

УДК 339.13 · DOI: 10.31429/2224042X\_2026\_81\_79

# Раннее прогнозирование движения финансовых активов и отраслевых рынков на основе многомерных рыночных факторов с применением технологий машинного обучения

Early Forecasting of Financial Asset and Local Market Movements Based on Multidimensional Market Factors Using Machine Learning Technologies

Сериков Д.А.<sup>1</sup>, Можогин С.С.<sup>2</sup>, Воронов А.А.<sup>3</sup>

<sup>1</sup> Кубанский государственный университет, Краснодар, Россия

<sup>2</sup> Московский физико-технический институт, Москва, Россия

<sup>3</sup> Петербургский государственный университет путей сообщения Императора Александра I, Санкт-Петербург, Россия

Serikov D.A.<sup>1</sup>, Mozhugin S.S.<sup>2</sup>, Voronov A.A.<sup>3</sup>

<sup>1</sup> Kuban State University, Krasnodar, Russia

<sup>2</sup> Moscow Institute of Physics and Technology, Moscow, Russia

<sup>3</sup> Emperor Alexander I St. Petersburg State Transport University, St. Petersburg, Russia

**Аннотация.** Статья посвящена разработке и оценке моделей машинного обучения для раннего прогнозирования направлений движения активов относительно бенчмарка на основе многомерных рыночных факторов. Показано, что гибридные ML-модели, объединяющие временные, межрыночные и структурные признаки, позволяют формировать устойчивые сигналы рыночных изменений. Продемонстрирована практическая применимость результатов не только для финансового анализа, но и для девелоперской отрасли: раннее выявление фаз рыночной ротации улучшает прогноз спроса на жильё, позволяет корректировать маркетинговые стратегии, определять динамику доступности ипотечного капитала и планировать объёмы строительства. Результаты исследования расширяют инструментарий анализа российского жилищного рынка, усиливая возможности прогнозирования поведения покупателей и инвестиционной активности. Цель исследования – выявление и обоснование оптимальных моделей машинного обучения для раннего прогнозирования направлений движения финансовых активов относительно рыночного бенчмарка на основе многомерных рыночных факторов, с последующей возможностью формирования торговых стратегий с повышенной доходностью.

**Abstract.** This article focuses on the development and evaluation of machine learning models for early forecasting of asset movement directions relative to a benchmark based on multidimensional market factors. It is shown that hybrid ML models integrating temporal, cross-market, and structural features make it possible to generate robust signals of market regime changes. The practical applicability of the results is demonstrated not only for financial analysis but also for the real estate development sector: early identification of market rotation phases improves housing demand forecasting, allows for adjustments in marketing strategies, supports the assessment of mortgage capital availability dynamics, and facilitates construction volume planning. The findings expand the analytical toolkit of the Russian housing market and strengthen the capacity to forecast buyer behavior and investment activity.

**Ключевые слова:** финансовые рынки, машинное обучение, прогнозирование, временные ряды, потоки капитала, относительная сила активов, классификация, жилищный рынок, прогнозирование спроса.

**Keywords:** financial markets, machine learning, time series forecasting, capital flows, relative strength, classification, housing market, demand forecasting.

**Цитирование:** Сериков Д.А., Можогин С.С., Воронов А.А. Раннее прогнозирование движения финансовых активов и отраслевых рынков на основе многомерных рыночных факторов с применением технологий машинного обучения // ЭКОНОМИКА: теория и практика. 2026. № 1. С. 79–85. DOI: 10.31429/2224042X\_2026\_81\_79

**История публикации:** рукопись поступила 5.01.2026, опубликована 23.03.2026.

## Введение

Актуальность темы определяется усложнением глобальных финансовых взаимосвязей и необходимостью раннего выявления условий, способствующих перетоку капитала между регионами, секторами экономики и типами инвестиционных инструментов. Исследования показывают, что секторальная структура потоков капитала (банковский сектор, нефинансовые корпорации, оффшорные финансовые центры) демонстрирует различную чувствительность к глобальной ликвидности, волатильности и динамике сырьевых цен, что определяет неравномерность реакции разных сегментов экономики на внешние шоки [8]. Положительная корреляция между притоками и оттоками капитала, особенно в периоды роста глобальной волатильности, указывает на значимость раннего прогнозирования структуры потоков для стабилизационной политики и инвестиционных стратегий.

Использование технологий машинного обучения создает возможность объединения анализа временных рядов с межрыночными и секторальными факторами, что позволяет выявлять скрытые закономерности в потоках капитала и оценивать их влияние на относительную силу активов. Гибридные подходы, объединяющие методы анализа временных рядов и машинного обучения (например, ARIMA, XGBoost и LSTM), демонстрируют улучшение точности прогнозов и устойчивость к изменению рыночных режимов [4]. При этом применение таких моделей для выявления ранних признаков изменения структуры капитала остается недостаточно разработанным направлением.

Существующие исследования преимущественно сосредоточены на прогнозировании динамики отдельных активов и не учитывают межсекторальные и межрегиональные зависимости [1]. Мультизадачные архитектуры, позволяющие моделировать связанные рынки и классы активов в едином пространстве признаков, предложены сравнительно недавно [9]. При этом большинство публикаций акцентирует внимание на статистических метриках точности, не оценивая экономическую значимость получаемых результатов [6, 7].

Современные финансовые рынки характеризуются высокой степенью волатильности, усложнением структуры инвестиционных потоков

и возникновением нелинейных межрыночных связей. Эти особенности обуславливают необходимость разработки методов, способных обеспечивать раннее выявление изменений направлений движения капитала. Исследования секторальных и межрегиональных потоков капитала показывают, что различные сегменты финансовой системы демонстрируют разную чувствительность к глобальной ликвидности, волатильности и динамике цен на сырьевые товары [8].

Большинство традиционных моделей ориентированы на прогнозирование абсолютных значений цен или макроэкономических показателей, что ограничивает их применимость для задач раннего распознавания структурных сдвигов. Методы машинного обучения, способные работать с многомерными данными и выявлять латентные закономерности, становятся важным инструментом для повышения точности прогнозов [3–5].

Возрастающий интерес вызывает анализ относительной силы активов — их способности опережать или отставать от рыночного ориентира. Изменение относительной силы выступает практическим отражением ротации капитала между инструментами, секторами и классами активов, даже если прямых данных о потоках капитала нет.

Теоретическая лакуна выбранной темы заключается в недостаточной проработанности подходов, позволяющих объединять временные, межрыночные и структурные факторы в единой ML-архитектуре для решения задачи классификации направлений будущего движения актива. Это определяет актуальность исследования. Кроме того, оно направлено на решение актуальной научно-практической задачи — повышение точности и экономической эффективности прогнозирования направлений движения цены на актив за счет интеграции гибридных моделей машинного обучения, анализа временных рядов и мультизадачного подхода.

Проблематика раннего прогнозирования отдельных аспектов финансовой отрасли сохраняет свою актуальность и для жилищного рынка. Финансовая устойчивость девелоперов зависит от стоимости капитала, процентных ставок, макроэкономических циклов, поведения инвесторов и динамики финансовых рынков. Изменения на фондовом, валютном и сырьевом

рынках нередко предвосхищают изменения в спросе на жильё, доступности ипотеки и скорости продаж. Модели, способные улавливать ранние признаки движения капитала, обладают высокой прикладной ценностью для стратегического планирования девелоперских проектов.

Существующие исследования концентрируются преимущественно на прогнозировании отдельных инструментов и редко учитывают структуру межрыночной ротации. Мультифакторные ML-подходы позволяют преодолеть это ограничение и сформировать системный взгляд на динамику активов, что может быть использовано при прогнозировании спроса на жильё и формировании маркетинговой политики застройщиков.

### Методология

Методологическая основа настоящего исследования заключается в разработке и экспериментальной проверке гибридного подхода к классификации направлений относительной силы активов относительно бенчмарка.

Модель интегрирует временные, межрыночные и секторальные признаки, отражающие ранние сигналы изменения структуры потоков капитала, и реализует принципы мультизадачного обучения для одновременного прогнозирования по множеству связанных активов и индексов. Это обеспечивает более высокую устойчивость результатов к изменению рыночных режимов [9].

Мы рассматриваем рынок как систему, в которой ценовая динамика взаимодействует с макроэкономическими и политическими факторами, а рыночные цены нередко реагируют на внешние шоки с временной задержкой. Поэтому замысел исследования состоит в объединении рыночных индикаторов и внешних драйверов в единую витрину (панель), формировании строгого набора признаков без утечки информации во времени и сопоставлении семейств моделей по их способности давать ранние и устойчивые сигналы предстоящей ротации капитала.

В работе использованы количественные методы анализа временных рядов и инструменты машинного обучения. Методология включает построение целевой переменной, формирование многомерной выборки и применение моделей машинного обучения.

Будущая относительная сила актива определяется как бинарный показатель: опережает ли актив в заданном горизонте доходности рыночный бенчмарк. Формирование многомерной выборки включает доходность активов различных горизонтов, межрыночные индикаторы (фондовые индексы, валюты, товары), показатели волатильности, структурные макроэкономические факторы. Таким образом, исследование опирается на многомерную витрину, включающую мировые индексы, валюты, товары, индикаторы волатильности и прокси-показатели потоков капитала.

Используемые модели машинного обучения: логистическая регрессия, Random Forest, XGBoost; гибридные композиции (ML + анализ временных рядов). Такая комбинация моделей рекомендуется в литературе по прогнозированию финансовых временных рядов [3, 4, 6]. Все табличные признаки стандартизируются; параметры стандартизации вычисляются исключительно на обучающем множестве и затем применяются к последующим блокам. Для моделей деревьев нормирование носит вспомогательный характер и не влияет на структуру разбиений.

Метрики оценки: ROC-AUC, precision, recall для классификации, а также доходность и максимальная просадка для торговых стратегий (экономические метрики). Оценка качества базируется на площади под ROC-кривой как устойчивой ранжирующей метрике, слабо чувствительной к возможной дисбалансировке классов. Дополнительно контролируются accuracy, precision, recall и F1-мера. Для стратегической интерпретации используется правило эксплуатации сигналов: позиция в активе открывается на следующий день после того, как вероятность превышает заданный порог. Все сигналы применяются со сдвигом на один день, что исключает эффект заглядывания в будущее и приближает оценку к реализуемой торговой логике.

Собранные метрики формируют единую таблицу и ранжированный лидерборд. Интерфейс эксперимента автоматически выделяет наиболее эффективную модель на валидации и на тесте. При использовании скользящей проверки дополнительно определяется метод, показавший наилучшие средние показатели по окнам, что позволяет избежать выбора модели по случайному всплеску.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
1	date	AGG	CBR	IMOEX	MCXRGBI	MOEXFN	RVI	SBER	SPSY	SPX	USDRUB	USRATE	VIX	VTBR	XAUUSD
2	02.11.2015	109.020000	11.000000	1735.750000	124.250000	6057.370000	37.150000	93.650000	329.210000	2104.100000	63.621600	0.250000	14.150000	362.500000	1133.750000
3	03.11.2015	108.820000	11.000000	1763.600000	124.980000	6101.370000	35.080000	95.400000	329.050000	2109.800000	62.535000	0.250000	14.540000	369.800000	1117.600000
4	04.11.2015	108.820000	11.000000	1763.600000	124.980000	6101.370000	35.080000	95.400000	327.810000	2102.300000	63.140000	0.250000	15.510000	369.800000	1107.440000
5	05.11.2015	108.770000	11.000000	1766.280000	125.930000	6138.450000	33.960000	95.500000	329.190000	2099.900000	63.260000	0.250000	15.050000	380.750000	1103.950000
6	06.11.2015	108.250000	11.000000	1754.360000	125.410000	6101.810000	37.260000	94.090000	332.650000	2099.200000	64.235000	0.250000	14.330000	379.250000	1088.640000
7	09.11.2015	108.180000	11.000000	1751.440000	125.350000	6060.250000	36.600000	92.950000	328.730000	2078.600000	64.557700	0.250000	16.520000	380.000000	1092.100000
8	10.11.2015	108.380000	11.000000	1746.940000	125.590000	6063.510000	35.380000	94.350000	330.150000	2081.700000	64.400000	0.250000	15.290000	378.800000	1089.910000
9	11.11.2015	108.240000	11.000000	1740.560000	126.270000	6044.890000	35.920000	94.000000	329.460000	2075.000000	65.295000	0.250000	16.060000	380.000000	1086.140000
10	12.11.2015	108.340000	11.000000	1739.960000	125.460000	5959.300000	36.890000	94.290000	324.210000	2046.000000	66.597500	0.250000	18.370000	377.100000	1085.050000
11	13.11.2015	108.550000	11.000000	1728.170000	125.190000	5927.090000	37.950000	93.400000	321.430000	2023.000000	66.825000	0.250000	20.080000	379.000000	1083.640000
12	16.11.2015	108.640000	11.000000	1739.800000	125.080000	6084.740000	36.170000	95.800000	325.450000	2053.200000	65.308000	0.250000	18.160000	379.400000	1082.850000
13	17.11.2015	108.720000	11.000000	1787.230000	125.520000	6283.020000	34.610000	102.500000	324.700000	2050.400000	65.052500	0.250000	18.840000	379.750000	1070.370000
14	18.11.2015	108.640000	11.000000	1810.480000	125.810000	6318.690000	34.220000	104.000000	330.640000	2083.600000	64.810000	0.250000	16.850000	380.500000	1071.140000
15	19.11.2015	108.690000	11.000000	1811.200000	126.110000	6325.630000	34.960000	104.860000	331.080000	2081.200000	64.480000	0.250000	16.990000	381.000000	1082.400000
16	20.11.2015	108.620000	11.000000	1826.720000	126.910000	6366.630000	34.840000	107.300000	331.510000	2089.200000	64.600000	0.250000	15.470000	380.050000	1078.100000
17	23.11.2015	108.650000	11.000000	1868.070000	126.100000	6463.840000	36.010000	109.980000	330.230000	2086.600000	65.815000	0.250000	15.620000	381.500000	1069.340000
18	24.11.2015	108.750000	11.000000	1810.050000	125.360000	6307.780000	37.090000	105.600000	329.220000	2089.100000	65.445000	0.250000	15.930000	364.150000	1075.490000
19	25.11.2015	108.800000	11.000000	1833.530000	125.200000	6403.370000	36.120000	108.510000	329.340000	2088.900000	65.575000	0.250000	15.190000	372.500000	1071.390000
20	26.11.2015	108.800000	11.000000	1828.300000	125.630000	6414.370000	35.060000	106.480000	329.340000	2088.900000	65.837000	0.250000	15.190000	380.000000	1072.250000
21	27.11.2015	108.770000	11.000000	1795.700000	125.300000	6347.220000	37.670000	104.550000	330.370000	2090.100000	66.355000	0.250000	15.120000	363.550000	1058.810000
22	30.11.2015	108.810000	11.000000	1771.050000	125.550000	6240.490000	38.230000	102.900000	329.480000	2080.400000	66.300000	0.250000	16.130000	355.000000	1064.420000
23	01.12.2015	108.820000	11.000000	1772.970000	125.750000	6291.100000	37.410000	101.300000	333.660000	2102.600000	66.652500	0.250000	14.670000	366.400000	1069.490000
24	02.12.2015	108.690000	11.000000	1770.130000	125.810000	6270.150000	36.590000	102.500000	329.530000	2079.500000	67.415000	0.250000	15.910000	361.250000	1053.690000
25	03.12.2015	107.890000	11.000000	1787.230000	125.630000	6310.930000	36.130000	104.000000	324.240000	2049.600000	67.428000	0.250000	18.110000	358.500000	1062.570000
26	04.12.2015	108.240000	11.000000	1755.220000	125.650000	6260.170000	40.030000	103.050000	332.860000	2091.700000	68.025000	0.250000	14.810000	361.500000	1086.990000
27	07.12.2015	108.400000	11.000000	1741.140000	125.230000	6237.260000	39.720000	103.000000	329.910000	2077.100000	69.155000	0.250000	15.840000	362.350000	1070.390000
28	08.12.2015	108.440000	11.000000	1718.770000	124.910000	6069.540000	44.300000	97.000000	325.570000	2063.600000	69.450000	0.250000	17.600000	362.250000	1074.690000
29	09.12.2015	108.440000	11.000000	1733.090000	125.030000	6142.690000	34.560000	100.660000	321.820000	2047.600000	69.610000	0.250000	19.610000	375.250000	1073.210000
30	10.12.2015	108.420000	11.000000	1732.890000	125.320000	6153.280000	36.840000	100.130000	321.990000	2052.200000	68.205000	0.250000	19.340000	378.750000	1071.540000
31	11.12.2015	108.690000	11.000000	1720.310000	125.330000	6153.380000	34.350000	98.150000	314.990000	2012.400000	70.360000	0.250000	24.390000	378.500000	1074.890000
32	14.12.2015	108.180000	11.000000	1708.700000	124.580000	6096.930000	38.860000	97.700000	315.490000	2021.900000	70.470000	0.250000	22.730000	378.750000	1062.900000
33	15.12.2015	108.190000	11.000000	1742.460000	124.850000	6287.520000	32.600000	100.000000	322.990000	2043.400000	69.908400	0.250000	20.950000	381.200000	1060.740000
34	16.12.2015	108.000000	11.000000	1754.710000	124.560000	6346.320000	36.470000	102.450000	328.260000	2073.100000	70.265000	0.500000	17.860000	387.500000	1072.940000
35	17.12.2015	108.150000	11.000000	1780.970000	125.070000	6462.420000	30.980000	103.750000	323.070000	2041.900000	71.290000	0.500000	18.940000	393.850000	1051.740000
36	18.12.2015	108.380000	11.000000	1719.160000	125.160000	6219.220000	32.020000	98.810000	314.960000	2005.500000	71.007000	0.500000	20.700000	376.000000	1066.190000

Рис. 1. Витрина FINANCE.csv

Анализ межрыночных зависимостей осуществляется через включение в модель наборов внешних факторов, что согласуется с результатами исследований мультифакторных потоков капитала [8–9].

Классификационная постановка задачи («актив опередит / не опередит бенчмарк») позволяет получить интерпретируемые сигналы, применимые в экономическом анализе.

Рабочая выборка охватывает десятилетний интервал — с середины 2010-х гг. по текущий момент. Формируется синхронизированная дата-сетка и набор столбцов, включающий широкие рыночные индексы по регионам, секторальные индексы, валютные пары, товары и прокси-показатели экономической и политической неопределенности. Источники с месячной частотой доводятся до дневной шкалы прямой протяжкой без использования будущих значений. Все ряды выравниваются по датам, а пропуски в признаках закрываются медианой, вычисленной на тренировочном окне, что предотвращает подсмотр валидационных отрезков и сохраняет причинную структуру данных.

Постановка задачи классификации заключается в оценке вероятности того, что выбранный

актив опередит бенчмарк на горизонте  $H$  торговых дней. Целевая переменная строится на основе форвардной доходности со строгим сдвигом вперед. Признаки включают дневные доходности базовых рядов, лаги до заданной глубины, а также скользящие средние, сглаживающие высокочастотный шум. Признаковое описание формируется единообразно для всех временных рядов, что позволяет модели учитывать как внутрисерийные паттерны, так и перекрестные зависимости между активами и макроиндикаторами.

Разделение данных на обучающую, валидационную и тестовую части проводится строго по времени: сначала выделяется непрерывный блок для обучения, затем следующий блок для валидации и самый свежий блок для тестирования. Это предотвращает переоценку качества, характерную для случайного перемешивания наблюдений в нестационарных процессах. Дополнительно используется скользящая кросс-валидация по схеме расширяющегося окна: на каждом шаге модель обучается на всей предшествующей истории и проверяется на следующем временном фрагменте фиксированной длины. Усреднение оценок по окнам обеспечивает

устойчивое измерение качества и приближает эксперимент к реальным условиям эксплуатации.

## Результаты

Экспериментальная часть исследования выполнена на основе данных рыночных индикаторов, включенных в витрину *FINANCE.csv* (рис. 1).

Это единая витрина финансовых и макроэкономических временных рядов, включающая секторные и региональные индексы, валюты, товары и показатели неопределенности, синхронизированные на дневной частоте. Набор построен для выявления условий, при которых актив начинает опережать бенчмарк, т.е. для раннего распознавания ротации капитала. Многомерность витрины позволяет моделям использовать как внутрисерийные, так и перекрестные зависимости, что повышает точность классификационных прогнозов.

Витрина синхронизирована по годам и обеспечивает идеальные условия для построения правильных признаков без пропусков в данных. Многомерность позволяет моделям использовать перекрестные зависимости между классами активов. Поддержка классификационных задач: формирование целевой переменной происходит чисто из цен актива и бенчмарка; остальные ряды работают как факторы.

Модель классификации показала высокую значимость межрыночных факторов, что соответствует выводам исследований, подчеркивающих важность внешних индикаторов для прогнозирования ценовых аномалий и потоков капитала [4–5].

Также фиксируется экономическая эффективность применяемой методики. При моделировании торговой стратегии на основе предсказаний

классификатора наблюдалось превышение доходности над стратегией *Buy&Hold* более, чем на 15%, что подтверждает гипотезу о практической значимости применения ML-подходов (рис. 2).

Предложенная модель показывает уверенный статистически значимый сигнал. Показатель ROC AUC для модели XGBoost составил 0,65. Это высокий результат для финансовых рынков, означающий, что модель выявляет устойчивый прогностический сигнал в условиях рыночной зашумленности.

Отсутствие резких просадок капитала. За счет использования коэффициента порога уверенности выше 0,7 стратегия показывает рост при росте базовой стратегии и боковую динамику при проседании базовой стратегии, позволяя сохранить капитал.

## Обсуждение

Разработанная модель обеспечивает превышение совокупной доходности базовой стратегии *Buy&Hold* не менее, чем на 15% на тестовом периоде. Этот порог задает критерий практической значимости модели и опирается на эмпирические выводы о способности методов машинного обучения улучшать эффективность инвестиционных стратегий [3].

Представленные активы охватывают основные драйверы глобального капитала: несколько региональных рынков, секторальные индексы отражают ротации внутри экономики, валюты мгновенно реагируют на глобальные события, товары — сильные маркеры макрорежимов («инфляция», «риск-офф», «риск-он»).

Такой набор обеспечивает широкую факторную среду для выявления условий смещения потоков капитала. Обладают взаимозависимостью,




Рисунок 2. Кумулятивная доходность стратегии с учетом порога уверенности моделей и использования бенчмарка для определения направления движения в моделях классификации в сравнении с базовой стратегией *Buy&Hold* (тикер: SBER)

которую может использовать ML, так как валюты отражают макроэкономические циклы. Золото реагирует на геополитические риски, развивающиеся рынки следуют за движениями США с лагами.

Машинное обучение способно выделять скрытые связи, особенно проявленные на длительном горизонте и с качественной частотой (дневной). Это позволяет построить 10-летнюю выборку, выровненную по датам панель (около 2600 наблюдений), набор признаков без утечки информации. Дают возможность изучать относительную силу.

Исследование определило пользу мультифакторного описания, заключающуюся во включении в набор признаков политико-экономических индикаторов наряду с рыночными рядами, преимущество моделей, ориентированных на временную структуру данных, над чисто табличными методами и значимость региональной и отраслевой структуры на сериях экспериментов с различными активами и бенчмарками.

Полученные результаты согласуются с современными тенденциями финансовой аналитики, где машинное обучение применяется для выявления скрытых закономерностей в многомерных данных, включая нелинейные и стохастические взаимосвязи [6, 9]. Результаты подтверждают, что классификация направлений движения актива — более эффективная постановка задачи, чем прогноз абсолютной цены, особенно в условиях высокой волатильности. Этот вывод соответствует выводам зарубежных работ, где акцент делается на предсказании «направления движения», а не конкретного уровня цены [3].

Дополнительным вкладом является акцент на межрыночных факторах. Как показывают исследования секторальных потоков капитала [8], экономические взаимоотношения между секторами и рынками часто опережают динамику отдельных инструментов, что делает использование многомерных данных критически важным.

## Заключение

Пилотное исследование на финансовых инструментах доказало, что гибридные ML-модели способны выявлять ранние сигналы изменения рыночных режимов. Эти сигналы могут быть использованы девелоперами для прогнозирования спроса на жильё, выбора момента запуска

проектов, адаптации маркетинговой стратегии, управления рисками проектного финансирования.

Работа расширяет инструментарий анализа жилищного рынка, предлагая методологию, способную повышать точность прогнозов и устойчивость управленческих решений в условиях неопределённости. Исследованы возможности методов машинного обучения для раннего прогнозирования направлений относительного движения финансовых активов. На основе многомерных временных рядов и межрыночных факторов показано, что классификационные модели обладают высокой способностью к выявлению ранних сигналов изменения структуры рыночной привлекательности активов.

Более того, движение капитала между активами, секторами и регионами влияет на доступность ипотечных ресурсов, динамику ставок проектного финансирования, инвестиционную привлекательность жилья как актива.

ML-модели, выявляющие ранние сигналы изменения рыночных режимов, позволяют девелоперам прогнозировать ускорение / замедление спроса, изменение платежеспособности домохозяйств, фазы снижения и роста ипотечных ставок.

*ML-модель может применяться в более общем отраслевом стратегировании жилищной отрасли, планировании объёмов строительства.* Так, предварительные сигналы ротации капитала позволяют оптимизировать ввод объектов и темпы строительства, минимизировать риски кассовых разрывов, адаптировать стратегию использования эскроу-счетов, корректировать маркетинговую политику застройщиков.

ML-прогнозирование улучшает выбор целевых сегментов, определение ценовой политики, планирование рекламных кампаний, адаптацию предложений к конкретной фазе регионального рынка. Например, если поступает ранний сигнал роста глобальной волатильности, то вероятен рост ипотечных ставок, возникает необходимость усиления программ рассрочки и акций, стимулирующих ускорение продаж. Считаем, что возможна применимость для цифровых платформ рынка недвижимости. Модели могут быть интегрированы в составе аналитики девелоперов, цифровых витрин недвижимости, инструментов ценового и маркетингового прогнозирования.

Основные заключительные положения:

1. Предложена ML-архитектура, интегрирующая временные и межрыночные признаки для раннего выявления изменения относительной силы активов.

2. Классификационный подход используется как форма представления «ранних сигналов», заменяющая традиционный прогноз цен.

3. Показана применимость структурных и межрыночных факторов для моделирования рыночной ротации капитала без прямых данных о потоках. Это означает, что даже без прямой статистики о потоках капитала можно успешно моделировать рыночную ротацию, используя структурные и межрыночные индикаторы, поскольку они отражают поведение капитала косвенным образом.

## БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Акуста А. Analysis of the Relationship Between Cross Capital Flows and Stock Exchange Index with Machine Learning // Abant Sosyal Bilimler Dergisi. 2024.
2. Бутер Д. Forecasting project Cost Flow using Machine Learning // Международный журнал экономических исследований. 2020.
3. Вельмуруган Д.К., Мира Т., Миначи Р. Stock Market Prediction using Machine Learning Algorithms // International Journal of Advanced Research in Science, Communication and Technology. 2022.
4. Гаде С.Г., Сайяд Ш.Ф. Enhancing Stock Market Prediction with ARIMA and Machine Learning // Proceeding International Conference on Science and Engineering. 2023.
5. Гонсалес Рохас К. Foreign Exchange Forecasting via Machine Learning // Международный журнал экономического анализа. 2018.
6. Дербенцев В., Даценко Н., Степаненко О., Безкоровайный В. Forecasting Cryptocurrency Prices Time Series Using Machine Learning // Международный журнал финансовых исследований. 2019.
7. Дербенцев В., Матвийчук А., Даценко Н., Безкоровайный В., Азарян А. Machine learning approaches for financial time series forecasting // Advanced Studies of Financial Technologies and Cryptocurrency Markets. 2020.
8. Леперс Э., Меркадо Р.В. Analysing sectoral capital flows // OECD Working Papers on International Investment. 2021.
9. Ма Т., Ке Г. Multi-task Learning for Financial Forecasting // ArXiv. 2018.

## REFERENCES

1. Acusta, A. (2024). Analysis of the relationship between cross capital flows and stock exchange index with machine learning. Abant Sosyal Bilimler Dergisi.
2. Buter, D. (2020). Forecasting project cost flow using machine learning. International Journal of Economic Research.
3. Velmurugan, D. K., Mira, T., & Minachi, R. (2022). Stock market prediction using machine learning algorithms. International Journal of Advanced Research in Science, Communication and Technology.
4. Gade, S. G., & Saiyad, S. F. (2023). Enhancing stock market prediction with ARIMA and machine learning. In Proceedings of the International Conference on Science and Engineering.
5. Gonzalez Rojas, K. (2018). Foreign exchange forecasting via machine learning. International Journal of Economic Analysis.
6. Derbentsev, V., Datsenko, N., Stepanenko, O., & Bezkorovainyi, V. (2019). Forecasting cryptocurrency prices time series using machine learning. International Journal of Financial Research.
7. Derbentsev, V., Matviychuk, A., Datsenko, N., Bezkorovainyi, V., & Azaryan, A. (2020). Machine learning approaches for financial time series forecasting. Advanced Studies of Financial Technologies and Cryptocurrency Markets.
8. Lepers, E., & Mercado, R. V. (2021). Analysing sectoral capital flows. OECD Working Papers on International Investment.
9. Ma, T., & Ke, G. (2018). Multi-task learning for financial forecasting. arXiv.

## СВЕДЕНИЯ ОБ АВТОРАХ

**Сериков Денис Андреевич**, канд. экон. наук, преподаватель кафедры мировой экономики Кубанского государственного университета; e-mail: deenis@mail.ru

**Можогин Сергей Сергеевич**, студент магистратуры Московского физико-технического института.

**Воронov Александр Александрович**, д-р экон. наук, доцент, профессор кафедры логистики и коммерческой работы Петербургского государственного университета путей сообщения Императора Александра I; e-mail: voronov.a@mail.ru