



ISSN INTERNATIONAL
STANDARD
SERIAL
NUMBER

ISSN
2782-4365

Проверить
номер:



Научно-образовательный электронный журнал

ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ


Выпуск №67-3 (том 3)
(октябрь, 2025)



Google
Scholar



Периодичность выпуска: 1 раз в неделю
Сайт: mpcareer.ru/oinv21veke. Почта: obrmpcareer@mail.ru



Международный научно-образовательный
электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ»

ISSN 2782-4365

УДК 37

ББК 94

**Международный научно-образовательный электронный журнал
«ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ». Выпуск №67-3 (том 3) (октябрь,
2025). Дата выхода в свет: 20.10.2025.**

Журнал объединяет авторов на территории стран СНГ и помогает обмениваться передовыми научно-образовательными исследованиями.

Содержит научные статьи отечественных и зарубежных авторов по экономическим, техническим, философским, юридическим и другим наукам.

Миссия научно-образовательного электронного журнала «ОБРАЗОВАНИЕ И НАУКА В XXI ВЕКЕ» состоит в поддержке интереса читателей к оригинальным исследованиям и инновационным подходам в различных тематических направлениях, которые способствуют распространению лучшей отечественной и зарубежной практики в интернет пространстве.

Целевая аудитория журнала охватывает работников сферы науки и образования (педагоги, учителя, ученые, преподаватели, научные сотрудники, бакалавры, магистранты, аспиранты).

Материалы публикуются в авторской редакции. За соблюдение законов об интеллектуальной собственности и за содержание статей ответственность несут авторы статей. Мнение редакции может не совпадать с мнением авторов статей. При использовании и заимствовании материалов ссылка на издание обязательна.

© ООО «МОЯ ПРОФЕССИОНАЛЬНАЯ КАРЬЕРА»

© Коллектив авторов

Гурбанова Амангуль, Джумаева Айджахан, Ходжалыева Гульнар, Какаджанов Деркар СИСТЕМЫ ТОЧНОГО ЗЕМЛЕДЕЛИЯ: АНАЛИЗ ЭФФЕКТИВНОСТИ ПРИМЕНЕНИЯ ДРОНОВ И ДАТЧИКОВ В ПОЛЕВЫХ КУЛЬТУРАХ	500
Мередов Агамырат, Абдуллаев Баймырат, Керимов Мерген ДУХОВНО-НРАВСТВЕННОЕ ВОСПИТАНИЕ В ЦИФРОВУЮ ЭПОХУ: ПОИСК НОВЫХ ОРИЕНТИРОВ И МЕХАНИЗМОВ РЕАЛИЗАЦИИ	505
Мухаммедов М.А., Эзизова С. МИРОВОЙ ОПЫТ ПЕРЕХОДА К УСТОЙЧИВОМУ РАЗВИТИЮ	510
Мухаммедова Медине, Аннагулыев Бегенч, Шыхлыева Огулнар, Абдыева Чынар ПЕРЕХОД К "ЗЕЛЕНОМУ" СЕЛЬСКОМУ ХОЗЯЙСТВУ: МЕТОДОЛОГИЯ ОЦЕНКИ ЭКОЛОГИЧЕСКОЙ УСТОЙЧИВОСТИ АГРОСИСТЕМ	516
Сяхетгулыева Тязегуль ЦИФРОВАЯ ТРАНСФОРМАЦИЯ КАК ФАКТОР УСТОЙЧИВОГО ЭКОНОМИЧЕСКОГО РОСТА: ИНСТИТУЦИОНАЛЬНЫЙ И МЕТОДОЛОГИЧЕСКИЙ АНАЛИЗ	521
Ходжалыева Майагозель, Гаррыев Гуванч, Ашыров Кемал ПРИМЕНЕНИЕ МНОГОМЕРНОГО СТАТИСТИЧЕСКОГО АНАЛИЗА ДЛЯ СЕГМЕНТАЦИИ ПОТРЕБИТЕЛЬСКИХ РЫНКОВ	527
Ходжалыева Майагозель, Гаррыев Гуванч, Ашыров Кемал АНАЛИЗ ВРЕМЕННЫХ РЯДОВ С ПРИМЕНЕНИЕМ МАШИННОГО ОБУЧЕНИЯ: ГИБРИДНЫЕ ПРОГНОСТИЧЕСКИЕ МОДЕЛИ	532
Чарыева Оразджемал, Атаева Лейли РОЛЬ И ЗНАЧЕНИЕ ВСЕМИРНОЙ ТОРГОВОЙ ОРГАНИЗАЦИИ В РАЗВИТИИ МЕЖДУНАРОДНОЙ ТОРГОВЛИ	537
Чарыева Оразджемал, Бегьяммедова Энегуль РАЗВИТИЕ ВНЕШНЕЙ ТОРГОВЛИ РАЗВИВАЮЩИХСЯ СТРАН	542
Ходжамухаммедова Г. ЭКОНОМИЧЕСКОЕ ЗНАЧЕНИЕ ВНЕДРЕНИЯ УСЛОВНО-НАКОПИТЕЛЬНОГО КОМПОНЕНТА В ПЕНСИОННУЮ СИСТЕМУ ТУРКМЕНИСТАНА	548
Непесова М., Дурдыева Б. ЗНАЧЕНИЕ ЭКОЛОГИЧЕСКИХ СТАНДАРТОВ В ПОВЫШЕНИИ КОНКУРЕНТОСПОСОБНОСТИ ЭКОНОМИКИ	553

ФИО автора(-ов): *Ходжалыева Майагозель, преподаватель, Туркменский государственный институт экономики и управления*

Гаррыев Гуванч, студент, Туркменский государственный институт экономики и управления

Ашыров Кемал, студент, Туркменский государственный институт экономики и управления

г. Ашхабад, Туркменистан

Название публикации: «АНАЛИЗ ВРЕМЕННЫХ РЯДОВ С ПРИМЕНЕНИЕМ МАШИННОГО ОБУЧЕНИЯ: ГИБРИДНЫЕ ПРОГНОСТИЧЕСКИЕ МОДЕЛИ»

Аннотация. Настоящая работа посвящена комплексному исследованию и разработке гибридных прогностических моделей, сочетающих классические подходы анализа временных рядов с современными алгоритмами машинного обучения (МО). Актуальность исследования обусловлена растущей потребностью в высокоточном прогнозировании сложных, нелинейных и нестационарных временных данных в различных прикладных областях, таких как финансовые рынки, энергопотребление, эпидемиология и климатология. Традиционные статистические модели, такие как ARIMA или GARCH, эффективны для моделирования линейных зависимостей и автокорреляционных структур, но часто не справляются с улавливанием нелинейных трендов, аномалий и сложных стохастических паттернов, характерных для реальных данных. В противовес этому, методы машинного обучения, включая рекуррентные нейронные сети (RNN), в частности LSTM (Долгая Краткосрочная Память) и трансформеры, обладают высокой способностью к извлечению сложных нелинейных признаков. В статье исследуется концепция гибридизации, где прогностическая задача разделяется на две части: сначала классическая модель (например, ARIMA) используется для извлечения и прогнозирования линейной компоненты временного ряда, а затем алгоритм машинного обучения (например, LSTM или градиентный бустинг) применяется для моделирования и предсказания остатков – нелинейной компоненты, которую не смогла объяснить

первая модель. Анализируется эффективность различных архитектур гибридных моделей, включая последовательное, параллельное и интегративное совместное обучение.

Ключевые слова. Анализ временных рядов, машинное обучение, гибридные модели, прогнозирование, LSTM, ARIMA, нейронные сети, нестационарные данные, нелинейность, прогностическая точность.

Задача прогнозирования временных рядов является центральной проблемой во многих областях, включая экономику, финансы, инженерию, медицину и науку об окружающей среде. Традиционные статистические модели, такие как методы Бокса-Дженкинса (ARIMA) или модели из семейства GARCH, долгое время служили основой для анализа, демонстрируя высокую эффективность в моделировании линейных и стационарных зависимостей. Однако большинство реальных временных рядов характеризуются высокой степенью нелинейности, нестационарностью и наличием стохастического шума, что ограничивает прогностическую способность классических подходов. Появление и развитие машинного обучения (МО), в особенности глубоких нейронных сетей, предложило мощные альтернативные инструменты, способные автоматически извлекать сложные нелинейные паттерны из данных. Эволюция в этой области привела к необходимости разработки гибридных прогностических моделей, которые объединяют сильные стороны обеих парадигм для достижения максимальной точности.

Концепция Гибридизации и Декомпозиция Ряда

Ключевая идея гибридного подхода заключается в декомпозиции временного ряда на компоненты, каждая из которых лучше поддается моделированию определенным классом алгоритмов. Типичный временной ряд может быть условно представлен как сумма линейной компоненты, нелинейной компоненты и шума. Линейная компонента, включающая авторегрессионные и скользящие средние зависимости, эффективно извлекается и прогнозируется

классическими статистическими моделями, например, ARIMA. Они хорошо работают с корреляциями между последовательными наблюдениями.

Прогностические остатки от статистической модели, которые представляют собой ошибки прогноза, содержат в себе нелинейные зависимости и сложные стохастические структуры, которые модель ARIMA не смогла объяснить. Именно этот остаточный ряд, обладающий более сложной и менее структурированной природой, становится входными данными для второго уровня гибридной модели, основанного на машинном обучении. Здесь особенно эффективны рекуррентные нейронные сети (RNN), в частности, архитектура Долгой Краткосрочной Памяти (LSTM). Сети LSTM обладают внутренней архитектурой, позволяющей им эффективно запоминать долгосрочные зависимости и обрабатывать временные последовательности, автоматически обнаруживая и моделируя нелинейные связи в остатках.

Таким образом, гибридная модель реализуется в два последовательных этапа: сначала строится модель ARIMA для исходного ряда, затем ее ошибки прогнозирования используются для обучения модели LSTM. Финальный прогноз временного ряда является суммой прогноза, полученного от статистической модели, и прогноза нелинейных остатков, выданного моделью машинного обучения. Это позволяет максимально использовать информацию, содержащуюся в данных, обеспечивая более высокую робустность и точность прогноза по сравнению с каждой из монолитных моделей.

Архитектуры и Реализации Гибридных Моделей

Помимо последовательной декомпозиционной схемы, существуют и другие архитектуры гибридных моделей. Одна из них — параллельная гибридизация, при которой статистическая и МО-модели обучаются независимо друг от друга на исходном ряду. Их прогнозы затем объединяются (взвешенно усредняются) с помощью интегративной модели, которая также может быть реализована с помощью простого алгоритма машинного обучения. Этот подход особенно полезен, когда исследователю сложно однозначно выделить линейные и нелинейные компоненты.

Среди алгоритмов машинного обучения, помимо LSTM, часто используются модели градиентного бустинга, такие как XGBoost или LightGBM. Они демонстрируют высокую производительность при работе с табличными данными, к которым можно свести временные ряды путем генерации признаков, таких как лаги, скользящие средние и индикаторы тренда. Использование ансамблевых методов, таких как бустинг, в гибридной архитектуре позволяет повысить ее обобщающую способность и снизить риск переобучения.

Эффективность любой гибридной модели должна быть тщательно оценена с помощью метрик прогностической точности, таких как среднеквадратичная ошибка (RMSE), средняя абсолютная ошибка (MAE) и средняя абсолютная процентная ошибка (MAPE), на независимых тестовых выборках. Практическое применение гибридных моделей в реальных задачах, например, при прогнозировании курсов валют или спроса на электроэнергию, многократно доказало их превосходство над традиционными методами, особенно на горизонте долгосрочного прогнозирования, где нелинейные эффекты накапливаются и становятся доминирующими.

Заключение

Интеграция классических статистических методов с алгоритмами машинного обучения в рамках гибридных прогностических моделей представляет собой перспективное направление развития анализа временных рядов. Благодаря способности разделять и моделировать линейные и нелинейные компоненты данных с помощью специализированных инструментов, эти модели обеспечивают беспрецедентную точность и робустность прогнозов. Дальнейшие исследования будут сосредоточены на разработке более сложных интегративных архитектур, использующих трансформеры и другие передовые модели глубокого обучения, а также на создании автоматизированных систем для выбора оптимальной структуры гибридной модели и ее гиперпараметров для конкретного типа временного ряда.

Список литературы:

1. Бокс, Дж., Дженкинс, Г., Рейнсель, Г., Люн, Л. (2015). Анализ временных рядов: Прогнозирование и управление. Москва: Издательство ЛКИ.
2. Хачен, С. (2018). Глубокое обучение с Python. Санкт-Петербург: Питер.
3. Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
4. Siami-Namini, S., & Namin, A. S. (2018). Forecasting time series with deep learning: A comparative analysis between RNN-LSTM and ARIMA. *The Journal of Defense Modeling and Simulation: Applications, Methodology, Technology*, 15(3), 235–248.
5. Lai, G., Chang, W., Yang, Y., & Liu, H. (2018). Modeling long- and short-term temporal dependencies in time series forecasting with recurrent neural networks. *Proceedings of the 41st International ACM SIGIR Conference on Research and Development in Information Retrieval*, 723–732.