

СОВРЕМЕННЫЕ ПОДХОДЫ К ПРОГНОЗИРОВАНИЮ НЕСТАЦИОНАРНЫХ ВРЕМЕННЫХ РЯДОВ

А. В. Слипченко

Российский экономический университет имени Г. В. Плеханова,
Москва, Россия

В статье рассматриваются современные методы прогнозирования нестационарных временных рядов, актуальные для анализа социально-экономических систем, финансовых рынков и других областей с высокой неопределенностью. Проведен сравнительный анализ классических подходов (ARIMA, GARCH) и их модификаций, учитывающих структурные сдвиги, нелинейные зависимости и экзогенные факторы. Особое внимание уделено нейросетевым методам, включая LSTM, трансформеры (Informer, Autoformer) и их гибридные варианты, демонстрирующие высокую эффективность при работе с длинными последовательностями. Отдельно рассмотрены адаптивные методы, такие как скользящее окно, и их интеграция с машинным обучением для повышения точности прогнозирования в условиях неустойчивости. Исследование включает критический анализ ограничений классических моделей ARIMA и GARCH; обзор современных архитектур нейронных сетей для временных рядов; практические аспекты выбора моделей в зависимости от характеристик данных; перспективные направления развития методов, включая адаптивные алгоритмы и ансамблевые подходы.

Ключевые слова: ARIMA, GARCH, LSTM, трансформеры, адаптивные методы, машинное обучение.

CURRENT APPROACHES TO FORECASTING NON-STATIONARY TIME SERIES

Alexey V. Slipchenko

Plekhanov Russian University of Economics, Moscow, Russia

The article studies current methods of forecasting non-stationary time series effective to analyze social and economic systems, finance markets and other fields with high rate of uncertainty. Comparative analysis of classical approaches (ARIMA, GARCH) and their modifications was carried out as they take into account structural changes, non-linear dependences and exogenous factors. Special attention was paid to neural network methods, including LSTM, transformers (Informer, Autoformer) and their hybrid versions that demonstrate high efficiency working with long successions. Apart from that adaptive methods were studied such as sliding window and their integration with machine learning to raise accuracy of forecasting in conditions of uncertainty. The research includes critical analysis of restrictions of classical models ARIMA and GARCH, the review of current architecture of neural nets for time series, practical aspects of choosing models depending on data characteristics, promising lines in developing methods, including adaptive algorithms and ensemble approaches.

Keywords: ARIMA, GARCH, LSTM, transformers, adaptive methods, machine learning.

Введение

Современные социально-экономические системы, включая финансовые рынки, логистические цепочки и макроэкономические процессы, функционируют в условиях высокой неопределенности и нестационарности данных. Как

отмечают исследователи [9], традиционные методы прогнозирования демонстрируют значительные ошибки в периоды кризисов, таких, например, как пандемия COVID-19, и санкционных шоков 2022 г., что требует разработки альтернативных, более адаптивных подходов.

Особую сложность представляют слабо структурированные системы, где данные характеризуются нерегулярной динамикой (скачки, режимные сдвиги), высокой волатильностью (кластеризация колебаний, асимметричные реакции на шоки) или короткой историей наблюдений, как, например, криптовалютные рынки.

Проведем обзор классических методов прогнозирования нестационарных временных рядов и их современных модификаций.

Подходы, основанные на моделях ARIMA

Модель авторегрессии скользящего среднего (ARIMA) – это обобщение модели ARMA, модифицированной для работы с нестационарными временными рядами. Первоначальный этап построения модели –

$$(1 - \sum_{i=1}^p \phi_i L^i)(1 - L)^d y_t = c + (1 + \sum_{j=1}^q \theta_j L^j) \epsilon_t,$$

где p – порядок авторегрессии (AR);

d – порядок дифференцирования;

q – порядок скользящего среднего;

L – оператор лага ($L^k y_t = y_{t-k}$);

ϵ_t – белый шум.

Модель ARIMA (p, d, q) обрабатывает временной сигнал, предварительно отделив его от шума, и выдает его прогноз для последующего момента времени. Как следует из аббревиатуры метода, она состоит из следующей структуры [16]:

– AR (p) – авторегрессия: регрессионная модель, использующая зависимость между наблюдением и рядом запаздывающих наблюдений (параметр модели p);

проведение тестов на стационарность Дики – Фуллера (ADF):

$$\Delta y_t = \alpha + \beta t + \gamma t_{t-1} + \sum_{i=1}^k \phi_i \Delta y_{t-i} + \epsilon_t.$$

После подтверждения гипотезы о нестационарности временной ряд требуется преобразовать в стационарный. Классическими методами здесь выступают логарифмирование и дифференцирование [6]. После каждого преобразования следует повторное тестирование на стационарность. Возможно, при дифференцировании потребуются применить данные процедуры повторно. В этом случае количество дифференцирований – это степень лагового оператора модели. Стационарный временной ряд можно разложить на комбинацию сигнала и шума.

Классическую модель ARIMA можно представить в следующем виде [16]:

– I (d) – интеграция: вычисление разностей между наблюдениями в разные моменты времени (параметр модели d), направленное на то, чтобы сделать временной ряд стационарным;

– MA (q) – скользящее среднее: этот подход учитывает зависимость, которая может существовать между наблюдениями и условиями ошибки, возникающими при использовании модели скользящего среднего для наблюдений с временным лагом (параметр модели q).

Наиболее популярные вариации ARIMA представлены в табл. 1 [16].

Т а б л и ц а 1

Вариации модели ARIMA

Прогнозное выражение	ARIMA (p, d, q)
Модель авторегрессии 1-го порядка	ARIMA (1, 0, 0)
Случайное блуждание	ARIMA (0, 1, 0)
Интегрированная модель авторегрессии 1-го порядка	ARIMA (0, 1, 0)
Простое экспоненциальное сглаживание	ARIMA (0, 1, 1)
Простое экспоненциальное сглаживание с ростом	ARIMA (0, 1, 1)
Линейное экспоненциальное сглаживание	ARIMA (0, 2, 1)
	ARIMA (0, 2, 2)
Линейное экспоненциальное сглаживание с затухающим трендом	ARIMA (1, 1, 2)

Оптимальный выбор параметров ARIMA p, d и q имеет решающее значение для успе-

ха процедуры прогнозирования. Комбинация параметров p и q основывается на гра-

фиках автокорреляционной функции (ACF) и частичной автокорреляционной функции (PACF) для конкретного набора данных, а параметр d выбирается с целью стационаризации временного ряда.

Важнейшая задача состоит в определении наиболее эффективной модели ARIMA среди нескольких различных ее моделей (p, d, q) для конкретной задачи прогнозирования [14; 16]. В этих случаях критерии выбора включают информационные критерии Акаике (AIC) и Байеса (BIC):

$$AIC = 2k - 2\ln(\hat{L}),$$

$$BIC = k\ln(n) - 2\ln(\hat{L}).$$

AIC измеряет качество модели прогнозирования, сохраняя баланс между чрезмерной подгонкой и сложностью модели. В случае с BIC действует то же правило, но с более высоким штрафом для сложных моделей. В обоих критериях более низкие значения означают лучшую модель [14; 16].

Для автоматического подбора параметров ARIMA-модели исследователями применяются библиотеки `auto.arima` [15] в R и `pmдарима` [18] в Python. Оба инструмента применяют схожий алгоритм: проверку стационарности (KPSS/ADF) с последующим подбором лага дифференцирования (d), перебор комбинаций (p, q) с минимизацией AIC/BIC, учет сезонности и опциональный пошаговый поиск (*stepwise*), позволяющий контролировать полный перебор комбинаций или пропуск некоторых из них.

В то же время классическая модель ARIMA накладывает существенные ограничения в исследовательский процесс, что проявляется в таких моментах, как:

- чувствительность к нестационарности и структурным изменениям [6]: модель предполагает стационарность ряда, что требует предварительного преобразования данных, включая дифференцирование, которое при избыточном применении может привести к передифференцированию;
- отсутствие адаптации к резким структурным сдвигам [14]: ARIMA не учитывает внезапные изменения динамики временного ряда, такие как экономические кризисы;

- ограниченная способность к моделированию сложных паттернов [16]: линейная структура ARIMA не позволяет адекватно улавливать нелинейные зависимости в данных;

- сложности с включением экзогенных переменных [15]: базовая спецификация ARIMA не поддерживает учет внешних факторов.

На каждую из перечисленных выше проблем есть решение в части модифицированных моделей или механизмов обработки данных. Так, например, проблему работы в условиях нестационарности решает механизм `auto.arima` (`pmдарима`), автоматически подбирая параметры и снижая риск передифференцирования. Модели со структурными изменениями представлены TVP-ARIMA (Time-Varying-Parameter), позволяя параметрам модели изменяться со временем.

Марковские модели переключения и ARIMA с интервенционным анализом вводят фиктивные переменные для дат кризисов, а модели с разладкой учитывают смену режимов, как, например, кризисные и посткризисные моменты. Проблему неспособности улавливать нелинейные зависимости решают нелинейные ARIMA, а также гибридные модели ARIMA+LSTM или ARIMA+GARCH, а включение экзогенных переменных предусматривает модель ARIMAX:

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \sum_{k=1}^m \beta_k x_{t,k}.$$

Модели авторегрессии и скользящего среднего (ARIMA) остаются стандартным инструментом для прогнозирования стационарных и нестационарных рядов. Среди преимуществ выделяются простота интерпретации параметров (автокорреляции, порядки дифференцирования) и относительно низкая вычислительная сложность.

Подходы, основанные на моделях GARCH

GARCH (p, q) (Generalized AutoRegressive Conditional Heteroskedasticity) является

продолжением модели ARCH (q), дополняя ее p -лагами условной дисперсии [4].

Нижеприведенная система уравнений представляет классическую модель GARCH (p, q), которая, несмотря на свою популярность в анализе финансовой волатильности [4], имеет ряд существенных ограничений. Во-первых, предположение о нормальном распределении инноваций $z_t \sim N(0,1)$ часто не соответствует «тяжелым хвостам» реальных финансовых данных [8]. Во-вторых, модель не учитывает резкие структурные изменения в динамике волатильности, характерные для периодов финансовых кризисов [17]. В дополнение вычислительная сложность оценки параметров возрастает при увеличении порядков p и q [2]:

$$\begin{cases} r_t = \mu + \varepsilon_t, \\ \varepsilon_t = \sigma_t z_t, z_t \approx N(0,1), \\ \sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2, \end{cases}$$

где r_t – логарифмическая доходность;

σ_t – условная дисперсия;

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^q (\alpha_i z_{t-i} + \gamma(|z_{t-i}| - E|z_{t-i}|)) + \sum_{j=1}^p \beta_j \ln(\sigma_{t-j}^2).$$

Преимущества модели EGARCH – учет эффекта рычага (отрицательные шоки сильнее увеличивают волатильность).

Модель использовалась для прогнозирования цен на криптовалюту Bitcoin с 2013 по 2020 г. [21]. Анализ начинался с классической ARMA и продолжался до избавления от гетероскедастичных остатков (прохождение теста ARCH-LM). Критерием качества модели выступает информационный критерий Акаике. По итогам модель EGARCH сравнивалась с другими моделями, в том числе с классическими ARMA, ARCH. Модель признается подходящей для дальнейшего использования в купе с GARCH (1,1).

Модели GARCH эффективно описывают кластеризацию волатильности в финансовых временных рядах [4] и применяются для прогнозирования рисков (VaR,

α_i – влияние прошлых шоков (ARCH-эффект);

β_j – влияние волатильности (GARCH-эффект).

Для преодоления этих и иных ограничений в литературе предлагается более 100 модификаций модели, среди которых [5]:

– TGARCH и EGARCH – учитывают асимметричное влияние шоков [11; 17];

– GARCH- t и GARCH-GED – заменяют нормальное распределение на t -Стюдента и обобщенное экспоненциальное [8];

– методы байесовской оценки – снижают вычислительную сложность [2].

Модель GARCH реагирует симметрично как на положительные, так и на отрицательные шоки волатильности, что может не в полной мере отражать динамику финансовых рынков, когда участники торгов готовы мириться с большими по абсолютной величине убытками, чем прибылью. Для включения этого эффекта Нельсоном была разработана модель EGARCH [17]:

CVaR) [21]. Их преимуществами являются учет волатильности и гибкость спецификации модели. Существуют модификации (EGARCH, GJR-GARCH) для учета асимметричных эффектов, например, «рынок сильнее реагирует на плохие новости» [11].

Среди их преимуществ выделяют четкую экономическую интерпретацию (долгосрочная волатильность, скорость возврата к среднему). Недостатками моделей являются необходимость предположения о стационарности, а также неучитываемость сложных нелинейных паттернов, например, режимных сдвигов в кризисы и неадаптируемости к резким изменениям, как в кризис 2022 г. [8].

Нейросетевые подходы

Архитектура LSTM (Long Short-Term Memory), предложенная в 1997 г. [13], дол-

гое время была стандартом для работы с последовательностями. Ее ключевое преимущество – способность захватывать долгосрочные зависимости через систему гейтов (входного, выходного и забывания). Однако эффективность LSTM сильно зависит от гиперпараметров: упрощение структуры гейтов может снизить вычислительные затраты без потери качества в ряде задач [12].

Ограничения LSTM становятся очевидны в сценариях с экстремально длинными последовательностями, где даже модифицированные ячейки не предотвращают затухание градиентов. Это стимулировало поиск альтернатив, таких как Dilated RNN [7].

Модель Dilated RNN, представленная на NeurIPS 2017, вводит механизм дилаций (пропуск определенных шагов в последовательности) для увеличения воспринимаемого поля без роста числа параметров. Это особенно эффективно в задачах классификации аудиосигналов или прогнозирования энергопотребления, где критичен широкий контекст. Однако настройка шага дилации требует доменных знаний, а сама архитектура менее гибка, чем трансформеры, из-за жесткой структуры рекуррентных связей.

Одним из главных препятствий для внедрения трансформеров [19] остается их вычислительная сложность $O(n^2)$, связанная с механизмом self-attention. Модель Informer [22] решает эту проблему через:

- ProbSparse Attention – вероятностное сокращение числа ключевых векторов, снижающее сложность алгоритма;
- дистилляцию внимания – иерархическое сжатие промежуточных представлений.

Эксперименты на данных энергопотребления показали, что Informer превосходит LSTM и стандартные трансформеры в долгосрочном прогнозировании (до 1 000 шагов). Однако его производительность зависит от параметров спарсификации, что усложняет настройку.

Модель Autoformer [20] расширяет идеи Informer, интегрируя декомпозицию временных рядов прямо в архитектуру. Стандартный механизм внимания заменен на Auto-Correlation, который выявляет периодические паттерны через задержанные корреляции между элементами последовательности. Это позволяет явно разделять тренд и сезонную составляющую, что критично для таких данных, как метеорологические наблюдения.

Сравнение Autoformer и Informer на наборе ETTh2 (энергопотребление) демонстрирует снижение ошибки прогноза на 15–20% для горизонтов свыше 500 шагов. Однако сложность реализации автокорреляционных слоев ограничивает применимость модели в реальном времени.

Для систематизации результатов предложена матрица выбора архитектуры (табл. 2).

Т а б л и ц а 2
Матрица выбора архитектуры

Модель	Применение
LSTM	Для коротких последовательностей (до 100 шагов) с акцентом на интерпретируемость
Dilated RNN	Нишевое применение в задачах с четкими долгосрочными паттернами (аудио, физические сигналы)
Informer	Баланс между точностью и скоростью для рядов средней длины (100–500 шагов)
Autoformer	Эталон для сверхдлинных рядов с выраженной сезонностью

Современные архитектуры нейросетей демонстрируют высокую точность в прогнозировании сложных временных рядов. LSTM [12; 13] эффективна для длинных последовательностей, но страдает от исчезающих градиентов; трансформеры [19; 20; 22] обеспечивают высокую точность за счет механизма внимания, но требуют значительных ресурсов.

Скользящее окно

Еще одним перспективным, хотя и не до конца систематизированным как самостоятельная единица, является подход к прогнозированию, основанный на примене-

нии метода скользящего окна. Данная методика преимущественно используется для сегментации временных рядов на подвыборки, однако обладает большей универсальностью – позволяет идентифицировать повторяющиеся структурные элементы временных рядов, называемые мотивами или паттернами ряда, что открывает новые возможности в задачах прогнозирования.

Метод скользящего окна демонстрирует широкий спектр областей применения. Так, например, скользящее окно применяется для сегментации временных рядов для последующего поиска участков со схожей динамикой [1]. Кроме того, применяется скользящее окно фиксированной ширины в качестве входных данных для обучения модели LSTM с целью определения оптимального времени запаздывания (лага) при прогнозировании осадков [3]. Рядом авторов в исследовании представлен также алгоритм автоматического подбора размера скользящего окна, учитывающий три важных фактора: корреляцию трендов, временную автокорреляцию и стохастические колебания нагрузки серверов [10].

Метод скользящего окна, несмотря на свою кажущуюся простоту, обладает значительным потенциалом для развития в следующих направлениях:

– *интеллектуальная адаптация параметров окна*. Современные исследования показывают, что ключевым направлением развития является создание самонастраивающихся алгоритмов, которые автоматически определяют оптимальные параметры окна [1]:

а) динамическое изменение ширины окна в зависимости от локальных характеристик ряда (волатильность, частота изменений);

б) автоматический подбор шага смещения окна на основе анализа информативности новых данных;

в) многооконные подходы, использующие одновременно несколько окон разного размера;

– *глубокая интеграция с machine learning*. Перспективным направлением является сочетание метода скользящего окна с современными алгоритмами машинного обучения [3]:

а) использование оконных сегментов в качестве входных данных для нейронных сетей на архитектуре трансформера с механизмами внимания;

б) применение методов трансферного обучения (*transfer learning*) для переноса паттернов между разными рядами;

в) развитие ансамблевых подходов, комбинирующих анализ нескольких оконных представлений.

Метод скользящего окна остается актуальным инструментом, приобретая новые качества благодаря развитию вычислительных технологий и алгоритмов машинного обучения. Его дальнейшее развитие будет способствовать решению сложных задач прогнозирования в условиях неопределенности и быстроменяющихся ситуаций.

Заключение

Проведенный всесторонний анализ современных методов прогнозирования нестационарных временных рядов, которые играют ключевую роль в экономике, финансах и других динамически изменяющихся системах, позволяет сделать следующие выводы:

1. Классические методы (ARIMA, GARCH) остаются важным инструментом благодаря простоте интерпретации и низкой вычислительной сложности. Однако они обладают существенными ограничениями: чувствительностью к структурным изменениям, неспособностью учитывать нелинейные зависимости и сложности с включением внешних факторов. Современные модификации (TVP-ARIMA, ARIMAX, EGARCH) частично решают эти проблемы, но требуют тщательной настройки.

2. Нейросетевые подходы (LSTM, трансформеры) демонстрируют высокую эффективность при работе с длинными и

сложными временными рядами. Архитектуры на основе внимания (Informer, Autoformer) особенно перспективны для задач долгосрочного прогнозирования, хотя и требуют значительных вычислительных ресурсов.

3. Адаптивные методы, такие как скользящее окно, в сочетании с машинным обучением открывают новые возможности для анализа нестабильных данных. Их развитие в направлении автоматической настройки параметров и интеграции с современными алгоритмами представляет особый интерес для практического применения.

Выбор метода должен основываться на характеристиках данных и поставленной задаче. Для коротких рядов с выраженной авторегрессией подходят классические модели, тогда как для сложных нестационарных процессов с нелинейными зависимо-

стями предпочтительны нейросетевые архитектуры.

Перспективными направлениями дальнейших исследований являются:

- разработка гибридных моделей, сочетающих преимущества статистических и нейросетевых подходов;
- создание более эффективных механизмов адаптации к структурным изменениям;
- улучшение интерпретируемости сложных моделей для практического применения.

Несмотря на значительный прогресс в области прогнозирования, задача точного предсказания нестационарных временных рядов в условиях высокой неопределенности остается актуальной и требует дальнейших исследований.

Список литературы

1. Гладиллин Д. Л. Применение ковариационного анализа с принципом «скользящего окна» для оценки связности нестационарных временных рядов // Экспериментальная психология. – 2020. – Т. 13. – № 2. – С. 15–28.
2. Ardia D., Bluteau K., Boudt K. Bayesian Estimation of the GARCH (1, 1) Model with Student-t Innovations // The R Journal. – 2019. – Vol. 11. – N 2. – P. 370–384.
3. Bateni M. et al. Forecast of Rainfall Distribution Based on Fixed Sliding Window Long Short-Term Memory // Engineering Applications of Computational Fluid Mechanics. – 2022. – Vol. 16. – N 1. – P. 248–261.
4. Bollerslev T. Generalized Autoregressive Conditional Heteroskedasticity // Journal of Econometrics. – 1986. – Vol. 31. – N 3. – P. 307–327.
5. Bollerslev T. Glossary to ARCH (GARCH). – URL: <https://ssrn.com/abstract=1263250> (дата обращения: 01.05.2025).
6. Box G. E. P., Jenkins G. M., Reinsel G. C., Ljung G. M. Time Series Analysis: Forecasting and Control : 5th ed. – Wiley, 2015.
7. Chang S. et al. Dilated Recurrent Neural Networks // Advances in Neural Information Processing Systems 30 (NIPS 2017). – 2017. – P. 77–87.
8. Cont R. Empirical Properties of Asset Returns: Stylized Facts and Statistical Issues // Quantitative Finance. – 2001. – Vol. 1. – P. 223–236.
9. Engle R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation // Econometrica. – 1982. – Vol. 50. – N 4. – P. 987–1007.
10. FAST: A Forecasting Model with Adaptive Sliding Window and Time Locality Integration for Dynamic Cloud Workloads // IEEE Transactions on Cloud Computing. – 2022.
11. Glosten L. R., Jagannathan R., Runkle D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks // Journal of Finance. – 1993. – Vol. 48. – N 5. – P. 1779–1801.

12. Greff K., Srivastava R. K., Koutník J., Steunebrink B. R., Schmidhuber J. LSTM: A Search Space Odyssey // *IEEE Transactions on Neural Networks and Learning Systems*. – 2017. – Vol. 28. – N 10. – P. 2222–2232.
13. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. – 1997. – Vol. 9. – N 8. – P. 1735–1780.
14. Hyndman R. J., Athanasopoulos G. *Forecasting: Principles and Practice* : 3rd ed. – OTexts, 2021. – URL: <https://otexts.com/fpp3/> (дата обращения: 01.05.2025).
15. Hyndman R. J., Khandakar Y. Automatic Time Series Forecasting: The forecast Package for R // *Journal of Statistical Software*. – 2008. – Vol. 27. – N 3. – P. 1–22.
16. Kontopoulou V. I., Panagopoulos A. D., Kakkos I., Matsopoulos G. K. A Review of ARIMA vs Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. – URL: https://www.researchgate.net/publication/372771636_A_Review_of_ARIMA_vs_Machine_Learning_Approaches_for_Time_Series_Forecasting_in_Data_Driven_Networks#read
17. Nelson D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach // *Econometrica*. – 1991. – Vol. 59. – N 2. – P. 347–370.
18. Smith T. et al. pmdarima: ARIMA estimators for Python. – 2017. – URL: <https://alkaline-ml.com/pmdarima/> (дата обращения: 01.05.2025).
19. Vaswani A. et al. Attention is All You Need // *Advances in Neural Information Processing Systems* 30 (NIPS 2017). – 2017. – P. 5998–6008.
20. Wu H. et al. Autoformer: Decomposition Transformers for Auto-Correlation-based Long-Term Series Forecasting // *Advances in Neural Information Processing Systems* 34 (NeurIPS 2021). – 2021. – P. 22419–22430.
21. Yildirim H., Bekun F. V. Predicting Volatility of Bitcoin Returns with ARCH, GARCH and EGARCH Models // *Financial Innovation*. – 2022. – Vol. 8. – P. 1–15.
22. Zhou T. et al. Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting // *Proceedings of the 35th AAAI Conference on Artificial Intelligence (AAAI-21)*. – 2021. – Vol. 35. – N 12. – P. 11106–11115.

References

1. Gladilin D. L. Primenenie kovariatsionnogo analiza s printsipom «skolzyashchego okna» dlya otsenki svyaznosti nestatsionarnykh vremennykh ryadov [Application of Covariance Analysis with a Sliding Window Principle for Assessing Connectivity of Non-Stationary Time Series]. *Eksperimentalnaya psikhologiya* [Experimental psychology], 2020, Vol. 13, No. 2, pp. 15–28. (In Russ.).
2. Ardia D., Bluteau K., Boudt K. Bayesian Estimation of the GARCH (1, 1) Model with Student-t Innovations. *The R Journal*, 2019, Vol. 11, No. 2, pp. 370–384.
3. Bateni M. et al. Forecast of Rainfall Distribution Based on Fixed Sliding Window Long Short-Term Memory. *Engineering Applications of Computational Fluid Mechanics*, 2022, Vol. 16, No. 1, pp. 248–261.
4. Bollerslev T. Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 1986, Vol. 31, No. 3, pp. 307–327.
5. Bollerslev T. Glossary to ARCH (GARCH). Available at: <https://ssrn.com/abstract=1263250> (accessed 01.05.2025).
6. Box G. E. P., Jenkins G. M., Reinsel G. C., Ljung G. M. *Time Series Analysis: Forecasting and Control*. 5th ed. Wiley, 2015.
7. Chang S. et al. Dilated Recurrent Neural Networks. *Advances in Neural Information Processing Systems* 30 (NIPS 2017), 2017, pp. 77–87.

8. Cont R. Empirical Properties of Asset Returns: Stylized Facts and Statistical Issues. *Quantitative Finance*, 2001, Vol. 1, pp. 223–236.
9. Engle R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 1982, Vol. 50, No. 4, pp. 987–1007.
10. FAST: A Forecasting Model with Adaptive Sliding Window and Time Locality Integration for Dynamic Cloud Workloads. *IEEE Transactions on Cloud Computing*, 2022.
11. Glosten L. R., Jagannathan R., Runkle D. E. On the Relation between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. *Journal of Finance*, 1993, Vol. 48, No. 5, pp. 1779–1801.
12. Greff K., Srivastava R. K., Koutník J., Steunebrink B. R., Schmidhuber J. LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, Vol. 28, No. 10, pp. 2222–2232.
13. Hochreiter S., Schmidhuber J. Long Short-Term Memory. *Neural Computation*, 1997, Vol. 9, No. 8, pp. 1735–1780.
14. Hyndman R. J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. OTexts, 2021. Available at: <https://otexts.com/fpp3/> (accessed 01.05.2025).
15. Hyndman R. J., Khandakar Y. Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 2008, Vol. 27, No. 3, pp. 1–22.
16. Kontopoulou V. I., Panagopoulos A. D., Kakkos I., Matsopoulos G. K. A Review of ARIMA vs Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. Available at: https://www.researchgate.net/publication/372771636_A_Review_of_ARIMA_vs_Machine_Learning_Approaches_for_Time_Series_Forecasting_in_Data_Driven_Networks#read
17. Nelson D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica*, 1991, Vol. 59, No. 2, pp. 347–370.
18. Smith T. et al. pmdarima: ARIMA estimators for Python. 2017. Available at: <https://alkaline-ml.com/pmdarima/> (accessed 01.05.2025).
19. Vaswani A. et al. Attention is All You Need. *Advances in Neural Information Processing Systems 30 (NIPS 2017)*, 2017, pp. 5998–6008.
20. Wu H. et al. Autoformer: Decomposition Transformers for Auto-Correlation-based Long-Term Series Forecasting. *Advances in Neural Information Processing Systems 34 (NeurIPS 2021)*, 2021, pp. 22419–22430.
21. Yildirim H., Bekun F. V. Predicting Volatility of Bitcoin Returns with ARCH, GARCH and EGARCH Models. *Financial Innovation*, 2022, Vol. 8, pp. 1–15.
22. Zhou T. et al. Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *Proceedings of the 35th AAAI Conference on Artificial Intelligence (AAAI-21)*, 2021, Vol. 35, No. 12, pp. 11106–11115.

Поступила: 13.05.2025

Принята к печати: 25.07.2025

Сведения об авторе

Алексей Вячеславович Слипченко
аспирант кафедры прикладной информатики
и информационной безопасности
РЭУ им. Г. В. Плеханова.
Адрес: ФГБОУ ВО «Российский
экономический университет
имени Г. В. Плеханова»,
109992, Москва, Стремянный пер., д. 36.
E-mail: alexey.slipchenko@yandex.ru

Information about the author

Alexey V. Slipchenko
Post-Graduate Student of the Department
of Applied Informatics and Information Security
of the PRUE.
Address: Plekhanov Russian University
of Economics, 36 Stremyanny Lane,
Moscow, 109992,
Russian Federation.
E-mail: alexey.slipchenko@yandex.ru