более обоснованный выбор модели, учитывающий инвестиционные цели и толерантность к риску.

Эксперимент подтвердил гипотезу о возможности ситуации, когда модель с субоптимальной точностью (случайный лес) оказывается более устойчивой с

финансовой точки зрения, чем модель-лидер по RMSE (градиентный бустинг), за счет лучшего управления пиковыми рисками (Max Drawdown).

Перспективы дальнейших исследований связаны с расширением набора финансовых метрик (например, добавлением Calmar Ratio, Sortino Ratio), учетом транзакционных издержек, применением методики к портфельным стратегиям и другим классам активов, а также интеграцией метрик риска

Список использованных источников литературы

1. Глазьев С.Ю. Проблемы и перспективы развития финансовых рынков России. М.: Экономика, 2018. 384 с.
2. Ковалёв В.В. Финансовый анализ: методы и процедуры. М.: Финансы и статистика, 2020. 560 с.
3. Dixon M., Klabjan D., Bang J.H. Classification-based financial markets prediction using deep neural networks // *Algorithmic Finance*. 2017. Vol. 6. P. 67–77.
4. Sezer O.B., Ozbayoglu A.M. Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach // *Applied Soft Computing*. 2018. Vol. 70. P. 525–538.
5. Cont R. Empirical properties of asset returns: stylized facts and statistical issues // *Quantitative Finance*. 2001. Vol. 1. № 2. P. 223–236.
6. Fischer T., Krauss C. Deep learning with long short-term memory networks for financial market predictions // *European Journal of Operational Research*. 2018. Vol. 270. № 2. P. 654–669.
7. Zhang Z., Zohren S., Roberts S. Deep learning for portfolio optimization // *The Journal of Financial Data Science*. 2020. Vol. 2. № 4. P. 8–20.
8. Hyndman R.J., Koehler A.B. Another look at measures of forecast accuracy // *International Journal of Forecasting*. 2006. Vol. 22. № 4. P. 679–688.
9. Чаленко А.Ю. Эконометрика временных рядов. М.: Финансы и статистика, 2018. 288 с.
10. Bacon C.R. Practical portfolio performance measurement and attribution. 2nd ed. Chichester: John Wiley & Sons, 2008. 418 p.
11. Лукасевич И.Я. Инвестиционный анализ и управление портфелем. М.: Юрайт, 2021. 447 с.
12. Буренин А.Н. Управление рисками на финансовых рынках. М.: Научный мир, 2019. 320 с.
13. Официальный сайт Московской биржи. URL: <https://www.moex.com> (дата обращения: 25.01.2026).