

МИНОБРНАУКИ РОССИИ

Федеральное государственное бюджетное образовательное учреждение

высшего образования

«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ

ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ

ИМЕНИ Н. Г. ЧЕРНЫШЕВСКОГО»

Кафедра теории функций и стохастического анализа

ПОРТФЕЛИ ЦЕННЫХ БУМАГ

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 4 курса 412 группы

направления 01.03.02 — Прикладная математика и информатика

механико-математического факультета

Морозов Сергей Александрович

Научный руководитель

доцент, к. ф.-м. н., доцент

Л. В. Борисова

Заведующий кафедрой

д. ф.-м. н., доцент

С. П. Сидоров

Саратов 2026

СРАВНИТЕЛЬНЫЙ АНАЛИЗ МОДЕЛЕЙ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ АКЦИЙ МОСБИРЖИ И ФОРМИРОВАНИЯ ОПТИМАЛЬНОГО ПОРТФЕЛЯ

Содержание

1	МАТЕМАТИЧЕСКИЙ АППАРАТ МОДЕЛЕЙ	3
1.1	Статистические модели	3
1.1.1	ARIMAX (Autoregressive Integrated Moving Average with Exogenous Variables)	3
1.1.2	ETS (Exponential Smoothing State Space Model)	4
1.2	Ансамбли деревьев решений	4
1.2.1	Random Forest	4
1.2.2	XGBoost (Extreme Gradient Boosting)	5
1.3	Рекуррентные и свёрточные нейронные сети	6
1.3.1	LSTM (Long Short-Term Memory)	6
1.3.2	GRU (Gated Recurrent Unit)	7
1.3.3	TCN (Temporal Convolutional Network)	7
1.4	Графовые нейронные сети	8
1.4.1	GCN (Graph Convolutional Network)	8
2	ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ	9
2.1	Постановка эксперимента и данные	9
2.2	Сравнительный анализ моделей прогнозирования	9
2.3	Детальный анализ по активам (на примере ARIMAX)	10
2.4	Ансамблевое прогнозирование и формирование портфеля	11

ВВЕДЕНИЕ

Современный российский фондовый рынок характеризуется повышенной волатильностью, структурными сдвигами и высокой чувствительностью к макроэкономическим факторам. В условиях роста алгоритмической торговли способность корректно прогнозировать динамику цен активов и формировать сбалансированные портфели приобретает критическую значимость. Традиционные линейные методы часто оказываются недостаточными, что обуславливает необходимость применения гибридных ансамблей, включающих статистические модели, градиентный бустинг и архитектуры глубокого обучения.

Актуальность исследования заключается в необходимости перехода от прогнозирования отдельных активов к комплексному управлению рисками портфеля с использованием современных методов машинного обучения. Особую значимость имеет разработка методологии, которая не только минимизирует ошибку предсказания (MAPE), но и обеспечивает диверсификацию капитала, исключая чрезмерную концентрацию на отдельных бумагах.

Целью работы является проведение сравнительного анализа эффективности широкого спектра моделей (ARIMAX, ETS, RF, XGBoost, LSTM, GRU, TCN, GCN) при прогнозировании акций Мосбиржи и разработка алгоритма формирования *сбалансированного* инвестиционного портфеля на основе ансамбля прогнозов.

Для достижения цели решались следующие **задачи**:

1. Реализовать и обучить 8 моделей прогнозирования, включая классические статистические (ARIMAX, ETS), ансамбли деревьев (XGBoost, Random Forest) и нейросетевые архитектуры (LSTM, GRU, TCN).
2. Внедрить графовую нейронную сеть (GCN) для уточнения прогнозов с учётом межсекторальных корреляций.
3. Разработать методологию ансамблевого прогнозирования, усредняющую выходы лучших моделей для снижения дисперсии ошибки.
4. Построить алгоритм оптимизации портфеля (Markowitz Mean-Variance) с применением сжатия ковариационной матрицы Ledoit–Wolf и жёсткими ограничениями на веса активов ($w_{\max} \leq 8\%$) для обеспечения диверсификации.
5. Оценить экономическую эффективность стратегий через коэффициент Шарпа и Directional Accuracy.

Объектом исследования является ликвидный сегмент российского фондового рынка (30 акций, включая СБЕР, ГАЗП, ЛКОЙЛ и др.).

Предметом исследования выступают алгоритмы машинного обучения и методы стохастической оптимизации для краткосрочного прогнозирования и управления портфелем.

1 МАТЕМАТИЧЕСКИЙ АППАРАТ МОДЕЛЕЙ

1.1 Статистические модели

1.1.1 ARIMAX (Autoregressive Integrated Moving Average with Exogenous Variables)

Модель ARIMAX объединяет три компоненты: авторегрессию (AR), интегрирование (I) и скользящее среднее (MA), дополненные экзогенными переменными (X).

Математическая формулировка:

Пусть y_t — логарифмическая доходность акции в момент времени t . Общий вид модели ARIMAX(p, d, q):

$$\phi_p(B)(1 - B)^d y_t = c + \sum_{i=1}^k \beta_i x_{t,i} + \theta_q(B)\varepsilon_t, \quad (1)$$

где:

- B — оператор сдвига (backshift): $B y_t = y_{t-1}$, $B^2 y_t = y_{t-2}$;
- $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$ — полином авторегрессии порядка p ;
- $\theta_q(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$ — полином скользящего среднего порядка q ;
- d — порядок дифференцирования (для обеспечения стационарности);
- $x_{t,i}$ — экзогенные переменные (доходность индекса ИМОЕХ, объём торгов);
- $\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$ — белый шум.

Пример для ARIMAX(1,0,1):

Рассмотрим упрощённый случай с одной экзогенной переменной (индекс ИМОЕХ):

$$(1 - 0.6B)y_t = 0.01 + 0.4x_t + (1 + 0.3B)\varepsilon_t \quad (2)$$

Раскроем операторы:

$$y_t - 0.6y_{t-1} = 0.01 + 0.4x_t + \varepsilon_t + 0.3\varepsilon_{t-1} \quad (3)$$

Отсюда получаем явную формулу прогноза:

$$y_t = 0.01 + 0.6y_{t-1} + 0.4x_t + \varepsilon_t + 0.3\varepsilon_{t-1} \quad (4)$$

Численный расчёт:

- Дано: $y_{t-1} = 0.02$ (2% доходность вчера), $x_t = 0.015$ (ИМОЕХ вырос на 1.5%)
- Ошибки: $\varepsilon_{t-1} = 0.001$, $\varepsilon_t = 0$ (ожидаемое значение)
- Подставляем:

$$y_t = 0.01 + 0.6 \cdot 0.02 + 0.4 \cdot 0.015 + 0 + 0.3 \cdot 0.001 = 0.0283 \quad (5)$$

- Прогноз: доходность составит 2.83%

1.1.2 ETS (Exponential Smoothing State Space Model)

Модель ETS декомпозирует ряд на три компоненты: Error (ошибка), Trend (тренд) и Seasonality (сезонность). Рассмотрим модель с аддитивным трендом и без сезонности.

Математическая формулировка:

Система уравнений состояния:

$$\begin{aligned} \text{Уровень: } l_t &= \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \\ \text{Тренд: } b_t &= \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \end{aligned} \quad (6)$$

$$\text{Прогноз: } \hat{y}_{t+h|t} = l_t + h \cdot b_t$$

где $\alpha, \beta \in [0, 1]$ — параметры сглаживания.

Численный пример:

Пусть $\alpha = 0.3$, $\beta = 0.1$. На момент $t - 1$: $l_{t-1} = 100$, $b_{t-1} = 2$ (тренд +2 в день).

Шаг 1: Наблюдаем $y_t = 103$.

Шаг 2: Обновляем уровень:

$$l_t = 0.3 \cdot 103 + (1 - 0.3)(100 + 2) = 30.9 + 71.4 = 102.3 \quad (7)$$

Шаг 3: Обновляем тренд:

$$b_t = 0.1 \cdot (102.3 - 100) + (1 - 0.1) \cdot 2 = 0.23 + 1.8 = 2.03 \quad (8)$$

Шаг 4: Прогноз на 5 дней вперёд:

$$\hat{y}_{t+5|t} = 102.3 + 5 \cdot 2.03 = 112.45 \quad (9)$$

1.2 Ансамбли деревьев решений

1.2.1 Random Forest

Модель строит M решающих деревьев на бутстрэп-выборках и усредняет их предсказания.

Математическая формулировка:

Для регрессии итоговый прогноз:

$$\hat{y} = \frac{1}{M} \sum_{m=1}^M T_m(x) \quad (10)$$

Каждое дерево T_m рекурсивно разбивает пространство признаков. В листе j дерева m прогноз равен среднему значению целевой переменной обучающих примеров, попавших в этот лист:

$$c_{jm} = \frac{1}{N_{jm}} \sum_{i: x_i \in R_{jm}} y_i \quad (11)$$

Численный пример (3 дерева):

Предсказываем доходность акции. Признаки: $x = [\text{объём, изменение цены}]$.

Дерево 1: $T_1(x) = 0.025$ (2.5%)

Дерево 2: $T_2(x) = 0.018$ (1.8%)

Дерево 3: $T_3(x) = 0.022$ (2.2%)

Итоговый прогноз Random Forest:

$$\hat{y} = \frac{0.025 + 0.018 + 0.022}{3} = 0.0217 \quad (2.17\%) \quad (12)$$

1.2.2 XGBoost (Extreme Gradient Boosting)

Модель строит ансамбль деревьев аддитивно, минимизируя регуляризованную функцию потерь.

Математическая формулировка:

На шаге t добавляется дерево f_t :

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (13)$$

Целевая функция с регуляризацией:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (14)$$

где $\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$ штрафует за сложность (T — число листьев, w_j — веса листьев).

Разложение в ряд Тейлора до второго порядка:

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^n \left[g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right] + \Omega(f_t) \quad (15)$$

где $g_i = \partial_{\hat{y}} l(y_i, \hat{y}_i)$ — градиент, $h_i = \partial_{\hat{y}}^2 l(y_i, \hat{y}_i)$ — гессиан.

Оптимальный вес листа j :

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (16)$$

Численный пример:

Рассмотрим упрощённый случай с MSE-потерей $l(y, \hat{y}) = \frac{1}{2}(y - \hat{y})^2$.

Дано:

- 3 примера в листе: $y = [0.03, 0.02, 0.04]$
- Текущий прогноз: $\hat{y}^{(0)} = 0.02$ для всех
- $\lambda = 1$ (параметр регуляризации)

Шаг 1: Вычисляем градиенты и гессианы для MSE:

$$g_i = \hat{y}_i - y_i, \quad h_i = 1 \quad (17)$$

- $g_1 = 0.02 - 0.03 = -0.01$
- $g_2 = 0.02 - 0.02 = 0$
- $g_3 = 0.02 - 0.04 = -0.02$

Шаг 2: Оптимальный вес листа:

$$w^* = - \frac{(-0.01) + 0 + (-0.02)}{1 + 1 + 1 + 1} = \frac{0.03}{4} = 0.0075 \quad (18)$$

Шаг 3: Обновлённый прогноз для примеров в листе:

$$\hat{y}^{(1)} = 0.02 + 0.0075 = 0.0275 \quad (2.75\%) \quad (19)$$

1.3 Рекуррентные и свёрточные нейронные сети

1.3.1 LSTM (Long Short-Term Memory)

Ячейка LSTM решает проблему затухания градиента через механизм гейтов.

Математическая формулировка:

Для входа x_t и предыдущего скрытого состояния h_{t-1} :

$$\begin{aligned} \text{Гейт забывания: } f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f) \\ \text{Гейт входа: } i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \text{Кандидат: } \tilde{c}_t &= \tanh(W_c[h_{t-1}, x_t] + b_c) \\ \text{Состояние: } c_t &= f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \\ \text{Гейт выхода: } o_t &= \sigma(W_o[h_{t-1}, x_t] + b_o) \\ \text{Выход: } h_t &= o_t \odot \tanh(c_t) \end{aligned} \tag{20}$$

Численный пример (упрощённый):

Пусть размерность $h_t = 1$ (скаляр). Параметры (для примера):

- $W_f = 0.5, b_f = 0; W_i = 0.4, b_i = 0; W_c = 0.6, b_c = 0; W_o = 0.3, b_o = 0$
- Дано: $h_{t-1} = 0.5, c_{t-1} = 0.8, x_t = 0.2$

Шаг 1: Гейт забывания:

$$f_t = \sigma(0.5 \cdot [0.5, 0.2]) = \sigma(0.35) \approx 0.59 \tag{21}$$

(забываем 41% старой информации)

Шаг 2: Гейт входа:

$$i_t = \sigma(0.4 \cdot 0.7) = \sigma(0.28) \approx 0.57 \tag{22}$$

Шаг 3: Кандидат:

$$\tilde{c}_t = \tanh(0.6 \cdot 0.7) = \tanh(0.42) \approx 0.40 \tag{23}$$

Шаг 4: Новое состояние:

$$c_t = 0.59 \cdot 0.8 + 0.57 \cdot 0.40 = 0.47 + 0.23 = 0.70 \tag{24}$$

Шаг 5: Гейт выхода:

$$o_t = \sigma(0.3 \cdot 0.7) = \sigma(0.21) \approx 0.55 \tag{25}$$

Шаг 6: Выход:

$$h_t = 0.55 \cdot \tanh(0.70) = 0.55 \cdot 0.60 \approx 0.33 \tag{26}$$

1.3.2 GRU (Gated Recurrent Unit)

Упрощённая версия LSTM с двумя гейтами.

Математическая формулировка:

$$\begin{aligned}
 z_t &= \sigma(W_z[h_{t-1}, x_t] + b_z) && \text{(update gate)} \\
 r_t &= \sigma(W_r[h_{t-1}, x_t] + b_r) && \text{(reset gate)} \\
 \tilde{h}_t &= \tanh(W[r_t \odot h_{t-1}, x_t] + b) \\
 h_t &= (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t
 \end{aligned} \tag{27}$$

Численный пример:

Параметры: $W_z = 0.6$, $W_r = 0.5$, $W = 0.7$. Дано: $h_{t-1} = 0.5$, $x_t = 0.2$.

Шаг 1: Update gate:

$$z_t = \sigma(0.6 \cdot 0.7) = \sigma(0.42) \approx 0.60 \tag{28}$$

Шаг 2: Reset gate:

$$r_t = \sigma(0.5 \cdot 0.7) = \sigma(0.35) \approx 0.59 \tag{29}$$

Шаг 3: Кандидат:

$$\tilde{h}_t = \tanh(0.7 \cdot [0.59 \cdot 0.5, 0.2]) = \tanh(0.7 \cdot 0.495) \approx 0.33 \tag{30}$$

Шаг 4: Новый выход:

$$h_t = (1 - 0.60) \cdot 0.5 + 0.60 \cdot 0.33 = 0.20 + 0.20 = 0.40 \tag{31}$$

1.3.3 TCN (Temporal Convolutional Network)

Сеть использует каузальные свёртки с дилатацией для захвата долгосрочных зависимостей.

Математическая формулировка:

Свёртка с дилатацией d :

$$F(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \tag{32}$$

Для TCN с L слоями и размером ядра $k = 3$:

- Слой 1: $d = 2^0 = 1$ (охват 3 шага)
- Слой 2: $d = 2^1 = 2$ (охват 5 шагов)
- Слой 3: $d = 2^2 = 4$ (охват 9 шагов)

Численный пример:

Входная последовательность (доходности): $x = [0.01, 0.02, -0.01, 0.03, 0.015]$.

Фильтр $k = 3$: $f = [0.2, 0.5, 0.3]$.

Слой 1 ($d = 1$), вычисляем $F(4)$ (последний элемент):

$$F(4) = 0.2 \cdot x_4 + 0.5 \cdot x_3 + 0.3 \cdot x_2 = 0.2 \cdot 0.015 + 0.5 \cdot 0.03 + 0.3 \cdot (-0.01) = 0.015 \tag{33}$$

Слой 2 ($d = 2$):

$$F(4) = 0.2 \cdot x_4 + 0.5 \cdot x_2 + 0.3 \cdot x_0 = 0.2 \cdot 0.015 + 0.5 \cdot (-0.01) + 0.3 \cdot 0.01 = 0.001 \tag{34}$$

Таким образом, TCN агрегирует информацию с разных временных масштабов.

1.4 Графовые нейронные сети

1.4.1 GCN (Graph Convolutional Network)

Модель учитывает корреляции между акциями через графовую структуру.

Математическая формулировка:

Пусть A — матрица смежности графа (корреляции), X — матрица признаков узлов.

Правило распространения (Kipf & Welling, 2017):

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (35)$$

где:

- $\tilde{A} = A + I$ (добавляем самосвязи)
- $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ (степени вершин)
- $W^{(l)}$ — обучаемая матрица весов

Численный пример:

Рассмотрим граф из 3 акций: СБЕР, ГАЗП, ЛКОЙЛ.

Шаг 1: Матрица корреляций (смежности):

$$A = \begin{bmatrix} 1.0 & 0.7 & 0.5 \\ 0.7 & 1.0 & 0.6 \\ 0.5 & 0.6 & 1.0 \end{bmatrix} \quad (36)$$

Шаг 2: Добавляем самосвязи (уже есть на диагонали).

Шаг 3: Вычисляем степени:

$$D = \text{diag}([2.2, 2.3, 2.1]) \quad (37)$$

Шаг 4: Нормализованная матрица:

$$\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} \approx \begin{bmatrix} 0.45 & 0.31 & 0.23 \\ 0.31 & 0.43 & 0.27 \\ 0.23 & 0.27 & 0.48 \end{bmatrix} \quad (38)$$

Шаг 5: Признаки узлов (доходности): $X = [0.02, 0.015, 0.025]^T$.

Шаг 6: Агрегация (без активации и весов для простоты):

$$H^{(1)} = \begin{bmatrix} 0.45 \cdot 0.02 + 0.31 \cdot 0.015 + 0.23 \cdot 0.025 \\ 0.31 \cdot 0.02 + 0.43 \cdot 0.015 + 0.27 \cdot 0.025 \\ 0.23 \cdot 0.02 + 0.27 \cdot 0.015 + 0.48 \cdot 0.025 \end{bmatrix} = \begin{bmatrix} 0.0194 \\ 0.0194 \\ 0.0207 \end{bmatrix} \quad (39)$$

Таким образом, новая эмбединг-вектор СБЕРа (0.0194) учитывает информацию от ГАЗП и ЛКОЙЛ пропорционально их корреляциям.

Интерпретация: GCN позволяет «распространять» информацию по графу: если ГАЗП показывает высокую доходность, это косвенно повлияет на прогноз для СБЕРа через ребро с весом 0.7.

2 ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

2.1 Постановка эксперимента и данные

Эксперименты проводились на данных 30 ликвидных акций Мосбиржи за период с января 2024 по декабрь 2025 года. Целевой переменной выступала логарифмическая доходность $r_t = \ln(P_t/P_{t-1})$. Данные разделялись хронологически на обучающую (70%), тестовую (20%) и прогнозную (30 дней) выборки.

2.2 Сравнительный анализ моделей прогнозирования

На основе вычислительных экспериментов был проведён сравнительный анализ семи моделей прогнозирования. Результаты представлены в таблице 1.

Таблица 1: Рейтинг моделей по среднему значению MAPE (%) на тестовом горизонте 30 дней

Место	Модель	Средний MAPE, %	Категория
1	TCN	5.37	Глубокое обучение
2	LSTM	6.28	Глубокое обучение
3	GRU	7.80	Глубокое обучение
4	ETS	11.36	Статистическая
5	ARIMAX	15.14	Статистическая
6	Random Forest	20.81	Ансамбль деревьев
7	XGBoost	21.56	Ансамбль деревьев

Примечание: Зелёным выделены модели с MAPE < 10% (высокая точность).

Ключевые выводы из рейтинга

- Доминирование нейросетевых архитектур:** Три лучшие модели (TCN, LSTM, GRU) относятся к классу рекуррентных и свёрточных сетей глубокого обучения. Их преимущество составляет **2–4 раза** по точности относительно статистических методов.
- TCN как лидер:** Временная свёрточная сеть (TCN) показала наименьшую ошибку (5.37%), что подтверждает эффективность каузальных свёрток с дилатацией для захвата долгосрочных зависимостей в финансовых рядах.
- Ограничения деревьев:** Модели Random Forest и XGBoost, несмотря на популярность в табличных задачах, показали наихудшие результаты (20–21%). Вероятная причина: недостаточный учёт временной структуры данных при ручном создании лагов.
- Статистические модели как бенчмарк:** ARIMAX и ETS продемонстрировали умеренную точность (11–15%), что делает их пригодными для базового сравнения, но не для промышленного использования.

2.3 Детальный анализ по активам (на примере ARIMAX)

Для иллюстрации вариативности качества прогноза в таблице 2 приведены результаты модели ARIMAX по отдельным акциям.

Таблица 2: Метрики ARIMAX по выборке акций (упорядочено по возрастанию ошибки)

Тикер	MAPE, %	Оценка	Тикер	MAPE, %	Оценка
SNGS	1.82	✓ Отлично	NLMK	4.71	✓ Хорошо
GAZP	1.94	✓ Отлично	YDEX	4.71	✓ Хорошо
AKRN	2.11	✓ Отлично	NVTK	4.27	✓ Хорошо
SGZH	2.21	✓ Отлично	AFLT	8.35	! Удовл.
SBER	2.38	✓ Отлично	RTKM	8.86	! Удовл.
FEES	2.99	✓ Отлично	PLZL	7.94	! Удовл.
UPRO	3.50	✓ Отлично	ROSN	6.35	! Удовл.
PHOR	6.75	! Удовл.	OZON	6.37	! Удовл.
BSPB	6.81	! Удовл.	LKOH	10.65	× Слабо
ALRS	13.09	× Слабо	GMKN	13.40	× Слабо
MAGN	13.83	× Слабо	HYDR	13.78	× Слабо
HEAD	21.88	× Слабо	TATN	21.16	× Слабо
VTBR	21.37	× Слабо	CHMF	29.46	× Слабо
PIKK	35.40	Провал	MOEX	40.47	Провал
SMLT	43.11	Провал	MTSS	94.39	Провал

Легенда: ✓ MAPE < 5% | ! 5-15% | × 15-30% | Провал > 30%

Анализ вариативности результатов

1. Полярность качества прогноза.

Модель ARIMAX демонстрирует **крайне неоднородное** поведение:

- **Лучший результат: SNGS (1.82%)** — прогноз с ошибкой менее 2 рублей на 100 рублей цены.
- **Худший результат: MTSS (94.39%)** — ошибка, превышающая саму цену, что делает прогноз бесполезным.
- **Разброс:** отношение худшего MAPE к лучшему составляет **52:1**, что указывает на высокую чувствительность модели к свойствам конкретного актива.

2. Группировка по устойчивости.

Таблица 3: Распределение акций по категориям точности (модель ARIMAX)

Категория	Критерий	Число акций	Доля
✓ Отлично	$MAPE < 5\%$	8	27%
! Удовлетворительно	$5\% \leq MAPE < 15\%$	10	33%
× Слабо	$15\% \leq MAPE < 30\%$	8	27%
Провал	$MAPE \geq 30\%$	4	13%
Итого		30	100%

2.4 Ансамблевое прогнозирование и формирование портфеля

Для снижения дисперсии ошибки был реализован подход **Ensemble Learning**. Прогнозы моделей с наилучшими показателями (TCN, LSTM, GRU) усреднялись:

$$\hat{r}_{t,ensemble} = \frac{1}{3} (\hat{r}_{t,TCN} + \hat{r}_{t,LSTM} + \hat{r}_{t,GRU}) \quad (40)$$

На основе ансамблевых прогнозов формировался вектор ожидаемых доходностей μ . Для оценки рисков использовалась ковариационная матрица Σ , сжатая по методу Ledoit-Wolf.

Оптимизация портфеля проводилась с модифицированной целевой функцией, включающей штраф за концентрацию:

$$\min_w \left(-\frac{w^\top \mu}{\sqrt{w^\top \Sigma w}} + \lambda \sum w_i^2 \right) \quad (41)$$

при условиях: $\sum w_i = 1, \quad 0.015 \leq w_i \leq 0.08$.

Ограничение $w_{\max} \leq 8\%$ гарантирует, что портфель будет содержать значительное количество активов (в среднем 20-25 акций), что снижает идиосинкразические риски.

Таблица 4: Риск-доходностные профили портфельных стратегий

Стратегия	Ожид. доходность	Волатильность	Sharpe Ratio
Equal Weight (Бенчмарк)	14.2%	22.1%	0.64
Markowitz (Без ограничений)	18.5%	24.5%	0.75
Balanced Portfolio (Ensemble)	17.1%	16.2%	1.05

Стратегия **Balanced Portfolio**, использующая ансамбль прогнозов и ограничения на диверсификацию, продемонстрировала наилучший коэффициент Шарпа (1.05) при существенно сниженной волатильности по сравнению с бенчмарком.

ЗАКЛЮЧЕНИЕ

В ходе работы был проведён комплексный анализ применимости современных методов машинного обучения для прогнозирования российского фондового рынка и управления портфелем.

Основные выводы:

- Сравнение моделей:** Нелинейные модели (LSTM, TCN, GRU) стабильно превосходят статистические бенчмарки (ARIMAX, ETS) за счёт способности улавливать сложные паттерны. Архитектура TCN показала наивысшую эффективность (средний MAPE 5.37%) при параллельном обучении.
- Преимущество ансамбля:** Усреднение прогнозов разнородных моделей (нейросети) позволило снизить дисперсию ошибки и повысить устойчивость прогноза. Ансамблевый подход особенно эффективен для акций с умеренной волатильностью.
- Портфельная оптимизация:** Классическая оптимизация Марковица без ограничений ведёт к чрезмерной концентрации рисков. Предложенная модификация с жёсткими лимитами ($w \leq 8\%$) и штрафом за концентрацию позволила сформировать сбалансированный портфель с коэффициентом Шарпа 1.05, что значительно выше рыночного бенчмарка (Equal Weight, Sharpe 0.64).
- Практическая значимость:** Разработанная программная система автоматизирует полный цикл: от загрузки биржевых данных до визуализации сбалансированного портфеля. Результаты подтверждают целесообразность использования гибридных ансамблевых подходов в задачах алгоритмической торговли.

Направления дальнейших исследований:

- Интеграция новостного фона и макроэкономических индикаторов в качестве дополнительных признаков.
- Применение методов онлайн-обучения для адаптации моделей к изменяющимся рыночным условиям.
- Расширение графовой архитектуры (GCN) за счёт включения фундаментальных связей между компаниями (поставщики, конкуренты, отраслевая принадлежность).

Поставленная цель работы достигнута: проведён сравнительный анализ моделей прогнозирования, разработана методология формирования диверсифицированного портфеля и подтверждена экономическая целесообразность применения ансамблевых алгоритмов в условиях российского фондового рынка.