



Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением

Д. И. Милосердов^а, канд. техн. наук, старший научный сотрудник, orcid.org/0000-0002-5312-5531, dmmil94@yandex.ru

^аСанкт-Петербургский Федеральный исследовательский центр РАН, 14-я линия В. О., 39, Санкт-Петербург, 191718, РФ

Введение: прогнозирование групп временных рядов является сложной прикладной проблемой, когда необходимо учитывать как внутрисерийные, так и межсерийные взаимосвязи, оперативно реагировать на изменения в законах формирования рядов. **Цель:** совершенствование систем прогнозирования групп временных рядов, позволяющее повысить точность получаемых прогнозов. **Результаты:** разработана усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением, в состав которой включен блок корректировки, позволяющий автоматически подбирать гиперпараметры прогнозирования и производить наиболее корректный ассоциативный вызов информации из памяти нейронной сети. Предложены новые правила реализации системы в программном исполнении с улучшенным ассоциативным вызовом информации из нейросетевой памяти, что повысило устойчивость функционирования самих нейронных сетей. Разработан и программно реализован алгоритм работы блока корректировки, обеспечивающий подбор коэффициента ослабления, ретроспективной глубины компонентов группового временного ряда, а также порога возбуждения нейронов. Исследована зависимость точности прогнозирования от размера нейросетевых каналов. На примере прогнозирования рыночных показателей продемонстрировано преимущество разработанной системы по сравнению с известными аналогами. **Практическая значимость:** усовершенствованная программная система позволяет получать более точные прогнозы временных рядов для решения задач прикладной направленности. Так, средняя абсолютная ошибка снижается на 2–35 %, средняя абсолютная процентная ошибка на 4–37 % и среднеквадратическая ошибка на 3–29 %. **Обсуждение:** в дальнейшем для повышения эффективности системы необходима разработка правил автоматического выбора других гиперпараметров, а также оптимизация алгоритма их подбора для снижения вычислительных затрат.

Ключевые слова – прогнозирование групп временных рядов, прогнозирование многомерных временных рядов, рекуррентная нейронная сеть, автоматический подбор гиперпараметров, управление ассоциативным вызовом.

Для цитирования: Милосердов Д. И. Усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением. *Информационно-управляющие системы*, 2024, № 1, с. 20–30. doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

For citation: Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

Введение

Прогнозирование групп временных рядов является сложной прикладной проблемой. Зачастую оно применяется при анализе трудноразрешимых процессов, законы проявления которых не могут быть в достаточной полноте описаны одним параметром. Востребовано такое прогнозирование при анализе погодных явлений [1–3], финансовых и экономических показателей [4, 5], дорожно-транспортных событий [6], трафика и энергопотребления [7]. Оно применимо также в сельском хозяйстве [8–10].

В настоящее время к прогнозированию групп временных рядов имеется два основных подхода, называемых локальным и глобальным. Суть локального подхода заключается в том, что вводится предположение о наличии своего закона формирования для каждого ряда. Однако такой подход зачастую неэффективен из-за чрезмер-

ной подгонки модели [11]. На снижение точности прогнозирования в этом случае работает и отсутствие учета взаимосвязей между отдельными рядами. Такое прогнозирование неэффективно в условиях влияния рядов друг на друга, например при прогнозировании дорожного трафика на сети дорог [12]. Тем не менее из-за своей простоты объединение простых прогнозных моделей стало наиболее распространенным подходом к автоматическому прогнозированию временных рядов.

Идея глобального подхода заключается в предположении, что все временные ряды в наборе получены в результате одного и того же процесса. Глобальные методы объединяют данные всех рядов вместе и соответствуют единой одномерной функции прогнозирования [11]. Однако это сложная задача, поскольку необходимо учитывать как внутрисерийные временные корреляции, так и межсерийные корреляции одновременно. В последнее время появилось множество

работ, пытающихся зафиксировать обе корреляции, но большинство, если не все из них, фиксируют только временные корреляции во временной области и прибегают к заранее определенным приоритетам в качестве отношений между рядами [13].

При обработке многомерного временного ряда как единого процесса используют различные подходы. Традиционные методы, такие как многомерная линейная регрессия [1], авторегрессия, гауссов процесс [14], оказываются не в состоянии уловить сложные нелинейные зависимости между временными шагами и между несколькими временными рядами [15, 16]. В свою очередь, возможностей классических архитектур нейронных сетей, таких как долгая краткосрочная память (Long Short-Term Memory – LSTM), оказывается недостаточно для моделирования долговременных зависимостей в условиях многомерного временного ряда. Это вынуждает использовать так называемые глубокие LSTM (Deep LSTM), усложняя архитектуру и ее обучение и прибегая к гибридным методам. Остаются ограниченными и возможности нейросетей по моделированию коррелированных функций, имеющих место в многомерных временных рядах [17]. Кроме того, производительность моделей LSTM может сильно зависеть от выбора величины предыстории прогноза [18]. Согласно [19] графовые нейронные сети продемонстрировали достаточно высокие возможности по извлечению скрытых пространственных зависимостей между парами переменных. Между тем такие сети требуют четко определенных графовых структур для распространения информации, что означает, что они не могут быть применены напрямую для многомерных временных рядов, где зависимости заранее неизвестны.

В работе [2] сверточная нейронная сеть сочетается с декомпозицией временного ряда на несколько рядов, удалением высокочастотной составляющей и извлечением основных характеристик и периодических законов временных рядов. В работе [20] предлагается подход для структурно-параметрической настройки когнитивных моделей, основанных на нечетких правилах. В ней показано, что являются актуальными вопросы выбора оптимальной ретроспективной глубины для исследуемых временных рядов.

Кроме того, большинство существующих моделей временных рядов требуют полных данных временных рядов в качестве входных данных, в то время как в реальных наборах данных временных рядов проблема с недостающими данными почти неизбежна из-за различных факторов. Для таких рядов недавно было предложено несколько примечательных подходов, основанных на матрично-тензорной факторизации. Они по-

казали большие возможности прогнозирования, однако эти модели, как правило, требуют тщательной настройки параметров регуляризации, что в свою очередь ведет к большим вычислительным затратам, и стоимость увеличивается экспоненциально с увеличением количества параметров [12].

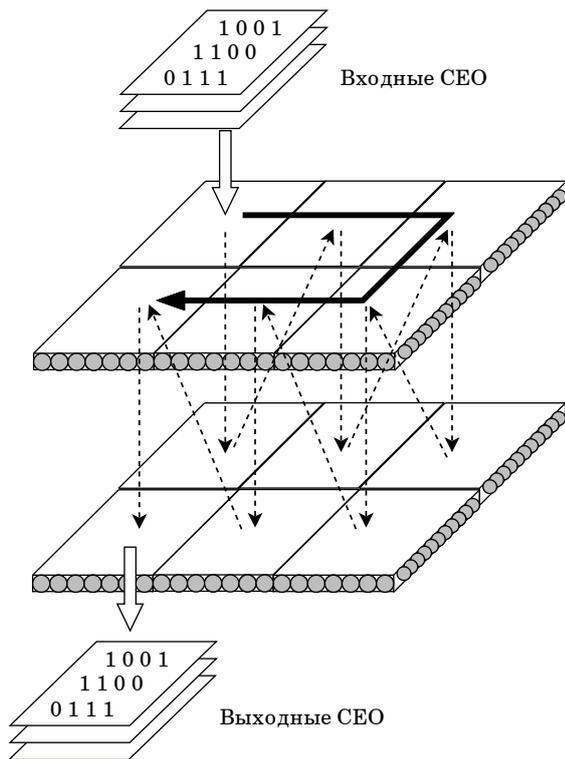
Применяются также гибридные архитектуры [например, 21, 22]. Однако процедура настройки этих моделей должна выполняться для каждой конкретной задачи/набора данных, и универсальных решений в настоящий момент не существует.

Кроме того, законы формирования многомерных временных рядов и их межсерийных связи могут стремительно меняться, что приводит к быстрому устареванию сформированных прогнозных моделей. В таких условиях актуальны методы непрерывного обучения, способные быстро адаптироваться и учитывать новые закономерности при формировании прогнозов.

Постановка задачи совершенствования известной системы нейросетевого прогнозирования групп временных рядов с непрерывным обучением

В последние годы развиваются системы прогнозирования с непрерывным обучением, в основу которых положены рекуррентные нейронные сети (РНС; Recurrent Neural Network – RNN) с управляемыми элементами [23, 24]. Такая нейронная сеть состоит из двух слоев, связанных управляемыми синапсами, и блока управления нейронной сетью. Информационные сигналы передаются посредством единичных импульсов возбужденных нейронов; возбуждение нейрона и излучение импульса происходит при превышении порога возбуждающего потенциала на входе нейрона. Управляемые синапсы сдвигают сигналы при их передаче от слоя к слою, за счет чего реализуется продвижение данных вдоль слоев РНС, от входа к выходу. Слои разбиты на логические поля одинакового размера, а величина сдвига равна размеру логического поля по соответствующей оси. Таким образом, сеть оперирует блоками данных, закодированными в виде состояний нейронов логического поля. Эти блоки данных носят название совокупностей единичных образов (CEO; Sets of Single Patterns – SSP). В зависимости от правил сдвигов CEO при их передаче от слоя к слою, данные могут продвигаться от входа к выходу РНС по различным маршрутам [23, 24]. На рис. 1 приведен пример логической структуры РНС с размером слоев 2×3 логических поля.

В системах прогнозирования с непрерывным обучением имеется две идентичные РНС (РНС1



■ **Рис. 1.** Пример структуры РНС. Черной сплошной стрелкой показан маршрут продвижения СЕО вдоль слоев, черной пунктирной — продвижения от слоя к слою, белой стрелкой показаны точки входа и выхода

■ **Fig. 1.** Example of a structure of RNN. The black solid arrow shows the SSPs route along the layers, the black dotted arrow shows the progress from layer to layer, the white arrow shows the input and output

и РНС2) и блок управления прогнозированием. РНС1 непрерывно находится в режиме обучения. При этом через нее проходит поток данных, закодированных в виде последовательностей СЕО. В процессе такого прохождения на управляемых синапсах посредством изменения их весовых коэффициентов осуществляется установление ассоциативных связей между элементами обрабатываемого потока. Когда возникает необходимость, по команде с блока управления прогнозированием состояние РНС1 копируется в РНС2, и на РНС2 осуществляется прогнозирование [24–26].

Процесс прогнозирования в используемых нейронных сетях осуществляется за счет управления ассоциативным вызовом информации из нейросетевой памяти. Вес синапса, помимо весового коэффициента, включает в свой состав функцию ослабления расходящихся единичных образов [25]

$$\beta_{ij}(t) = 1/(1 + \alpha r_{ij}(t)), \quad (1)$$

которая зависит от коэффициента ослабления α и расстояния между связываемыми синапсом

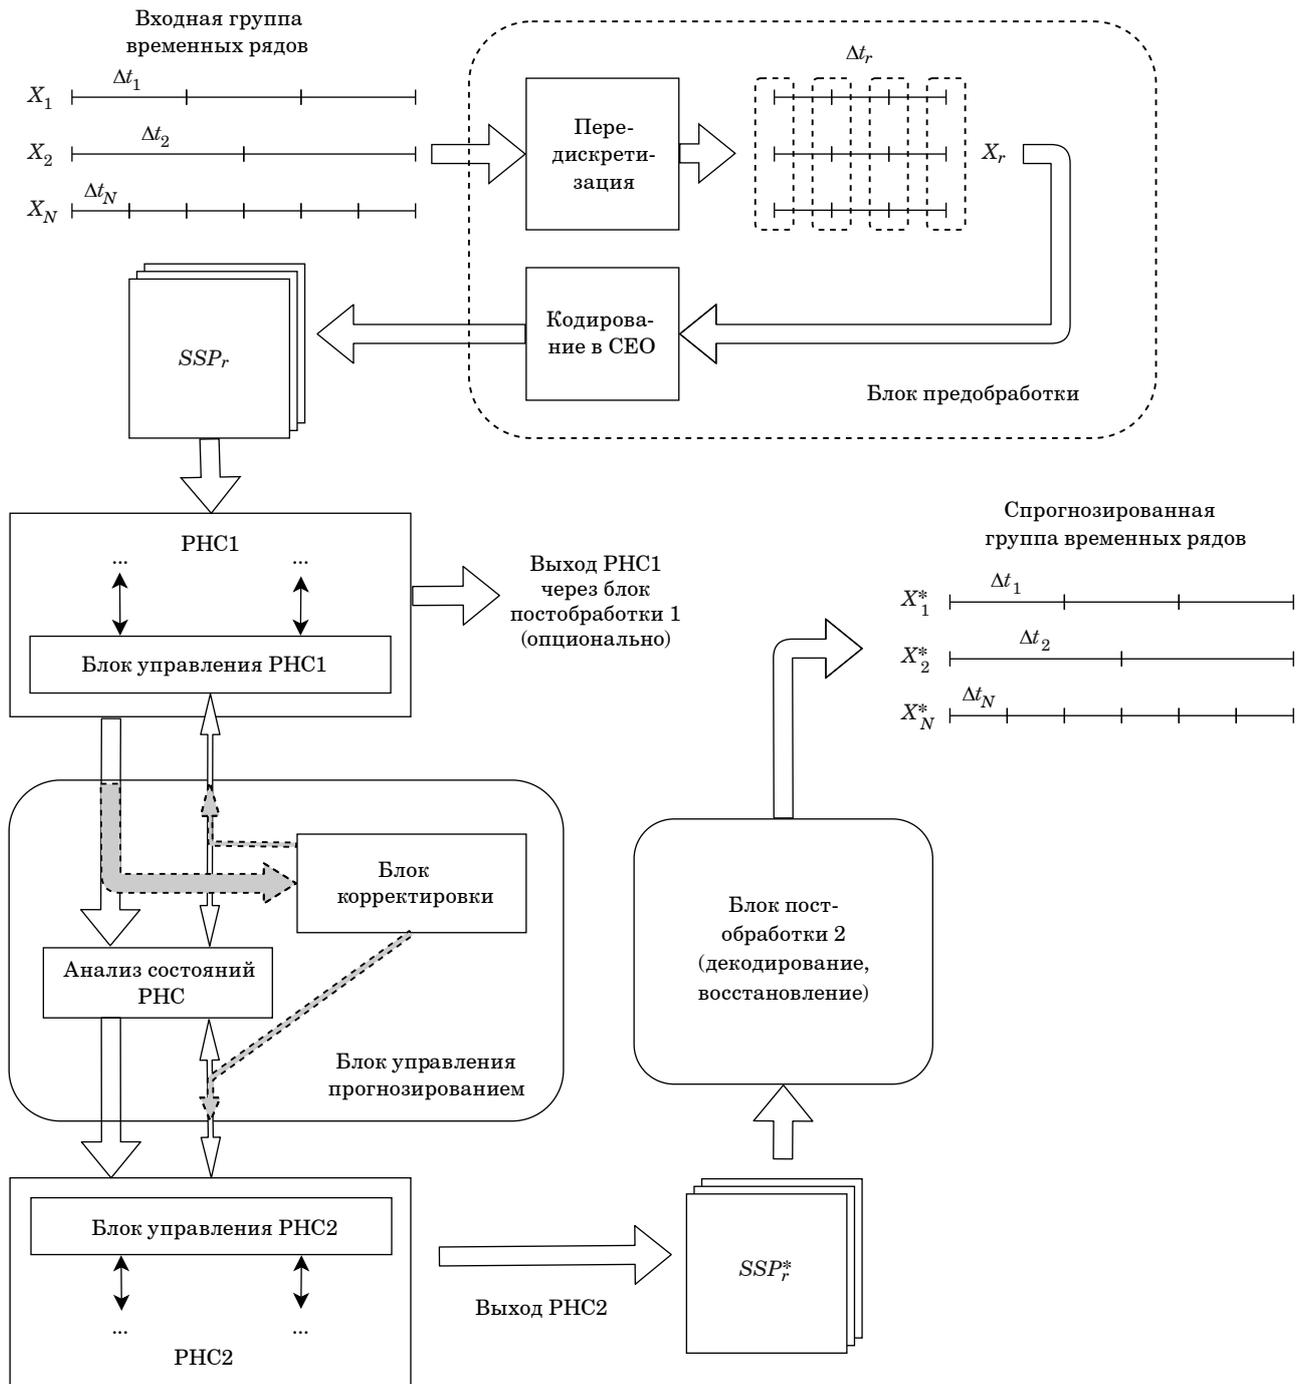
нейронами $r_{ij}(t)$. Варьируя значения α , можно существенно изменять направленность и силу ассоциативного взаимодействия импульсов в сети [25].

Непрерывность обучения и прогнозирования позволяет системе быстро адаптироваться под изменения в законах проявления наблюдаемых событий. Эти свойства делают системы прогнозирования с непрерывным обучением потенциально применимыми для прогнозирования групп временных рядов. В то же время остаются нерешенными вопросы, связанные с управлением гиперпараметрами и устойчивостью функционирования рекуррентных нейронных сетей с управляемыми элементами. Необходимость подбора гиперпараметров приводит к тому, что при отсутствии наблюдения и участия оператора точность прогнозов снижается. Некорректность значений гиперпараметров, таких как порог возбуждения и коэффициент ослабления, может приводить к перегрузке РНС в процессе прогнозирования либо, наоборот, к чрезмерному затуханию и недостатку возбуждающего потенциала нейронов для ассоциативного вызова новой информации. Кроме того, в гиперпараметрах ассоциативного вызова должны быть отражены закономерности наблюдаемого нейросетью потока данных, что не выполняется в случае задания их вручную.

В интересах устранения этих недостатков необходимо усовершенствовать известную систему нейросетевого прогнозирования групп временных рядов с непрерывным обучением.

Усовершенствованная система

Поясним предлагаемые усовершенствования на примере рис. 2. На входе имеются группы временных рядов $\{X_1, X_2, \dots, X_N\}$, которые поступают в блок предобработки. В отличие от известных решений, на блок предобработки, помимо кодирования входного потока в формат СЕО, возлагается задача передискретизации входных рядов и приведения их от собственных интервалов $\Delta t_1, \Delta t_2, \dots, \Delta t_N$ к единому интервалу Δt_r . Метод передискретизации и величина интервала Δt_r выбираются исходя из особенностей временных рядов, которые необходимо обработать, а также аппаратных возможностей используемой вычислительной машины. В блоке предобработки группа временных рядов $\{X_1, X_2, \dots, X_N\}$ преобразуется в набор передискретизированных рядов $\{X_{1r}, X_{2r}, \dots, X_{Nr}\}$, составляющий многомерный ряд X_r , который затем кодируется в последовательность СЕО SSP_r и подается в РНС1. В свою очередь на слоях РНС предусматривается наличие N нейросетевых каналов, по числу об-



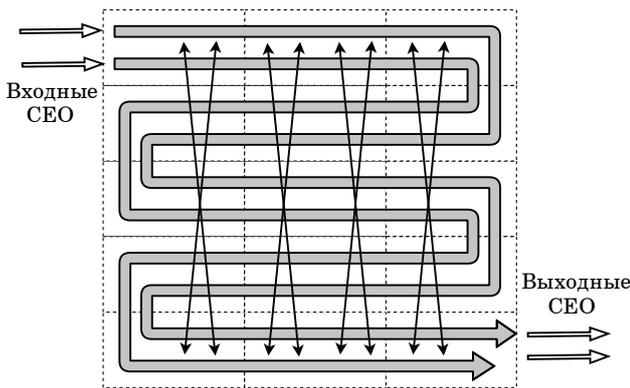
■ **Рис. 2.** Усовершенствованная система прогнозирования групп временных рядов с непрерывным обучением и корректировкой гиперпараметров

■ **Fig. 2.** Improved system for grouped time series forecasting with continuous learning and hyperparameter correction

рабатываемых временных рядов. Под нейросетевым каналом понимается часть нейронов и синапсов РНС, выделяемая для обработки одного временного ряда. Пример канальной структуры слоев РНС для двух рядов и змеевидного маршрута представлен на рис. 3 [24].

В процессе прохождения потока CEO через РНС1 на ее синапсах формируется простран-

ственно-временная модель. Блок управления анализирует состояния слоев РНС и определяет режим прогнозирования [26]. Однако для автоматического подбора гиперпараметров ассоциативного вызова информации из нейросетевой памяти блок управления также наделяется новым блоком, предназначенным для их корректировки. Для этого используется информация о



■ **Рис. 3.** Пример канальной структуры слоев РНС размером 3×5 логических полей (показаны пунктирной линией) для двух нейросетевых каналов (показаны серыми стрелками) и змеевидного маршрута. Тонкими стрелками условно показан процесс установления ассоциативных связей между элементами нейронной сети

■ **Fig. 3.** Example of a channel structure of RNN layers with a size of 3×5 logical fields (shown by a dotted line) for two neural network channels (shown by gray arrows) and a serpentine route. Thin arrows conditionally show the process of establishing associative connections between elements of a neural network

состояниях слоев РНС1 (на рис. 2 показана толстой серой стрелкой). Рассмотрим работу блока корректировки более подробно.

Блок корректировки отвечает за определение порога возбуждения нейронов B и коэффициентов ослабления расходящихся единичных образов α [25]. Кроме того, на этот блок возлагается задача для каждого из рядов $X_{1r}, X_{2r}, \dots, X_{Nr}$ определить глубину предыстории h_1, h_2, \dots, h_N , влияющей на формирование прогнозных значений. Глубина предыстории, используемой в прогнозах для каждого ряда, регулируется длиной фрагмента соответствующего ему нейросетевого канала, при этом

$$h_n \leq H, n = 1, 2, \dots, N, \quad (2)$$

где H — длина нейросетевых каналов в РНС.

Суть работы блока корректировки заключается в подборе значений гиперпараметров, позволяющих произвести наиболее корректный ассоциативный вызов информации из памяти РНС. Процедура ассоциативного вызова прогнозного значения SSP_f в РНС с пространственно-временной моделью W за счет возбуждающего потенциала имеющихся на полях CEO $SSPs$ описывается выражением

$$SSP_f = RNN(W, SSPs, B, h_n, \alpha), \quad (3)$$

где RNN — оператор обработки в нейросети.

Корректировка основывается на оценке состояний слоев РНС1 во время прохождения данных

через нее и обучения. В логическом поле, копия которого в РНС2 предназначена для получения прогнозных значений, с определенной периодичностью оцениваются величины возбуждающих потенциалов на входах нейронов при различных значениях гиперпараметров. Выбранные значения гиперпараметров из блока корректировки затем передаются в блоки управления нейронными сетями, что на рис. 2 обозначено узкими серыми стрелками. Далее эти значения используются для корректного ассоциативного вызова прогнозных значений.

По результату обработки в РНС2 на выходе имеются спрогнозированные последовательности совокупностей единичных образов SSP_n^* , которые передаются в блок постобработки 2. Данный блок выполняет операции, обратные блоку предобработки: сначала декодирует, а потом восстанавливает исходные частоты, в результате чего на выходе системы имеют место спрогнозированные группы временных рядов $\{X_1^*, X_2^*, \dots, X_N^*\}$.

Программная реализация

Нейросетевая система прогнозирования была реализована программно на языке Qt (C++). Программная реализация заимствует некоторые компоненты программного обеспечения эмуляции пары РНС с управляемыми элементами, использованного в [24], в частности, блок визуализации слоев нейронных сетей. Однако внутренняя логика новой программы существенно отличается. В новой реализации проведен рефакторинг, добавлены функции кодирования и декодирования для многомерного временного ряда, реализована канальная структура слоев с возможностью настройки собственной ретроспективной глубины для каждого канала.

Основным отличием новой программной реализации является функция автоматического подбора гиперпараметров прогнозирования в соответствии с предлагаемым усовершенствованием известного метода. Согласно ему при инициализации системы задается набор комбинаций значений гиперпараметров $\{h_n, \alpha\}$. Диапазон возможных значений ретроспективной глубины определяется условием (2). Коэффициент α согласно [25] не может быть больше 0, в то же время по мере его увеличения вклад обучаемых синапсов в ассоциативный вызов информации из нейросетевой памяти становится пренебрежимо малым.

На этапе обучения, как и в известном методе, РНС1 отводится под прохождение последовательности CEO и обучение синапсов. Однако при этом с установленной периодичностью про-

исходит запоминание индексов возбужденных нейронов в логическом поле, копия которого в РНС2 отводится под вызов прогнозных значений (для удобства обозначим это поле F_0), и в логических полях, копии которых в РНС2 будут создавать возбуждающий потенциал для этого вызова (F_p). Когда необходимо осуществить процедуру подбора, для каждой комбинации гиперпараметров из имеющегося набора по запомненным индексам нейронов полей F_p осуществляется расчет возбуждающего потенциала нейронов в поле F_0 . В соответствии с выбранной схемой кодирования данных определяется число нейронов в поле F_0 , на входе которых имеется наибольший возбуждающий потенциал, и выбирается такое значение порога B , при котором эти и только эти нейроны были бы возбуждены. Полученная таким образом оценка сравнивается с фактическим состоянием нейронов F_0 , запомненным во время обучения. Степень сходства определяется показателем «пересечения над объединением». В конечном счете, при прогнозировании в РНС2 выбирается та комбинация гиперпараметров, которая соответствует наибольшему значению этого показателя.

Эксперименты и обсуждение

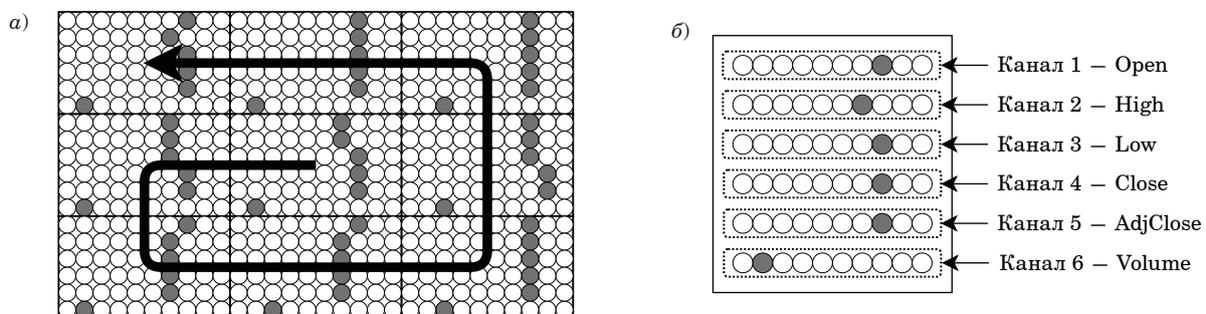
В целях проверки работоспособности усовершенствованной системы проводился ряд экспериментов. В качестве исходных данных для прогнозирования был выбран датасет рыночных показателей Yahoo Finance [27]. Он содержит данные, снимаемые ежедневно (кроме выходных) и включающие показатели: Open, Close, AdjClose – цены на момент открытия и закрытия торгов, смежная цена закрытия; High, Low – наибольшая и наименьшая цена за день; Volume – дневной объем торгов.

В экспериментах прогнозировались все шесть показателей, имеющихся в датасете Yahoo Finance. Таким образом, структура РНС содержала шесть нейросетевых каналов. На кодирование значений каждого канала в первой серии экспериментов отводилось по 10 нейронов. Таким образом, логические поля РНС содержали 60 нейронов. Слои нейронных сетей содержали девять логических полей, маршрут продвижения данных от входа к выходу был выбран в виде расходящейся спирали. Наглядные пояснения структуры РНС, использованной в экспериментах, приведены на рис. 4, а и б.

Кодирование значений каждого показателя осуществлялось следующим образом. Диапазон значений показателя торгов на истории наблюдения разбивался на интервалы, причем количество интервалов равно количеству нейронов в канале. Интервалу, в который попадает текущее значение показателя торгов, ставился в соответствие возбужденный нейрон. Декодирование значений на выходе происходило в обратном порядке.

Для оценивания преимущества по сравнению с другими подходами была выбрана нейронная сеть LSTM. Эта сеть хорошо зарекомендовала себя при обработке временных последовательностей и по сегодня остается одной из самых эффективных и используемых, в том числе при прогнозировании финансово-экономических показателей [28–30].

В каждой серии проведено по семь экспериментов. Глубина прогноза составляла 50 дней, а горизонт – пять дней. Точности прогнозирования определялись по показателям средней абсолютной ошибки (Mean Absolute Error – MAE), средней абсолютной процентной ошибки (Mean Absolute Percentage Error – MAPE), среднеквадратической ошибки (Root Mean Squared Error – RMSE) [24]. Усредненные по приведенным экспе-



■ **Рис. 4.** Структура РНС, использованной в экспериментах: а – общий вид; б – назначение и кодирование показателей торгов в нейросетевых каналах. Серыми кружками показаны возбужденные нейроны, белыми – нейроны в состоянии ожидания, черной стрелкой указан маршрут продвижения данных

■ **Fig. 4.** The structure of the RNN used in the experiments: а – general form; б – assignment and coding of finance indicators in neural network channels. Gray circles show excited neurons, white ones show neurons in a waiting state, the black arrow indicates the route of data

риментам результаты для предлагаемого метода (при размере нейросетевого канала 10 нейронов) и для нейронной сети LSTM приведены в табл. 1.

Полученные результаты свидетельствуют, что усовершенствованная система уверенно превосходит LSTM по усредненным показателям. Так, снижение усредненного MAE по шести показателям торгов составило от 2 до 35 %, MAPE – от 4 до 37 %, RMSE – от 3 до 29 %. Наименьший прирост эффективности достигнут по показателям Close, AdjClose, наибольший – по показателям Open, Low.

Особенностью применения системы является разбиение диапазона значений на интервалы и кодирование интервалов. Это приводит к закруглению результатов пропорционально размеру интервала. Слишком малое число нейронов в канале приводит к увеличению ошибки кодирования, в то же время увеличение числа нейронов при постоянной глубине истории ведет к разреживанию пространственно-временной модели внутри нейронной сети, что также негативно отражается на точности прогнозирования. В целях исследования зависимости величины нейросете-

вых каналов и точности прогнозирования была проведена еще одна серия экспериментов. На тех же исходных данных, что и в первой серии экспериментов, проведено прогнозирование на нейронных сетях с размерами каналов 5, 10, 15 и 20 нейронов. Результаты представлены в табл. 2.

Согласно полученным результатам подтверждается зависимость точности прогнозов от корректного выбора размера нейросетевого канала. В то же время имеется локальный минимум ошибки, который может быть определен на этапе подготовки к прогнозированию, и может быть выбрано целесообразное значение размера нейросетевого канала. В данном примере оно равно 10. На рис. 5, а–в приведены величины ошибок для всех шести прогнозируемых значений, нормированные для наглядности от 0 до 1. Как видно из рисунков, ошибки снижаются по мере увеличения размера каналов и увеличения точности кодирования и приходят к минимуму при размере канала, равном 10, а затем начинают возрастать, что вызвано увеличением разреженности пространственно-временной модели.

■ **Таблица 1.** Значения ошибок для предлагаемой системы и LSTM

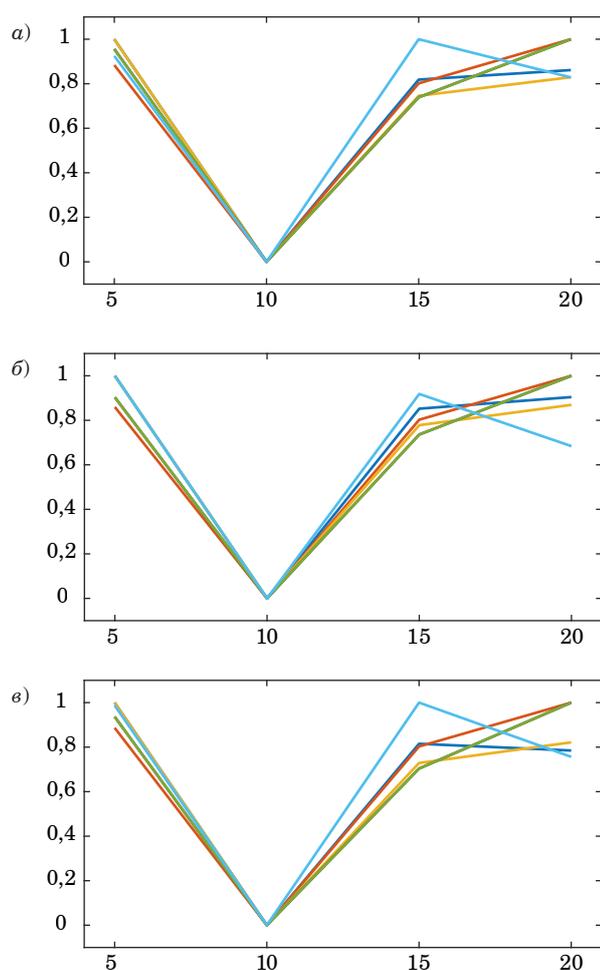
■ **Table 1.** Error values for proposed method and LSTM

Ошибка	Open		High		Low		Close		AdjClose		Volume, ×10 ⁸	
	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM	RNN	LSTM
MAE	42,28	57,38	44,17	52,02	45,42	60,77	57,08	58,54	57,08	59,90	2,73	3,35
MAPE	1,73	2,38	1,78	2,18	1,91	2,58	2,36	2,47	2,36	2,53	10,50	14,34
RMSE	49,06	60,69	48,98	57,17	53,09	68,64	63,91	66,96	63,91	67,15	3,93	4,05

■ **Таблица 2.** Усредненные значения ошибок

■ **Table 2.** Averaged error values

Размер канала	Open	High	Low	Close	AdjClose	Volume, ×10 ⁸
MAE						
5	129,66	124,08	142,47	136,29	136,29	6,18
10	42,28	44,17	45,42	57,08	57,08	2,73
15	113,80	116,66	117,79	118,30	118,30	6,46
20	117,55	134,59	125,91	139,94	139,94	5,82
MAPE						
5	5,18	4,96	5,74	5,44	5,44	26,79
10	1,73	1,78	1,91	2,36	2,36	10,5
15	4,67	4,75	4,89	4,87	4,87	25,46
20	4,85	5,48	5,24	5,77	5,77	21,64
RMSE						
5	133,20	127,32	146,25	140,86	140,86	7,01
10	49,06	48,98	53,09	63,91	63,91	3,93
15	117,64	119,92	120,97	121,71	121,71	7,05
20	115,09	137,33	129,62	146,06	146,06	6,29



■ **Рис. 5.** Динамика ошибок MAE (а), MAPE (б), RMSE (в) в зависимости от величины нейросетевого канала

■ **Fig. 5.** Dynamics of MAE (а), MAPE (б), RMSE (в) errors depending on the size of the neural network channel

Литература

1. **Mudelsee M.** Trend analysis of climate time series: A review of methods. *Earth-Science Reviews*, 2018, vol. 190, pp. 310–322. doi:10.1016/j.earscirev.2018.12.005
2. **Wang J., Li Z.** Wind speed interval prediction based on multidimensional time series of Convolutional Neural Networks. *Engineering Applications of Artificial Intelligence*, 2023, vol. 121, p. 105987. doi:10.1016/j.engappai.2023.105987
3. **Faisal A. N. M., Rahman A., Habib M. T., Siddique A., Hasan M., Khan M.** Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results in Engineering*, 2022, vol. 13, p. 100365. doi:10.1016/j.rineng.2022.100365
4. **Tran Q. H.** The impact of green finance, economic growth and energy usage on CO₂ emission in Vietnam – a multivariate time series analysis. *China Fi-*

Заключение

В статье предложена усовершенствованная система нейросетевого прогнозирования групп временных рядов с непрерывным обучением. На примере прогнозирования группы показателей торгов датасета Yahoo Finance показано, что предлагаемая система позволяет снижать ошибки MAE от 2 до 35 %, MAPE от 4 до 37 %, RMSE от 3 до 29 % по сравнению с известными решениями на основе LSTM. Высокая точность прогнозов обуславливается повышением гибкости управления ассоциативным вызовом информации из нейросетевой памяти. В то же время метод чувствителен к правильности выбора размеров нейросетевых каналов. Показано, что слишком большое или слишком малое количество кодирующих нейронов в нейросетевом канале способно приводить к снижению точности.

В дальнейших исследованиях планируется сосредоточиться на разработке механизмов автоматического определения требуемой величины канала прямо в процессе работы системы. Другим направлением совершенствования системы прогнозирования станет оптимизация процесса подбора гиперпараметров, поскольку перебор возможных их комбинаций становится вычислительно затратным при увеличении числа временных рядов в прогнозируемой группе.

Финансовая поддержка

Исследование выполнено за счет гранта Российского научного фонда № 23-19-20081 (<https://rscf.ru/project/23-19-20081/>) и Санкт-Петербургского научного фонда.

nance Review International, 2022, vol. 12, no. 2, pp. 280–296. doi:10.1108/CFRI-03-2021-0049

5. **Mehtab S., Sen J.** Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. *2nd Intern. Conf. on Advances in Distributed Computing and Machine Learning (ICADCML '21)*, January 15–16, 2021, Bhubaneswar, India, 2020. doi:10.13140/RG.2.2.22226.38083/1
6. **Praveen Kumar B., Hariharan K.** Multivariate time series traffic forecast with long short term memory based deep learning model. *Intern. Conf. on Power, Instrumentation, Control and Computing (PICC 2020)*, December 17–19, 2020, Thrissur, India, 2020, pp. 1–5. doi:10.1109/PICC51425.2020.9362455
7. **Jin M., Zheng Y., Li Y. F., Chen S., Yang B., Pan S.** Multivariate time series forecasting with dynamic graph neural ODEs. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 9, pp. 9168–9180. doi:10.1109/TKDE.2022.3221989

8. **Dittrich I., Gertz M., Maassen-Francke B., Kru-dewig K.-H., Junge W., Krieter J.** Estimating risk probabilities for sickness from behavioural patterns to identify health challenges in dairy cows with multivariate cumulative sum control charts. *Animal*, 2022, vol. 16, p. 100601. doi:10.1016/j.animal.2022.100601
9. **Hounslow J., Fossette S., Byrnes E., Whiting S., Lambourne R., Armstrong N., Tucker A., Richardson A., Gleiss A.** Multivariate analysis of biologging data reveals the environmental determinants of diving behaviour in a marine reptile. *Royal Society Open Science*, 2022, vol. 9, iss. 8. doi:10.1098/rsos.211860
10. **Santos A., Medeiros V., Gonçalves G.** Monitoring and classification of cattle behavior: A survey. *Smart Agricultural Technology*, 2023, vol. 3, p. 100091. doi:10.1016/j.atech.2022.100091
11. **Montero-Manso P., Hyndman R.** Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 2021, vol. 37, iss. 4, pp. 1632–1653. doi:10.1016/j.ijforecast.2021.03.004
12. **Chen X., Sun L.** Bayesian temporal factorization for multidimensional time series prediction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, vol. 44, iss. 9, pp. 4659–4673. doi:10.1109/TPAMI.2021.3066551
13. **Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q.** Spectral temporal graph neural network for multivariate time-series forecasting. *Machine Learning*, 2021. doi.org/10.48550/arXiv.2103.07719
14. **Wan R., Mei S., Wang J., Liu M., Yang F.** Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 2019, vol. 8, iss. 8, p. 876. doi:10.3390/electronics8080876
15. **Huang S., Wang D., Wu X., Tang A.** DSANet: Dual self-attention network for multivariate time series forecasting. *Proc. of the 28th ACM Intern. Conf. on Information and Knowledge Management (CIKM '19)*, Association for Computing Machinery, New York, 2019, pp. 2129–2132. doi:10.1145/3357384.3358132
16. **Wallot S., Mønster D.** Multidimensional joint recurrence quantification analysis: detecting coupling between time series of different dimensionalities. *Data Analysis, Statistics and Probability*, 2023. arXiv. 2303.16907
17. **Sagheer A., Kotb M.** Unsupervised pre-training of a deep LSTM-based stacked autoencoder for multivariate time series forecasting problems. *Scientific Reports*, 2019, vol. 9, p. 19038. doi:10.1038/s41598-019-55320-6
18. **Zhang T., Song S., Li S., Ma L., Pan S., Han L.** Research on gas concentration prediction models based on LSTM multidimensional time series. *Energies*, 2019, vol. 12, iss. 1, p. 161. doi:10.3390/en12010161
19. **Wu Z., Pan S., Long G., Jiang J., Chang X., Zhang C.** Connecting the dots: Multivariate time series forecasting with graph neural networks. *Proc. of the 26th ACM SIGKDD Intern. Conf. on Knowledge Discovery & Data Mining*, 2020, pp. 753–763. doi:10.1145/3394486.3403118
20. **Borisov V., Luferov V.** Forecasting of multidimensional time series basing on fuzzy rule-based models. *XXI Intern. Conf. Complex Systems: Control and Modeling Problems (CSCMP)*, 2019. doi:10.1109/CSCMP45713.2019.8976821
21. **Xu X., Ren W.** A hybrid model of stacked autoencoder and modified particle swarm optimization for multivariate chaotic time series forecasting. *Applied Soft Computing*, 2021, vol. 116, p. 108321. doi:10.1016/j.asoc.2021.108321
22. **Castán-Lascorz M. A., Jiménez-Herrera P., Troncoso A., Cortés G.** A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting. *Information Sciences*, 2021, vol. 586. doi:10.1016/j.ins.2021.12.001
23. **Osipov V., Osipova M.** Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
24. **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, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
25. **Осипов В. Ю., Милосердов Д. И.** Нейросетевое прогнозирование событий для роботов с непрерывным обучением. *Информационно-управляющие системы*, 2020, № 5, с. 33–42. doi:10.31799/1684-8853-2020-5-33-42
26. **Осипов В. Ю., Кулешов С. В., Милосердов Д. И., Зайцева А. А., Аксенов А. Ю.** Рекуррентные нейронные сети с непрерывным обучением в задачах многофункциональной обработки новостных потоков. *Информатика и автоматизация*, 2022, т. 21, № 6, с. 1145–1168. doi:10.15622/ia.21.6.3
27. **YFinance.** <https://pypi.org/project/yfinance/> (дата обращения: 26.07.2023).
28. **Siami-Namini S., Namin A. S.** Forecasting economics and financial time series: ARIMA vs. LSTM. *Machine Learning*, 2018. doi.org/10.48550/arXiv.1803.06386
29. **Mehtab S., Sen J.** *Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models*. Advances in Distributed Computing and Machine Learning. Lecture Notes in Networks and Systems, 2022, vol. 302, pp. 405–423. doi:10.1007/978-981-16-4807-6_39
30. **Sirisha U. M., Belavagi M. C., Attigeri G.** Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 2022, vol. 10, pp. 124715–124727. doi:10.1109/ACCESS.2022.3224938

UDC 004.827

doi:10.31799/1684-8853-2024-1-20-30

EDN: FRWKWP

Advanced neural network forecasting system with continuous learning for grouped time seriesD. I. Miloserdov^a, PhD, Tech., Senior Researcher, orcid/org/0000-0002-5312-5531, dmmil94@yandex.ru^aSt. Petersburg Federal Research Center of the RAS, 39, 14th Line, 199178, Saint-Petersburg, Russian Federation

Introduction: Forecasting of grouped time series is a complex applied problem when it is necessary to take into account both intra-series and inter-series relationships, and promptly respond to changes in the laws of series formation. **Purpose:** To improve forecasting systems for grouped time series, allowing to increase the accuracy of the received forecasts. **Results:** We develop an improved system of neural network forecasting of grouped time series with continuous learning, which includes the correction unit that allows to automatically select hyperparameters of forecasting and make the most correct associative call of information from the neural network memory. We propose new rules for the implementation of the system in software execution with improved associative recall of information from neural network memory, which increases the stability of the functioning of neural networks themselves. We develop and programmatically implement the algorithm of the correction unit operation, which provides the selection of the attenuation coefficient, the retrospective depth of the components of the grouped time series, as well as the threshold of neuronal excitation. The dependence of prediction accuracy on the size of neural network channels is investigated. The example of forecasting market indicators demonstrates the advantage of the developed system in comparison with known analogues. **Practical relevance:** The improved software system makes it possible to obtain more accurate time series forecasts for solving applied problems. Thus, the average absolute error is reduced by 2–35%, the average absolute percentage error by 4–37% and the standard error by 3–29%. **Discussion:** In the future, to increase the efficiency of the system, it is necessary to develop rules for the automatic selection of other hyperparameters, as well as to optimize the algorithm for their selection to reduce computational costs.

Keywords – grouped time series forecasting, multidimensional time series forecasting, recurrent neural network, automatic selection of hyperparameters, control of associative recall.

For citation: Miloserdov D. I. Advanced neural network forecasting system with continuous learning for grouped time series. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2024, no. 1, pp. 20–30 (In Russian). doi:10.31799/1684-8853-2024-1-20-30, EDN: FRWKWP

Financial support

The research is supported by the grant of Russian Science Foundation No. 23-19-20081 (<https://rscf.ru/en/project/23-19-20081/>) and Saint-Petersburg Science Foundation.

References

- Mudelsee M. Trend analysis of climate time series: A review of methods. *Earth-Science Reviews*, 2018, vol. 190, pp. 310–322. doi:10.1016/j.earscirev.2018.12.005
- Wang J., Li Z. Wind speed interval prediction based on multidimensional time series of Convolutional Neural Networks. *Engineering Applications of Artificial Intelligence*, 2023, vol. 121, p. 105987. doi:10.1016/j.engappai.2023.105987
- Faisal A. N. M., Rahman A., Habib M. T., Siddique A., Hasan M., Khan M. Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results in Engineering*, 2022, vol. 13, p. 100365. doi:10.1016/j.rineng.2022.100365
- Tran Q. H. The impact of green finance, economic growth and energy usage on CO₂ emission in Vietnam – a multivariate time series analysis. *China Finance Review International*, 2022, vol. 12, no. 2, pp. 280–296. doi:10.1108/CFRI-03-2021-0049
- Mehtab S., Sen J. Analysis and forecasting of financial time series using CNN and LSTM-based deep learning models. *2nd Intern. Conf. on Advances in Distributed Computing and Machine Learning (ICADCML '21)*, Bhubaneswar, India, 2020. doi:10.13140/RG.2.2.22226.38083/16
- Praveen Kumar B., Hariharan K. Multivariate time series traffic forecast with long short term memory based deep learning model. *Intern. Conf. on Power, Instrumentation, Control and Computing (PICC 2020)*, Thrissur, India, 2020, pp. 1–5. doi:10.1109/PICC51425.2020.9362455
- Jin M., Zheng Y., Li Y. F., Chen S., Yang B., Pan S. Multivariate time series forecasting with dynamic graph neural ODEs. *IEEE Transactions on Knowledge and Data Engineering*, 2023, vol. 35, no. 9, pp. 9168–9180. doi:10.1109/TKDE.2022.3221989
- Dittrich I., Gertz M., Maassen-Francke B., Krudewig K.-H., Junge W., Krieter J. Estimating risk probabilities for sickness from behavioural patterns to identify health challenges in dairy cows with multivariate cumulative sum control charts. *Animal*, 2022, vol. 16, p. 100601. doi:10.1016/j.animal.2022.100601
- Hounslow J., Fossette S., Byrnes E., Whiting S., Lambourne R., Armstrong N., Tucker A., Richardson A., Gleiss A. Multivariate analysis of biologging data reveals the environmental determinants of diving behaviour in a marine reptile. *Royal Society Open Science*, 2022, vol. 9, iss. 8. doi:10.1098/rsos.211860
- Santos A., Medeiros V., Gonçalves G. Monitoring and classification of cattle behavior: a survey. *Smart Agricultural Technology*, 2023, vol. 3, p. 100091. doi:10.1016/j.atech.2022.100091
- Montero-Manso P., Hyndman R. Principles and algorithms for forecasting groups of time series: Locality and globality. *International Journal of Forecasting*, 2021, vol. 37, iss. 4, pp. 1632–1653. doi:10.1016/j.ijforecast.2021.03.004
- Chen X., Sun L. Bayesian temporal factorization for multidimensional time series prediction. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, vol. 44, iss. 9, pp. 4659–4673. doi:10.1109/TPAMI.2021.3066551
- Cao D., Wang Y., Duan J., Zhang C., Zhu X., Huang C., Tong Y., Xu B., Bai J., Tong J., Zhang Q. Spectral temporal graph neural network for multivariate time-series forecasting. *Machine Learning*, 2021. doi.org/10.48550/arXiv.2103.07719
- Wan R., Mei S., Wang J., Liu M., Yang F. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*, 2019, vol. 8, iss. 8, p. 876. doi:10.3390/electronics8080876
- Huang S., Wang D., Wu X., Tang A. DSANet: Dual self-attention network for multivariate time series forecasting. *Proc. of the 28th ACM Intern. Conf. on Information and Knowledge Management (CIKM '19)*, Association for Computing Machinery, New York, 2019, pp. 2129–2132. doi:10.1145/3357384.3358132
- Wallot S., Mønster D. Multidimensional joint recurrence quantification analysis: detecting coupling between time series of different dimensionalities. *Data Analysis, Statistics and Probability*, 2023. arXiv:2303.16907
- Sagheer A., Kotb M. Unsupervised pre-training of a deep LSTM-based stacked autoencoder for multivariate time series forecasting problems. *Scientific Reports*, 2019, vol. 9, p. 19038. doi:10.1038/s41598-019-55320-6
- Zhang T., Song S., Li S., Ma L., Pan S., Han L. Research on gas concentration prediction models based on LSTM multidimensional time series. *Energies*, 2019, vol. 12, iss. 1, p. 161. doi:10.3390/en12010161
- Wu Z., Pan S., Long G., Jiang J., Chang X., Zhang C. Connecting the dots: Multivariate time series forecasting with

- graph neural networks. *Proc. of the 26th ACM SIGKDD Intern. Conf. on Knowledge Discovery & Data Mining*, 2020, pp. 753–763. doi:10.1145/3394486.3403118
20. Borisov V., Luferov V. Forecasting of multidimensional time series basing on fuzzy rule-based models. *XXI Intern. Conf. Complex Systems: Control and Modeling Problems (CSCMP)*, 2019. doi:10.1109/CSCMP45713.2019.8976821
 21. Xu X., Ren W. A hybrid model of stacked autoencoder and modified particle swarm optimization for multivariate chaotic time series forecasting. *Applied Soft Computing*, 2021, vol. 116, p. 108321. doi:10.1016/j.asoc.2021.108321
 22. Castán-Lascorz M. A., Jiménez-Herrera P., Troncoso A., Cortés G. A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting. *Information Sciences*, 2021, vol. 586. doi:10.1016/j.ins.2021.12.001
 23. Osipov V., Osipova M. Space-time signal binding in recurrent neural networks with controlled elements. *Neurocomputing*, 2018, vol. 308, pp. 194–204. doi:10.1016/j.neucom.2018.05.009
 24. 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, vol. 32, pp. 14885–14897. doi:10.1007/s00521-020-04843-5
 25. Osipov V. Yu., Miloserdov D. I. Neural network event forecasting for robots with continuous training. *Informatsionno-upravliaiushchie sistemy* [Information and Control Systems], 2020, no. 5, pp. 33–42 (In Russian). doi:10.31799/1684-8853-2020-5-33-42
 26. Osipov V., Kuleshov S., Miloserdov D., Zaytseva A., Aksenov A. Recurrent neural networks with continuous learning in problems of news streams multifunctional processing. *Informatics and Automation*, 2022, vol. 21, no. 6, pp. 1145–1168 (In Russian). doi:10.15622/ia.21.6.3
 27. *YFinance*. Available at: <https://pypi.org/project/yfinance/> (accessed 26 July 2023).
 28. Siami-Namini S., Namin A. S. Forecasting economics and financial time series: ARIMA vs. LSTM. *Machine Learning*, 2018. doi.org/10.48550/arXiv.1803.06386
 29. Mehtab S., Sen J. *Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models*. In: *Advances in Distributed Computing and Machine Learning*. Lecture Notes in Networks and Systems, 2022, vol. 302, pp. 405–423. doi:10.1007/978-981-16-4807-6_39
 30. Sīrisha U. M., Belavagi M. C., Attigeri G. Profit prediction using ARIMA, SARIMA and LSTM models in time series forecasting: A comparison. *IEEE Access*, 2022, vol. 10, pp. 124715–124727. doi:10.1109/ACCESS.2022.3224938

УВАЖАЕМЫЕ АВТОРЫ!

Научные базы данных, включая Scopus и Web of Science, обрабатывают данные автоматически. С одной стороны, это ускоряет процесс обработки данных, с другой — различия в транслитерации ФИО, неточные данные о месте работы, области научного знания и т. д. приводят к тому, что в базах оказывается несколько авторских страниц для одного и того же человека. В результате для всех по отдельности считаются индексы цитирования, что снижает рейтинг ученого.

Для идентификации авторов в сетях Thomson Reuters проводит регистрацию с присвоением уникального индекса (ID) для каждого из авторов научных публикаций.

Процедура получения ID бесплатна и очень проста, есть возможность провести регистрацию на 12 языках, включая русский (чтобы выбрать язык, кликните на зеленое поле сверху справа на стартовой странице): <https://orcid.org>