

УДК: 004.9

Нейросетевое обоснование управляющих решений по цифровизации города

В. Ю. Осипов

Санкт-Петербургский федеральный исследовательский центр Российской академии наук,
Россия, 199178, г. Санкт-Петербург, 14-я линия В. О., д. 39

E-mail: osipov_vasily@mail.ru

Получено 13.03.2026, после доработки — 03.08.2026.

Принято к публикации 06.08.2026.

Современная цифровизация городов происходит по законам, которые пока не четко определены. Сложность понимания этих законов связана с высокой неопределенностью городских событий и трудностей формирования их адекватных аналитических моделей. Для обоснования целесообразных управляющих решений по цифровизации городов в этих условиях необходимо наличие эффективных методов обработки многомерных временных рядов. Ставится задача по разработке одного из перспективных методов. Основу предлагаемого метода составляют новая модель нейросетевой системы управления и алгоритмы реализации ее основных функций. К отличительным особенностям модели относятся как структурные аспекты, так и новые правила нейросетевого обоснования управляющих решений по цифровизации города с обучением применяемой рекуррентной нейронной сети без учителя. Эта модель предусматривает адаптивное нейросетевое управление цифровизацией города по скользящей программе. Предложены новые правила прямого и обратного преобразования многомерных временных рядов, моделирования работы потоковой импульсной рекуррентной нейронной сети, поиска целесообразных программ цифровизации города. Предложенные правила позволяют исключить потери информации в такой сети и обеспечить ее устойчивое функционирование. Отражены особенности работы этой нейронной сети при обосновании целесообразных программ цифровизации города. Обоснованы требования к программной реализации предложенного метода. Приведены результаты экспериментов на данных по Санкт-Петербургу. В качестве этих данных выступали месячные объемы отгруженных компьютеров, электронных и оптических изделий, а также месячные объемы отгруженной продукции по всем обрабатывающим производствам за вычетом значений первого ряда на интервале с января 2021 года по декабрь 2025 года. Прогнозирование эффективности управляющих решений по цифровизации города осуществлялось по суммарным объемам отгруженной продукции на горизонт с января по декабрь 2026 года. Показано, что применение предложенного метода позволяет расширить возможности по адаптивному обоснованию целесообразных управляющих решений по цифровизации города со снижением затрат на компьютерное моделирование.

Ключевые слова: город, цифровизация, нейросетевое управление, алгоритмы моделирования, прогнозирование

UDC: 004.9

Neural network-based justification of management decisions on city digitalization

V. Yu. Osipov

St. Petersburg Federal Research Center of the Russian Academy of Sciences,
39 14th Line, V. O., St. Petersburg, 199178, Russia

E-mail: osipov_vasily@mail.ru

Received 13.03.2026, after completion — 03.08.2026.

Accepted for publication 06.08.2026.

The modern digitalization of cities occurs according to laws that are not yet clearly defined. The difficulty in understanding these laws is due to the high uncertainty of urban events and the difficulties in developing adequate analytical models for them. To substantiate management decisions on city digitalization in these conditions, effective methods for processing multidimensional time series are necessary. The objective is to develop a promising method. The proposed method is based on a new model of a neural network control system and algorithms for implementing its main functions. Distinctive features of the model include both structural aspects and new rules for neural network-based substantiation of management decisions on city digitalization, using unsupervised training of the applied recurrent neural network. This model provides for adaptive neural network management of city digitalization according to a sliding program. New rules are proposed for the forward and backward transformation of multidimensional time series, modeling the operation of a streaming recurrent neural network, and identifying feasible programs for city digitalization. By adhering to the proposed rules, it is possible not only to eliminate information loss in such a network but also to ensure its stable operation. The features of this neural network's operation in substantiating feasible urban digitalization programs are described. The requirements for the software implementation of the proposed method are substantiated. The results of experiments using data for St. Petersburg are presented. These data included monthly volumes of shipped computers, electronic and optical products, as well as monthly volumes of shipped products for all manufacturing industries minus the first-time series values for the period from January 2021 to December 2025. The effectiveness of management decisions on the city's digitalization was predicted based on the total volumes of shipped products to the horizon from January to December 2026. It is shown that the application of the proposed method allows for expanded capabilities for adaptively substantiating feasible management decisions on the city's digitalization while reducing computer modeling costs.

Keywords: city, digitalization, neural network control, modeling algorithms, forecasting

Citation: *Computer Research and Modeling*, 2026, vol. 18, no. 4, pp. 1053–1070 (Russian).

1. Введение

Современная цифровая трансформация городов предусматривает преобразование собственных им социально-экономических процессов за счет развития и внедрения цифровых технологий, прежде всего искусственного интеллекта и роботов. С позиции цифровой трансформации города очень трудно формализуемы [Юсупов, Тулупьева, 2003]. Они функционируют с достижением множества различных трудносвязываемых целей и условий, с широким спектром внешних воздействий и постоянно изменяющимися законами поведения. Сложно построить адекватную аналитическую модель любого города. Однако можно анализировать динамику множества известных показателей [Итоги. . . , 2026], отражающих состояния города, и обосновывать целесообразные решения по его цифровой трансформации.

В качестве искомых управляющих решений могут выступать целесообразные программы цифровизации города. К ним можно отнести последовательности: значений финансовых средств, выделяемых на цифровизацию города; объемов выпуска и внедрения современных цифровых технологий, заказов на приобретение технологий искусственного интеллекта и роботов и др. Несомненно, для обоснования целесообразных решений по цифровизации города необходимо наличие соответствующих моделей и методов.

Известны подходы [Mendis et al., 2024] к решению подобных задач с использованием векторной авторегрессии [Tänzer, 2024; Bragoudakis, Krompas, 2025; Hana, Othman, 2025], нейросетевых [Домашенко, Никулин, 2017; Tänzer, 2024; Mardjo, Choksuchat, 2024; Хуснутдинов и др., 2025; Chege et al., 2025; Feng et al., 2025; Shen et al., 2025] и других моделей с поиском целесообразных управлений. Они применяются для прогнозирования с учетом возможных управлений, валового внутреннего продукта, инфляции, процентных ставок, обменных курсов, производственных показателей, спроса на товары. Известны публикации, посвященные непосредственно прогнозированию и управлению цифровой трансформацией [Вертакова и др., 2018; Прохоров, Минашкин, 2021; Ермакова, 2022]. В частности, в [Прохоров, Минашкин, 2021] напрямую отражаются аспекты анализа и прогнозирования динамики цифровой трансформации экономики Российской Федерации. В [Ермакова, 2022] анализируется воздействие развития цифровых технологий на экономический рост ведущих стран Латинской Америки.

К основному недостатку применения векторной аналитической авторегрессии относится невозможность непрерывно учитывать изменяющиеся связи между переменными временных рядов. Требуется подбирать целесообразные законы изменения этих связей и пересчитывать коэффициенты применяемых уравнений.

К наиболее перспективным подходам к обоснованию управляющих решений по цифровизации города на основе анализа многомерных временных рядов его показателей следует отнести нейросетевые модели и методы. Среди них наибольший интерес представляют идеи прогнозирующего нейроуправления [Omatu et al., 2011; Schwenzer et al., 2021; Осипов и др., 2024; Lawgynczuk, Zarzycki, 2025]. Для обоснования управляющих решений по цифровизации города в некоторой мере применимы нелинейные авторегрессионные нейронные сети [Домашенко, Никулин, 2017], нейронные сети с долгой кратковременной памятью [Mardjo, Choksuchat, 2024; Chege et al., 2025; Lawgynczuk, Zarzycki, 2025], комбинированные нейронные сети [Feng et al., 2025], а также нейронные сети совместно с векторной авторегрессией [Chege et al., 2025] и другие. Один из обзоров сравнительного анализа нейросетевых моделей применительно к моделированию динамики валового регионального продукта приведен в [Вавилова и др., 2025]. В некоторой мере для обоснования управляющих решений по цифровизации города применимы также большие языковые модели GPT, DeepSeek и другие.

Несмотря на ряд преимуществ известных нейросетевых подходов к решению рассматриваемой задачи, они во многом несовершенны. Все эти решения малоадаптивны к изменяющимся

законам поведения города. В большинстве случаев применяемые нейросетевые модели предусматривают обучение только с учителем. На это расходуются значительные временные, вычислительные и другие ресурсы. При этом с течением времени эти модели могут быстро устаревать. Известны нейросетевые решения с непрерывным обучением [Osipov, Osipova, 2018; Осипов, Милосердов, 2019; Osipov et al., 2020; Осипов и др., 2024], предусматривающие применение для обоснования целесообразных управлений двух идентичных потоковых рекуррентных нейронных сетей (РНС) и блока управления ими. Из них первая РНС функционирует в режиме непрерывного обучения. С использованием второй РНС в ускоренном времени на основе данных, считываемых с первой сети, обосновываются управляющие решения. Такой подход успешно применим, когда входные данные поступают в первую РНС в реальном времени с периодом повторения, соизмеримым с длительностью тактов работы сети. При поступлении входных данных в РНС блоками в сжатом виде это решение ограничено по функциональности. Также оно требует существенных вычислительных затрат на моделирование сразу двух идентичных РНС и предусматривает сложную работу блока управления. Необходимо для рассматриваемого случая расширить функциональность нейросетевой системы и снизить затраты на моделирование. Желательно, чтобы обоснование управляющих решений осуществлялось только при использовании одной РНС с обучением без учителя и функционирующей с одной скоростью обработки информации.

Необходимо разработать новый метод нейросетевого обоснования управляющих решений по цифровизации города на основе анализа многомерных временных рядов его показателей, лишенный отмеченных недостатков.

2. Модель нейросетевой системы управления

В интересах решения поставленной задачи рассмотрим усовершенствованную модель нейросетевой системы управления цифровизацией города. Ее функциональная структура приведена на рис. 1.

В обобщенном виде функционирование этой системы можно описать следующей последовательностью шагов.

Ш1. Начало. $T = 0$, $L = 0$, $M = 0$.

Ш2. $T = T + 1$.

Ш3. Если $T > T_{\text{зад}}$, то завершение работы.

Ш4. Осуществление сбора данных о текущих значениях показателей процессов цифровизации города, включая показатели управляющих воздействий.

Ш5. Если текущие данные совпадают с результатами прогноза в соответствии с ранее обоснованной программой цифровизации города — то переход к Ш14. В противном случае $L = 0$, $M = 0$.

Ш6. Относительно момента T формирование с заданной глубиной временных рядов анализируемых показателей с разделением их на управляемые и управляющие.

Ш7. Преобразование временных рядов в последовательные совокупности единичных импульсов (СЕИ), несущие всю информацию о них.

Ш8. Подача СЕИ в потоковую импульсную рекуррентную нейронную сеть (РНС). Связывание в пространстве и времени продвигающихся в РНС совокупностей единичных импульсов. Формирование модели этих рядов в РНС, запоминание результатов связывания на элементах сети.

Ш9. После введения в РНС последних СЕИ входной последовательности, несущей информацию об исходных многомерных временных рядах, считывание информации о состояниях импульсных нейронов и весах синапсов в подсистему управления и принятия решений (ПУПР). Запоминание этой информации.

Ш10. $M = M + 1$. Если $M > M_{\text{зад}}$, то $L = 0$, $M = 0$, преобразование найденной целесообразной программы в виде последовательностей СЕИ в соответствующие ей исходные временные ряды и переход к Ш14.

Ш11. Ввод в РНС сформированной в ПУПР M -й альтернативной программы с одновременным переводом сети в режим генерации (вызова из ассоциативной памяти результатов прогнозирования управляемых показателей).

Ш12. Считывание результатов прогнозирования с РНС в ПУПР и оценивание прогнозируемой эффективности города по заданному интегральному показателю. Сопоставление результатов этого оценивания с предыдущими оценками. Запоминание программы, позволяющей добиться наибольшей эффективности.

Ш13. Инициализация РНС. Считывание в нее информации о состоянии импульсных нейронов и весах синапсов, запомненной в ПУПР. Переход к Ш10.

Ш14. $L = L + 1$. Если $L \leq L_{\text{зад}}$ — то реализация L -го шага управления согласно найденной целесообразной программе цифровизации города, в противном случае $L = 0$. Переход к Ш2.




Рис. 1. Функциональная структура нейросетевой системы управления цифровой трансформацией города

Обоснование управляющих решений, согласно этой модели, осуществляется исходя из результатов прогнозирования поведения города на несколько шагов вперед. После получения целесообразной программы цифровизации делается один шаг по ее реализации. В случаях, когда результаты прогнозирования совпадают с реальными данными, можно делать очередной шаг. В противном случае требуется обосновывать новую программу, предусматривающую многошаговые управляющие воздействия.

Отличия предлагаемой модели от известных решений состоят как в структурных особенностях, так и в новых правилах нейросетевого обоснования управляющих решений по цифровизации города. Согласно предлагаемой модели решения могут обосновываться с обучением РНС без учителя, что обеспечивает оперативную адаптивность системы к изменяющимся условиям. Эта модель предусматривает нейросетевое управление цифровизацией города согласно скользящей программе.

Поясним ниже особенности алгоритмов, реализующих основные функции нейросетевой системы управления цифровизацией города.

3. Алгоритмы реализации основных функций

3.1. Правила прямого и обратного преобразования временных рядов

Подлежащие прямому преобразованию управляемые (s) и управляющие (u) временные ряды показателей, отражающие процессы цифровизации города, можно представить в виде

$$s_i(t_k) \in E_i, \quad u_j(t_k) \in E_j, \quad i = \overline{1, N}, \quad j = \overline{1, M}, \quad k = \overline{1, K},$$

где i, j — номера временных рядов, $s_i(t_k), u_j(t_k)$ — значения переменных временных рядов показателей на k -й момент времени, E_i, E_j — допустимые множества значений. Для ввода временных рядов в РНС их необходимо преобразовать в последовательные совокупности единичных импульсов, $\text{СЕИ}_k^s = \text{СЕИ}_{1k}^s \cup \text{СЕИ}_{2k}^s \cup \dots \cup \text{СЕИ}_{Nk}^s$, $\text{СЕИ}_k^u = \text{СЕИ}_{1k}^u \cup \text{СЕИ}_{2k}^u \cup \dots \cup \text{СЕИ}_{Mk}^u$, $\text{СЕИ}_k = \text{СЕИ}_k^s \cup \text{СЕИ}_k^u$ по единым правилам, например, $s_i(t_k) \rightarrow \text{СЕИ}_{ik}^s \in \text{СЕИ}_i^s, i = \overline{1, N}, k = \overline{1, K}$.

Это осуществимо одним из целесообразных способов кодирования. В частности, любое число можно закодировать в виде конечного числа единичных образов, соотнесенных с пространством логических полей применяемой потоковой РНС.

При таком кодировании для обработки СЕИ в потоковой импульсной рекуррентной сети без потери информации требуется, чтобы соблюдались следующие условия:

$$\text{СЕИ}_{k+1} \cap \text{СЕИ}_k = \emptyset, \quad (1)$$

$$\text{СЕИ}_{1k} \cap \text{СЕИ}_{2k} \cap \dots \cap \text{СЕИ}_{(N+M)k} = \emptyset, \quad (2)$$

$$\begin{aligned} \text{СЕИ}_k &\in \text{СЕИ}, \\ k &= \overline{1, K}. \end{aligned} \quad (3)$$

В отличие от [Auge et al., 2021] согласно (1) смежные по времени входные СЕИ не должны пересекаться. Каждый единичный импульс из входной СЕИ должен поступать на соответствующий ему входной нейрон в состоянии ожидания. Если входной нейрон будет в состоянии невосприимчивости, то поступающий на него импульс будет потерян. По условию (2) пересечения СЕИ, несущих информацию о вводимых в РНС временных рядах на k -е моменты времени, должны отсутствовать. Входные СЕИ, относящиеся к различным временным рядам, должны подаваться на свои непересекающиеся группы входных нейронов.

При несоблюдении этих условий при обработке СЕИ в РНС будут потери информации из-за невозможности возбуждения входных импульсных нейронов, находящихся в состояниях временной невосприимчивости.

Для соблюдения условий (1)–(3) целесообразно кодировать отдельные значения временных рядов не одной, а двумя, тремя и более СЕИ. При таком варианте кодирования первая СЕИ может нести информацию о наибольшем разряде, например десятичного числа, а другие СЕИ — о меньших разрядах. Таким образом, можно кодировать не только значения показателей, но и многие отношения их к реальным объектам.

Обратное преобразование результатов обработки СЕИ в РНС осуществимо по схеме зеркальной прямому преобразованию.

Выполнение условий (1)–(3) также влияет на устойчивость функционирования РНС. При обработке в РНС последовательные СЕИ передаются от слоя к слою. Из-за нахождения нейронов принимающего слоя как в состояниях ожидания, так и невосприимчивости возбужденными нейронами передающего слоя формируются не только возбуждающие, но и тормозящие воздействия. Чем больше возбуждений нейронов на k -м временном такте, тем больше тормозящих воздействий на $(k+1)$ -м такте и, как следствие, меньше возбуждений нейронов на $(k+2)$ -м такте.

За счет этого формируется некоторый баланс между возбуждающими и тормозящими воздействиями в РНС.

Принципиальное отличие предлагаемых правил кодирования сигналов от известных моделей состоит в более полном учете времени невосприимчивости нейронов после возбуждения.

3.2. Алгоритм моделирования работы потоковой РНС

Для раскрытия особенностей этого алгоритма поясним специфику применяемой потоковой импульсной рекуррентной нейронной сети [Osipov, Osipova, 2018]. Это двухслойная РНС (рис. 2). В этой РНС импульсные нейроны одного слоя связаны синапсами только с нейронами другого слоя. Время задержки единичных импульсов в образуемых двухслойных контурах РНС меньше времени невосприимчивости нейронов после возбуждения. В такой нейронной сети при передаче сигналов в виде СЕИ от одного слоя к другому реализуются их пространственные сдвиги. За счет таких сдвигов слои РНС разделяются на одинаковые логические поля, а сеть может наделяться линейной, спиральной, петлевой и другими логическими структурами. Пример РНС с линейной структурой показан на рис. 3.

На уровне нейросетевых каналов эту РНС можно представить в виде рис. 4. В частности, на один из двух связанных каналов могут подаваться СЕИ1, несущие информацию о переменных (показателях) управляемых многомерных временных рядов, а на другой канал — СЕИ2, отражающие значения показателей управляющих также многомерных временных рядов.




Рис. 2. Схема потоковой импульсной рекуррентной нейронной сети

При обработке СЕИ продвигаются не только между слоями РНС, но и вдоль их. Соответствие между входным и выходным языками РНС обеспечивается за счет приоритетности сильных связей между нейронами. В нашем случае проходящие по сети совокупности единичных импульсов связываются в пространстве и во времени только с последующими СЕИ. Результаты связывания запоминаются на элементах РНС.

Суммарное воздействие на вход каждого i -го нейрона принимающего слоя в РНС на момент t_i можно представить суммой воздействий, несущих информацию о сигналах в моменты




Рис. 3. Потокосная РНС с линейной структурой: 1 — линии разбивки слоев на логические поля за счет реализуемых пространственных сдвигов СЕИ, передаваемых от слоя к слою; 2, 3 — направления продвижения СЕИ вдоль и между слоями; 4 — нейроны. Штрихпунктирными стрелками показаны направления рекуррентного ассоциативного вызова СЕИ из памяти в режиме генерации сигналов




Рис. 4. Структура РНС на уровне нейросетевых каналов: 1 — каналы, 2 — рекуррентные ассоциативные взаимодействия обрабатываемых СЕИ

времени $t_k, t_{k-1}, \dots, t_{k-D}$:

$$I_{i\Sigma} = \sum_{j \in E(t_k)} w_{ij}(t_k) \cdot x_j(t_k) + \sum_{j \in E(t_{k-1})} w_{ij}(t_{k-1}) \cdot x_j(t_{k-1}) + \dots + \sum_{j \in E(t_{k-D})} w_{ij}(t_{k-D}) \cdot x_j(t_{k-D}), \quad (4)$$

где $E(t_k), E(t_{k-1}), \dots, E(t_{k-D})$ — пространства логических полей нейронов передающего слоя сети, отвечающих за события в рассматриваемые моменты времени.

Состояние $x_i(t_{k+1})$ i -го нейрона принимающего слоя РНС на момент времени t_{k+1} можно выразить как

$$x_i(t_{k+1}) = \begin{cases} +1, & \text{если } I_{i\Sigma}(t_k) \geq ID_i(t_k), t_{i \text{ ож}} \geq t_{i \text{ реф}}, \\ -1, & \text{если } t_{i \text{ ож}} < t_{i \text{ реф}}, \\ 0 & \text{— в других случаях,} \end{cases} \quad (5)$$

где $ID_i(t_k)$ — порог возбуждения i -го нейрона на момент t_k ; $t_{i \text{ ож}}$ — время ожидания после предыдущего возбуждения i -го нейрона; $t_{i \text{ реф}}$ — длительность невосприимчивости (рефрактерности) i -го нейрона после возбуждения.

Веса $w_{ij}(t_k)$ синапсов в (4) определяются через произведение их весовых коэффициентов $k_{ij}(t_k)$ и функций ослабления $\mu_{ij}(t_k)$ расходящихся единичных импульсов:

$$w_{ij}(t_k) = k_{ij}(t_k) \cdot \mu_{ij}(t_k), \quad (6)$$

$$k_{ij}(t_k) = \frac{1 - \exp(-\gamma \cdot g_{ij}(t_k))}{1 + \exp(-\gamma \cdot g_{ij}(t_k))} = \tanh\left(\frac{\gamma \cdot g_{ij}(t_k)}{2}\right), \quad (7)$$

$$g_{ij}(t_k) = g_{ij}(t_{k-1}) \pm \Delta g_{ij}(t_{k-1}). \quad (8)$$

В (7), (8) приняты следующие обозначения: γ — постоянный коэффициент; $g_{ij}(t_k)$ — суммарное число единичных импульсов, прошедших через соответствующий синапс, с учетом их знака, на момент t_k . Значение $\Delta g_{ij}(t_{k-1})$ зависит от состояний взаимодействующих i -го и j -го нейронов. Если возбужденный j -й нейрон вызвал возбуждение i -го нейрона, то значение $\Delta g_{ij}(t_{k-1})$ положительное. Когда сгенерированный j -м нейроном сигнал воздействует на i -й нейрон в состоянии невосприимчивости, то $\Delta g_{ij}(t_{k-1})$ отрицательно. В остальных случаях $\Delta g_{ij}(t_{k-1}) = 0$. Функции ослабления $\mu_{ij}(t_k)$, за счет изменения которых реализуются пространственные сдвиги СЕИ, можно определить согласно ранее предложенным правилам [Osipov, Osipova, 2018].

Формулы (6)–(8) не противоречат известным правилам Хебба. При определении весовых коэффициентов учитываются условия перехода и нахождения нейронов в состояниях рефрактерности (невосприимчивости).

Равномерная устойчивость по Ляпунову применяемой РНС при обработке потоков информации обеспечивается за счет установления баланса между возбуждающими и тормозящими воздействиями нейронов [Осипов, 2025].

3.3. Особенности правил поиска целесообразной программы цифровизации

Для пояснения этих правил представим структуру РНС на рис. 4 в виде рис. 5. При анализе каждой альтернативной программы цифровизации города предлагается исходить из состояния, когда в РНС при обучении без учителя введены последние СЕИ со стороны подсистемы прямого преобразования временных рядов. Только после этого в сеть начинают поступать лишь СЕИ, несущие информацию об анализируемой программе цифровизации, сформированной ПУПР.




Рис. 5. Структура РНС на уровне нейросетевых каналов при прогнозировании эффективности анализируемых программ цифровизации

При переводе РНС в режим генерации (усиления рекуррентного ассоциативного вызова сигналов из ассоциативной памяти) сетью формируются результаты прогнозирования на задан-

ный горизонт. В формализованном виде это можно представить в виде последовательности смежных состояний РНС:

$$\begin{aligned}
 & \left\{ \begin{array}{c} \text{СЕИ}_1^s, \dots, \text{СЕИ}_K^s \\ \otimes \quad \otimes \quad \otimes \quad \otimes \\ \text{СЕИ}_1^u, \dots, \text{СЕИ}_K^u \end{array} \right\} \rightarrow \left\{ \begin{array}{c} \text{СЕИ}_1^s, \dots, \text{СЕИ}_K^s, \emptyset, \dots, \emptyset \\ \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \\ \text{СЕИ}_1^u, \dots, \text{СЕИ}_K^u, \text{СЕИ}_{K+1}^{u*} \end{array} \right\} \rightarrow \\
 & \rightarrow \left\{ \begin{array}{c} \text{СЕИ}_1^s, \dots, \text{СЕИ}_K^s, \text{СЕИ}_{K+1}^{s*}, \emptyset, \dots, \emptyset \\ \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \\ \text{СЕИ}_1^u, \dots, \text{СЕИ}_K^u, \text{СЕИ}_{K+1}^{u*}, \text{СЕИ}_{K+2}^{u*} \end{array} \right\} \rightarrow \\
 & \rightarrow \left\{ \begin{array}{c} \text{СЕИ}_1^s, \dots, \text{СЕИ}_K^s, \text{СЕИ}_{K+1}^{s*}, \text{СЕИ}_{K+2}^{s*}, \emptyset, \dots, \emptyset \\ \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \quad \otimes \\ \text{СЕИ}_1^u, \dots, \text{СЕИ}_K^u, \text{СЕИ}_{K+1}^{u*}, \text{СЕИ}_{K+2}^{u*}, \text{СЕИ}_{K+3}^{u*} \end{array} \right\}. \quad (9)
 \end{aligned}$$

В (9) приняты следующие обозначения: $\text{СЕИ}_1^s, \dots, \text{СЕИ}_K^s, \text{СЕИ}_1^u, \dots, \text{СЕИ}_K^u$ — последовательности СЕИ в РНС, несущие информацию о показателях (переменных) управляемых и управляющих временных рядов, введенных в сеть со стороны подсистемы прямого преобразования; $\text{СЕИ}_{K+1}^{u*}, \text{СЕИ}_{K+2}^{u*}$ — введенные в РНС СЕИ со стороны ПУПР, несущие информацию об оцениваемой альтернативной программе цифровизации; $\emptyset$ — знак пустых множеств; $\otimes$ — знаки связывания в пространстве и времени обрабатываемых совокупностей единичных импульсов в РНС; $\text{СЕИ}_{K+1}^{s*}, \text{СЕИ}_{K+2}^{s*}$ — результаты прогнозирования.

После получения результатов прогнозирования каждой r -й проанализированной программе PRG_r цифровизации в ПУПР ставится в соответствие значение прогнозной эффективности $W_r(PRG_r)$. Из всех проанализированных программ выбирается наилучшая согласно правилу

$$W_{opt}(PRG_{opt}) = \text{extr}_{r \in R} W_r(PRG_r). \quad (10)$$

В частном случае эффективность $W_r(PRG_r)$ программы PRG_r цифровизации города после преобразования $\text{СЕИ}_{K+1}^{s*}, \text{СЕИ}_{K+2}^{s*}, \dots, \text{СЕИ}_Z^{s*}$ в соответствующие им исходные значения временных рядов управляемых параметров можно рассчитать как

$$W_r(PRG_r) = \sum_{l=N+1}^Z \sum_{i=1}^N A_i \cdot s_i^*(\text{СЕИ}_{lr}^{s*}(PRG_r), t_l), \quad (11)$$

где $s_i^*(\text{СЕИ}_{lr}^{s*}(PRG_r), t_l)$ — спрогнозированное значение i -го временного ряда на момент t_l при реализации программы PRG_r , Z — момент времени, до которого оценивается программа цифровизации, N — число спрогнозированных показателей (переменных) управляемых временных рядов, A_i — относительные веса i -х временных рядов. Возможны и другие варианты показателей эффективности.

В ряде случаев нейросетевое обоснование искомых программ цифровизации осуществимо из стремления минимизировать расхождение между заданным результатом и получаемым прогнозом.

4. Требования к программной реализации нейросетевой системы обоснования управляющих решений по цифровизации города

Для нейросетевого обоснования управляющих решений по цифровизации города рассмотренным методом применяемая РНС должна иметь соответствующие размеры и функционировать с учетом реального масштаба времени. Если требуется обосновывать такие решения на основе

одновременного анализа H временных рядов фиксированной длины с заданными пределами значений параметров, то необходимо ориентироваться на наибольшую СЕИ, отражающую возможные значения временных рядов. При этом число нейронов F в каждом логическом поле слоев РНС должно быть не меньше мощности СЕИ, $F \geq |СЕИ|$. Число G нейронов в каждом слое определяется как $G = F \cdot D \cdot Q$, где D — число одновременно обрабатываемых в РНС последовательных значений параметров одного временного ряда, Q — число СЕИ для кодирования одного значения параметров временного ряда.

Например, для нейросетевой обработки двух временных рядов со значениями показателей в каждом ряде, не превышающими 399, требуются логические поля размером 42 нейрона. На кодирование значений каждого разряда преобразуемого числа в логическом поле отводится своя группа нейронов

При анализе двадцати четырех временных рядов со значениями показателей в каждом ряду, не превышающими 39, потребуются логические поля РНС размером 288 импульсных нейронов. При одновременном анализе в РНС шестидесяти таких СЕИ каждый слой сети должен содержать 17 280 нейронов. При этом полный размер РНС будет равен 34 560 нейронов. Моделирование РНС с такими размерами осуществимо как на скалярных многоядерных, так и на графических процессорах, например, уровня GTX1080.

При реализации применяемой РНС на скалярных процессорах вычислительная сложность C_c задачи пропорциональна квадрату числа N нейронов в каждом слое сети, $C_c = a \cdot N^2$, где a — постоянный коэффициент. При использовании графических процессоров можно распараллелить процесс передачи сигналов от возбужденных нейронов передающего слоя РНС к каждому нейрону принимающего слоя с учетом весов синапсов. Также осуществимо распараллеливание процесса пересчета этих весов синапсов по результатам реакции принимающих нейронов. В результате сложность C_G задачи моделирования РНС сводится к $C_G = b \cdot N$, где b — постоянный коэффициент. Если для моделирования работы каждого нейрона использовать отдельный графический процессор, то потенциально можно исключить зависимость сложности задачи реализации РНС от числа нейронов в каждом слое. Однако это связано с большим расходом аппаратных средств.

Во всех случаях число сохраняемых параметров и требуемый объем памяти пропорциональны квадрату числа нейронов в каждом слое РНС.

5. Результаты моделирования

Для доказательства работоспособности предложенного метода осуществлялось нейросетевое обоснование управляющих решений по цифровизации города на простом примере применительно к данным по Санкт-Петербургу [Итоги... , 2026]. Анализировались одновременно два временных ряда. Это ряд объемов отгруженных компьютеров, электронных и оптических изделий и ряд объемов отгруженной продукции по всем обрабатывающим производствам за вычетом значений первого ряда в млрд руб. Длина каждого ряда составляла 60 месячных значений с января 2021 года по декабрь 2025 года.

Для нейросетевого обоснования решений по цифровизации использовалась реализованная в среде MatLab потоковая РНС с линейной структурой с числом нейронов в каждом слое 1260 единиц. Слои РНС за счет реализуемых пространственных сдвигов СЕИ при передаче СЕИ от слоя к слою делились на 30 логических полей размером по 42 нейрона. Время реализации одного цикла работы РНС на ПЭВМ с четырехядерным процессором Intel Core i3 равнялось одной секунде.

Анализировались программы цифровизации города, отличающиеся друг от друга значениями планируемых объемов отгружаемых компьютеров, электронных и оптических изделий на

год вперед. Программы формировались в ПУПР и подавались в РНС в соответствии с ранее рассмотренными правилами. Структуры трех из этих программ отражены в таблице 1.

В таблице 1 месячные значения показателей программы цифровизации отражают объемы планируемых для отгрузки компьютеров, электронных и оптических изделий в млрд руб. Результаты прогноза эффективности — это объемы ожидаемой отгруженной продукции по всем обрабатывающим производствам, за исключением значений программы в млрд руб.

Из анализа таблицы 1 следует, что на интервале 61–68 (с января по август) 2026 года наилучшей по эффективности выступает вторая программа со значением интегрального показателя 3470. Однако на интервале 61–72 (с января по декабрь) 2026 года на первое место выходит первая программа со значением интегрального показателя 5250. Интегральные показатели определялись как суммы частных показателей на анализируемом интервале времени.

Таблица 1. Результаты прогнозирования эффективности анализируемых программ

№ программы	Годы	2026 год											
	Номера месяцев начиная с 2021 года	61	62	63	64	65	66	67	68	69	70	71	72
1	Значения программы	66	58	46	68	39	63	59	63	59	63	59	63
	Результаты прогноза эффективности	560	590	430	390	430	390	230	390	530	390	530	390
2	Значения программы	66	58	66	48	66	48	69	68	39	49	69	68
	Результаты прогноза эффективности	560	590	430	390	460	390	260	390	230	390	230	390
3	Значения программы	66	58	36	68	39	68	29	69	56	63	56	69
	Результаты прогноза эффективности	560	590	430	390	430	390	230	390	230	390	230	390

Из анализа исходных временных рядов и результатов прогнозирования эффективности исходных программ цифровизации города можно утверждать следующее. С увеличением объемов отгруженных компьютеров, электронных и оптических изделий растут также объемы отгруженной продукции по всем другим обрабатывающим производствам. При этом наибольшие результаты проявляются при планировании равномерных объемов отгруженных компьютеров, электронных и оптических изделий. Примеры результатов компьютерного моделирования в виде графических зависимостей показаны на рис. 6.

Заметим, что сами анализируемые программы, за исключением частного случая, не прогнозируются, а генерируются в ПУПР. Они жестко вводятся в РНС в процессе ассоциативного вызова из ее ассоциативной памяти ожидаемых объемов отгруженной продукции по интересующим обрабатывающим производствам города. На рис. 6, а видно, что при отсутствии ассоциативного рекуррентного вызова сигналов из памяти сети на горизонте прогнозирования присутствует только анализируемая программа. При наличии ассоциативного вызова сигналов из памяти РНС, при работе сети в режиме генерации, помимо анализируемых программ на рис. 6, б, в, г, наблюдаются также результаты прогнозирования.




Рис. 6. Результаты прогнозирования эффективности анализируемых программ цифровизации города в млрд руб: до штрихпунктирной линии (временной интервал 0–60, с января 2021 года по декабрь 2025 года) — значения переменных анализируемых временных рядов; после штрихпунктирной линии (временной интервал 60–70, с января по декабрь 2026 года) — прогнозы; (а) результат без ассоциативного вызова информации из памяти РНС; (б), (в), (г) результаты прогнозирования эффективности первой, второй и третьей программ цифровизации; 1 — месячные объемы отгруженной продукции по всем обрабатывающим производствам за вычетом значений управляющего ряда, 2 — месячные объемы отгруженных компьютеров, электронных и оптических изделий

Проводились исследования по анализу точности прогнозирования временных рядов. В качестве показателей использовались средняя абсолютная ошибка (mean absolute error, MAE), средняя абсолютная процентная ошибка (mean absolute percentage error, MAPE) и среднеквадратическая ошибка (root mean square error, RMSE). Полученные результаты сопоставлялись с аналогичными показателями при применении известных методов. В качестве них выступали методы прогнозирования с использованием долгой краткосрочной памяти (long short – term memory, LSTM) и интегрированной модели авторегрессии — скользящего среднего (autoregressive integrated average, ARIMA). Применение потоковых импульсных РНС по сравнению с LSTM позволяет

снизить MAE на 21,8 %, MAPE на 9,6 %, RMSE на 15,3 %. По отношению к ARIMA выигрыш потоковых импульсных РНС составил по MAE 21,0 %, MAPE — 21,3 %, RMSE — 11,0 %.

За счет использования для нейросетевого обоснования управляющих решений одной потоковой РНС, вместо двух, требуется меньше оперативной памяти, с сохранением точности прогнозирования с непрерывным обучением без учителя. При этом заметим, что предлагаемый метод нейросетевого обоснования управляющих решений по цифровизации города не требует вмешательства в подстройку модели при изменении законов поведения обрабатываемых временных рядов. Метод позволяет без изменения структуры потоковой РНС обрабатывать различные по природе и значениям временные ряды, преобразуя их в последовательности совокупностей единичных импульсов. Подача СЕИ в РНС, согласованная с временем рефрактерности нейронов, позволяет устранить потери вводимой информации с достижением баланса между возбуждающими и тормозящими воздействиями в сети. Учет времени рефрактерности нейронов в РНС также исключает катастрофическое забывание информации в сети при поступлении новых сигналов. Установлено, что суммарный вес синапсов сети, являясь положительным по значению, с увеличением длины последовательностей обрабатываемых СЕИ до 1500 совокупностей стремится к некоторой точке равновесия. Наблюдается равномерное распределение положительных и отрицательных значений весов синапсов. Информация о каждом запоминаемом импульсе распределяется по множеству синапсов РНС, связывающих его с другими импульсами. Поступление новой информации может влиять на постепенное понижение чувствительности ассоциативного вызова информации из памяти РНС, но не приводит к катастрофическому забыванию ранее запомненных сигналов.




Рис. 7. Пример распределения значений положительных и отрицательных ассоциаций сигналов через синапсы между двумя логическими полями

Пример распределения значений положительных и отрицательных ассоциаций сигналов через синапсы между двумя логическими полями (размером $42 = 6 \times 7$ нейронов) разных слоев РНС показан на рис. 7. Оси на рис. 7 соответствуют номерам нейронов, взаимодействующих

двух полей разных слоев РНС. Цветными пикселями обозначены синапсы, через которые реализуются ассоциации между нейронами. Цвет каждого синапса отражает суммарное число единичных импульсов, прошедших через него с учетом их знака. Справа на рис. 7 — цветовая шкала значений.

Установлено также, что количество возбужденных нейронов в РНС при непрерывном обучении находится в пределах некоторой трубки, что соответствует условиям равномерной устойчивости сети по Ляпунову.

В условиях постоянно изменяющихся законов поведения города, когда нет возможности строить его строгие математические модели, предложенный метод позволяет оперативно осуществлять обоснование управляющих программ цифровизации с обучением без учителя. С помощью него можно обосновывать широкий спектр программ цифровизации города, включая массовое внедрение цифровых платформ, обеспечение населения доступом к цифровым сервисам, применение больших языковых моделей, подобных GPT, DeepSeek, интеллектуальных роботов и других цифровых технологий.

Основные преимущества предлагаемого метода состоят в его высокой адаптивности к изменяющейся обстановке, в отсутствии необходимости перестраивать РНС, в расширенных возможностях по обработке различных данных, в невысоких затратах на разработку реализующих его систем по сравнению традиционным математическим и программным моделированием.

6. Заключение

Предложен метод нейросетевого обоснования управляющих решений по цифровизации города, отличающийся от известных решений новой функциональностью и позволяющий снизить затраты на моделирование.

Основу метода составляют модель нейросетевой системы управления цифровизацией города и алгоритмы реализации ее основных функций в части правил прямого и обратного преобразования временных рядов, моделирования работы потоковой РНС, поиска целесообразных программ цифровизации.

В отличие от подходов с применением рекуррентных нейронных сетей LSTM и GRU предлагаемый метод не требует обучения с учителем и позволяет оперативно формировать модели анализируемых временных рядов в потоковой РНС с управляемыми элементами, а затем их использовать для обоснования управляющих решений в условиях высокой неопределенности событий. Возможна обработка различных, заранее неизвестных сигналов без изменения структуры РНС.

Сформулированы новые условия прямого преобразования многомерных временных рядов перед вводом в РНС. При соблюдении этих условий отсутствуют потери информации об этих рядах в РНС и обеспечивается устойчивое ее функционирование.

Определены требования к программной реализации нейросетевой системы обоснования управляющих решений по цифровой трансформации города.

Результаты компьютерного моделирования показали, что применение предложенного метода позволяет успешно находить целесообразные управляющие решения в условиях необходимости анализа трудно формализуемых процессов.

Предлагаемый метод рекомендуется использовать при анализе выборок временных рядов с длиной, превышающей число логических полей в РНС.

Метод также может найти применение для нейросетевого управления другими трудно формализуемыми процессами в обществе и экономике, когда нет возможности в приемлемые сроки строить их математические модели и использовать их для обоснования целесообразных управляющих решений.

Список литературы (References)

- Вавилова Д. Д., Кетова К. В., Зерари Р. Компьютерное моделирование динамики валового регионального продукта: сравнительный анализ нейросетевых моделей // Компьютерные исследования и моделирование. — 2025. — Т. 17, № 6. — С. 1219–1236.
Vavilova D. D., Ketova K. V., Zerari R. Komp'yuternoe modelirovanie dinamiki valovogo regional'nogo produkta: sravnitel'nyj analiz nejrosetevykh modelej [Computer modeling of the gross regional product dynamics: a comparative analysis of neural network models] // Computer Research and Modeling. — 2025. — Vol. 17, No. 6. — P. 1219–1236 (in Russian).
- Вертакова Ю. В., Клевцова М. Г., Положенцева Ю. С. Прогнозирование цифровой трансформации экономики на основе опережающих и сигнальных индикаторов // Экономика и управление. — 2018. — № 11 (157). — С. 47–56. — <https://emjume.elpub.ru/jour/article/view/498>
Vertakova Yu. V., Klevcova M. G., Polozhenceva Yu. S. Prognozirovanie cifrovoj transformacii ekonomiki na osnove operezhayushchih i signal'nyh indikatorov [Forecasting digital transformation of the economy based on leading and alert indicators] // Ekonomika i upravlenie [Economics and Management]. — 2018. — No. 11 (157). — P. 47–56. — <https://emjume.elpub.ru/jour/article/view/498> (in Russian).
- Домащенко Д. В., Никулин Э. Е. Прогнозирование рядов динамики рыночных индикаторов на основе нелинейной авторегрессионной нейронной сети // Статистика и экономика. — 2017. — Т. 14, № 3. — <https://doi.org/10.21686/2500-3925-2017-3-4-9>
Domashchenko D. V., Nikulin E. E. Prognozirovanie ryadov dinamiki rynochnykh indikatorov na osnove nelinejnoj avtoregressionnoj nejronnoj seti [Forecasting time series of the market indicators based on a nonlinear autoregressive neural network] // Statistika i ekonomika [Statistics and Economics]. — 2017. — Vol. 14, No. 3. — <https://doi.org/10.21686/2500-3925-2017-3-4-9> (in Russian).
- Ермакова А. Среднесрочный прогноз влияния цифровой трансформации на экономику: страны Латинской Америки // Международный аспект. — 2022. — № 1–2 (7–8). — С. 53–75. — <https://www.intaspect.ru/jour/article/view/5>
Ermakova A. Srednesrochnyj prognoz vliyaniya cifrovoj transformacii na ekonomiku: strany Latinskoj Ameriki [Medium-term forecast of the impact of digital transformation on the economy: Latin American countries] // Mezhdunarodnyj aspekt [International Aspect]. — 2022. — No. 1–2 (7–8). — P. 53–75. — <https://www.intaspect.ru/jour/article/view/5> (in Russian).
- Итоги социально-экономического развития Санкт-Петербурга за 2021, 2022, 2023, 2024, 2025 годы. — [Электронный ресурс]. — <https://cedipt.gov.spb.ru/monitoring-pokazatelej/analiz-socialno-ekonomicheskogo-razvitiya/itogi-socialno-ekonomicheskogo-razvitiya-sankt-peterburga/> (дата обращения: 12.03.2026).
Itogi social'no-ekonomicheskogo razvitiya Sankt-Peterburga za 2021, 2022, 2023, 2024, 2025 gody. — [Electronic resource]. — <https://cedipt.gov.spb.ru/monitoring-pokazatelej/analiz-socialno-ekonomicheskogo-razvitiya/itogi-socialno-ekonomicheskogo-razvitiya-sankt-peterburga/> (accessed: 12.03.2026; in Russian).
- Осипов В. Ю. Устойчивость интеллектуальной обработки сигналов потоковыми рекуррентными нейронными сетями с непрерывным обучением // Информатика и автоматизация. — 2025. — Т. 24, № 6. — С. 1649–1679.
Osipov V. Yu. Ustojchivost' intellektual'noj obrabotki signalov potokovymi rekurrentnymi nejronnymi setyami s nepreryvnyim obucheniem [Stability of intelligent signal processing by streaming recurrent neural networks with continuous learning] // Informatika i avtomatizaciya [Informatics and Automation]. — 2025. — Vol. 24, No. 6. — P. 1649–1679 (in Russian).
- Осипов В. Ю., Кулешов С. В., Зайцева А. А., Милосердов Д. И. Интеллектуальное нейроуправление новостными потоками с непрерывным обучением // Информационно-управляющие системы. — 2024. — № 6. — С. 35–45.
Osipov V. Yu., Kuleshov S. V., Zajceva A. A., Miloserdov D. I. Intellektual'noe nejroupravlennie novostnymi potokami s nepreryvnyim obucheniem [Intelligent neurocontrol of news streams with continuous learning] // Informacionno-upravlyayushchie sistemy [Information and Control Systems]. — 2024. — No. 6. — P. 35–45 (in Russian).
- Осипов В. Ю., Милосердов Д. И. Программа прогнозирования событий на основе рекуррентных нейронных сетей с управляемыми элементами. RU 2019662053, 16.09.2019. Бюл. № 9.
Osipov V. Yu., Miloserdov D. I. Programma prognozirovaniya sobytij na osnove rekurrentnykh nejronnykh setej s upravlyaemymi ehlementami. RU 2019662053, 16.09.2019. Byul. No. 9 (in Russian).
- Прохоров П. Э., Минашкин В. Г. Анализ и прогнозирование динамики цифровой трансформации экономики Российской Федерации // Вопросы статистики. — 2021. — Т. 28, № 4. — С. 107–120. — <https://doi.org/10.34023/2313-6383-2021-28-4-107-120>
Prohorov P. E., Minashkin V. G. Analiz i prognozirovanie dinamiki cifrovoj transformacii ekonomiki Rossijskoj Federacii [Analysis and forecasting dynamics of digital transformation of economy of the Russian Federation] //

- Voprosy statistiki. — 2021. — Vol. 28, No. 4. — P. 107–120. — <https://doi.org/10.34023/2313-6383-2021-28-4-107-120> (in Russian).
- Хуснутдинов А. О., Хабаров В. И., Карманов В. С. Глубокое обучение для анализа многомерных временных рядов: систематизация типов данных, задач, архитектур и подходов // Системы анализа и обработки данных. — 2025. — Т. 99, № 3. — С. 113–136.
- Husnutdinov A. O., Habarov V. I., Karmanov V. S. Glubokoe obuchenie dlya analiza mnogomernykh vremennykh ryadov: sistematizatsiya tipov dannykh, zadach, arhitektur i podhodov [Deep learning for multivariate time series analysis: systematization of data types, tasks, architectures and approaches] // Sistemy analiza i obrabotki dannykh [Analysis and data processing systems]. — 2025. — Vol. 99, No. 3. — P. 113–136 (in Russian).
- Цифровая трансформация. Основные принципы, этапы и результаты реализации. Москва 2024. — [Электронный ресурс]. — <https://roskachestvo.gov.ru/about/competence/digital/docs/standart.pdf> (дата обращения: 12.03.2026).
- Cifrovaya transformatsiya. Osnovnye principy, etapy i rezul'taty realizatsii. Moskva 2024. — [Electronic resource]. — <https://roskachestvo.gov.ru/about/competence/digital/docs/standart.pdf> (accessed: 12.03.2026; in Russian).
- Юсупов Р. М., Тулупьева Т. В. (ред.) Компьютерные модели развития города. Труды семинара. — СПб.: Наука, 2003. — 112 с.
- Yusupov R. M., Tulupeva T. V. Komp'yuternye modeli razvitiya goroda. Trudy seminar [Computer models of urban development]. — St. Petersburg: Nauka, 2003. — 112 p. (in Russian).
- Auge D., Hille J., Mueller E., Knoll A. A survey of encoding techniques for signal processing in spiking neural networks // Neural Processing Letters. — 2021. — No. 53. — P. 4693–4710. — <https://doi.org/10.1007/s11063-021-10562-2>
- Bragoudakis Z., Krompas I. Greek GDP forecasting using Bayesian multivariate models // Bulletin of Applied Economics. — 2025. — No. 12 (2). — P. 63–76. — <https://dx.doi.org/10.2139/ssrn.4764854>
- Chege C., Kithinji M., Gachoki P. A hybrid VAR-LSTM-GARCH model for multivariate volatility forecasting // International Journal of Data Science and Analysis. — 2025. — Vol. 11, No. 4. — P. 99–113. — DOI: <https://doi.org/10.11648/j.ijdsa.20251104.11>
- Feng S., Zhao P., Liu L., Wu P., Shen Z. HDT: Hierarchical discrete transformer for multivariate time series forecasting // Proceedings of the AAAI Conference on Artificial Intelligence. — 2025. — Vol. 39, No. 1. — P. 746–754. — <https://doi.org/10.48550/arXiv.2502.08302>
- Hana D., Othman S. A. Multivariate time series analysis of the USD/IQD exchange rate using VAR, SVAR, and SVECM models // Statistics Optimization & Information Computing. — 2025. — Vol. 13, No. 5. — P. 1899–1915. — <https://doi.org/10.19139/soic-2310-5070-2371>
- Lawrynczuk M., Zarzycki K. LSTM and GRU type recurrent neural networks in model predictive control: A review // Neurocomputing. — 2025. — No. 632. — 129712.
- Mardjo A., Choksuchat C. HyBiLSTM: Multivariate bitcoin price forecasting using hybrid time series models with bidirectional LSTM // IEEE Access. — 2024. — Vol. 12. — DOI: 10.1109/ACCESS.2024.3386029
- Mendis K., Wickramasinghe M., Marasinghe P. Multivariate time series forecasting: A review. CVIPPR 2024 // 2024 2nd Asian Conference on Computer Vision, Image Processing and Pattern Recognition. — 2024. — No. 58. — doi.org/10.1145/3663976.366424
- Mickiewicz B., Volkava K. Current trends, assessment and directions of digital economy development // VUZF Review. — 2022. — Vol. 7, No. 2. — P. 78–87. — DOI: 10.38188/2534-9228.22.2.08
- Omatu S., Khalid M., Yusof R. Neuro-control and its applications, advances in industrial control. — New York: Springer-Verlag LLC, 2011. — 255 p.
- Osipov V., Nikiforov V., Zhukova N., Miloserdov D. Urban traffic flows forecasting by recurrent neural networks with spiral structures of layers // Neural Computing and Applications. — 2020. — No. 32. — P. 14885–14897. — <https://doi.org/10.1007/s00521-020-04843-5>
- Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements // Neurocomputing. — 2018. — No. 308. — P. 194–204. — <https://doi.org/10.1016/j.neucom.2018.05.009>

- Schwenzer M., Ay M., Bergs T., Abel D.* Review on model predictive control: an engineering perspective // *Int. J. Adv. Manuf. Technol.* — 2021. — No. 117. — P. 1327–1349.
- Shen L., Wang Y., Fan X., Wei Y., Qiu H.* Variable-dynamic multivariate time series forecasting for IoT systems // *IEEE Internet of Things Journal.* — 2025. — Vol. 12, No. 14. — P. 28479–28492. — <https://doi.org/10.1109/JIOT.2025.3565737>
- Tänzer A.* Multivariate macroeconomic forecasting: From DSGE and BVAR to artificial neural networks. — IMFS Working Paper Series. — Goethe University Frankfurt, Institute for Monetary and Financial Stability (IMFS), Frankfurt a.M., 2024. — No. 205. — <https://hdl.handle.net/10419/295733>