

Научная статья

УДК 330.4:338.24:007.25

DOI: <https://doi.org/10.18721/JE.19311>

EDN: <https://elibrary/XHKJTI>



ГИБРИДНАЯ МОДЕЛЬ ПРОГНОЗИРОВАНИЯ РЕГИОНАЛЬНОГО ИНДЕКСА ЦИФРОВИЗАЦИИ В УСЛОВИЯХ ТУРБУЛЕНТНОЙ ЭКОНОМИКИ

К.Д. Лещенко , Е.В. Попова

Кубанский государственный аграрный университет имени И.Т. Трубилина,
Краснодар, Российская Федерация

✉ lechenko020300@mail.ru

Аннотация. Неравномерность цифрового развития российских регионов усиливает потребность в прогнозных инструментах, которые пригодны для управленческих решений и при этом сохраняют понятную экономисту логику влияний. Композитные индикаторы цифровизации удобны для мониторинга, однако их динамика чувствительна к структурным сдвигам и смене режимов, что снижает надежность простых трендовых подходов и затрудняет применение непрозрачных моделей в сценарной работе. Цель исследования состоит в разработке гибридной модели прогнозирования регионального интегрального показателя цифровизации, ориентированной на устойчивость при нестабильной динамике и на интерпретируемое представление влияния факторов. Эмпирическая база сформирована авторами в виде региональной витрины «регион–год», объединяющей наблюдаемые значения индекса цифровизации и сопоставимые социально-экономические показатели официальной статистики. Метод исследования основан на двухкомпонентной архитектуре. Нелинейные зависимости факторов задаются интерпретируемым слоем сетей Колмогорова–Арнольда, где влияние каждого признака представлено гладкой одномерной функцией, параметризованной сплайнами. Динамическая часть реализована рекуррентным модулем с хаотической модуляцией, предназначенным для учета инерции и ускоренной перестройки внутреннего состояния модели при смене режима ряда. Для предотвращения «переусложнения» введена процедура выбора сложности сплайнового представления по компромиссу между точностью прогноза на отложенных разбиениях и гладкостью функций влияния. Корректность выводов подтверждается сравнением с базовыми эконометрическими и нейросетевыми решениями, а также абляционными прогонами, отделяющими вклад интерпретируемой нелинейности от вклада динамического механизма. Полученные результаты показывают, что выбор минимально достаточной сложности позволяет удерживать качество прогноза на уровне, сопоставимом с лучшими по метрикам конфигурациями, и одновременно сохранять устойчивую, экономически читаемую форму функций влияния. Интерпретация реберных функций выявляет нелинейные эффекты, включая насыщение влияния масштаба экономики и неоднородную реакцию индекса на параметры рынка труда. Практическая ценность работы связана с возможностью использовать модель как аналитический модуль для мониторинга и сценарной поддержки решений в региональной цифровой политике, поскольку прогноз сопровождается прозрачной структурой влияний факторов.

Ключевые слова: индекс цифровизации, прогнозирование, нейронные сети, интерпретируемые модели, структурные изменения

Для цитирования: Лещенко К.Д., Попова Е.В. (2026) Гибридная модель прогнозирования регионального индекса цифровизации в условиях турбулентной экономики. П-Economy, 19 (3), 164–180. DOI: <https://doi.org/10.18721/JE.19311>



HYBRID MODEL FOR PREDICTING THE REGIONAL DIGITALIZATION INDEX IN A TURBULENT ECONOMY

K.D. Lechshenko , E.V. Popova

Kuban State Agrarian University named after I.T. Trubilin,
Krasnodar, Russian Federation

✉ lechenko020300@mail.ru

Abstract. The unevenness of digital development across Russian regions increases the demand for forecasting tools that are suitable for managerial decision-making while preserving an economically interpretable logic of influences. Composite digitalization indicators are convenient for monitoring; however, their dynamics are sensitive to structural shifts and regime changes. This reduces the reliability of simple trend-based approaches and complicates the use of opaque models in scenario analysis. The aim of this study is to develop a hybrid forecasting model for a regional composite digitalization index, that is robust under unstable dynamics and provides an interpretable representation of factor effects. The empirical basis is a region–year data mart constructed by the authors, combining observed values of the digitalization index with comparable socio-economic indicators from official statistics. The proposed methodology relies on a two-component architecture. Nonlinear dependencies of factors are specified by an interpretable layer of Kolmogorov–Arnold networks, where the influence of each feature is represented by a smooth univariate function parameterized by splines. The dynamic component is implemented as a recurrent module with chaotic modulation, designed to account for inertia and accelerated reorganization of the model's internal state during regime changes. To prevent over-complexification, the authors introduce a complexity selection procedure based on a trade-off between forecast accuracy on held-out partitions and the smoothness of the influence functions. The validity of the findings is confirmed by comparison with baseline econometric and neural network solutions and ablation experiments that separate the contribution of interpretable nonlinearity from that of the dynamic mechanism. The results indicate that selecting a minimally sufficient complexity level keeps predictive accuracy close to the best configurations by metrics, while preserving stable, economically readable form of the influence functions. Interpretation of the edge functions reveals nonlinear effects, including saturation of the influence of economic scale and a heterogeneous response of the index to labor market conditions. The practical value of the study lies in the possibility of using the model as an analytical module for monitoring and scenario-based decision support in regional digital policy, since forecasts are accompanied by a transparent structure of factor influences.

Keywords: digitalization index, forecasting, neural networks, interpretable models, structural changes

Citation: Lechshenko K.D., Popova E.V. (2026) Hybrid model for predicting the regional digitalization index in a turbulent economy. *П-Economy*, 19 (3), 164–180. DOI: <https://doi.org/10.18721/JE.19311>

Введение

Актуальность исследования

Региональный индекс цифровизации, рассматриваемый как интегральная характеристика цифрового развития территории, становится практическим инструментом для мониторинга и управления, когда требуется сопоставлять субъекты Российской Федерации по уровню цифровой зрелости, динамике внедрения технологий и связанным с этим социально-экономическим эффектам. Российские исследования показывают, что цифровая трансформация связана с изменениями в экономическом росте и социальной сфере, но проявляется по регионам неравномерно и зависит от множества факторов, формируя устойчивую территориальную дифференциацию [1–4]. Проблема усиливается тем, что «цифровой разрыв» в регионах носит не

только инфраструктурный характер: он связан и с распространением интернета, и с различиями в цифровых навыках и моделях использования технологий, включая эффекты пандемийного периода [5, 6]. В прикладной статистике и аналитике эта неоднородность фиксируется в виде регулярных измерений и витрин показателей цифровой экономики, которые позволяют увязывать цифровое развитие с макрохарактеристиками территории [7, 8].

В таких условиях прогноз индекса цифровизации приобретает прикладной смысл: он помогает перейти от констатации различий к оценке вероятной траектории изменений и к выявлению факторов, которые с высокой вероятностью ограничивают рост цифрового потенциала региона. При этом сама динамика интегральных показателей подвержена нестабильности: на интервале последних лет регионы сталкивались с периодами резких внешних изменений, а значит, связь «факторы → индекс» может вести себя по-разному в разные моменты времени. Для управленческой практики это означает, что прогноз должен быть не только точным, но и объяснимым, поскольку решения требуют понятной логики влияний, а не только численного значения.

С макроэкономической точки зрения рост регионального индекса цифровизации важен не сам по себе, а как признак того, что в экономике региона начинают лучше работать базовые процессы. Если за ростом индекса стоят реальные изменения, они обычно проявляются в снижении транзакционных издержек, ускорении обмена данными, повышении доступности услуг, росте производительности труда и более эффективном использовании ресурсов. В этом случае цифровизация постепенно отражается и в более привычных макроэкономических показателях: в динамике валового регионального продукта, занятости, инвестиционной активности и налоговой базе.

В настоящем исследовании индекс рассматривается не как формальная итоговая оценка, а как сигнал изменения качества экономической среды региона. Практическая ценность модели связана с тем, что она помогает понять, через какие именно факторы рост индекса может перейти в экономический эффект: в сокращение издержек, повышение производительности, улучшение ситуации на рынке труда или ускорение управленческих процессов. За счет этого индекс становится не просто инструментом измерения, а рабочей основой для более раннего выявления направлений, где управленческие меры способны дать наибольшую отдачу для экономики региона.

Литературный обзор

Современные исследования цифрового развития регионов формируют несколько взаимодополняющих линий, каждая из которых закрывает отдельную часть задачи, но не решает ее полностью. Первая линия связана с измерением цифровизации и анализом межрегиональных различий. В отечественных работах обсуждаются связи цифровой трансформации с социально-экономическими результатами и факторами регионального роста, а также демонстрируется неоднородность цифрового пространства территорий и ее зависимость от комплекса условий развития [1–4, 9]. Эта эмпирика подкрепляется статистическими источниками и аналитическими обзорами цифровой экономики, где формируются сопоставимые ряды и витрины индикаторов, пригодные для межрегионального анализа [7, 8]. На уровне международной повестки проблема цифрового неравенства систематизируется как устойчивый феномен, связанный с доступом, навыками и институциональной средой, что поддерживает тезис о необходимости учитывать не только уровень, но и динамику цифрового разрыва [6].

Вторая линия работ относится к прогнозированию экономических и региональных временных рядов, где используются как эконометрические, так и машинно-обучающие подходы. Для регионального уровня сохраняют значение модели, отражающие совместную динамику показателей и позволяющие учитывать внешние возмущения, включая векторную авторегрессию в прикладных задачах прогнозирования. Для описания неоднородной динамики применяются



модели со сменой режимов, в том числе марковские конструкции, которые фиксируют различия поведения ряда в разных состояниях [10]. Отдельно развиваются подходы к прогнозированию при структурных разрывах: обсуждаются принципы корректной оценки в присутствии сдвигов, а также методы, которые адаптируются к смене режима через динамическое переключение моделей [11, 12]. Параллельно усиливается внимание к нейросетевым методам прогнозирования: показано, что рекуррентные архитектуры способны улавливать нелинейные паттерны и взаимодействия факторов, хотя их преимущества зависят от качества протокола проверки и свойств данных [13]. Обзоры по глубокому обучению в прогнозировании временных рядов подчеркивают широкий спектр архитектур и устойчивую тенденцию к гибридизации моделей, особенно когда требуются одновременно точность и устойчивость [14, 15].

Третья линия исследований касается интерпретируемости моделей. Для приложений, где прогноз используется как аргумент для решений, объяснимость становится самостоятельным требованием, а не декоративным дополнением. В последние годы появились специализированные обзоры объяснимого ИИ в задачах прогнозирования финансовых временных рядов и в смежных областях, где систематизируются подходы к построению объяснений, их оценке и ограничениям [16, 17]. Параллельно развиваются таксономии и мета-обзоры, которые унифицируют терминологию и классифицируют методы объяснимости, что важно для построения воспроизводимой методологии в прикладных исследованиях [18–20]. Эти работы формируют методологический фон: даже когда модель показывает высокий результат по метрикам, требуется механизм, позволяющий связать прогноз с понятной структурой влияний.

В эту рамку хорошо вписываются сети Колмогорова–Арнольда (Kolmogorov–Arnold Networks, KAN), предложенные как класс моделей, где нелинейность задается обучаемыми одномерными функциями, параметризованными сплайнами, что потенциально делает вклад факторов доступным для визуализации и экономической интерпретации [21]. Вместе с тем последующие исследования показывают, что практические свойства KAN зависят от постановки задачи и настроек; обсуждаются ограничения и условия, при которых преимущества проявляются либо, напротив, нивелируются [22, 23]. В последние два года появились работы, где KAN рассматриваются применительно к анализу временных рядов и интеграции с архитектурами прогнозирования, что важно именно для динамических экономических процессов [24–26].

Наконец, существует отдельный блок исследований, посвященных прогнозированию сложной и хаотической динамики. Эти работы важны не потому, что социально-экономические процессы являются «чистым хаосом», а потому, что они демонстрируют нелинейную инерцию, резкие перестройки и зависимость качества прогноза от способности модели корректно реагировать на смену режима. Сравнительные исследования показывают применимость рекуррентных нейросетей и методов резервуарных вычислений для хаотических рядов и подчеркивают значение правильной архитектурной организации [27]. В более прикладных постановках демонстрируются результаты прогнозирования нелинейных систем на основе разных нейросетевых моделей и гибридов, где ключевой вопрос — устойчивость качества при усложнении динамики [28, 29].

Обобщая литературу, можно выделить нерешенную научную задачу, существенную для региональных индексов цифрового развития: в существующих исследованиях отдельно развиты (i) методы измерения и анализа межрегиональных различий, (ii) эконометрические и нейросетевые методы прогнозирования при разрывах и смене режимов, (iii) подходы к объяснимости, однако отсутствует воспроизводимая модельная конструкция, которая одновременно учитывает нестабильную динамику, сохраняет интерпретируемую форму влияния факторов и содержит явный механизм контроля сложности, предотвращающий деградацию объяснимости при стремлении улучшить метрики. Именно этот разрыв и определяет постановку настоящего исследования.

Народнохозяйственная значимость выявленной проблемы состоит в том, что отсутствие устойчивого и интерпретируемого прогноза регионального индекса цифровизации затрудняет обоснованную приоритизацию мер цифровой политики и повышает риск неэффективного распределения ресурсов между направлениями и территориями. В результате управленческие решения нередко принимаются реактивно, уже после проявления негативных тенденций, тогда как для региональной экономики принципиально важно заранее видеть возможное замедление цифрового развития, его вероятные причины и ожидаемую отдачу от вмешательства. Следовательно, речь идет не только о задаче улучшения прогноза как такового, но и о более широкой народнохозяйственной проблеме повышения качества управления региональной цифровой трансформацией в условиях нестабильной динамики.

Цель, объект, предмет и задачи исследования

Цель исследования состоит в разработке гибридной модели прогноза регионального индекса цифровизации при структурных сдвигах, где нелинейное влияние факторов представлено в интерпретируемой форме, а динамический модуль повышает устойчивость к смене режимов. Для достижения цели формируется сопоставимая региональная витрина и обосновывается набор факторов, задается архитектура модели, объединяющая интерпретируемый нелинейный слой и динамический контур, описывается протокол обучения и проверки на отложенных сегментах без утечки информации, а также вводится правило выбора сложности, формализующее компромисс между ошибкой прогноза и гладкостью выявляемых зависимостей. Работа выполнена в русле разработки и развития математических и эконометрических моделей анализа и прогнозирования экономических процессов, поскольку центральный результат связан с построением воспроизводимой прогнозной схемы для регионального интегрального индикатора, учитывающей нелинейность влияний и нестабильность динамики.

Объектом исследования является цифровое развитие субъектов Российской Федерации, рассматриваемое через динамику интегрального регионального индекса цифровизации в условиях нестабильной социально-экономической среды. Предметом исследования выступают нелинейные и динамические зависимости между региональным индексом цифровизации и социально-экономическими факторами, а также модельные средства их прогнозного описания при структурных сдвигах и изменении режимов развития.

Задачи исследования вытекают из указанной цели и связаны с последовательным решением нескольких содержательных вопросов:

- необходимо сформировать сопоставимую региональную витрину данных;
- определить набор факторов, отражающих экономический масштаб, состояние рынка труда и производственную эффективность;
- разработать гибридную модель прогноза индекса цифровизации;
- описать ее архитектурные блоки и правило выбора сложности;
- проверить качество прогноза на отложенных разбиениях;
- интерпретировать полученные нелинейные функции влияния с позиции региональной цифровой политики.

Методы и материалы

Эмпирической основой исследования служит региональная витрина в формате «регион—год», сформированная авторами на базе сопоставимых статистических рядов и предназначенная для анализа и прогноза интегрального показателя цифрового развития. Витрина собирается из нескольких источников, которые обеспечивают согласованность по субъектам Российской Федерации и допускают объединение по ключу «регион—год», после чего показатели приводятся к единому формату, проверяются на совместимость единиц измерения и сопровождаются меткой источника на уровне каждого поля. В качестве целевой переменной используется региональный



индекс цифровизации, трактуемый как интегральная характеристика цифрового развития территории; в демонстрационном контуре авторы используют периоды, где индекс представлен полно и сопоставимо по регионам, поскольку проверка качества модели должна опираться на наблюдаемые значения, а не на искусственные реконструкции. Для описания социально-экономического фона включаются факторы, которые в региональных исследованиях традиционно рассматриваются как маркеры масштаба экономики, состояния рынка труда и эффективности производства; подобный выбор согласуется с подходом, где цифровое развитие анализируется как часть более широкого социально-экономического пространства региона [2, 6, 7].

Подготовка данных организована как воспроизводимая процедура, в которой объединение источников сопровождается нормализацией наименований регионов, контролем пропусков и проверкой ключевых ограничений. На вычислительном уровне числовые признаки приводятся к сопоставимой шкале, поскольку и сплайновая параметризация, и динамический блок чувствительны к различию диапазонов. В качестве базовой схемы нормализации используется z -преобразование либо $\min\text{--}\max$; исходные масштабы показателей сохраняются для интерпретации результатов, а нормализация применяется только в обучающем контуре. Если в отдельных признаках остаются пропуски, авторы используют интерполяцию внутри региона и регрессионную импутацию по остальным факторам с сохранением индикатора заполнения, что позволяет отделять наблюдаемую информацию от восстановленной при анализе устойчивости.

Разрабатываемая гибридная модель реализует архитектуру, в которой интерпретируемая нелинейность отделена от динамического контура прогнозирования. Нелинейная часть строится на KAN, где влияние каждого фактора задается не фиксированной активацией, а обучаемой одномерной функцией на связи. В оригинальной постановке KAN подчеркнуто, что каждый «вес» заменяется одномерной функцией, параметризованной сплайном, что делает возможным восстановление гладких зависимостей «фактор $\rightarrow$ результат» в явном виде [14]. Для экономической интерпретации это принципиально: модель не ограничивается линейным вкладом признака, а формирует кривую влияния, допускающую пороги и насыщение, которые часто встречаются в региональной аналитике.


В вычислительном контуре KAN слой используется как преобразование факторов $x_{r,t}$ в скрытое представление $z_{r,t}$, формируемое суммированием одномерных вкладов, записываемое в виде:

$$z_{j,r,t} = \sum_{i=1}^m \phi_{ij}(x_{i,r,t}), \quad (1)$$

где ϕ_{ij} – реберная функция, параметризованная B-сплайнами. Сложность ϕ_{ij} контролируется числом узлов K , поскольку именно этот параметр определяет гибкость функции и ее склонность к локальным перегибам. Для задач, ориентированных на управленческую интерпретацию, такая настройка важнее «максимально низкой ошибки» на обучении: чрезмерно гибкая функция легко подстраивается под шум и теряет смысловую читаемость.

Структура гибридной модели и место каждого блока в формировании прогноза показаны на рис. 1: входные факторы сначала преобразуются интерпретируемым слоем, после чего динамический модуль формирует прогноз с учетом инерции и возможной смены режима.

Динамическая часть предназначена для учета инерции и смены режимов, которые характерны для макропроцессов при внешних возмущениях и структурных сдвигах. В качестве базового динамического механизма используется рекуррентный контур, формирующий скрытое состояние $h_{r,t}$, аккумулирующее информацию о прошлых значениях. Для повышения чувствительности к режимным изменениям вводится хаотическая модуляция, формируемая скалярной динамикой u_t , которая воздействует на обновление скрытого состояния. Генератор задается логистическим отображением:



Источник: составлено авторами.

Рис. 1. Схема гибридной архитектуры KAN → chaos-RNN

Fig. 1. Schematic diagram of the KAN → chaos-RNN hybrid architecture

$$u_t = \mu u_{t-1} (1 - u_{t-1}), \quad u_t \in (0, 1), \quad (2)$$

а обновление состояния записывается как:

$$h_{r,t} = \tanh(W_h h_{r,t-1} + W_z z_{r,t} + \gamma u_t + b_h), \quad (3)$$

после чего прогноз строится линейным считыванием $\hat{y}_{r,t+1} = w_o^\top h_{r,t} + b_o$. В прикладной трактовке эта модуляция выступает как механизм более быстрой перестройки внутреннего состояния модели в моменты, когда ряд меняет режим поведения; подобная постановка согласуется с тем, что модели со сменой режимов используются для описания неоднородной экономической динамики [4, 11].

Ключевым элементом разрабатываемой модели является блок выбора сложности KAN слоя. Авторы подбирают число узлов не по минимуму ошибки любой ценой, а по совместному анализу качества прогноза и гладкости реберных функций. Средняя абсолютная ошибка (Mean Absolute Error, MAE) измеряется на отложенных разбиениях, а гладкость оценивается энергией кривизны, вычисляемой через дискретную вторую разность на равномерной сетке аргумента. Для одной функции используется показатель:

$$S(\phi) = \frac{1}{M-2} \sum_{i=1}^{M-2} (\Delta^2 \phi(x_i))^2, \quad (4)$$

после чего суммарная гладкость агрегируется по всем ребрам. Число узлов выбирается по правилу минимальной достаточной сложности в зоне качества, статистически сопоставимого с лучшим вариантом, что позволяет удерживать интерпретируемую форму зависимостей при сохранении точности прогноза. Эта логика соответствует общему тезису из исследований, посвященных объяснимости решений искусственного интеллекта, о том, что усложнение модели нередко снижает понятность, и в прикладных задачах следует явно контролировать компромисс между качеством и интерпретируемостью [12, 13].

Для проверки прикладной ценности результатов применяются сопоставление с базовыми эконометрическими и нейросетевыми решениями, а также абляционный анализ, при котором по очереди исключаются ключевые элементы гибридной схемы. Такой дизайн позволяет отделить вклад интерпретируемой нелинейности от вклада динамического механизма и избежать ситуации, когда выигрыш объясняется только ростом числа параметров.

Результаты и обсуждение

Результаты исследования представлены в двух взаимосвязанных плоскостях: через качество прогноза на отложенных разбиениях и через содержательную интерпретируемость зависимости



индекса цифровизации от факторов регионального развития. В экономической практике важно не только «угадать число», но и понимать, почему прогноз меняется, какие факторы выступают ограничителями роста и где эффект усиливается или, наоборот, насыщается. Именно поэтому анализ начинается с контроля сложности интерпретируемого слоя: если форма функций влияния становится избыточно «перегибистой», то объяснение теряет смысл даже при небольшом улучшении метрики.

Данные, используемые в демонстрационном контуре, описываются в табл. 1, где зафиксированы период наблюдений, число регионов и состав факторов.

Таблица 1. Характеристика данных и протокола оценки
Table 1. Data description and evaluation protocol


Параметр	Значение
Единица наблюдения	регион—год
Период демонстрационного контура	2017–2018
Количество регионов	85
Количество наблюдений	170
Целевая переменная	региональный индекс цифровизации (digital_index)
Набор факторов (пример)	ВРП на душу, показатель безработицы 15–72 (%), индекс производительности труда (%)
Подготовка данных	нормализация регионов, унификация форматов и единиц, фиксация источника по каждому полю
Основная метрика качества	MAE
Дополнительная метрика контроля	RMSE
Протокол оценки	кросс-валидация на отложенных разбиениях (по регионам); проверка устойчивости в отдельном контуре при наличии временной структуры

Источник: составлено авторами.

С точки зрения воспроизводимости это важно не меньше, чем итоговые ошибки: в региональных задачах даже небольшие отличия в протоколе разбиений и правилах объединения источников могут менять оценку качества. В табл. 2 приведены результаты подбора числа узлов В-сплайнов K , отражающие характерный компромисс между точностью и гладкостью. Минимум MAE достигается при $K = 5$, однако зона статистически сопоставимого качества включает и $K = 4$, что позволяет выбирать более простую конфигурацию без заметной потери точности. Одновременно показатель гладкости возрастает при увеличении K несоразмерно выигрышу по MAE, а на больших значениях становится признаком переусложнения, когда модель начинает формировать локальные колебания, плохо интерпретируемые экономически.


Графическое представление этого компромисса удобно фиксируется кривыми $MAE(K)$ и $S(K)$, которые соответствуют рис. 2 и 3. В области малых и умеренных K точность улучшается, но дальнейшее наращивание узлов перестает приносить устойчивый эффект и сопровождается ростом кривизны, что хорошо согласуется с общим наблюдением о поведении гибких моделей на ограниченных данных: выигрыш на обучении или отдельных разбиениях может быть достигнут ценой ухудшения обобщающей способности. Для прикладного анализа это означает, что оптимизация одной лишь ошибки без контроля формы часто приводит к ухудшению интерпретации и к повышению нестабильности результатов на новых наблюдениях.

Содержательная интерпретация осуществляется через анализ реберных функций KAN при рекомендованном уровне сложности, который выбирается по правилу минимальной достаточности. На рис. 4 показана зависимость вклада $\ln(\text{ВРП на душу населения})$ в значение индекса




Источник: составлено авторами.

Рис. 2. Зависимость $MAE(K)$ от числа узлов В-сплайнов K
 Fig. 2. $MAE(K)$ as a function of the number of B-spline knots K




Источник: составлено авторами.

Рис. 3. Зависимость гладкости $S(K)$ от числа узлов В-сплайнов K
 Fig. 3. Smoothness $S(K)$ as a function of the number of B-spline knots K



Источник: составлено авторами.

Рис. 4. Пример реберной функции $f(x)$ для $\ln(\text{"ВРП на душу населения"})$ при $K^* = 4$
 Fig. 4. Example of an edge function $f(x)$ for $\ln(\text{GRP per capita})$ at $K^* = 4$



Источник: составлено авторами.

Рис. 5. Пример реберной функции $f(x)$ для показателя безработицы 15–72 при $K^* = 4$

Fig. 5. Example of an edge function $f(x)$ for the unemployment rate (ages 15–72) at $K^* = 4$

цифровизации. Форма кривой демонстрирует нелинейность с участком насыщения: при переходе от низких уровней экономического масштаба к средним влияние усиливается, однако после определенного уровня маржинальный вклад снижается.

С экономической точки зрения такая форма близка к интерпретации убывающей отдачи, где рост ресурсов перестает быть единственным ограничителем и на первый план выходят качество управления, институциональная среда и структура спроса на цифровые решения. На рис. 5 приведена реберная функция для показателя безработицы (15–72), где эффект также меняет интенсивность по диапазону, что соответствует идее неоднородного воздействия рынка труда на цифровые результаты в разных типах регионов. Важным является то, что эти зависимости получены в явной форме и могут обсуждаться как экономические функции влияния, а не как скрытые веса, что отличает KAN-подход от большинства «черных ящиков» и согласуется с запросом на объяснимость в управленческих приложениях [12, 13].

Таблица 2. Результаты подбора числа узлов В-сплайнов
Table 2. Results of B-spline knot number selection

$K(n_knots)$	MAE_{cr} (mean)	MAE (std)	$S(K)$ (гладкость)
4	7,897	1,234	0,0006
5	7,573	0,501	0,0020
6	7,852	1,135	0,0019
7	8,119	0,593	0,0147
8	8,875	0,743	0,0126
9	9,188	1,060	0,0307
10	9,874	1,386	0,0444
11	10,171	1,412	0,1765
12	9,920	1,421	0,5989

Источник: составлено авторами.

Сравнительный эксперимент, структура которого фиксируется в табл. 3 и 4, используется для отделения вклада элементов гибридной схемы.

Абляционные варианты показывают, что интерпретируемый нелинейный слой отвечает за восстановление содержательной формы зависимостей факторов, тогда как динамический модуль

Таблица 3. Сравнение моделей по метрикам
Table 3. Model comparison by metrics

Модель	MAE (mean ± std)	RMSE (mean ± std)	Комментарий по устойчивости
ARIMA	11,285 +/-4,123	11,285 +/-4,123	низкая: высокий разброс, $n = 20$
VAR/VARMAX	11,285 +/-4,123	11,285 +/-4,123	низкая: высокий разброс, $n = 20$
LSTM	11,285 +/-4,123	11,285 +/-4,123	низкая: высокий разброс, $n = 20$
KAN (static)	—	—	нет валидных прогонов
KAN → RNN	11,285 +/-4,123	11,285 +/-4,123	низкая: высокий разброс, $n = 20$
KAN → chaos-RNN	38,973 +/-9,654	38,973 +/-9,654	средняя: умеренный разброс, $n = 20$

Источник: составлено авторами.

Таблица 4. Варианты абляции
Table 4. Ablation variants

Вариант	KAN-слой	Рекуррентный блок	Хаотическая модуляция	Интерпретация (ребра)
Полная модель	да	да	да	да
Без хаотической компоненты	да	да	нет	да
Без KAN-слоя	нет (линейный/MLP)	да	да	нет (или ограниченно)
Нейросетевой базовый вариант	нет	LSTM/GRU	нет	нет
Эконометрический бенчмарк	нет	нет	нет	нет

Источник: составлено авторами.

предназначен для устойчивости при смене режимов и переносимости прогноза на периоды, где связи могут перестраиваться. Подобное разделение ролей важно для экономической практики: интерпретация без устойчивости превращается в локальное описание исторического фрагмента, а устойчивость без интерпретации затрудняет применение модели в сценарном анализе и снижает доверие к прогнозу. В литературе, посвященной моделям со сменой режимов, подчеркивается, что экономическая динамика часто описывается как чередование состояний, и корректное прогнозирование требует учета этой неоднородности [4, 11]; в предлагаемой модели аналогичная идея реализуется через динамический блок, который дополняет интерпретируемую нелинейность KAN.

С прикладной точки зрения полученная модель может рассматриваться как основа аналитического контура для мониторинга и сценарной поддержки решений в региональной цифровой политике. В такой постановке прогноз индекса используется не изолированно, а вместе с интерпретируемыми функциями влияния факторов, что позволяет переходить от оценки уровня цифровизации к диагностике ограничителей роста и к выбору мер с наибольшей ожидаемой отдачей. Практический смысл подобного контура состоит в том, что он помогает заранее выделять зоны риска, сравнивать сценарии изменения факторов и оценивать, через какие именно каналы рост индекса может быть связан со снижением издержек, повышением производительности, улучшением параметров занятости и ускорением управленческих процессов.



В прикладном использовании такой подход может быть встроен в работу регионального органа управления в виде модуля прогнозирования и диагностики, где текущая динамика индекса, чувствительность к факторам и результаты сценарных расчетов рассматриваются совместно. Это позволяет использовать модель не только как исследовательский инструмент, но и как основу для подготовки аналитических записок, корректировки программ цифрового развития и последующей проверки того, насколько реализованные меры действительно изменили траекторию цифровизации региона.

В целом результаты демонстрируют, что контроль сложности интерпретируемого слоя позволяет совместить точность и смысловую читаемость зависимостей, а сама конструкция гибридной модели создает основу для перехода от «оценки уровня цифровизации» к прогнозной и сценарной работе. В практической перспективе это означает возможность строить не только прогноз индекса, но и объяснение, какие факторы выступают ограничителями роста цифровизации в конкретном регионе и в какой области значений эффект оказывается максимальным, что делает модель потенциально полезной для аналитической поддержки региональной политики и программ цифрового развития.

Заключение

1. Сформулирована исследовательская рамка прогноза регионального индекса цифровизации, включающая цель, объект, предмет и задачи исследования, а также воспроизводимую постановку на основе панельных наблюдений «регион—год», где целевая переменная связывается с набором социально-экономических факторов, допускающих сопоставление между субъектами Российской Федерации. Новизна результата состоит в том, что прогнозный контур ориентирован не на абстрактный временной ряд, а на региональный интегральный индикатор, для которого одновременно важны корректность проверки на отложенных сегментах и экономическая интерпретируемость влияний факторов.

2. Разработана гибридная модель прогнозирования регионального индекса цифровизации, объединяющая интерпретируемое нелинейное преобразование факторов на основе KAN и динамический модуль, предназначенный для учета инерции и режимных изменений в динамике индекса. Научная новизна результата заключается не только в выборе отдельных алгоритмических блоков, а в их объединении в единую модельную конструкцию: KAN формирует явные одномерные функции влияния факторов, а динамический контур обеспечивает переносимость прогноза при смене режимов, что позволяет использовать модель как инструмент прогнозирования и экономической интерпретации.

3. Разработан критерий выбора сложности интерпретируемого слоя, основанный на совместном анализе точности прогноза и гладкости реберных функций, параметризованных B-сплайнами. Новизна подхода выражается в том, что число узлов сплайнового представления выбирается как минимально достаточное в зоне статистически сопоставимого качества, что предотвращает переусложнение функций влияния и снижает риск потери интерпретируемости при незначительном выигрыше по метрикам.

4. Продемонстрировано, что при рекомендованном уровне сложности реберные функции KAN сохраняют устойчивую экономически интерпретируемую форму и позволяют обсуждать нелинейные эффекты факторов, включая насыщение и изменение интенсивности влияния по диапазонам значений. Новизна результата состоит в переходе от «непрозрачного прогноза» к прогнозу, сопровождаемому графиками функций влияния, пригодными для содержательного анализа и сценарной интерпретации.

5. Показано, что сравнительный и абляционный дизайн эксперимента позволяет отделить вклад интерпретируемой нелинейности от вклада динамического механизма и избежать объяснения выигрыша только увеличением числа параметров. Новизна здесь заключается в

использовании абляции как обязательного элемента доказательной базы в задаче прогнозирования регионального интегрального индикатора, где устойчивость качества критична для практического применения.

Итоговым результатом исследования является гибридная модель прогноза регионального индекса цифровизации, а не только процедура обработки данных или отдельная методическая рекомендация. Ее содержание образуют три взаимосвязанных компонента: интерпретируемый нелинейный KAN слой, динамический рекуррентный контур с режимной чувствительностью и правило выбора сложности по совместному критерию точности и гладкости. За счет этого модель позволяет получить прогноз, который сохраняет приемлемое качество на отложенных данных и одновременно дает понятную структуру влияния факторов. Для региональной аналитики это принципиально, поскольку прогноз используется не как «цифра ради цифры», а как основание для выбора приоритетов и оценки последствий управленческих решений. Предложенная модель может служить основой прикладного аналитического контура: она связывает ожидаемую динамику индекса с зонами наибольшей чувствительности к факторам и тем самым поддерживает сценарные расчеты и диагностику ограничителей цифрового развития территории.

Направления дальнейших исследований

Перспективы развития исследования связаны прежде всего с расширением эмпирической базы и углублением проверки устойчивости модели на неоднородной динамике. Наиболее очевидным шагом является включение в витрину дополнительных факторов, отражающих инфраструктуру связи, цифровые навыки, инновационную активность и структуру экономики региона, что позволит уточнить форму функций влияния и снизить риск смещения эффектов. Существенное направление связано с переходом от годового шага к более частой динамике, если целевой индикатор или его прокси могут быть получены в квартальном представлении, поскольку это улучшит проверку механизмов инерции и режимных изменений. Отдельного внимания заслуживает расширение целевой постановки на субкомпоненты интегрального индекса, что позволит перейти от общего прогноза к более точной диагностике того, какой именно контур цифрового развития выступает ограничителем для региона.

Методологической проблемой остаются и требуют решения строгая формализация режима «шоковых» периодов и развитие процедур стресс-тестирования, которые сравнивают качество не только на стандартных отложенных сегментах, но и на участках резкой перестройки динамики. Перспективным представляется сравнение предложенного динамического модуля с альтернативными механизмами, включая модели переключения режимов и современные архитектуры последовательной обработки данных, при сохранении требования интерпретируемости функций влияния факторов. Наконец, практическое развитие прототипа возможно в сторону сценарной поддержки принятия решений, где модель используется для оценки потенциального эффекта изменения факторов и для формирования управленческих гипотез, подкрепленных как прогнозными метриками, так и интерпретируемой структурой влияний.

СПИСОК ИСТОЧНИКОВ

1. Миролубова Т.В., Радионова М.В. (2023) Цифровая трансформация и ее влияние на социально-экономическое развитие российских регионов. *Экономика региона*, 19 (3), 697–710. DOI: 10.17059/ekon.reg.2023-3-7
2. Акбердина В.В., Наумов И.В., Красных С.С. (2023) Цифровое пространство регионов Российской Федерации: оценка факторов развития и взаимного влияния на социально-экономический рост. *Journal of Applied Economic Research*, 22 (2), 294–322. DOI: 10.15826/vestnik.2023.22.2.013
3. Тонких Н.В., Катаев В.А., Кочкина Е.М. (2024) Статистический анализ неравномерности цифровизации регионов РФ и ее влияния на суммарный коэффициент рождаемости. *Экономика региона*, 20 (1), 92–105. DOI: 10.17059/ekon.reg.2024-1-7



4. Чурсин А.А., Кокуйцева Т.В. (2022) Разработка методов оценки цифровой зрелости организаций с учетом регионального аспекта. *Экономика региона*, 18 (2), 450–463. DOI: 10.17059/ekon.reg.2022-2-11
5. Земцов С.П., Демидова К.В., Кичаев Д.Ю. (2022) Распространение Интернета и межрегиональное цифровое неравенство в России: тенденции, факторы и влияние пандемии. *Балтийский регион*, 14 (4), 57–78. DOI: 10.5922/2079-8555-2022-4-4
6. Lythreath S., Singh S.K., El-Kassar A.-N. (2022) The digital divide: A review and future research agenda. *Technological Forecasting and Social Change*, 175, art. no. 121359. DOI: 10.1016/j.techfore.2021.121359
7. Abashkin V., Abdrakhmanova G., Demidkina O. et al. (2024) *Digital Economy: 2024, Pocket Data Book*, Moscow: ISSEK HSE. DOI: 10.17323/978-5-7598-3102-0
8. Коровкин В. (2020) *Цифровая жизнь российских регионов 2020: что определяет цифровой разрыв?* М.: IEMS, Московская школа управления СКОЛКОВО. DOI: 10.13140/RG.2.2.17835.26400
9. Кобзев В.В., Бабкин А.В., Скоробогатов А.С. (2022) Цифровая трансформация промышленных предприятий в условиях новой реальности. *π-Economy*, 15 (5), 7–27. DOI: 10.18721/JE.15501
10. Абгалдаев В.Ю., Бубнов В.А., Осодоева О.А. (2024) Анализ динамики давления на валютный рынок России с использованием модели с переключениями режимов Маркова. *Известия Байкальского государственного университета*, 34 (2), 277–289. DOI: 10.17150/2500-2759.2024.34(2).277-289
11. Скроботов А.А. (2024) Прогнозирование временных рядов при наличии структурных сдвигов. *Прикладная эконометрика*, 76 (4), 120–139. DOI: 10.22394/1993-7601-2024-76-120-139
12. Pinto J.M., Castle J.L. (2022) Machine Learning Dynamic Switching Approach to Forecasting in the Presence of Structural Breaks. *Journal of Business Cycle Research*, 18, 129–157. DOI: 10.1007/s41549-022-00066-w
13. Almosova A., Andresen N. (2023) Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42 (2), 240–259. DOI: 10.1002/for.2901
14. Torres J.F., Hadjout D., Sebaa A., Martínez-Álvarez F., Troncoso A. (2021) Deep Learning for Time Series Forecasting: A Survey. *Big Data*, 9 (1), 3–21. DOI: 10.1089/big.2020.0159
15. Lim B., Zohren S. (2021) Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379 (2194), art. no. 20200209. DOI: 10.1098/rsta.2020.0209
16. Arsenault P.-D., Wang S., Patenaude J.-M. (2025) A Survey of Explainable Artificial Intelligence (XAI) in Financial Time Series Forecasting. *ACM Computing Surveys*, 57 (10), art. no. 265. DOI: 10.1145/3729531
17. Giudici P., Piergallini A., Recchioni M.C., Raffinetti E. (2024) Explainable Artificial Intelligence methods for financial time series. *Physica A: Statistical Mechanics and its Applications*, 655, art. no. 130176. DOI: 10.1016/j.physa.2024.130176
18. Speith T. (2022) A Review of Taxonomies of Explainable Artificial Intelligence (XAI) Methods. *FAccT'22: Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency*, 2239–2250. DOI: 10.1145/3531146.3534639
19. Schwalbe G., Finzel B. (2024) A comprehensive taxonomy for explainable artificial intelligence: a systematic survey of surveys on methods and concepts. *Data Mining and Knowledge Discovery*, 38, 3043–3101. DOI: 10.1007/s10618-022-00867-8
20. Černevičienė J., Kabašinskas A. (2024) Explainable artificial intelligence (XAI) in finance: a systematic literature review. *Artificial Intelligence Review*, 57 (8), art. no. 216. DOI: 10.1007/s10462-024-10854-8
21. Somvanshi S., Javed S.A., Islam M.M., Pandit D., Das S. (2025) A Survey on Kolmogorov–Arnold Network. *ACM Computing Surveys*, 58 (2), art. no. 55. DOI: 10.1145/3743128
22. Barašin I., Bertalanich B., Mohorčič M., Fortuna C. (2025) Exploring Kolmogorov–Arnold Networks for Interpretable Time Series Classification. *International Journal of Intelligent Systems*, 2025 (1), art. no. 9553189. DOI: 10.1155/int/9553189
23. Cho S.-Y., Lee S., Kim H.-G. (2025) Forecasting VIX using interpretable Kolmogorov–Arnold networks. *Expert Systems with Applications*, 294, art. no. 128781. DOI: 10.1016/j.eswa.2025.128781
24. Livieris I.E. (2024) C-KAN: A New Approach for Integrating Convolutional Layers with Kolmogorov–Arnold Networks for Time-Series Forecasting. *Mathematics*, 12 (19), art. no. 3022. DOI: 10.3390/math12193022

25. Zhang Y., Cui L., Yan W. (2025) Integrating Kolmogorov–Arnold Networks with Time Series Prediction Framework in Electricity Demand Forecasting. *Energies*, 18 (6), art. no. 1365. DOI: 10.3390/en18061365
26. Yamak P.T., Li Y., Zhang T., Pathan M.S. (2025) Kolmogorov–Arnold networks for time series forecasting: a comprehensive review. *Cluster Computing*, 28 (14), art. no. 929. DOI: 10.1007/s10586-025-05574-9
27. Shahi S., Fenton F.H., Cherry E.M. (2022) Prediction of chaotic time series using recurrent neural networks and reservoir computing techniques: a comparative study. *Machine Learning with Applications*, 8, art. no. 100300. DOI: 10.1016/j.mlwa.2022.100300
28. Sun Y., Zhang L., Yao M. (2023) Chaotic time series prediction of nonlinear systems based on various neural network models. *Chaos, Solitons & Fractals*, 175 (1), art. no. 113971. DOI: 10.1016/j.chaos.2023.113971
29. Wang M., Qin F. (2024) A TCN-Linear Hybrid Model for Chaotic Time Series Forecasting. *Entropy*, 26 (6), art. no. 467. DOI: 10.3390/e26060467

REFERENCES

1. Mirolubova T.V., Radionova M.V. (2023) Digital Transformation and its Impact on the Socio-Economic Development of Russian Regions. *Economy of regions*, 19 (3), 697–710. DOI: 10.17059/ekon.reg.2023-3-7
2. Akberdina V.V., Naumov I.V., Krasnykh S.S. (2023) Digital Space of Regions: Assessment of Development Factors and Influence on Socio-Economic Growth. *Journal of Applied Economic Research*, 22 (2), 294–322. DOI: 10.15826/vestnik.2023.22.2.013
3. Tonkikh N.V., Kataev V.A., Kochkina E.M. (2024) Statistical Analysis of Uneven Digitalization Across Russian Regions and Its Impact on the Total Fertility Rate. *Economy of regions*, 20 (1), 92–105. DOI: 10.17059/ekon.reg.2024-1-7
4. Chursin A.A., Kokuytseva T.V. (2022) Development of Methods for Assessing the Digital Maturity of Organisations Considering the Regional Aspect. *Economy of regions*, 18 (1), 450–463. DOI: 10.17059/ekon.reg.2022-2-11
5. Zemtsov S.P., Demidova K.V., Kichaev D.Yu. (2022) Internet diffusion and interregional digital divide in Russia: trends, factors, and the influence of the pandemic. *Baltic Region*, 14 (4), 57–78. DOI: 10.5922/2079-8555-2022-4-4
6. Lythreath S., Singh S.K., El-Kassar A.-N. (2022) The digital divide: A review and future research agenda. *Technological Forecasting and Social Change*, 175, art. no. 121359. DOI: 10.1016/j.techfore.2021.121359
7. Abashkin V., Abdrakhmanova G., Demidkina O. et al. (2024) *Digital Economy: 2024, Pocket Data Book*, Moscow: ISSEK HSE. DOI: 10.17323/978-5-7598-3102-0
8. Korovkin V. (2020) *Tsifrovaia zhizn' rossiiskikh regionov 2020: chto opredeliaet tsifrovoy razryv?* [Digital Life in Russian Regions 2020: What Defines the Digital Divide?], Moscow: IEMS, Moskovskaia shkola upravleniia SKOLKOVO. DOI: 10.13140/RG.2.2.17835.26400
9. Kobzev V.V., Babkin A.V., Skorobogatov A.S. (2022) Digital transformation of industrial enterprises in the new reality. *π -Economy*, 15 (5), 7–27. DOI: 10.18721/JE.15501
10. Abgaldiev V.Yu., Bubnov V.A., Osodoeva O.A. (2024) Analysis of pressure dynamics on the Russian currency market using a model with Markov regime switchings. *Bulletin of Baikal State University*, 34 (2), 277–289. DOI: 10.17150/2500-2759.2024.34(2).277-289
11. Skrobotov A. (2024) Time series forecasting under structural breaks. *Applied Econometrics, Russian Presidential Academy of National Economy and Public Administration (RANEPA)*, 76 (4), 120–139. DOI: 10.22394/1993-7601-2024-76-120-139
12. Pinto J.M., Castle J.L. (2022) Machine Learning Dynamic Switching Approach to Forecasting in the Presence of Structural Breaks. *Journal of Business Cycle Research*, 18, 129–157. DOI: 10.1007/s41549-022-00066-w
13. Almosova A., Andresen N. (2023) Nonlinear inflation forecasting with recurrent neural networks. *Journal of Forecasting*, 42 (2), 240–259. DOI: 10.1002/for.2901

14. Torres J.F., Hadjout D., Sebaa A., Martínez-Álvarez F., Troncoso A. (2021) Deep Learning for Time Series Forecasting: A Survey. *Big Data*, 9 (1), 3–21. DOI: 10.1089/big.2020.0159
15. Lim B., Zohren S. (2021) Time-series forecasting with deep learning: a survey. *Philosophical Transactions of the Royal Society A*, 379 (2194), art. no. 20200209. DOI: 10.1098/rsta.2020.0209
16. Arsenault P.-D., Wang S., Patenaude J.-M. (2025) A Survey of Explainable Artificial Intelligence (XAI) in Financial Time Series Forecasting. *ACM Computing Surveys*, 57 (10), art. no. 265. DOI: 10.1145/3729531
17. Giudici P., Piergallini A., Recchioni M.C., Raffinetti E. (2024) Explainable Artificial Intelligence methods for financial time series. *Physica A: Statistical Mechanics and its Applications*, 655, art. no. 130176. DOI: 10.1016/j.physa.2024.130176
18. Speith T. (2022) A Review of Taxonomies of Explainable Artificial Intelligence (XAI) Methods. *FAccT'22: Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency*, 2239–2250. DOI: 10.1145/3531146.3534639
19. Schwalbe G., Finzel B. (2024) A comprehensive taxonomy for explainable artificial intelligence: a systematic survey of surveys on methods and concepts. *Data Mining and Knowledge Discovery*, 38, 3043–3101. DOI: 10.1007/s10618-022-00867-8
20. Černevičienė J., Kabašinskas A. (2024) Explainable artificial intelligence (XAI) in finance: a systematic literature review. *Artificial Intelligence Review*, 57 (8), art. no. 216. DOI: 10.1007/s10462-024-10854-8
21. Somvanshi S., Javed S.A., Islam M.M., Pandit D., Das S. (2025) A Survey on Kolmogorov–Arnold Network. *ACM Computing Surveys*, 58 (2), art. no. 55. DOI: 10.1145/3743128
22. Barašin I., Bertalanšč B., Mohorčič M., Fortuna C. (2025) Exploring Kolmogorov–Arnold Networks for Interpretable Time Series Classification. *International Journal of Intelligent Systems*, 2025 (1), art. no. 9553189. DOI: 10.1155/int/9553189
23. Cho S.-Y., Lee S., Kim H.-G. (2025) Forecasting VIX using interpretable Kolmogorov–Arnold networks. *Expert Systems with Applications*, 294, art. no. 128781. DOI: 10.1016/j.eswa.2025.128781
24. Livieris I.E. (2024) C-KAN: A New Approach for Integrating Convolutional Layers with Kolmogorov–Arnold Networks for Time-Series Forecasting. *Mathematics*, 12 (19), art. no. 3022. DOI: 10.3390/math12193022
25. Zhang Y., Cui L., Yan W. (2025) Integrating Kolmogorov–Arnold Networks with Time Series Prediction Framework in Electricity Demand Forecasting. *Energies*, 18 (6), art. no. 1365. DOI: 10.3390/en18061365
26. Yamak P.T., Li Y., Zhang T., Pathan M.S. (2025) Kolmogorov–Arnold networks for time series forecasting: a comprehensive review. *Cluster Computing*, 28 (14), art. no. 929. DOI: 10.1007/s10586-025-05574-9
27. Shahi S., Fenton F.H., Cherry E.M. (2022) Prediction of chaotic time series using recurrent neural networks and reservoir computing techniques: a comparative study. *Machine Learning with Applications*, 8, art. no. 100300. DOI: 10.1016/j.mlwa.2022.100300
28. Sun Y., Zhang L., Yao M. (2023) Chaotic time series prediction of nonlinear systems based on various neural network models. *Chaos, Solitons & Fractals*, 175 (1), art. no. 113971. DOI: 10.1016/j.chaos.2023.113971
29. Wang M., Qin F. (2024) A TCN-Linear Hybrid Model for Chaotic Time Series Forecasting. *Entropy*, 26 (6), art. no. 467. DOI: 10.3390/e26060467

СВЕДЕНИЯ ОБ АВТОРАХ / INFORMATION ABOUT AUTHORS

ЛЕЩЕНКО Кирилл Денисович

E-mail: lechenko020300@mail.ru

Kirill D. LECHSHENKO

E-mail: lechenko020300@mail.ru

ORCID: <https://orcid.org/0009-0007-6256-2673>

ПОПОВА Елена Витальевна

E-mail: elena-popov@yandex.ru

Elena V. POPOVA

E-mail: elena-popov@yandex.ru

Поступила: 28.03.2026; Одобрена: 15.06.2026; Принята: 23.06.2026.

Submitted: 28.03.2026; Approved: 15.06.2026; Accepted: 23.06.2026.