

КЛАССИФИКАЦИЯ ИЗОБРАЖЕНИЙ ВРЕМЕННЫХ РЯДОВ С ИСПОЛЬЗОВАНИЕМ ГЛУБОКИХ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

Э. Г. Тунян^{1,2,a}, Р. С. Сазиков^{1,2,3,b}, Т. В. Гавриленко^{1,3,c}

¹ Сургутский государственный университет, г. Сургут, Российская Федерация

² ООО «ЕДРО», г. Сургут, Российская Федерация

³ Сургутский филиал федерального государственного бюджетного учреждения «Федеральный научный центр Научно-исследовательский институт системных исследований Национального исследовательского центра «Курчатовский институт», г. Сургут, Российская Федерация

^a ORCID: <https://orcid.org/0009-0003-3260-1310>, ✉ tunyan@edro.su

^b ORCID: <https://orcid.org/0009-0005-0078-0013>, sazikov@edro.su

^c ORCID: <https://orcid.org/0000-0002-3243-2751>, taras.gavrilenko@gmail.com

Аннотация: работа посвящена задаче классификации временных рядов с использованием методов глубокого обучения, однако исходный сигнал здесь не обрабатывается напрямую. Сначала его переводят в двумерное представление — через рекуррентные диаграммы, которые фиксируют, когда система возвращается в схожие состояния и насколько часто это происходит. Такой шаг не всегда выглядит очевидным, но на практике упрощает дальнейшую обработку, после него ряд можно рассматривать как изображение и применять сверточные сети. Архитектура при этом остается достаточно стандартной: несколько сверточных слоев, затем подвыборка для уменьшения размерности и полносвязная часть, где формируется итоговое решение. Признаки заранее не задаются, они формируются в процессе обучения, хотя итог сильно зависит от того, насколько удачно выбрано само представление сигнала.

Ключевые слова: временные ряды, классификация, сверточные нейронные сети, глубокое обучение, рекуррентные диаграммы, преобразование данных, распознавание образов, извлечение признаков, машинное обучение.

Благодарности: работа выполнена в рамках государственного задания НИЦ «Курчатовский институт» — НИИСИ по теме № FNEF-2024-0001 «Создание и реализация доверенных систем искусственного интеллекта, основанных на новых математических и алгоритмических методах, моделях быстрых вычислений, реализуемых на отечественных вычислительных системах» (1023032100070-3-1.2.1).

Для цитирования: Тунян Э. Г., Сазиков Р. С., Гавриленко Т. В. Классификация изображений временных рядов с использованием глубоких сверточных нейронных сетей. *Успехи кибернетики*. 2026;7(2):139–145.

Поступила в редакцию: 25.04.2026.

В окончательном варианте: 15.05.2026.

TIME SERIES CLASSIFICATION USING RECURRENCE PLOTS AND DEEP CONVOLUTIONAL NEURAL NETWORKS

E. G. Tunyan^{1,2,a}, R. S. Sazikov^{1,2,3,b}, T. V. Gavrilenko^{1,3,c}

¹ Surgut State University, Surgut, Russian Federation

² EDRO, OOO, Surgut, Russian Federation

³ Surgut Branch of Scientific Research Institute for System Analysis of the National Research Centre “Kurchatov Institute”, Surgut, Russian Federation

^a ORCID: <https://orcid.org/0009-0003-3260-1310>, ✉ tunyan@edro.su

^b ORCID: <https://orcid.org/0009-0005-0078-0013>, sazikov@edro.su

^c ORCID: <https://orcid.org/0000-0002-3243-2751>, taras.gavrilenko@gmail.com

Abstract: we addressed the problem of time series classification using deep learning methods, where the raw signal is not processed directly. We first transformed the one-dimensional signal into a two-dimensional representation using recurrence plots, which capture when the system revisits similar states and how frequently these returns occur. This transformation is not always intuitive, but it simplifies subsequent processing, since the resulting representation can be treated as an image and processed using convolutional neural networks. We used a standard convolutional architecture consisting of several convolutional layers, followed by pooling layers for dimensionality reduction and a fully

connected layer that produces the final prediction. The model does not rely on manually designed features, as features are learned during training. However, the final performance strongly depends on how well the chosen signal representation preserves the relevant structure of the original time series.

Keywords: ntime series, classification, convolutional neural networks, deep learning, recurrent diagrams, data transformation, pattern recognition, feature extraction, machine learning.

Acknowledgements: this study is a part of the FNEF-2024-0001 government order contracted to the NRC “Kurchatov Institute” – SRISA, project No. 1023032100070-3-1.2.1 Development and Implementation of Trusted Artificial Intelligence Systems Based on new Mathematical Methods and Algorithms, Fast Computing Models for Domestic Computing Systems.

Cite this article: Tunyan E. G., Sazikov R. S., Gavrilenko T. V. Time Series Classification Using Recurrence Plots and Deep Convolutional Neural Networks. *Russian Journal of Cybernetics*. 2026;7(2):139–145.

Original article submitted: 25.04.2026.

Revision submitted: 15.05.2026.

Введение

Временной ряд обычно понимается как упорядоченная во времени последовательность наблюдений, где сама временная структура играет определяющую роль, а не просто служит фоном. Подобные данные встречаются в самых разных прикладных областях – от биомедицинских сигналов (ЭЭГ, ЭКГ) до финансовых показателей, промышленных сенсоров и биометрии. Сюда же можно отнести анализ видео, музыки и задачи прогноза, включая погодные. Соответственно, спектр задач достаточно широк: аппроксимация, прогнозирование, сегментация, классификация и кластеризация. В простейшем случае классификации каждой последовательности фиксированной длины сопоставляется метка класса, хотя используемые методы нередко переносятся и на смежные задачи – не всегда без дополнительных оговорок [1].

Подходы к классификации временных рядов обычно различают либо по типу признаков (временная или частотная область), либо по стратегии работы с данными. В последнем случае выделяют методы, основанные на сравнении с примерами из обучающей выборки (например, метод *k*-ближайших соседей или *Dynamic Time Warping*), и методы, использующие предварительное извлечение признаков с последующей классификацией. Первые просты и интуитивны, но могут страдать от проблем масштабируемости, вторые – более гибкие, хотя требуют аккуратного выбора представления. В последние годы усилился интерес к глубокому обучению, где признаки формируются автоматически. Особенно это касается сверточных нейронных сетей. Их успешность в задачах компьютерного зрения известна, однако при работе с временными рядами такие модели требуют более осторожного применения и, по сути, все еще находятся в стадии активного осмысления [2].




Рис. 1. Преобразование временного ряда в рекуррентную диаграмму (исходный сигнал, фазовое пространство, матрица расстояний) (составлено авторами на основе экспериментальных данных)

На рисунке 1 фактически показан весь переход от исходного временного ряда к его рекуррентной форме, хотя читается это не сразу. Слева – простой сигнал *xxx* из 12 точек. На первый взгляд, он выглядит почти тривиально, но, если присмотреться, там уже есть повторяющиеся фрагменты, просто они «размазаны» по оси времени. Дальше ряд начинают развора-

чивать в фазовое пространство с задержкой ($\tau = 1$), берутся пары соседних значений, то есть $s_1 = (x_1, x_2)$, $s_2 = (x_2, x_3)$, ..., $s_{11} = (x_{11}, x_{12})$. В итоге получается набор точек на плоскости – траектория, пусть и в самой простой размерности, но она уже ведет себя иначе, чем исходный график. После этого вводится матрица R , размером 11×11 : берутся все полученные состояния и просто сравниваются попарно через расстояние $R_{ij} = \text{dist}(s_i, s_j)$. Сначала это выглядит довольно формально – таблица и таблица, ничего особенного. Но потом начинает проявляться структура: похожие состояния оказываются рядом, и за счет этого видны повторения, которые в исходном ряду как-то терялись. Причем сам сигнал при этом не меняется, только способ записи – но этого оказывается достаточно, чтобы картина воспринималась иначе [3].

Сверточные сети здесь появляются не случайно, с ними обычно не приходится отдельно разбираться, какие признаки вытаскивать из данных. В случае CNN все это смешано в одном процессе, и сеть сама постепенно подстраивается под вход. Архитектура при этом собирается из повторяющихся частей – свертка, затем уменьшение размерности, дальше нелинейность. Нормализация добавляется не всегда и зависит от конкретной реализации. Часто на первых слоях сеть ловит более простые зависимости, а дальше – более сложные, но в реальной модели это не так четко разделено, и граница между ними скорее угадывается, чем действительно фиксируется [4].

В рамках данного исследования рассматривается сочетание рекуррентных диаграмм (RP) и CNN для классификации временных рядов. RP позволяет отразить повторяемость состояний траектории в фазовом пространстве в виде двумерного представления. Несмотря на неочевидность такого преобразования, оно оказывается полезным: временные ряды переводятся в изображения, и задача сводится к распознаванию текстур. Для этого используется CNN с двумя скрытыми слоями и последующим полносвязным слоем – конфигурация, выбранная как разумный баланс между сложностью модели и ее выразительностью [5].

Материалы и методы

В разделе кратко рассматриваются работы по применению глубокого обучения к классификации временных рядов. Еще недавно такие подходы оставались на периферии, но интерес к ним заметно вырос, хотя единых решений пока нет. Можно выделить два направления: либо CNN адаптируют под одномерные сигналы, либо временные ряды сначала переводят в изображения и затем обрабатывают привычными методами компьютерного зрения. Первый вариант реализуется, например, в моделях типа TDNN, но их глубины часто недостаточно для извлечения сложных зависимостей. Во втором случае применяются более мощные архитектуры, иногда даже с обучением в частотной области – решение, которое не всегда выглядит очевидным [6].

Существуют и промежуточные подходы: многоканальные сети для многомерных данных, предварительный отбор признаков, переход к представлению «время–частота», а также многомасштабные модели, где признаки извлекаются на разных уровнях. В задачах анализа активности данные нередко разбиваются на сегменты и подаются как изображения – при всей условности такой схемы она работает. В предлагаемом подходе это разделение снимается: признаки и классификация обучаются совместно, что, по имеющимся результатам, дает более устойчивое качество [7].



Рис. 2. Архитектура сверточной нейронной сети для классификации временных рядов (преобразование сигнала в изображение и последовательность слоев CNN) (составлено авторами на основе разработанной модели)

На рисунке 2 представлена используемая двухэтапная архитектура CNN для классификации временных рядов. Рекуррентные диаграммы предварительно масштабируются до размеров 28×28 , 56×56 или 64×64 (в зависимости от конкретного набора данных) и подаются на вход сети. Архитектура, обозначаемая как 32(5)-2-32(5)-2-125-с, включает два сверточных слоя, два слоя подвыборки и два полносвязных слоя. Подобная конфигурация, несмотря на свою относительную компактность, демонстрирует достаточную выразительную способность, хотя вопрос о ее оптимальности остается открытым [8].

Для временных рядов довольно типична ситуация, когда одни и те же состояния со временем повторяются. Часто встречаются более сложные, нерегулярные циклы, которые по самому ряду уловить непросто. Такая повторяемость обычно связывается с поведением динамических, в том числе нелинейных, систем или стохастических процессов, из которых и формируются наблюдаемые сигналы. Рекуррентные диаграммы (Recurrence Plots, RP) используют именно эту особенность: траектория, заданная в фазовом пространстве размерности m , отображается на плоскость, и за счет этого становятся заметны возвраты в близкие состояния. Идея здесь достаточно простая: фиксируются моменты, когда система оказывается рядом с уже пройденными точками, – хотя в явном виде это задается формально следующим образом [9]:

$$R_{ij} = \theta(\varepsilon - \|s_i - s_j\|), s(\cdot) \in R^m, i, j = 1, \dots, K$$

где:

K обозначает число рассматриваемых состояний;

$\|\cdot\|$ – порог расстояния;

$\theta(\cdot)$ – выбранная норма;

R – функция Хевисайда.

На этом этапе уже начинает сказываться выбор параметров, причем не всегда понятно сразу, в какую сторону. Та же матрица R может выглядеть по-разному: иногда проступают линии, иногда почти ничего, кроме отдельных точек. По таким рисункам обычно пытаются что-то сказать о поведении системы, но это не всегда работает одинаково. Ослабление структуры к краям часто принимают за признак тренда, вертикальные или горизонтальные участки – за медленное изменение состояния. Хотя это зависит от настроек сильнее, чем хотелось бы: при небольшом сдвиге параметров картина меняется, и прежнее объяснение уже не выглядит таким очевидным [10].

На рисунке 1 показан простой пример. Сначала ряд разворачивается в фазовое пространство при $m = 2$, затем для полученных состояний считается матрица R – фактически попарные расстояния между точками. Если вводить порог, она становится бинарной (0 и 1), что удобно, но часть информации при этом теряется: различия между близкими состояниями сглаживаются, и это иногда сказывается на дальнейшей обработке [11]. В рамках метода классификации временных рядов с использованием CNN от жесткой бинаризации отказываются, переходя к полутонным текстурным изображениям на основе R . Эти изображения используются как вход для модели: исходные одномерные ряды x_n преобразуются в двумерные рекуррентные структуры, после чего признаки и классификатор обучаются совместно в рамках CNN [12].

На рисунке 3 иллюстрируется применение рекуррентных диаграмм с параметрами ($m = 3$, $\tau = 4$) для кодирования временных рядов в виде изображений на примере пяти наборов данных из архива UCR Time Series Archive (50words, TwoPatterns, FaceAll, OliveOil и Yoga). Уже на уровне визуального анализа можно заметить различия в текстурных характеристиках, хотя их формализация требует более строгих методов [13].

Операция подвыборки (pooling) используется для уменьшения размерности карт признаков, но этим ее роль не ограничивается. При агрегации значений в локальных областях часть деталей неизбежно теряется, зато представление становится более устойчивым к небольшим изменениям во входных данных – сдвигам, шуму, локальным искажениям. Визуально это часто выглядит как некоторое «сглаживание» структуры: резкие различия ослабляются, остаются более крупные элементы. В ряде задач это оказывается полезным, хотя при слишком агрессивной подвыборке можно, наоборот, потерять значимую информацию [14].

После завершения двух этапов извлечения признаков полученные карты уже не обрабатываются как двумерные структуры – их разворачивают в вектор и передают дальше. На этом

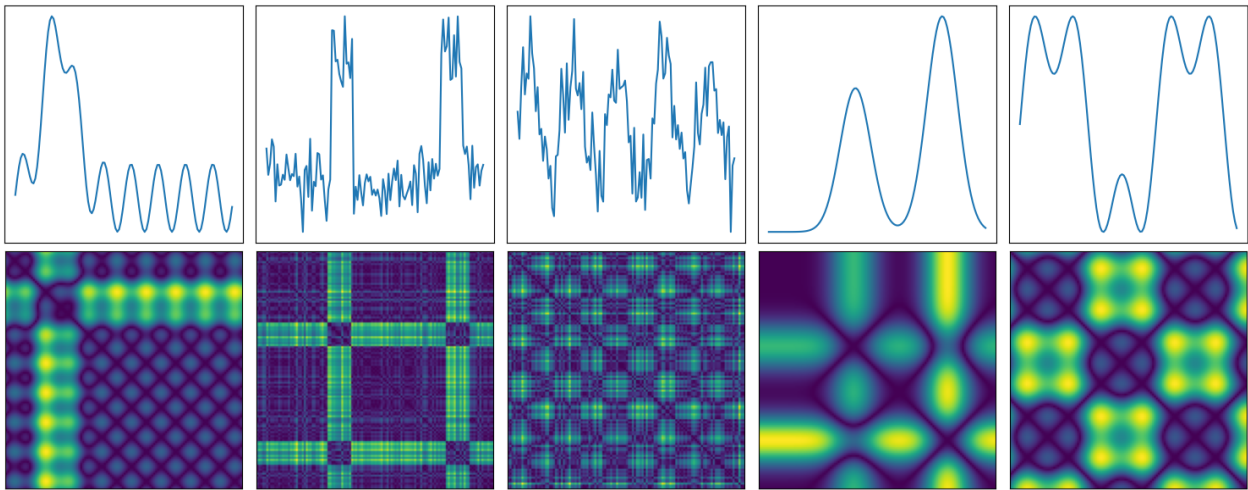


Рис. 3. Преобразование временных рядов в рекуррентные диаграммы для различных наборов данных (составлено авторами на основе экспериментальных данных)

этапе в работу вступает полносвязный слой, где каждый нейрон связан со всеми входами. Такая схема во многом напоминает классический многослойный перцептрон, но здесь она играет скорее завершающую роль: именно здесь происходит разделение по классам.

Обучение модели велось итерационно. Сначала для текущих данных считается выход сети (feedforward – то есть обычный проход от входа к выходу), затем по разнице между предсказанием и правильным ответом корректируются веса [15]. Ошибка не просто фиксируется, а распространяется обратно через слои (backpropagation), из-за чего становится понятно, какие параметры сильнее влияют на итог. На практике эти шаги идут один за другим и не всегда ощущаются как строго разделенные этапы [16].

Результаты

Для оценки эффективности предложенного подхода использован архив UCR Time Series Archive, который часто применяется при сравнении методов классификации временных рядов. Он включает 85 наборов данных, заметно различающихся по размеру и по типу сигналов – от относительно простых до более сложных и шумных. За счет этого можно проверить поведение метода на разных задачах, хотя итоговые результаты, естественно, зависят от того, какие именно наборы выбраны для экспериментов. В данной работе использована выборка из 20 датасетов. Такой набор встречается в ряде работ и позволяет сопоставлять полученные результаты без дополнительных преобразований [17].

В архиве обучающие и тестовые выборки заданы заранее, что упрощает сопоставление результатов с другими работами.




Рис. 4. Визуализация фильтров сверточных слоев CNN для набора данных TwoPattern (составлено авторами на основании результатов обучения модели)

Экспериментальная часть реализована на языке Python с использованием библиотек

Keras, Theano и TensorFlow. Вычисления проводились на системе с процессором 2.4 GHz \times 32 и объемом оперативной памяти 32 ГБ. Архитектура CNN требует фиксированного размера входных данных, в связи с чем изображения масштабируются до 28×28 , 56×56 или 64×64 пикселей – в зависимости от конкретного набора. Каждая из двух сверточных стадий включает 32 карты признаков с ядрами 3×3 , операцию подвыборки 2×2 и Dropout с коэффициентом 0.25. Полносвязный слой содержит 128 скрытых нейронов и C выходных, при $Dropout = 0.5$. В стандартной нотации архитектура может быть записана как $C_1(size) - S_1 - C_2(size) - S_2 - H - O$ [18].

В качестве функции потерь используется categorical cross-entropy, оптимизация осуществляется с помощью алгоритма Adam. Размеры пакетов и число эпох подбираются из дискретных множеств $\{5, 20\}$ и $\{50, 250, 1000, 2000\}$ соответственно, исходя из поведения на валидационной выборке. Параметрическая настройка сети, как известно, остается задачей с открытым финалом. В рассматриваемом случае выбор значений опирается, скорее, на эмпирические соображения, чем на строгую процедуру оптимизации. Визуализация фильтров первых двух слоев для набора TwoPattern приведена на рисунке 4 – и здесь можно наблюдать формирование характерных текстурных паттернов, хотя их интерпретация не всегда однозначна.

Заключение

В основе рассматриваемого подхода лежит использование рекуррентных диаграмм совместно со сверточными нейронными сетями. Временные ряды при этом не анализируются напрямую: исходный сигнал представляется в виде изображения (RP), где становятся различимы повторяющиеся участки и особенности взаимного расположения состояний. Такое представление отличается от исходной формы сигнала и по-другому отражает его структуру. Полученные изображения далее обрабатываются глубокой CNN, которая выделяет характерные визуальные элементы и использует их при решении задачи классификации.

Ключевых моментов здесь, по сути, два. С одной стороны, RP-представление фиксирует свойства траектории в m -мерном фазовом пространстве в удобной двумерной форме. С другой – CNN объединяет извлечение признаков и классификацию в рамках одной модели, причем сами представления формируются автоматически и под задачу.

ЛИТЕРАТУРА

1. Fu T.-C. A Review on Time Series Data Mining. *Engineering Applications of Artificial Intelligence*. 2011;24(1):164–181. DOI: 10.1016/j.engappai.2010.09.007.
2. Ismail Fawaz H., Forestier G., Weber J., Idoumghar L., Muller P.-A. Deep Learning for Time Series Classification: A Review. *Data Mining and Knowledge Discovery*. 2019;33:917–963. DOI: 10.1007/s10618-019-00619-1.
3. Takens F. Detecting Strange Attractors in Turbulence. *Dynamical Systems and Turbulence, Warwick 1980*. Berlin: Springer; 1981;898:366–381. DOI: 10.1007/BFb0091924.
4. LeCun Y., Bengio Y., Hinton G. Deep Learning. *Nature*. 2015;521(7553):436–444. DOI: 10.1038/nature14539.
5. Mathunjwa B. M., Lin Y.-T., Lin C.-H. et al. ECG Arrhythmia Classification by Using a Recurrence Plot and Convolutional Neural Network. *Biomedical Signal Processing and Control*. 2021;64:102262. DOI: 10.1016/j.bspc.2020.102262.
6. Waibel A., Hanazawa T., Hinton G., Shikano K., Lang K. J. Phoneme Recognition Using Time-Delay Neural Networks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*. 1989;37(3):328–339. DOI: 10.1109/29.21701.
7. Wang Z., Oates T. Encoding Time Series as Images for Visual Inspection and Classification Using Tiled Convolutional Neural Networks. *AAAI Workshop on Artificial Intelligence for Data Science*. 2015.
8. Hatami N., Gavet Y., Debayle J. Classification of Time-Series Images Using Deep Convolutional Neural Networks. 2017. arXiv:1710.00886. DOI: 10.48550/arXiv.1710.00886.
9. Marwan N., Romano M. C., Thiel M., Kurths J. Recurrence Plots for the Analysis of Complex Systems. *Physics Reports*. 2007;438(5–6):237–329. DOI: 10.1016/j.physrep.2006.11.001.

10. Webber C. L., Zbilut J. P. Dynamical Assessment of Physiological Systems and States Using Recurrence Plot Strategies. *Journal of Applied Physiology*. 1994;76(2):965–973. DOI: 10.1152/jappl.1994.76.2.965.
11. Eckmann J.-P., Kamphorst S. O., Ruelle D. Recurrence Plots of Dynamical Systems. *Europhysics Letters*. 1987;4(9):973–977. DOI: 10.1209/0295-5075/4/9/004.
12. Sipers A., Borm P., Peeters R. Robust Reconstruction of a Signal from Its Unthresholded Recurrence Plot Subject to Disturbances. *Physics Letters A*. 2017;381(6):604–615. DOI: 10.1016/j.physleta.2016.12.028.
13. Dau H. A., Bagnall A., Kamgar K. et al. The UCR Time Series Archive. *IEEE/CAA Journal of Automatica Sinica*. 2019;6(6):1293–1305. DOI: 10.1109/JAS.2019.1911747.
14. Scherer D., Muller A., Behnke S. Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition. *Artificial Neural Networks – ICANN 2010*. Berlin: Springer; 2010:92–101. DOI: 10.1007/978-3-642-15825-4_10.
15. Rumelhart D. E., Hinton G. E., Williams R. J. Learning Representations by Back-Propagating Errors. *Nature*. 1986;323(6088):533–536. DOI: 10.1038/323533a0.
16. Werbos P. J. *Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences*: PhD thesis. Cambridge: Harvard University; 1974.
17. Chen Y., Keogh E., Hu B. et al. *The UCR Time Series Classification Archive*. Riverside: University of California; 2015. Режим доступа: https://www.cs.ucr.edu/~eamonn/time_series_data/.
18. Chollet F. Keras. *GitHub*. 2015. Режим доступа: <https://github.com/keras-team/keras>.