

Л.О. Кіріченко, П.П. Зінченко

ЗАСТОСУВАННЯ РЕКУРЕНТНОГО АНАЛІЗУ ДЛЯ КЛАСИФІКАЦІЇ РЕАЛІЗАЦІЙ ЕНЦЕФАЛОГРАМ

Анотація. У статті розглянуто використання машинного навчання для класифікації часових реалізацій які подано у вигляді рекурентних діаграм. Кожна часова реалізація перетворюється в матрицю рекурентних станів і представляється як чорно біле зображення. Отримані зображення реалізацій класифікуються за допомогою глибоких нейронних мереж. В якості класифікатора для зображень використовується глибока нейронна мережа залишкового типу. Проводиться бінарна класифікація реалізацій ЕЕГ. Результатом бінарної класифікації є виявлення епілептичного нападу. Результати дослідження показують, що розглянутий метод має високу точність класифікації. Запропонований підхід до класифікації може бути легко використаний на практиці.

Ключові слова: класифікація з використанням машинного навчання, класифікація часових рядів, рекурентні діаграми, реалізація ЕЕГ, глибокі залишкові мережі.

Актуальність і постановка задачі

Однією з найважчих завдань класифікації є класифікація часових рядів. Часовий ряд можна представити як часову реалізацію деякої динамічної системи, яка відображає багато внутрішніх і зовнішніх зв'язків цієї системи. Складні динамічні системи відповідають біологічним, інформаційним, технічним та соціальним процесам. Часові реалізації таких процесів є частково або повністю випадковими, мають зворотній нелінійний зв'язок та довгострокову кореляційну залежність. Добре відомим прикладом часових рядів, що мають вищеописану структуру, є реалізації електроенцефалограми (ЕЕГ), які мають фрактальні властивості [1].

Людський мозок має електричне поле, яке характеризується електричними сигналами від декількох міліампер до кількох сотень міліампер. Кожен нейрон мозку генерує зміну електричного потенціалу, цей процес можна виміряти. Аналіз електричного поля мозку широко використовується для діагностики різних захворювань [2]. Таким чином, виникає завдання класифікації реалізацій ЕЕГ.

На сьогоднішній день для класифікації часових рядів широко використовується машинне навчання. Різні підходи до методів машинного навчання для класифікації часових рядів, включаючи алгоритми, вибір ознак та застосування, розглянуті в оглядових статтях [3-5]. Слід відзначити велику кількість алгоритмів, метрик та ознак, які можуть бути використані для порівняння та подальшої класифікації часових рядів.

Найчастіше, після передобробки часового ряду, з нього вилучається набір деяких ознак, які є вхідними для класифікатора. Вибір ознак залежить від завдання класифікації. Найпростішими ознаками для класифікації можуть бути значення самого часового ряду. В [6] було показано, що в разі виражених фрактальних властивостей достатньо розглядати значення ряду без розрахунку фрактальних характеристик. Популярним методом вилучення ознак є перетворення часового ряду в частотний домен за допомогою перетворення Фур'є або вейвлет-перетворення [7].

Вищезазначені підходи широко використовуються для класифікації реалізацій ЕЕГ. У огляді [8] представлено більшість сучасних методів машинного навчання, які використовуються для класифікації сигналів ЕЕГ. Огляд [9] акцентує увагу на використанні глибокого навчання для завдань класифікації ЕЕГ.

У той же час, в останні десятиліття, стали поширеними методи аналізу часових рядів на основі методів нелінійної динаміки. Вихідним пунктом у цьому випадку є факт, що одна часова реалізація дисипативної системи є достатньою для відновлення її атрактора, який містить усю інформацію про систему. Зокрема, мозок (або його частина) може бути розглянутим як нелінійна динамічна система, яка чутлива до початкових умов, і ЕЕГ є траєкторією цієї динамічної системи [2].

Один із методів, що виник у нелінійній динаміці, - аналіз рекурентності (метод рекурентних діаграм), спочатку запропонований в [10], а подальше розвинений в [11,12]. На сьогоднішній день аналіз рекурентності є поширеним і використовується для дослідження різних систем, включаючи ті, що мають фрактальні властивості [13]. Рекурентна діаграма містить інформацію про повторюваність станів дисипативної динамічної системи, що представлена часовим рядом. Рекурентні властивості можуть бути візуалізовані у формі геометричних структур і наочно продемонструвати динаміки часового ряду. Таким чином, техніка рекурентних діаграм перетворює часові ряди на зображення, які можуть бути класифіковані за допомогою методів комп'ютерного зору [14-16]. Проте такі дослідження досить нові і ще не стали широко поширеними.

Метою даної роботи є проведення класифікації ЕЕГ на основі рекурентних діаграм, які перетворюються на зображення і після цього класифікуються за допомогою нейромережі залишкового типу.

Класифікація часових рядів на основі графіків рекурентності

Метод рекурентних діаграм ґрунтується на відновленні атрактора системи з одиночної часової реалізації (процедура Паккарда-Такенса) [17]. У цьому випадку псевдофазовий простір станів X системи може бути отриманий шляхом реалізації значень u_i

$$x_i = (u_i, u_{i+\tau}, \dots, u_{i+(m-1)\tau}) \quad (1)$$

де x_i - значення псевдофазової траєкторії на i -му моменті часу, u_i - значення часової реалізації на i -му моменті часу, m - розмір псевдофазового простору, τ - затримка часу. Автори [11] запропонували метод, який дозволяє відобразити m -вимірну псевдофазову траєкторію x_i , $i = 1, \dots, N$, в бінарну матрицю розміром $N \times N$. Елемент з координатами (i, j) приймає значення 1, якщо стан $\vec{x}_j$ є рекурентним до стану $\vec{x}_i$, тобто $\vec{x}_j$ потрапляє в певний заданий окіл $\vec{x}_i$, і елемент (i, j) дорівнює 0 у зворотному випадку.

Така матриця (рекурентна діаграма) містить інформацію про поведінку часового ряду. Рекурентна діаграма RP - це матриця, де значення $RP_{i,j}$ дорівнює 1, коли відстань між $\vec{x}_i$ і $\vec{x}_j$ менше ε :

$$RP_{i,j} = \theta(\varepsilon \|x_i - x_j\|), \quad x_i, x_j \in R^m, \quad i, j = 1, \dots, N \quad (2)$$

де ε - радіус m -вимірного околу точки x_i , $\|x_i - x_j\|$ - відстань між точками, $\theta(\cdot)$ - функція Хевісайда. Рекурентні діаграми легко візуалізуються в чорно-білому форматі. Тоді рекурентні стани відображаються чорним кольором, а решта - білим. В [1, 12, 18] було показано, що зміна кореляційної структури системи призводить до зміни топології рекурентної діаграми. Таким чином, аналіз рекурентних діаграм дозволяє класифікувати спостережувані часові ряди.

Вхідні дані

Для здійснення класифікації були обрані популярні дані записів мозкової активності [19]. Початковий набір даних містив записи мозкової активності для різних станів людини: епілептичний напад, зону пухлини, здорову частину мозку, коли людина має закриті очі, і коли вони відкриті. Таким чином, дані були розподілені на 5 класів. Кожен клас містив 100 файлів, де кожен файл відповідав одному об'єкту (людині). Кожен файл містив записи мозкової активності

протягом 23,5 секунди, що відповідало часовому ряду довжиною 4097 значень. У [2] було надано детальний опис цих даних мозкової активності та показано їхні нелінійні властивості. Незважаючи на те, що набір даних містив 5 класів часових рядів, більшість досліджень проводили бінарну класифікацію, де клас епілептичного нападу порівнювався з рештою. У [20] епілептичні напади діагностувалися за допомогою методів машинного навчання, таких як штучні нейронні мережі, наївний баєсівський класифікатор, k -найближчих сусідів, метод опорних векторів та k -середніх. Експеримент показав дуже добрі результати: для більшості алгоритмів точність бінарної класифікації записів тривалістю 23 секунди перевищувала 99%.

Складнішою задачею є визначення нападу в разі значно коротших даних. У наборі даних кожна часова реалізація з 4097 значень була розділена на 23 частини по 178 значень, що відповідало 1 секундi. У цій роботі ми використовували вищезгадані часові реалізації мозкової активності довжиною 178 значень. На рис. 1 показані часові реалізації ЕЕГ з 1-го класу (епілептичний напад) у верхній частині (а) та реалізації з інших класів у нижній частині (б). Рисунок 2 показує рекурентні діаграми, що відповідають часовим реалізаціям, представленим на рисунку 1. Варто відзначити, що практично неможливо візуально знайти різницю між класами ЕЕГ як у реалізаціях, так і в рекурентних діаграмах.




Рисунок 1 - Реалізації ЕЕГ епілептичного нападу а) та інших класів б)

Нейронні мережі для класифікації зображень

На сьогоднішній день, в зв'язку зі зростанням обчислювальної потужності та появою баз даних зображень, технології комп'ютерного зору стали дуже поширеними. Стало можливим застосовувати ці технології не лише в різних галузях науково-технічної діяльності, але й у повсякденному житті. Найкращі результати розпізнавання зображень показали глибокі нейронні мережі, зокрема згорткові нейронні мережі, які, відмінно від багат шарового перцептрона, враховують двовимірні топології зображень [21,22].




Рисунок 2 - Рекурентні діаграми епілептичного нападу а) та інших класів б)

Згорткові нейронні мережі отримують ознаки у багат шаровому режимі "від початку до кінця". Дослідження показали, що зі зростанням кількості шарів точність розпізнавання не збільшується значно: спочатку точність може зростати незначно, але чим глибше ми розширюємо мережу, тим гірше вона починає класифікувати. Це пов'язано з тим, що мережі навчаються методом зворотного поширення помилок, і внаслідок диференціювання за правилом ланцюга градієнт затухає для досить глибоких шарів. Для вирішення цієї проблеми була розроблена структура мережі зі залишковими блоками [23]. Особливістю залишкової мережі є те, що результат класифікації розширеної мережі не буде гіршим за базовий. Основна ідея полягає в заміні звичайного послідовного з'єднання шарів на скорочене з'єднання. Скорочені з'єднання обходять кілька шарів і передають значення відхилення. Їхні вихідні дані додаються до вихідних

даних групових шарів. Основною одиницею залишкової мережі є два шари з вагами, які не обов'язково є згортковими, та скорочене з'єднання, яке просто передає сигнал на вихід.

У рамках експерименту була використана залишкова нейронна мережа з 131 шаром з вагами. Мережа складалася з 11 окремих та 120 з'єднаних в блоки скорочених з'єднань. Перші 127 шарів призначені для виявлення характеристик (ознак), останні 4 використовуються для побудови функції класифікації. Глибока залишкова нейронна мережа містить десять блоків, три згорткових шари та один повністю з'єднаний шар. Вихід останнього повністю з'єданого шару подається на логістичну функцію, яка розподіляє на два класи. Нейрони в повністю з'єданому шарі з'єднані з усіма нейронами в попередньому шарі. Підвибіркові шари слідує після другого та третього згорткових шарів. Функція ReLU використовується для виходу кожного згорткового та повністю з'єданого шару. Для навчання на мережі використовувався адаптивний алгоритм оптимізації швидкості навчання Adam.

Експеримент, результати та обговорення

Експериментальні дані були взяті з [19]. Набір даних містить записи мозкової активності для близько 500 осіб протягом 23,5 секунди, які складаються з 4097 значень. В результаті було отримано 11500 часових рядів довжиною 178 значень для інтервалу 1 секунда.

Експеримент спочатку був проведений на вибірці з 7500 реалізацій (6000 без нападу / 1500 з нападом), де 6000 використовувалися для навчання, а 1500 - для тестування. Результати класифікації представлені у матриці помилок (Таблиця 1), де символ P означає, що об'єкт класифіковано як належний позитивному класу (напад), N - належність до негативного класу (без нападу), символ T показує, що клас був визначений правильно, а F - неправильне визначення.

Таблиця 1

Матриця помилок

	Значення	Справжній клас	
		Напад	Без нападу
Спрогнозований клас	Напад	279 (TP)	9 (FP)
	Без нападу	21 (FN)	1191 (TN)

На основі матриці помилок були обчислені класифікаційні метрики, які представлені в Таблиці 2. Варто зазначити, що результати класифікації, отримані в даній роботі на основі методу візуалізації рекурентних графіків, не пос-

тупаються за точністю результатам, отриманим у [21] за допомогою кількох різних класифікаторів.

Таблиця 2

Класифікаційні метрики

Вимір	Припадок(істина)
Точність (Accuracy)	0,98
Влучність (Precision)	0,96875
Повнота (Recall)	0,93
F1 міра (F1 score)	0,94898

Щоб визначити вплив розміру вибірки на якість класифікації, був використаний весь набір даних, де 8500 реалізацій було вибрано для навчання и 3000 - для тесту. Значення кваліфікаційних метрик не відрізнялися суттєво від результатів, поданих в табл.2.

Також на вибраному наборі даних була проведена багатокласова класифікація мозкової активності для різних станів людини, де номер класу відповідає відповідним ЕЕГ : 1-й - епілептичний напад, 2-й - зона пухлини, 3й -здорова частина мозку, 4 - закриті очі, 5- відкриті очі. Точність результатів класифікації, представлено в табл. 3.

Таблиця 3

Класифікаційні метрики

Класи	Точність
1, 2, 3, 4, 5	0,83
1, 3, 4	0,93
4, 5	0,87
3, 4	0,97

Висновки

У роботі було розглянуто досить новий підхід до вирішення завдання класифікації часових рядів на прикладі реалізацій ЕЕГ. Запропонований підхід, замість базується на перетворенні рядів в зображення та подальшій класифікації отриманих зображень за допомогою глибоких нейронних мереж. Для перетворення часових рядів у чорно-біле зображення використовувалася побудова рекурентних діаграм.

В якості класифікатора для зображень була вибрана мережа глибокого за-
лишкового зв'язку. Здійснювалася бінарна класифікація реалізацій ЕЕГ, що міс-
тили записи епілептичного нападу. Для експерименту використовувалися дані
з активності мозку з 178 значеннями, що відповідає 1 секунді. Результатом бі-
нарної класифікації було виявлення епілептичного нападу. Результати показа-
ли, що розглянутий метод класифікації має досить високу точність класифіка-
ції навіть при короткій довжині реалізацій ЕЕГ. Показники якості класифікації
- точність та F1-міра - дорівнювали відповідно 0,98 та 0,94898.

Проведений експеримент підтвердив успішність підходу до класифікації
часових рядів за їх візуалізацією. Подальше покращення якості класифікації
можливе двома способами. Перший - це покращення архітектури нейронної
мережі, а другий - розробка методів збільшення візуальної відмінності між ре-
курентними діаграмами різних класів часових рядів.

ЛІТЕРАТУРА / REFERENCES

1. Kirichenko, L., Radivilova, T., Bulakh, V.: Binary classification of fractal time se-
ries by machine learning methods. In: Advances in Intelligent Systems and Comput-
ing, vol. 1020, pp. 701–711 (2019). https://doi.org/10.1007/978-3-030-26474-1_49
2. Andrzejak, R.G., Lehnertz, K., Mormann, F., Rieke, C., David, P., Elger, C.E.: Indi-
cations of nonlinear deterministic and finite-dimensional structures in time series of
brain electrical activity: dependence on recording region and brain state. Phys. Rev.
E 64(6), 061907 (2001)
3. Bagnall, A., Lines, J., Bostrom, A., Large, J., Keogh, E.: The great time series classi-
fication bake off: a review and experimental evaluation of recent algorithmic ad-
vances. Data Min. Knowl. Disc. 31(3), 606–660 (2017)
4. Buza, K.: Time series classification and its applications. In: Proceedings of the 8th
International Conference on Web Intelligence, Mining and Semantics, pp. 1–4 (2018)
5. Esling, P., Agon, C.: Time-series data mining. ACM Comput. Surv. (CSUR) 45(1),
1–34 (2012)
6. Bulakh, V., Kirichenko, L., Radivilova, T.: Time series classification based on frac-
tal properties. In: 2018 IEEE Second International Conference on Data Stream Min-
ing & Processing (DSMP), pp. 198–201 (2018). <https://doi.org/10.1109/DSMP.2018.8478532>
7. Faraggi, M., Sayadi, K.: Time series features extraction using Fourier and Wavelet
transforms on ECG data (2019). <https://blog.octo.com/en/time-series-features-extraction-using-fourier-and-wavelet-transforms-on-ecg-data/>

8. Lotte, F., Bougrain, L., Cichocki, A., et al.: A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update. *J. Neural Eng.* 15(3), 031005 (2018)
9. Craik, A., He, Y., Contreras-Vidal, J.L.: Deep learning for electroencephalogram (EEG) classification tasks: a review. *J. Neural Eng.* 16(3), 031001 (2019). <https://doi.org/10.1088/1741-2552/ab0ab5>
10. Eckmann, J.P., Kamphorst, S.O., Ruelle, D.: Recurrence plots of dynamical systems. *World Sci. Ser. Nonlinear Sci. Ser. A* 16, 441–446 (1995)
11. Marwan, N., Romano, M.C., Thiel, M., Kurths, J.: Recurrence plots for the analysis of complex systems. *Phys. Rep.* 438(5–6), 237–329 (2007)
12. Marwan, N., Wessel, N., Meyerfeldt, U., Schirdewan, A., Kurths, J.: Recurrence plot-based measures of complexity and their application to heart-rate-variability data. *Phys. Rev. E* 66(2), 026702 (2002)
13. Kirichenko, L., Kobitskaya, Y., Habacheva, A.: Comparative analysis of the complexity of chaotic and stochastic time series. *Radioelectronics Inform. Manag.* 2(31), 126–134 (2014)
14. Hatami, N., Gavet, Y., Debayle, J.: Classification of time-series images using deep convolutional neural networks. In: Tenth International Conference on Machine Vision (ICMV 2017). International Society for Optics and Photonics (2018)
15. Hatami, N., Gavet, Y., Debayle, J.: Bag of recurrence patterns representation for time-series classification. *Pattern Anal. Appl.* 22(3), 877–887 (2019)
16. Michael, T., Spiegel, S., Albayrak, S.: Time series classification using compressed recurrence plots. In: Proceedings of ECML-PKDD (2015)
17. Kirichenko, L., Kobitskaya, Y., Habacheva, A.: Comparative analysis of the complexity of chaotic and stochastic time series. *Radioelectronics Inform. Manag.* 2(31), 126–134 (2014)
18. Takens, F.: Detecting strange attractors in turbulence. In: Rand, D., Young, L.S. (eds.) *Dynamical Systems and Turbulence*, Warwick 1980. Lecture Notes in Mathematics, vol. 898 (1980)
19. Wu, Q., Fokoue, E.: Epileptic Seizure Recognition Data Set. <https://archive.ics.uci.edu/ml/datasets/Epileptic+Seizure+Recognition>
20. Karlık, B., Hayta, B.: Comparison machine learning algorithms for recognition of epileptic seizures in EEG. In: Proceedings IWBBIO 2014 (2014)
21. Ciresan, D.C., Meier, U., Masci, J., Gambardella, L.M., Schmidhuber, J.: Flexible, high performance convolutional neural networks for image classification. In:

Twenty-Second International Joint Conference on Artificial Intelligence, pp. 1237–1242 (2011)

22. LeCun, Y., Bengio, Y.: Convolutional networks for images, speech, and time series. In: The Handbook of Brain Theory and Neural Networks, vol. 3361, no. 10 (1995)

23. Fung, V.: An overview of ResNet and its variants. Towards Data Science (2017)

Received 22.11.2022.

Accepted 29.11.2022.

Application of recurrent analysis to classify realizations of encephalograms

The current state of science and technology is characterized by a variety of methods and approaches to solving various tasks, including in the fields of time series analysis and computer vision. This abstract explores a novel approach to the classification of time series based on the analysis of brain activity using recurrent diagrams and deep neural networks.

The work begins with an overview of recent achievements in the field of time series analysis and the application of machine learning methods. The importance of time series classification in various domains, including medicine, finance, technology, and others, is emphasized. Next, the methodology is described, in which time series are transformed into grayscale images using recurrent diagrams. The key idea is to use recurrent diagrams to visualize the structure of time series and identify their nonlinear properties. This transformed information serves as input data for deep neural networks.

An important aspect of the work is the selection of deep neural networks as classifiers for the obtained images. Specifically, residual neural networks are applied, known for their ability to effectively learn and classify large volumes of data. The structure of such networks and their advantages over other architectures are discussed.

The experimental part of the work describes the use of a dataset of brain activity, which includes realizations from different states of a person, including epileptic seizures. The obtained visualization and classification methods are applied for binary classification of EEG realizations, where the class of epileptic seizure is compared with the rest. The main evaluation metrics for classification are accuracy, precision, recall, and F1-score. The experimental results demonstrate high classification accuracy even for short EEG realizations. The quality metrics of classification indicate the potential effectiveness of this method for automated diagnosis of epileptic seizures based on the analysis of brain signals.

The conclusions highlight the importance of the proposed approach and its potential usefulness in various domains where time series classification based on the analysis of brain activity and recurrent diagrams is required.

Кіріченко Людмила Олегівна – д.т.н., професор кафедри прикладної математики Харківського національного університету радіоелектроніки.

Зінченко Петро Петрович – аспірант кафедри прикладної математики Харківського національного університету радіоелектроніки.

Kirichenko Lyudmila Olehivna - Ph.D., professor of the Department of Applied Mathematics of the Kharkiv National University of Radio Electronics.

Zinchenko Petro Petrovych - graduate student of the Department of Applied Mathematics of the Kharkiv National University of Radio Electronics.