

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение
высшего образования

«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»

Кафедра дискретной математики и информационных технологий

**ИССЛЕДОВАНИЕ АДАПТИВНЫХ АНСАМБЛЕВЫХ МЕТОДОВ
ПРОГНОЗИРОВАНИЯ НАПРАВЛЕНИЯ ДВИЖЕНИЯ ЦЕНЫ BITCOIN**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 4 курса 421 группы
направления 09.03.01 — Информатика и вычислительная техника
факультета КНиИТ
Голубкова Артема Анатольевича

Научный руководитель

к. ф.-м. н., доцент

В. В. Кирьяшкин

Заведующий кафедрой

к. ф.-м. н., доцент

Л. Б. Тяпаев

Саратов 2026

СОДЕРЖАНИЕ

ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ	3
ВВЕДЕНИЕ	4
ЗАКЛЮЧЕНИЕ	10
СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ	11

ОБОЗНАЧЕНИЯ И СОКРАЩЕНИЯ

- BTC — Bitcoin, первая децентрализованная криптовалюта;
- ML — Machine Learning, машинное обучение;
- LSTM — Long Short-Term Memory, сеть с долгой краткосрочной памятью;
- GRU — Gated Recurrent Unit, управляемый рекуррентный блок;
- BiLSTM — Bidirectional LSTM, двунаправленная LSTM;
- CNN — Convolutional Neural Network, свёрточная нейронная сеть;
- RF — Random Forest, метод случайного леса;
- AWC — Adaptive Weighted Consensus, адаптивный взвешенный консенсус;
- CA — Confidence×Accuracy, стратегия «Уверенность×Точность»;
- B&H — Buy & Hold, стратегия «купи и держи»;
- RSI — Relative Strength Index, индекс относительной силы;
- MACD — Moving Average Convergence Divergence, схождение/расхождение скользящих средних;
- OT — обратное тестирование (бэктест).

ВВЕДЕНИЕ

Криптовалютный рынок стремительно превратился из узкого сегмента в полноценный сегмент мировой финансовой системы. Биткоин (BTC) — наиболее капитализированная криптовалюта — за период с 2018 по 2026 год прошёл путь от \$3 000 до исторических максимумов выше \$100 000, демонстрируя амплитуду дневных колебаний, многократно превышающую традиционные финансовые активы. Рынок BTC является *нестационарным*: периоды устойчивого тренда (ралли, коррекция) чередуются с боковым движением и всплесками волатильности, причём характеристики каждого режима существенно различаются.

Актуальность исследования обусловлена следующим. Несмотря на обилие публикаций о применении отдельных алгоритмов машинного обучения к задаче прогнозирования BTC, комплексных сравнительных работ, охватывающих одновременно классические ML-методы, нейросетевые архитектуры и ансамблевые подходы с оценкой торговой эффективности, крайне мало. Методы динамического взвешивания ансамблей исследованы преимущественно вне крипто-контекста и не проверялись на данных с явной сменой рыночных режимов. Открытым остаётся вопрос о том, как ширина окна при пересчёте весов влияет на способность ансамбля реагировать на изменения рынка.

Цель работы — разработка и исследование адаптивных ансамблевых методов прогнозирования направления движения цены Bitcoin на основе моделей машинного обучения; изучение зависимости адаптивности ансамбля от параметров метода динамического взвешивания.

Для достижения поставленной цели решаются следующие **задачи**:

- исследовать возможность повышения устойчивости прогнозирования на нестационарном криптовалютном рынке за счёт адаптивного ансамблирования моделей машинного обучения;
- формализовать и реализовать ансамблевые стратегии с динамическим пересчётом весов — AWC и CA, а также базовые методы сравнения Soft Voting и Stacking;
- реализовать и обучить набор базовых моделей: четыре нейросетевые архитектуры (LSTM, GRU, BiLSTM, CNN-LSTM) и пять классических ML-методов (Random Forest, XGBoost, LightGBM, SVR, Ridge);

- исследовать влияние ширины скользящего окна на адаптивность ансамбля;
- провести сравнительный анализ стратегий по метрикам классификации, торговой доходности и максимальной просадки посредством бэктестирования;
- исследовать динамику весов ансамблей и выявить поведенческие закономерности моделей в различных рыночных условиях;
- сопоставить результаты адаптивных ансамблей со стратегией Buy-and-Hold как базовым ориентиром;
- разработать программный конвейер загрузки, предобработки и визуализации данных для воспроизводимых экспериментов.

Объект исследования — методы машинного обучения для прогнозирования финансовых временных рядов. **Предмет исследования** — методы адаптивного ансамблирования, применяемые к задаче прогнозирования направления движения цены BTC-USD на горизонте один торговый день.

Практическая значимость работы состоит в создании готовой к развёртыванию системы ежедневного прогнозирования с интерактивным веб-интерфейсом и автоматическим обновлением предсказаний по расписанию, а также в получении воспроизводимых экспериментальных результатов, демонстрирующих влияние параметров адаптивного ансамблирования на торговую эффективность.

Работа состоит из пяти разделов, заключения и приложения. В первом разделе рассматриваются теоретические основы: особенности криптовалютного рынка, классические и нейросетевые ML-модели, ансамблевые стратегии. Второй раздел посвящён постановке задачи и описанию данных. В третьем разделе описывается программная реализация системы. Четвёртый раздел содержит результаты сравнительного эксперимента. Пятый раздел рассматривает ограничения метода и направления дальнейших исследований.

Первый раздел «Методы машинного обучения для прогнозирования криптовалют» содержит теоретическое обоснование применяемых подходов.

Показано, что рынок BTC обладает свойствами, отличающими его от традиционных финансовых рынков: круглосуточная работа без выходных, среднегодовое стандартное отклонение дневной доходности свыше 60 % (против 15–20 % для S&P 500), а также статистически значимая автокорреляция

доходностей в периоды высокой волатильности. Эмпирические данные опровергают выполнение слабой формы гипотезы эффективного рынка для BTC, что обосновывает применение методов машинного обучения.

Из классических ML-методов в работе использованы: *Random Forest* — ансамбль деревьев, обученных бэггингом; *XGBoost* и *LightGBM* — методы градиентного бустинга с регуляризацией; *SVR* и *Ridge (LogisticRegression)* — методы опорных векторов и линейная модель. Из нейросетевых архитектур применены: *LSTM* и *GRU* — рекуррентные сети с вентильным механизмом; *BiLSTM* — двунаправленная LSTM, обрабатывающая ряд одновременно в прямом и обратном направлениях; *CNN-LSTM* — гибрид свёрточного и рекуррентного слоёв для извлечения локальных и долгосрочных паттернов.

Раздел содержит формализацию четырёх ансамблевых стратегий. *Soft Voting* усредняет вероятности базовых моделей с равными весами. *Stacking* обучает мета-модель (логистическую регрессию) на предсказаниях базовых моделей. В отличие от этих фиксированных методов, разработанные стратегии AWC и CA динамически пересчитывают веса без дополнительного обучения. В AWC вес модели i в день t определяется её скользящей точностью за последние N дней:

$$w_i^{(t)} = \frac{\text{acc}_i^{(N,t)}}{\sum_{j=1}^K \text{acc}_j^{(N,t)}},$$

где $K = 9$ — число базовых моделей. В CA вес определяется произведением текущей уверенности модели в прогнозе $c_i^{(t)}$ на её историческую точность acc_i :

$$w_i^{(t)} = c_i^{(t)} \cdot \text{acc}_i.$$

Вероятностные выходы всех моделей откалиброваны по методу Платта [8], что позволяет напрямую интерпретировать их как оценки $p(\text{рост}) \in [0, 1]$.

Второй раздел «Постановка задачи и методология» описывает данные и экспериментальную схему.

Использовались дневные цены BTC-USD (OHLCV) с января 2018 по апрель 2026 года — всего около 2 900 торговых дней. Данные разбиты хронологически: 70 % — обучающая выборка, 15 % — валидационная, 15 % (около 420 дней) — тестовая. Такое разбиение исключает утечку информации из будущего в модели.

На основе ценового ряда вычислены 30 технических признаков: скользящие средние (SMA-7, SMA-21, EMA-12, EMA-26), индикаторы импульса (RSI, MACD, стохастический осциллятор), показатели волатильности (ATR, полосы Боллинджера), индикаторы тренда (ADX) и объёмные метрики (OBV, соотношение объёмов). Нейросетевые модели получают на вход трёхмерный тензор $(N, 30, F)$, классические модели — уплощённый вектор $(N, 600)$.

Задача формулируется как бинарная классификация: предсказать направление дневного изменения цены BTC (рост/падение). Торговая стратегия в бэктесте реализует позицию «в лонг» при сигнале роста и выход в кэш при сигнале падения; начальный капитал — \$1 000, транзакционные издержки не учитываются. Базовым ориентиром служит стратегия Buy-and-Hold.

Третий раздел «Архитектура и программная реализация» описывает разработанную систему.

Система реализована на Python и имеет шестиуровневую архитектуру: уровень данных (загрузка через ufinance, предобработка, генерация признаков), уровень моделей (унифицированный интерфейс BaseModel с методами `train / predict / evaluate`), уровень ансамблей (Soft Voting, Stacking, AWC, CA), уровень бэктестирования (обратное тестирование торговых стратегий), уровень базы данных (SQLite с таблицами предсказаний, метрик и кривых капитала) и уровень веб-интерфейса (FastAPI + Chart.js).

Обученные модели регистрируются в глобальном реестре MODEL_REGISTRY и переиспользуются всеми ансамблями. Планировщик APScheduler запускает ежедневное обновление предсказаний по всем моделям и обоим экспериментам. Веб-интерфейс предоставляет интерактивное сравнение всех стратегий с возможностью выбора временного периода и просмотра кривых капитала.

Четвёртый раздел «Сравнительный анализ результатов» содержит основные экспериментальные результаты.

Точность классификации базовых моделей на тестовой выборке составила 47–54 %, что типично для задачи прогнозирования направления цены на нестационарном рынке [15]. Ни одна отдельная модель не показала стабильного превосходства во всех четырёх анализируемых рыночных периодах (ралли, коррекция, боковик, рост).

Итоговые результаты ансамблевых стратегий на тестовом периоде

(420 дней, стартовый капитал \$1 000) приведены в таблице 1.

Таблица 1 – Результаты ансамблевых стратегий

Стратегия	Асс, %	Баланс, \$	Доходность, %	MaxDD, %
B&H	—	1 055	+5,5	—
Soft Voting	51,0	1 186	+18,6	33,1
Stacking	52,0	1 231	+23,1	42,2
AWC-10	52,3	1 113	+11,3	26,3
AWC-20	52,5	1 415	+41,5	23,1
AWC-30	52,5	1 396	+39,6	23,1
AWC-60	54,0	1 429	+42,9	22,6
CA	53,5	1 598	+59,8	11,3

Все ансамблевые стратегии существенно превзошли стратегию Buy-and-Hold (+5,5 %). Лучший результат показала стратегия CA: доходность +59,8 % при максимальной просадке 11,3 % — наименьшей среди всех протестированных стратегий. Это достигается за счёт избирательности: за тестовый период совершено 60 сделок с win rate 60 %, тогда как Soft Voting совершал до 70 сделок при win rate 50 %.

Среди вариантов AWC лучший финансовый результат показал AWC-60 (+42,9 %), что объясняется стабилизирующим эффектом широкого окна на данном тестовом отрезке. При этом AWC-10 с коротким окном ведёт себя активнее, но с большими потерями в нестабильные периоды.

Анализ динамики весов позволил выявить четыре устойчивые закономерности. **Первая:** в стратегии CA нейросетевые модели (LSTM, GRU, BiLSTM, CNN-LSTM) имеют практически одинаковые веса ($\sigma = 0,004$) ввиду схожей точности и уверенности; реальную адаптацию обеспечивают классические модели, прежде всего Ridge. **Вторая:** AWC автоматически обнаружил два поведенческих кластера: Группа А (BiLSTM + Random Forest + XGBoost, взаимная корреляция весов $r \approx 0,99$) и Группа Б (GRU + CNN-LSTM + LightGBM + Ridge). В периоды бокового движения и коррекции доминирует Группа А; в периоды направленного тренда — Группа Б. Структура выявлена без внешней разметки рыночных режимов. **Третья:** с ростом параметра N стандартное отклонение весов AWC монотонно снижается (от 0,033 при $N = 10$ до 0,016 при $N = 60$), и при $N \rightarrow \infty$ поведение AWC сходится к Soft Voting — тем самым Soft Voting является частным случаем AWC. **Четвёртая:** Stacking обеспечивает умеренный результат (+23,1 %) при наибольшей просадке (42,2 %) — фиксированные веса мета-модели не адаптируются к

смене рыночного режима.

Пятый раздел «Ограничения и направления дальнейших исследований» анализирует практические ограничения полученных результатов.

К основным ограничениям относятся следующие. Бэктест не учитывает транзакционные издержки и проскальзывание, что завышает расчётную доходность по сравнению с реальной торговлей. Тестовая выборка охватывает специфический период 2025–2026 гг., и результаты могут не воспроизводиться на других временных отрезках. Прогнозирование выполняется исключительно по ценовым данным и техническим индикаторам без учёта новостного фона и данных on-chain.

Перспективными направлениями являются: исследование поведения адаптивных ансамблей на часовых и недельных данных; проверка метода на других финансовых рынках (акции, фьючерсы); адаптивный подбор параметра окна N в AWC в зависимости от текущего состояния рынка; включение в ансамбль трансформерных архитектур.

ЗАКЛЮЧЕНИЕ

В настоящей работе исследовано поведение адаптивных ансамблевых методов прогнозирования в условиях нестационарного криптовалютного рынка на примере Bitcoin. Центральной задачей исследования являлось изучение того, каким образом динамическое изменение весов моделей влияет на способность ансамбля адаптироваться к смене рыночного режима.

Основным результатом работы стало установление зависимости между шириной скользящего окна в методе адаптивного взвешенного консенсуса (AWC) и характером поведения ансамбля. Показано, что уменьшение окна повышает скорость реакции ансамбля на изменение рыночной ситуации, однако делает веса более чувствительными к случайным колебаниям точности моделей. Напротив, увеличение окна приводит к более стабильному распределению весов ценой запаздывания адаптации. Экспериментально подтверждено, что при $N \rightarrow \infty$ поведение AWC приближается к Soft Voting с равномерным взвешиванием моделей.

Анализ динамики весов ансамблей показал, что различные группы моделей демонстрируют неодинаковое поведение в зависимости от рыночного режима. В периоды бокового движения большой вклад в ансамбль вносят деревья решений и BiLSTM, тогда как в условиях направленного тренда усиливается влияние линейных и части нейросетевых моделей. Полученная структура была выявлена автоматически, без использования внешней разметки рыночных состояний.

Наилучший практический результат продемонстрировала стратегия «Уверенность Точность» (CA), обеспечившая доходность +57,0 % при максимальной просадке 11,3 %. Все адаптивные ансамблевые стратегии существенно превзошли пассивную стратегию Buy-and-Hold (+5,5 %), что подтверждает эффективность динамического перераспределения весов в условиях нестационарного рынка.

В рамках работы реализованы и обучены девять базовых моделей машинного обучения, включающих нейросетевые архитектуры (LSTM, GRU, BiLSTM, CNN-LSTM) и классические ML-методы (Random Forest, XGBoost, LightGBM, SVR, Ridge), а также реализованы ансамблевые стратегии Soft Voting, Stacking, AWC и CA. Для проведения экспериментов разработан программный конвейер загрузки, предобработки и анализа данных,

дополненный веб-интерфейсом визуализации результатов и системой обратного тестирования.

Полученные результаты показывают, что эффективность ансамбля в условиях смены рыночного режима определяется в первую очередь не характеристиками отдельных моделей, а механизмом адаптивного управления их вкладом. Разработанный подход может быть использован при построении алгоритмических торговых систем для других финансовых рынков, а также расширен за счёт онлайн-адаптации базовых моделей и динамического изменения состава ансамбля.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

- 1 Nakamoto, S. Bitcoin: A Peer-to-Peer Electronic Cash System / S. Nakamoto. — 2008. — URL: <https://bitcoin.org/bitcoin.pdf> (дата обращения: 31.03.2026).
- 2 Fama, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work / E. F. Fama // The Journal of Finance. — 1970. — Vol. 25, No. 2. — P. 383–417.
- 3 Hochreiter, S. Long Short-Term Memory / S. Hochreiter, J. Schmidhuber // Neural Computation. — 1997. — Vol. 9, No. 8. — P. 1735–1780.
- 4 Cho, K. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation / K. Cho, B. van Merriënboer, C. Gulcehre et al. // arXiv preprint arXiv:1406.1078. — 2014.
- 5 Breiman, L. Random Forests / L. Breiman // Machine Learning. — 2001. — Vol. 45, No. 1. — P. 5–32.
- 6 Chen, T. XGBoost: A Scalable Tree Boosting System / T. Chen, C. Guestrin // Proceedings of the 22nd ACM SIGKDD. — 2016. — P. 785–794.
- 7 Ke, G. LightGBM: A Highly Efficient Gradient Boosting Decision Tree / G. Ke, Q. Meng, T. Finley et al. // Advances in Neural Information Processing Systems. — 2017. — Vol. 30. — P. 3146–3154.
- 8 Platt, J. C. Probabilistic Outputs for Support Vector Machines and Comparisons to Regularized Likelihood Methods / J. C. Platt // Advances in Large Margin Classifiers. — MIT Press, 1999. — P. 61–74.
- 9 Wolpert, D. H. Stacked Generalization / D. H. Wolpert // Neural Networks. — 1992. — Vol. 5, No. 2. — P. 241–259.
- 10 McNally, S. Predicting the Price of Bitcoin Using Machine Learning / S. McNally, J. Roche, S. Caton // 26th Euromicro International Conference on Parallel, Distributed and Network-based Processing. — 2018. — P. 339–343.
- 11 Livieris I. E., Pintelas E., Pintelas P. A CNN-LSTM model for gold price time-series forecasting // Neural Computing and Applications. — 2020. — Vol. 32. — P. 17351–17360.
- 12 Alessandretti L., ElBahrawy A., Aiello L. M., Baronchelli A. Anticipating cryptocurrency prices using machine learning // Complexity. — 2018. — Vol. 2018. — Article ID 8983590.

- 13 Polikar R. Ensemble based systems in decision making // IEEE Circuits and Systems Magazine. — 2006. — Vol. 6, No. 3. — P. 21–45.
- 14 Lim B., Zohren S. Time-series forecasting with deep learning: a survey // Philosophical Transactions of the Royal Society A. — 2021. — Vol. 379.
- 15 Bielskis A., Belovas I. Machine Learning and Ensemble Methods for Stock Index Forecasting // AIMS Mathematics. — 2026.
- 16 Littlestone N., Warmuth M. K. The Weighted Majority Algorithm // Information and Computation. — 1994. — Vol. 108, No. 2. — P. 212–261.