

Классификация Зашумленных Временных Рядов на Основе Рекуррентного Анализа

Людмила Кириченко
кафедра прикладной математики
Харьковский национальный университет
радиоэлектроники
Харьков, Украина
lyudmyla.kirichenko@nure.ua

Пётр Зинченко
кафедра прикладной математики
Харьковский национальный университет
радиоэлектроники
Харьков, Украина
petro.zinchenko@nure.ua

Time Series Classification Based on Recurrence Analysis

Lyudmyla Kirichenko
dept. of Applied Mathematic
Kharkiv University of Radioelectronics
Kharkiv, Ukraine
lyudmyla.kirichenko@nure.ua

Petro Zinchenko
dept. of Applied Mathematic
Kharkiv University of Radioelectronics
Kharkiv, Ukraine
petro.zinchenko@nure.ua

В статье рассматривается метод классификации временных рядов, основанный на построении и визуализации рекуррентных диаграмм. Временной ряд преобразуется в рекуррентную диаграмму, которая представляется черно-белым изображением, после чего для классификации используется сверточная нейронная сеть. Метод был исследован на модельных временных рядах. Результаты показали, что данный метод обладает достаточно высокой точностью классификации. Получены зависимости точности классификации от уровня зашумленности временных рядов.

In the article, a method of time series classification based on the construction of recurrence plots is considered. As a result of recurrence analysis the time series is transformed into a black-and-white image. Further, the convolutional neural network is used to classify the image. The application of the proposed method is demonstrated by examples of simulated time series. The dependences of the classification accuracy on the noise level of time series are researched. The results showed that the considered method has a high enough classification accuracy.

Ключевые слова — временные ряды; шум; рекуррентные диаграммы; сверточные нейронные сети.

Keywords — time series; noise; recurrence plot; convolutional neural network

I. ВВЕДЕНИЕ

Задача классификации временных рядов является одной из самых сложных задач интеллектуального анализа данных. Существует несколько подходов к классификации временных рядов, большинство из которых основаны на расчете различных метрик между временными рядами [1-2].

В последние несколько лет появился ряд исследований, в которых для классификации временных рядов используется метод рекуррентных диаграмм. Рекуррентный анализ основан на таком свойстве процесса, как повторяемость состояния, то есть рекуррентность. В этом случае рекуррентные свойства временного ряда представляются в виде геометрических структур и позволяют визуализировать динамику ряда. Методы рекуррентного анализа были первоначально предложены в [3].

В последние годы метод рекуррентных широко использовался для анализа стохастических временных рядов различной природы [4-6]. С развитием методов машинного обучения рекуррентные характеристики, рассчитанные по временным рядам, стали использоваться в качестве признаков для задач классификации [7-9].

Другим подходом к применению рекуррентных методов для классификации является распознавание временных рядов непосредственно по изображениям рекуррентных диаграмм. Поскольку лучшим инструментом для распознавания и классификации изображений являются сверточные нейронные сети, ряд исследователей используют их для классификации рекуррентных диаграмм [10].

Однако, поскольку такие исследования являются довольно новыми, до сих пор недостаточно внимания уделяется особенностям рекуррентного анализа для классификации зашумленных временных рядов. Целью представленной работы является проведение сравнительной классификации зашумленных временных рядов на основе визуализации рекуррентных диаграмм.



Інформаційні системи та технології ICT-2019

Секція 2.

Математичне та комп'ютерне моделювання у інформаційних системах.

II. МЕТОД РЕКУРРЕНТНЫХ ДИАГРАММ

Рекуррентный анализ является одним из методов нелинейной динамики, используемых для анализа временных рядов, и используется для выявления неочевидных зависимостей в динамике ряда. В рекуррентном анализе исследуется m -мерная траектория псевдофазового пространства, построенного по временной реализации. Хорошо известная процедура Паккарда-Такенса [11] для построения псевдофазового пространства только по одной реализации позволяет восстановить аттрактор динамической системы:

$$F(t) = [x(t), x(t + \tau), \dots, x(t + m\tau)],$$

где $F(t)$ – m -мерное псевдо-фазовое пространство, $x(t)$ – временная реализация системы, τ – период запаздывания.

Рекуррентная диаграмма является проекцией m -мерного псевдофазового пространства на плоскость. Пусть точка x_i соответствует точке фазовой траектории $x(t)$, описывающей динамическую систему в m -мерном пространстве в момент времени $t = i$ для $i = 1, \dots, N$, тогда рекуррентная диаграмма RP есть массив точек, где ненулевой элемент с координатами (i, j) соответствует случаю, когда расстояние между x_j и x_i меньше ε :

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

где ε – размер окрестности точки x_i , $\|x_i - x_j\|$ – расстояние между точками, $\Theta(\cdot)$ – функция Хэвисайда.

Важным этапом построения рекуррентной диаграммы является выбор метрики расстояния. Наиболее популярной является евклидова метрика, где форма окрестности представляет собой круг радиуса ε , и максимальная норма, где форма окрестности представляет собой квадрат со стороной ε . Во многих случаях выбор метрики не является принципиальным, но в каждой конкретной задаче имеет смысл экспериментировать. Очевидный факт состоит в том, что для однородных временных рядов подойдет евклидова норма, а в случае не однородных, резко меняющихся рядов максимальная норма, для которой окрестность имеет большую площадь, является более подходящей.

В этой работе при построении рекуррентных диаграмм мы использовали одномерное фазовое пространство, что позволяет нам значительно сократить время построения, и евклидову метрику.

III. СВЕРТОЧНАЯ НЕЙРОННАЯ СЕТЬ

Свёрточная нейронная сеть представляет собой особую архитектуру искусственных нейронных сетей, нацеленную на эффективное распознавание образов [12]. Это прототип зрительной коры. Идея, что специализи-

рованные компоненты решают определенные проблемы (например, клетки зрительной коры, которые ищут определенные характеристики), используется в машинном обучении.

Идея сверточных нейронных сетей состоит в чередовании сверточных слоев и слоев субвыборки. Структура сети является однонаправленной (без обратной связи), принципиально многослойной. Для обучения используются стандартные методы, чаще всего метод обратного распространения ошибок. Функция активации нейронов может быть различной, в зависимости от задачи. Архитектура сети получила свое название из-за операции свертки, суть которой заключается в том, что каждый фрагмент изображения умножается на матрицу (ядро) элемента свертки на элемент, а результат суммируется и записывается в одну и ту же позицию в выходное изображение.

Сеть работает следующим образом. Изображение проходит через ряд свёрточных, нелинейных слоев, объединяющих слоев и полносвязных слоев, и генерируется вывод. Вывод может быть классом или вероятностью классов, которые лучше всего описывают изображение.

Первый слой в сети всегда свёрточный. Это набор функциональных карт (это обычные матрицы), каждая карта имеет синаптическое ядро (сканирующее ядро или фильтр). Размер всех карт определенного сверточного слоя одинаков.

Ядро представляет собой фильтр или окно, которое скользит по всей области предыдущей карты и находит определенные признаки объектов

Когда изображение проходит через один сверточный слой, выход первого уровня становится входным значением 2-го уровня. После применения набора фильтров после первого слоя будут активированы фильтры, которые представляют свойства более высокого уровня. Чем больше сверточных слоев проходит изображение и чем дальше оно перемещается по сети, тем более сложные характеристики отображаются на картах объектов.

После сверточных слоев следует объединяющий слой. Он также называется слоем понижающей дискретизации. В этой категории также есть несколько вариантов слоев, причем выбор максимального является самым популярным. Обычно, каждая карта имеет ядро размером 2×2 , что позволяет уменьшить предыдущие карты свёрточного слоя в 2 раза. Вся карта признаков разделяется на ячейки 2×2 элемента, из которых выбираются максимальные по значению.

Последний тип слоя – это слой обычного многослойного персептрона. Целью слоя является классификация, он моделирует сложную нелинейную функцию, оптимизация которой повышает качество распознавания. Выходной слой связан со всеми нейронами предыдущего слоя. Количество нейронов соответствует количеству распознанных классов



IV. ОПИСАНИЕ РЕЗУЛЬТАТОВ ЭКСПЕРИМЕНТА

В эксперименте использовалась сверточная нейронная сеть, состоящая из шести слоев с весами; первые четыре сверточные, а остальные два полносвязные.

Выход последнего полносвязного слоя подается на логистическую функцию, которая производит распределение по 2 классам. Нейроны в полносвязных слоях связаны со всеми нейронами в предыдущем слое. Слои подвыборки следуют за вторым и четвертым сверточными слоями. Нелинейность ReLU применяется к выходу каждого сверточного и полностью связного слоя.

Первый сверточный слой фильтрует входное изображение размером 256×256 пикселей 8 ядрами размером 5×5 . Второй сверточный уровень принимает в качестве входных данных выход первого сверточного слоя и фильтрует его с 16 ядрами размером 4×4 . Третий сверточный слой имеет 32 ядра размером 3×3 , соединенные с выходами второго сверточного уровня. Четвертый сверточный слой имеет 64 ядра размером 3×3 . Полносвязные слои имеют по 1024 нейрона каждый. Для обучения в сети был использован Adam – алгоритм адаптивной оптимизации скорости обучения.

В качестве входных временных рядов в работе выбрано синусоидальные временные реализации с разными периодами колебаний и разными уровнями шума. Мы можем представить временную реализацию в виде суммы синусоидальной и шумовой составляющих: $X(t) = Y(t) + z(t)$, где $Y(t)$ – это временный ряд, $z(t)$ – аддитивный шум.

В качестве величины, характеризующей соотношение сигнала и шума, использовался коэффициент $Snr = S[Y(t)] / S[z(t)]$, где S – среднеквадратическое отклонение. Изменяя коэффициент Snr мы задаем разную степень зашумленности временного ряда.

Для проведения классификации входные временные ряды были разбиты на 2 класса. Первый класс составляли синусоиды, для которых диапазон частот изменялся от $f1 \pm fR$, для второго класса диапазон частот изменялся от $f2 \pm fR$.

Частоты в границах класса выбирались случайно. Значение $f1$, $f2$, fR , и $Fdist = |f1 - f2|$ изменялись в ходе эксперимента.

Таблица 1 демонстрирует точность классификации и количество эпох в зависимости от уровня шума Snr . Стоит отметить, что с увеличением размера обучающей выборки до 400 значений, точность классификации при шуме $Snr = 0.4$ увеличивается до 0.811.

ТАБЛИЦА 1. Точность классификации и количество эпох

Уровень шума Snr	Точность	Количество эпох
1	0.993	10
0.7	0.977	15
0.6	0.955	18
0.5	0.818	25
0.4	0.703	32

V. ВЫВОДЫ

В работе был исследован метод классификации временных рядов, основанный на построении рекуррентных диаграмм с использованием простой архитектуры сверточной нейронной сети. Проведен сравнительный анализ классификации шумовых временных рядов. Результаты показали, что рассмотренный метод обладает достаточно высокой точностью классификации даже при большой степени шума. Результаты работы могут быть использованы для классификации временных рядов стохастического типа по методам машинного обучения.

ЛИТЕРАТУРА REFERENCES

- [1] Esling P., Agon C.: *Time series data mining*. ACM Computing Surveys 46(1) (2012).
- [2] Ben D: Feature-based time-series analysis, <https://arxiv.org/abs/1709.08055>, last accessed 2019/08/20.
- [3] L.O. Kirichenko, Y. Kobitskaya, and A. Habacheva. "Comparative Analysis of the Complexity of Chaotic and Stochastic Time Series." *Radioelectronics*
- [4] J.P. Eckmann, S.O. Kamphorst, and D. Ruelle. "Recurrence Plots of Dynamical Systems." *EPL (Europhysics Letters)*, vol. 4, no. 9, 1987, pp. 973-977.
- [5] N. Marwan, N. Wessel, U. Meyerfeldt, A. Schirdewan and J. Kurths. "Recurrence-plots-based measures of complexity and application to heart-rate-variability data", *Physical Review E*, vol. 66, no. 2, pp. 026702-1 – 026702-6, 2002.
- [6] N. Marwan, M. Romano, M. Thiel, and J. Kurths, "Recurrence plots for the analysis of complex system." *Physics Reports*, vol. 438, no. 5-6, pp. 237-329, 2007.
- [7] . *Informatics. Management*, no. 2(31), pp. 126-134, 2014.
- [8] L. Kirichenko, T. Radivilova and V. Bulakh, "Classification of Fractal Time Series Using Recurrence Plots," 2018 International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T), Kharkiv, Ukraine, 2018, pp. 719-724. doi: 10.1109/INFOCOMMST.2018.8632010
- [9] Thilo Michael, Stephan Spiegel, Sahin Albayrak Time Series Classification using Compressed Recurrence Plots <http://www.dai-labor.de/fileadmin/Files/Publikationen/Buchdatei/Published.pdf> last accessed 2019/08/20.
- [10] Nima Hatami, Yann Gavet, Johan Debayle Classification of Time-Series Images Using Deep Convolutional Neural Networks <https://arxiv.org/abs/1710.00886> last accessed 2019/08/20
- [11] F. Takens, D.A. Rand, and L.-S. Young. "Detecting strange attractors in turbulence." *Dynamical Systems and Turbulence: Lecture Notes in Mathematics*, Springer-Verlag, vol. 898, pp. 366–381, 1981.
- [12] Y. LeCun and Y. Bengio: *Convolutional Networks for Images, Speech, and Time-Series*, in Arbib, M. A. (Eds), *The Handbook of Brain Theory and Neural Networks*, MIT Press, 1995

