Гибридная модель GSADF + LSTM-RNN для выявления ценовых пузырей на акциях российских технологических компаний

Кравченко Владислав Владимирович
аспирант, кафедра эконометрики и математических методов экономики, Московская школа экономики, Московский государственный университет имени М.В. Ломоносова, kravchenko.v.vladislav@gmail.com

Работа посвящена методам идентификации ценовых пузырей на фондовом рынке, соединяющие эконометрические тесты на взрывное поведение цен с алгоритмами машинного обучения. В качестве объекта исследования были собраны акции семи российских технологических компаний Московской биржи (Яндекс, Ozon Holdings, Positive Technologies, VK, МТС, Группа Астра, Softline) за 2014–2026 гг. с целью апробации двухэтапной гибридной схемы, в которой датирующая статистика BSADF из семейства тестов GSADF (Phillips, Shi, Yu, 2015) задает разметку пузырных эпизодов, а рекуррентная сеть LSTM обучается распознавать смену режима по комбинации ценовых признаков и финансовых мультипликаторов (P/E, P/S, EV/EBITDA). Специфику развивающегося рынка (короткую историю торгов, дисбаланс классов, структурные шоки) методология учитывает за счет BSADF-теста с подвижной начальной точкой окна, адаптивного порога разметки, «walk-forward» валидации без утечки данных из будущего и балансировки классов (SMOTE, ограничение весов). Качество работы модели проверено на временном ряду акций Tesla (2014–2024 гг.), где общепризнанный пузырь 2020–2021 гг. распознается с чувствительностью около 0,8. На российских данных выявлены эпизоды взрывного роста у Яндекса (2020–2021 гг. и 2024 г.) и Positive Technologies (2022–2023 гг. и 2025 г.). Итогом работы служит апробация связки GSADF и LSTM-RNN на данных российского технологического сектора и вытекающие из нее рекомендации построения гибридных моделей для развивающегося российского рынка технологических компаний.

Ключевые слова: ценовой пузырь, GSADF, BSADF, LSTM, рекуррентные нейронные сети, машинное обучение, российский фондовый рынок, технологические компании, гибридные модели.

Введение

Современные финансовые рынки отличаются высокой волатильностью, ускорением информационных потоков и растущей долей розничных инвесторов; все это повышает риск формирования ценовых пузырей и последующих резких коррекций. Кризисы последних десятилетий, от краха доткомов до пандемийного шока 2020 г., показывают, что пузыри остаются системным риском и для регуляторов и эмитентов, и для частных инвесторов. Актуальность темы усиливает глобальное ралли акций компаний, связанных с искусственным интеллектом, в 2023–2025 гг.

На российском рынке задача осложнена институциональной спецификой – короткой историей торгов по большинству технологических эмитентов, невысокой по мировым меркам ликвидностью и серией структурных шоков 2014, 2020 и 2022 гг., при которых предпосылки стационарности и стабильности параметров эконометрических моделей не выполняются. В этих условиях оправданы гибридные подходы, соединяющие строгий эконометрический аппарат датировки пузырей с гибкостью машинного обучения.

Цель работы – апробировать двухэтапную гибридную модель GSADF + LSTM-RNN на данных российских технологических компаний и вывести на этой основе принципы построения подобных моделей для развивающегося рынка России. Задачи: (1) датировать эпизоды взрывного роста цен средствами датирующей BSADF-статистики; (2) сопоставить выявленные эпизоды с динамикой финансовых мультипликаторов; (3) обучить LSTM-классификатор пузырных режимов и оценить его качество в схеме «walk-forward», с валидацией на позитивном контроле; (4) определить условия, при которых гибридная схема сохраняет работоспособность на коротких рядах. Центральный методологический вклад работы спецификация датирующего BSADF-теста, адаптированная к особенностям развивающегося рынка, применение эконометрического теста, как источника проверяемой разметки для машинного обучения. Забегая вперед, качество классификатора оказывается функцией глубины данных, этот контраст лежит в основе выводимых принципов.

Теоретические основы анализа пузырей заложены в работах Р. Шиллера [5], показавшего избыточную волатильность цен акций относительно дисконтированных дивидендов, и О. Бланшара и М. Уотсона [1], формализовавших концепцию рациональных пузырей. Современный эконометрический стандарт датировки пузырей, а именно семейство тестов SADF/GSADF П. Филлипса, С. Ши и Дж. Ю [2; 3], в которых нулевая гипотеза случайного блуждания тестируется против альтернативы взрывного корня ($\rho > 1$) на множестве подвыборок с подвижными границами. Альтернативную линию образуют модели лог-периодического степенного закона Д. Сорнетта [4].

Методы машинного обучения трактуют выявление пузырей как классификацию рыночных режимов или обнаружение аномалий. Применяются деревья решений и бустинг, глубокие нейронные сети [7], сетевые индикаторы режимных переключений [8]. Их сильная сторона заключается в работе со стохастическими процессами и высокоразмерными признаками, при склонности к переобучению на коротких рядах и ограниченной интерпретируемости (проблема «черного ящика»).

Гибридные конфигурации соединяют сильные стороны обоих классов методов, компенсируя их слабости. В литературе выделяются три типа таких конфигураций: (1) двухэтапные схемы, где эконометрические тесты формируют индикаторы перегрева, а модели машинного обучения распознают их комбинации, –пример для рынка S&P 500 дан в работе Ф. Башоглу-Кабран и К. Юнлю [9], для развивающихся рынков [10]; (2) ансамблевые и стеккинговые модели, агрегирующие выходы нескольких эконометрических процедур [11]; (3) интерпретируемо-ориентированные подходы, где машинное обучение ранжирует факторы, а итоговый вывод формулируется по эконометрическим критериям [12].

Эмпирическая база включает дневные котировки семи российских технологических компаний с листингом на Московской бирже: Яндекс (YNDX/YDEX), Ozon Holdings (OZON), Positive Technologies (POSI), VK (VKCO), МТС (MTSS), Группа Астра (ASTR) и Softline (SOFL). Данные получены с Московской биржи и охватывают период с июня 2014 г. по апрель 2026 г., суммарно более 10 000 торговых наблюдений. Для Яндекса ряды YNDX (до приостановки торгов в 2022 г.) и YDEX (после корпоративной реорганизации 2024 г.) соединены в единый ряд с устранением дубликатов (итоговая длина ряда – 3027 наблюдений). Динамика нормализованных цен пяти ключевых эмитентов представлена на рисунке (см. Рис. 1).

Финансовая отчетность по МСФО за 2021–2025 гг. собрана с платформы Smart-Lab. По каждой компании загружено от 54 до 63 показателей, из которых для моделирования взяты мультипликаторы P/E, P/S, EV/EBITDA, а также выручка, EBITDA, чистая прибыль и свободный денежный поток. Годовые значения мультипликаторов интерполированы на дневную сетку (линейная интерполяция между отчетными датами).

Расчетный контур включает позитивный контроль на основе котировок Tesla за 2014–2024 гг. (источник – Yahoo Finance), содержащий общепризнанный пузырь 2020–2021 гг. На этом ряду взрывная фаза 2020–2021 гг. распознается устойчиво (чувствительность около 0,8, F1-мера около 0,53, AUC

около 0,95 и доля ложных тревог около 0,06), что подтверждает работоспособность модели.

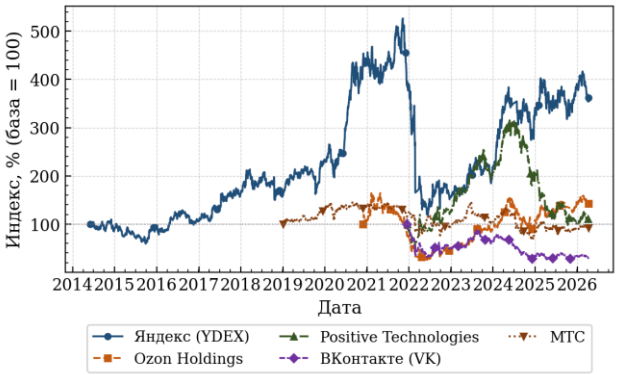


Рисунок 1 – Нормализованные индексы цен акций российских IT-компаний, 2014–2026 гг.
Источник: составлено автором по данным MOEX.

Ядром двухэтапной архитектуры является выбор датирующего теста. Мы используем датирующую статистику BSADF из семейства GSADF [2; 3] с подвижной начальной точкой окна. В каждый момент t берется супремум t-статистик коэффициента ρ в регрессии $\Delta y(\tau) = \mu + \rho \cdot y(\tau-1) + \varepsilon(\tau)$ по множеству окон $[t_0; t]$ с перебором начальной точки t_0 (минимальная длина окна – 60 торговых дней, максимальная – 504, шаг – 8 наблюдений). Превышение статистикой критического уровня трактуется как эпизод взрывного роста.

BSADF-тест проверяет статистическую нулевую гипотезу единичного корня (случайного блуждания) против альтернативы взрывного корня ($\rho > 1$) это статистическое свойство ряда («price explosiveness»). Спекулятивный пузырь – экономическая интерпретация, где устойчивое отклонение цены от фундаментальной стоимости. Вклад работы в том и состоит, чтобы использовать статистически датированные BSADF-эпизоды как разметку пузырных режимов, тогда как их экономическая природа устанавливается отдельным шагом с сопоставлением мультипликаторов и посткризисной динамики. На развивающемся рынке со структурными шоками взрывная динамика может отражать не спекуляцию, а скачкообразную переоценку после разрыва торгов или монетарной переоценки.

Наблюдение помечается как пузырь, если BSADF-статистика превышает адаптивный порог max(p90; 0,5), где p90 – 90-й процентиль эмпирического распределения статистики.

Вектор из семи признаков (BSADF-статистика, дневная лог-доходность, 30-дневная скользящая волатильность, 60-дневный моментум, интерполированные P/E, P/S и EV/EBITDA) подается на вход рекуррентной сети LSTM(64) → Dropout(0,3) → LSTM(32) → Dropout(0,2) → Dense(16, ReLU) → Dense(1, sigmoid) с длиной входной последовательности 30 дней (рисунок 2). Порог классификации понижен до 0,40. При дисбалансе классов порядка 90:10 стандартный порог 0,5 дает вырожденный прогноз, что пузыря нет. Передискретизация SMOTE выполняется на уровне последовательностей, где 30-дневное окно признаков разворачивается в единый вектор, и SMOTE интерполирует только между пузырными окнами, то есть по ближайшим соседям в пространстве развернутых окон, а не случайным парам, сохраняя временную структуру участка. Качество оценивается в схеме «walk-forward» (три блока). Площадь под ROC-кривой (AUC) вычисляется внутри каждого блока и усредняется, предсказания разных блоков обучены отдельными моделями и имеют несопоставимый масштаб вероятностей. Остальные метрики – матрицы ошибок, чувствительность (TPR) и доля ложно-положительных результатов(FPR), устойчивость оценок проверяется усреднением по нескольким инициализациям сети.

По итогу разметки BSADF-статистика выявляет у Яндекса краткие эпизоды взрывного роста в 2016 и 2018 гг. и два продолжительных. Первый приходится на 2020–2021 гг. и совпадает с пандемийным ралли технологических акций, второй –на 2024 г., ралли после возобновления торгов под тикером YDEX по завершении корпоративной реорганизации. Отдельный всплеск статистики в 2022 г. отражает скачкообразное восстановление котировок после возобновления торгов в марте 2022 г. У Positive Technologies эпизоды приходятся на 2022–2023 гг. и повторно на 2025 г. (см. Рис. 4). Для эпизода Яндекса 2020–2021 гг. порог разметки впервые превышен 6 июля 2020 г., тогда как максимум котировок (около 6160 руб.) достигнут лишь 8 ноября 2021 г. более чем за год до пика, что представляет интерес с точки зрения формирования долгосрочных прогнозов и стратегического планирования.

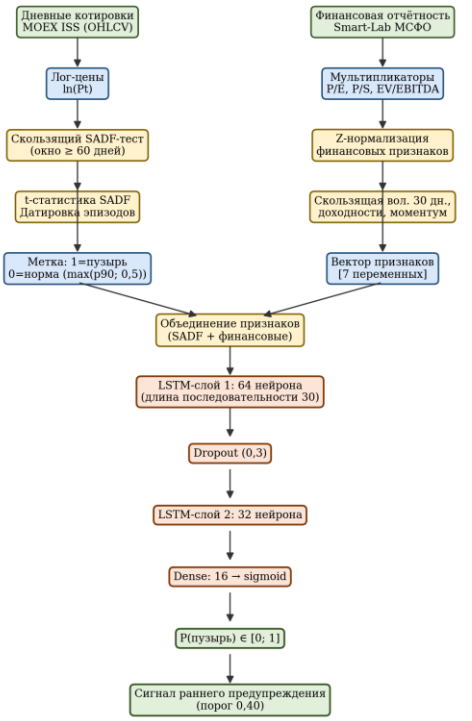


Рисунок 2 – Блок-схема гибридной модели GSADF + LSTM-RNN
Источник: составлено автором.

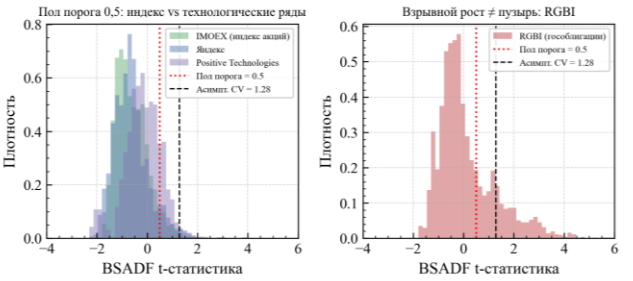


Рисунок 3 – Распределение датирующей BSADF-статистики для непузырных бенчмарков (RGBI, IMOEX) и технологических рядов
Источник: рассчитано автором по данным MOEX ISS.

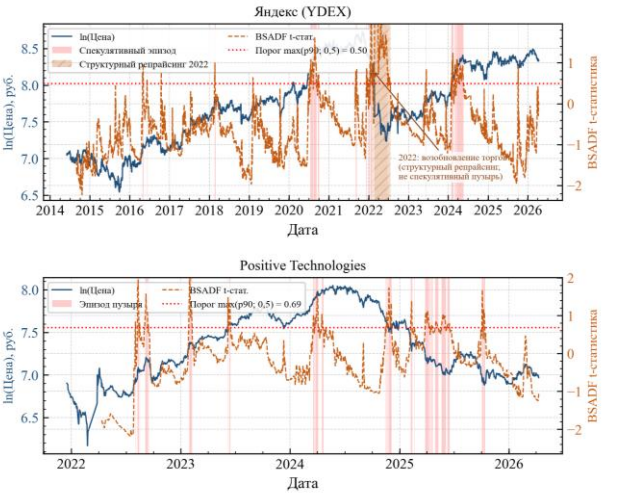


Рисунок 4 – Результаты BSADF-теста: лог-цены, датирующая статистика и эпизоды взрывного роста
Источник: рассчитано автором по данным MOEX ISS.

Сопоставление эпизодов с финансовыми мультипликаторами подтверждает спекулятивный характер роста (см. Таб. 1, Рис. 5). Соответствие выявленных пузырей действительности подтверждается посткризисной динами-

кой цен. Каждый датированный эпизод сопровождается выраженным взрывным ростом с последующей коррекцией. Например, эпизод Яндекса 2020–2021 гг. завершился обвалом котировок примерно на 77 % от пика ноября 2021 г., ралли перелистинга 2024 г. предвосхищал рост более чем вдвое, а перегрев Positive Technologies 2024 г. сменился просадкой около 43 %. Сочетание взрывного роста с последующим падением указывает именно на пузырь, а не на устойчивую переоценку.

Таблица 1
Эпизоды перегрева и их фундаментальный фон

Компания	Период эпизода	Мультипликаторы в фазе перегрева	Экономический контекст	Метод идентификации
Яндекс	2020–2021; 2024	P/E = 204,3 по итогам 2022 г. (капитализация фазы роста при обвале прибыли); нормализация до 15,4 к 2025 г.	Пандемийное ралли технологических акций; ралли после перелистинга YDEX	BSADF-тест
Positive Technologies	2022–2023; 2025	P/E = 29,8; EV/EBITDA = 21,6; P/S = 8,0 (2022); повторный рост P/E до 39,1 (2025)	Импортозамещение в кибербезопасности после ухода иностранных вендоров	BSADF-тест
Группа Астра*	2023–2024	P/E = 22,7–23,7; EV/EBITDA = 23,3–24,0; P/S = 11–13	IPO-ажиотаж, оценка на ожиданиях роста	Мультипликаторная диагностика
Ozon Holdings*	2021	P/E < 0 (устойчивый убыток); P/S > 10 в пике 2021 г.	Спекулятивная ставка на будущий рост e-commerce	Мультипликаторная диагностика

Источник: расчеты автора по данным MOEX ISS и Smart-Lab.

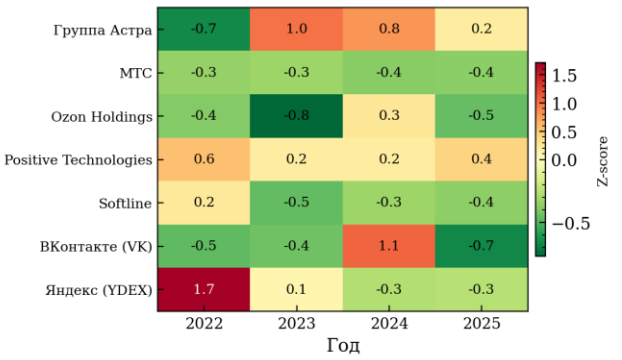


Рисунок 5 – Сводная карта пузырного риска: z-score по мультипликаторам P/E, P/S, EV/EBITDA, 2022–2025 гг.
Источник: рассчитано автором по данным Smart-Lab.

Результаты оценки качества LSTM-модели показаны на рисунках 6 и 7. Для Яндекса первые два блока валидации исключены автоматическим фильтром. На третьем блоке (обучение на 2014–2023 гг., тест на 2023–2026 гг., 726 наблюдений, из них 62 пузырных) модель дает AUC около 0,98 при чувствительности около 0,99. Таким образом при усреднении по нескольким инициализациям сети AUC составляет 0,985 ± 0,002. Доля ложных тревог при пороге классификации 0,40 составляет около 24 % (около 21 % при пороге 0,50); практически все размеченные BSADF пузырные наблюдения, включая эпизод перелистинга 2024 г., распознаны, а ложные срабатывания сосредоточены на границах эпизодов, где модель сигнализирует с небольшим опережением и запаздыванием относительно формальной разметки. Поэтому для практики релевантна не столько точечная классификация, сколько ранняя сигнализация: при AUC ≈ 0,98 аналитик выбирает рабочую точку под допустимое число ложных тревог, а высокая полнота гарантирует, что реальные эпизоды не пропущены.

У Positive Technologies на коротком ряду (1157 наблюдений) валидация проходит на трех блоках, и модель извлекает значимый, но неустойчивый сигнал. Усредненная по блокам площадь под ROC-кривой составляет 0,73 ± 0,10 заметно выше уровня случайного классификатора, однако от блока к блоку колеблется в широком диапазоне (в отдельных блоках от 0,42 до 0,99). Ключевой контраст с Яндексом не в наличии сигнала, а в его надежности: разброс AUC у Positive Technologies (±0,10) на два порядка выше, чем у Яндекса (±0,002). Тем самым эмпирически обосновывается принцип глубины данных. Она определяет не столько сам факт распознавания, сколько его устойчивость.

Полученные результаты позволяют сформулировать три рекомендации построения гибридных моделей выявления пузырей для развивающихся технологического российского рынка. Первый – приоритет экономически интерпретируемых признаков (мультипликаторов) над сырыми ценовыми, ради устойчивости, полноты и экономической осмысленности сигнала. Экономически интерпретируемый признак («переоценка по P/E») пригоден для обоснования регуляторных и инвестиционных решений, тогда как непрозрачный технический паттерн – нет.

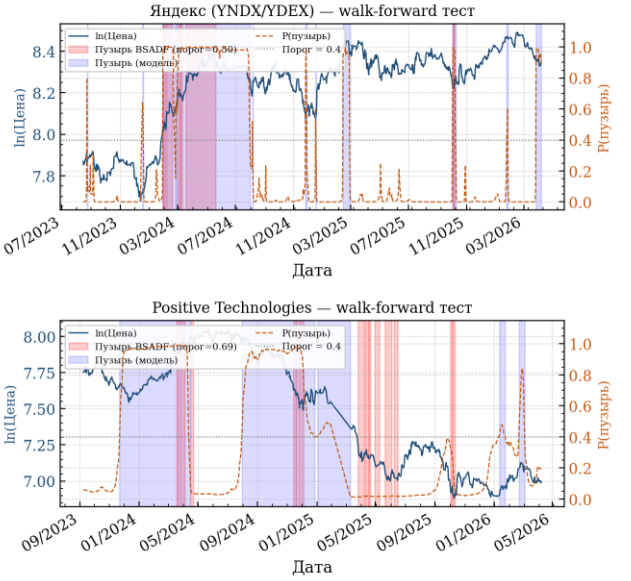


Рисунок 6 – Вероятность ценового пузыря P(пузырь): LSTM-RNN, walk-forward тест
Источник: рассчитано автором.

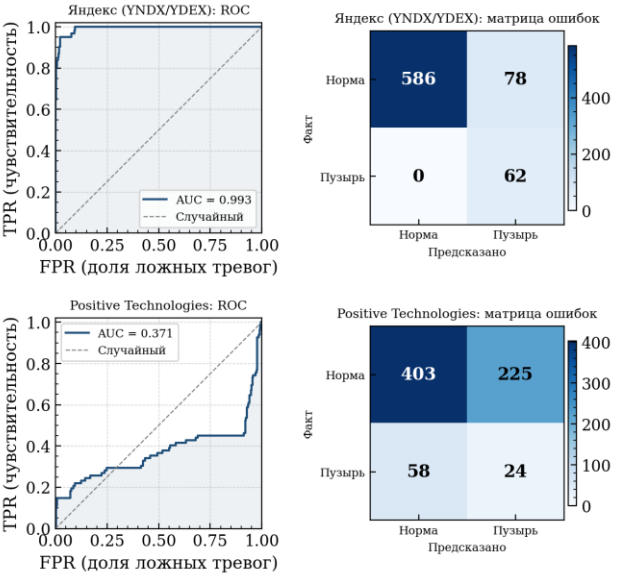


Рисунок 7 – Качество классификации: ROC-кривые и матрицы ошибок (порог 0,40)
Источник: рассчитано автором.

Второй принцип – явная связь разметки с проверяемой статистической гипотезой. BSADF-статистика тестирует нулевую гипотезу случайного блуждания против взрывного корня и дает метку, которую можно опровергнуть или подтвердить. Альтернатива (пороговая разметка по доходности (например, «пузырь, если доходность превысила 3σ за 30 дней»)) постулирует пузырь по произвольному правилу, не отделяя взрывной корень от обычной высокой волатильности, а получаемые метки непроверяемы и меняются с выбором σ и окна.

Третий принцип – учет глубины данных, для которого случай Positive Technologies служит не эмпирической неудачей, а теоретической границей применимости.

Из контраста Яндекс/POSI можно вывести конкретные требования. Работоспособность обеспечивается не абсолютным числом наблюдений самим по себе, а тем, чтобы обучающее окно «walk-forward» содержало хотя бы один пузырный эпизод, родственный тестовому, и давало тестовый блок с достаточным числом положительных меток. Между 1157 наблюдениями, на которых сигнал значим,

но неустойчив, и 3027 наблюдениями, на которых он стабилен, лежит практическая нижняя граница порядка 1500–2000 торговых наблюдений (шесть-восемь лет дневных котировок) при доле пузырных меток не менее 2 %. Вне этой области модель применять не следует, а ее неустойчивость на коротких рядах является корректной работой самодиагностики, а не ошибкой.

При прикладном использовании разработанной модели необходимо учитывать, что использованы асимптотические, а не бутстреп-критические значения BSADF. Перебор начальной точки окна с шагом 8 наблюдений есть вычислительный компромисс относительно полного GSADF. Институциональные шоки 2022 г. (приостановка и возобновление торгов, делистинг и перелистинг) не имеют аналогов в обучающей выборке, и часть взрывных сигналов этого периода отражает скачкообразную переоценку после разрывов торгов, а не классическую спекулятивную динамику. Глубина годовой отчетности (четыре-пять наблюдений на компанию) ограничивает мощность фундаментальной верификации, а интерполяция годовых мультипликаторов на дневную сетку сглаживает внутригодовую динамику. Наконец, разметка BSADF сама является оценкой, а не наблюдаемой истиной, поэтому метрики характеризуют согласованность двух методов, а не точность относительно объективного эталона.

Заключение

В задаче выявления пузырей классические эконометрические тесты и алгоритмы машинного обучения взаимно дополняют друг друга. GSADF/BSADF обеспечивает статистически обоснованную датировку, LSTM распознает сложные нелинейные комбинации индикаторов перегрева. На российском технологическом секторе гибридная модель выявила эпизоды взрывного роста у Яндекса (2020–2021 и 2024 гг.) и Positive Technologies (2022–2023 и 2025 гг). Впервые проведена эмпирическая апробация двухэтапной схемы GSADF с LSTM-RNN на данных российского технологического сектора за 2014–2026 гг. с количественной оценкой зависимости качества классификации от глубины данных. Ближайшие направления дальнейшей работы это полный GSADF с бутстреп-критическими значениями, переход на квартальную отчетность и мотивированный найденными ограничениями модуль анализа тональности новостного потока, способный отделить фундаментальную переоценку от спекулятивного ажиотажа там, где мультипликаторы не эффективны.

Литература

1. Blanchard O. J., Watson M. W. Bubbles, Rational Expectations and Financial Markets // Crises in the Economic and Financial Structure / ed. by P. Wachtel. Lexington: Lexington Books, 1982. P. 295–315.
2. Phillips P. C. B., Shi S., Yu J. Testing for Multiple Bubbles: Historical Episodes of Exuberance and Collapse in the S&P 500 // International Economic Review. 2015. Vol. 56. No. 4. P. 1043–1078.
3. Phillips P. C. B., Shi S., Yu J. Testing for Multiple Bubbles: Limit Theory of Real-Time Detectors // International Economic Review. 2015. Vol. 56. No. 4. P. 1079–1134.
4. Sornette D. Why Stock Markets Crash: Critical Events in Complex Financial Systems. Princeton: Princeton University Press, 2003. 448 p.
5. Shiller R. J. Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends? // American Economic Review. 1981. Vol. 71. No. 3. P. 421–436.
6. Atsiwo A. A three-step machine learning approach to predict market bubbles with financial news // arXiv. 2025. arXiv:2510.16636. DOI: 10.48550/arXiv.2510.16636.
7. Bashchenko O., Marchal A. Deep Learning for Asset Bubbles Detection // arXiv. 2020. arXiv:2002.06405. DOI: 10.48550/arXiv.2002.06405.
8. An S., Gao X., An F., Wu T. Early warning of regime switching in a complex financial system from a spillover network dynamic perspective // iScience. 2025. Vol. 28. No. 3. Art. 111924. DOI: 10.1016/j.isci.2025.111924.
9. Başoğlu Kabran F., Ünlü K. D. A two-step machine learning approach to predict S&P 500 bubbles // Journal of Applied Statistics. 2021. Vol. 48. No. 13–15. P. 2776–2794. DOI: 10.1080/02664763.2020.1823947.
10. Huynh T. T. Financial bubble detection using GSADF and LSTM-RNN model: evidence from emerging markets // International Journal of Applied and Actuarial Studies. 2025. URL: https://etamaths.com/index.php/ijaa/article/view/4165 (дата обращения: 22.02.2026).
11. Park S., Yang J.-S. Machine learning models based on bubble analysis for Bitcoin market crash prediction // Engineering Applications of Artificial Intelligence. 2024. Vol. 135. Art. 108857. DOI: 10.1016/j.engappai.2024.108857.
12. Щербинина А. В., Алжеев А. В. Сравнительный анализ качества прогнозирования классической статистической модели и модели машинного обучения на данных российского фондового рынка // Ученые записки Российской академии предпринимательства. 2021. Т. 20. № 3. С. 52–63. DOI: 10.24182/2073-6258-2021-20-3-52-63.
13. Кондратенко Н. А., Батищев А. В., Чепрасова А. С. Машинное обучение vs эконометрика: методологический анализ экономического прогнозирования // ЕГИ. 2025. № 2 (58). URL: https://cyberleninka.ru/article/n/mashinnoe-obuchenie-vs-ekonometrika-metodologicheskiy-analiz-ekonomicheskogo-prognozirovaniya (дата обращения: 22.02.2026).

Hybrid GSADF + LSTM-RNN model for detecting price bubbles in Russian technology stocks

Kravchenko V.V.
Lomonosov Moscow State University

JEL classification: G20, G24, G28, H25, H30, H60, H72, H81, K22, K34

The study focuses on methods for identifying price bubbles in the stock market by combining econometric tests for explosive price behavior with machine learning algorithms. The empirical sample includes the stocks of seven Russian technology companies listed on the Moscow Exchange (Yandex, Ozon Holdings, Positive Technologies, VK, MTS, Astra Group, and Softline) over the period from 2014 to 2026. The study tests a two-stage hybrid framework in which the BSADF dating statistic from the GSADF family of tests (Phillips, Shi, Yu, 2015) is used to label bubble episodes, while a recurrent LSTM network is trained to identify regime shifts using a combination of price-based indicators and financial multiples (P/E, P/S, EV/EBITDA). The methodology takes into account the specific features of an emerging market, including short trading histories, class imbalance, and structural shocks, by applying a BSADF test with a moving starting point of the estimation window, an adaptive labeling threshold, walk-forward validation without future data leakage, and class balancing techniques (SMOTE and weight constraints). The model is validated using Tesla stock data for 2014–2024, where the widely recognized 2020–2021 bubble is identified with a sensitivity of approximately 0.8. For Russian stocks, episodes of explosive growth are identified for Yandex in 2020–2021 and 2024 and for Positive Technologies in 2022–2023 and 2025. The main result of the study is the empirical testing of the GSADF and LSTM-RNN combination on data from the Russian technology sector and the formulation of recommendations for constructing hybrid bubble-detection models for the emerging Russian technology market.

Keywords: price bubble, GSADF, BSADF, LSTM, recurrent neural networks, machine learning, Russian stock market, technology companies, hybrid models.

References

1. Blanchard O. J., Watson M. W. Bubbles, Rational Expectations and Financial Markets // Crises in the Economic and Financial Structure / ed. by P. Wachtel. Lexington: Lexington Books, 1982. P. 295–315.
2. Phillips P. C. B., Shi S., Yu J. Testing for Multiple Bubbles: Historical Episodes of Exuberance and Collapse in the S&P 500 // International Economic Review. 2015. Vol. 56. No. 4. P. 1043–1078.
3. Phillips P. C. B., Shi S., Yu J. Testing for Multiple Bubbles: Limit Theory of Real-Time Detectors // International Economic Review. 2015. Vol. 56. No. 4. P. 1079–1134.
4. Sornette D. Why Stock Markets Crash: Critical Events in Complex Financial Systems. Princeton: Princeton University Press, 2003. 448 p.
5. Shiller R. J. Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends? // American Economic Review. 1981. Vol. 71. No. 3. P. 421–436.
6. Atsiwo A. A Three-Step Machine Learning Approach to Predict Market Bubbles with Financial News // arXiv. 2025. arXiv:2510.16636. DOI: 10.48550/arXiv.2510.16636.
7. Bashchenko O., Marchal A. Deep Learning for Asset Bubbles Detection // arXiv. 2020. arXiv:2002.06405. DOI: 10.48550/arXiv.2002.06405.
8. An S., Gao X., An F., Wu T. Early Warning of Regime Switching in a Complex Financial System from a Spillover Network Dynamic Perspective // iScience. 2025. Vol. 28. No. 3. Art. 111924. DOI: 10.1016/j.isci.2025.111924.
9. Başoğlu Kabran F., Ünlü K. D. A Two-Step Machine Learning Approach to Predict S&P 500 Bubbles // Journal of Applied Statistics. 2021. Vol. 48. No. 13–15. P. 2776–2794. DOI: 10.1080/02664763.2020.1823947.
10. Huynh T. T. Financial Bubble Detection Using GSADF and LSTM-RNN Model: Evidence from Emerging Markets // International Journal of Applied and Actuarial Studies. 2025. URL: https://etamaths.com/index.php/ijaa/article/view/4165 (accessed: 22.02.2026).
11. Park S., Yang J.-S. Machine Learning Models Based on Bubble Analysis for Bitcoin Market Crash Prediction // Engineering Applications of Artificial Intelligence. 2024. Vol. 135. Art. 108857. DOI: 10.1016/j.engappai.2024.108857.
12. Shcherbinina A. V., Alzheev A. V. Comparative Analysis of the Forecasting Quality of a Classical Statistical Model and a Machine Learning Model Using Russian Stock Market Data // Scientific Notes of the Russian Academy of Entrepreneurship. 2021. Vol. 20. No. 3. P. 52–63. DOI: 10.24182/2073-6258-2021-20-3-52-63. (In Russian).
13. Kondratenko N. A., Batishchev A. V., Cheprasova A. S. Machine Learning vs Econometrics: A Methodological Analysis of Economic Forecasting // EGI. 2025. No. 2 (58). URL: https://cyberleninka.ru/article/n/mashinnoe-obuchenie-vs-ekonometrika-metodologicheskiy-analiz-ekonomicheskogo-prognozirovaniya (accessed: 22.02.2026).