


Copyright © 2019 by Academic Publishing House Researcher s.r.o.



Published in the Slovak Republic  
 Modeling of Artificial Intelligence  
 Has been issued since 2014.  
 E-ISSN: 2413-7200  
 2019, 6(1): 13-18

DOI: 10.13187/mai.2019.1.13  
[www.ejournal11.com](http://www.ejournal11.com)



## Machine Learning Algorithm for Detecting Outliers and Anomalies

Maxim Vasilenko <sup>a, \*</sup>, Andrey Kopyrin <sup>a</sup>

<sup>a</sup> Sochi State University, Russian Federation

### Abstract

The detection of anomalies in the time series is an important topic in modern data science.

Existing solutions for detecting anomalies mainly look for deviations in parameter values. Consequently, their ability to detect anomalies and deviations in a priori unknown processes is limited, since it is difficult to determine their numerical characteristics. To solve this problem, the authors propose using machine learning technology to detect anomalies along with soft calculations based on fuzzy logic.

Modern artificial neural networks usually use a large number of neurons operating in parallel and arranged in layers, but due to the disappearing gradient problem, a large recurrent neural network will not be effectively trained.

It is proposed to use a network with Long Short-Term Memory (LSTM), since regular back propagation of an error is effective for teaching LSTM to store values for very long time intervals.

It is concluded that when analyzing time series, the LSTM network will efficiently process unstructured statistical information, which makes it suitable for use for big data analysis.

**Keywords:** anomaly search, neural networks, LSTM.

### 1. Введение

С быстрым развитием информационных технологий, вопрос анализа больших объемов экономических и технических данных также получает все больше и больше внимания. Исследования по обнаружению аномалий во временных рядах являются важной темой в современной науке об аналитике данных – data science.

Различные методологии обнаружения аномалий устанавливают расхождение модели в соответствии с реальным поведением объекта и проводят обнаружение выбросов на основе того, отличаются ли фактическое значение от моделируемого.

Однако с ростом объема анализируемых данных, а также несбалансированное распределение нормального и аномального поведения объекта, возникают проблемы низкой достоверности и скорости обнаружения выбросов.

Существующие решения обнаружения аномалий в основном ищут отклонения в значениях параметров, которые фиксируют свойства известных (или предполагаемых известными) процессов, а это означает, что они используют так называемые числовые признаки. Следовательно, их возможности по обнаружению аномалий и отклонений в априорно неизвестных процессов ограничены, так как трудно определить их числовые характеристики. Для решения данной проблемы, авторы предлагают использовать

\* Corresponding author

E-mail addresses: [renxi@yandex.ru](mailto:renxi@yandex.ru) (M. Vasilenko), [kopyrin\\_a@mail.ru](mailto:kopyrin_a@mail.ru) (A. Kopyrin)

технологии машинного обучения для обнаружения аномалий наряду с мягкими вычислениями на основе нечеткой логики.

В данной работе предложено обоснование выбора алгоритма обучения нейронной сети для выявления аномалий в темпоральных данных.

## 2. Обсуждение

Нейронные сети представляют собой набор алгоритмов, которые очень похожи на мозг человека и предназначены для распознавания паттернов. Они интерпретируют сенсорные данные через машинное восприятие, маркировку или кластеризацию необработанного ввода (Найкин, 1994). Они могут распознавать числовые шаблоны, содержащиеся в векторах, в которые должны быть переведены все реальные данные (изображения, звук, текст или временные ряды). Искусственные нейронные сети состоят из большого количества сильно взаимосвязанных элементов (нейронов), работающих вместе для решения поставленной задачи.

Согласно универсальной теореме аппроксимации (Горбань, 1998), простая нейронная сеть с  $n$ -ным количеством нейронов в 1 скрытом слое может аппроксимировать любую непрерывную функцию. Регулируя веса и смещения нейронов, сеть может принимать любые входные данные и аппроксимировать их, чтобы соответствовать примерно такому же поведению, что и у целевой функции. Обязательным условием является непрерывность целевой функции, если функция не является непрерывной, то нейронная сеть с одним скрытым слоем не сможет точно приблизиться к целевой функции, что, впрочем, может быть решено добавлением дополнительных слоев.

Современное машинное обучение акцентировано на использовании глубоких, многослойных сетей (в отличие от сетей с одним скрытым слоем). Основным преимуществом таких сетей является тот факт, что они могут эффективно выводить композиции функций. Это позволяет приближать сложные математические модели и выделять закономерности.

В современных искусственных нейронных сетях обычно используется большое количество нейронов, работающих параллельно и расположенных по слоям. Первый слой получает необработанную входную информацию – аналог зрительных нервов при визуальной обработке человеческим мозгом. Каждый последующий уровень получает выходные данные от предшествующего уровня, а не от необработанного ввода – таким же образом нейроны, находящиеся дальше от входа, получают сигналы от тех, кто ближе к нему. Последний уровень производит вывод системы.

Рекуррентная нейронная сеть (РНС) – это обобщение нейронной сети с прямой связью, имеющей внутреннюю память (Осипов, 2010; Найкин, 1994). Такая сеть является рекуррентной по своей природе, поскольку она выполняет одну и ту же функцию для каждого ввода данных, в то время как вывод текущего ввода зависит от предыдущих вычислений. После создания вывода он копируется и отправляется обратно в рекуррентную сеть. Для принятия решения она учитывает текущий ввод и вывод, который был получен из предыдущего ввода. В других типах нейронных сетей все входы независимы друг от друга, в РНС все входы связаны друг с другом. Этот факт, а также присутствие в нейронах кратковременной памяти позволяет производить контекстно-ориентированный анализ данных – в отличие от нейронных сетей с прямой связью, РНС могут использовать свою «память» для обработки последовательностей входных данных, таких как временные ряды, статистическая информация, с учетом их контекста.

Определим  $X$  как вектор входных данных, и  $H$  как вектор промежуточных результатов вычислений в рекуррентной сети. Таким образом: вначале сеть берет  $X(0)$  из последовательности ввода, а затем выводит  $H(0)$ , которое вместе с  $X(1)$  является входом для следующей итерации. Итак,  $H(0)$  и  $X(1)$  – это вход для следующего шага. В этом случае передача  $H(n)$  подобна использованию т.н. «входа смещения» в прямонаправленных сетях (feedforward, перцептроны). Отличие в том, что вход смещения подразумевает смещение на постоянную константу (обычно, 1 при диапазоне входных значений от 0 до 1). Аналогично,  $H(1)$  и  $X(2)$  являются входом для следующего шага и так далее. Таким образом, РНС учитывает контекст во время обучения.

Но применение рекуррентных нейронных сетей затруднено одной серьезной проблемой – проблемой исчезающего градиента (Созыкин, 2017).

Проблема исчезающего градиента состоит в том, что при добавлении в нейронные сети большого количества слоев, использующих определенные функции активации (обычно, сигмоид или гиперболический тангенс), градиенты функции потерь приближаются к нулю, что затрудняет обучение сети. Это происходит из-за того, что некоторые функции активации, такие как сигмоида, делят большое пространство входных значений на маленькое входное пространство между 0 и 1 или -1 и 1. Поэтому, большое изменение на входе, например, сигмоидной функции, вызовет небольшое изменение на выходе. Для небольших сетей с несколькими скрытыми слоями, которые используют такие функции активации, это не является проблемой, но в случае с крупными сетями производная функции в данной точке становится весьма небольшой, что снижает эффективность метода градиентного спуска при обучении сети.

Метод градиентного спуска заключается в нахождении градиентов нейронных сетей, обнаруживаемых с помощью метода обратного распространения (Федосин и др., 2010). Проще говоря, обратное распространение находит производные сети, перемещаясь слой за слоем от конечного слоя к начальному. Производные каждого уровня умножаются по сети, чтобы вычислить производные начальных слоев. Однако, когда  $n$  скрытых слоев используют функции активации, подобные сигмоидальной функции,  $n$  маленьких производных перемножаются вместе. Таким образом, градиент уменьшается по мере того, как обратное распространение доходит до начальных слоев.

Небольшой градиент означает, что веса и смещения начальных слоев не будут эффективно обновляться с каждой эпохой обучения. Поскольку эти начальные слои часто имеют решающее значение для распознавания основных элементов входных данных, это может привести к общей неточности всей сети.


Иными словами – большая РНС не будет эффективно обучаться.

Для решения этой проблемы были изобретены сети с долгой краткосрочной памятью (Long Short-Term Memory, LSTM), которые представляют собой модифицированную версию рекуррентной нейронной сети, которая облегчает запоминание прошлых данных в памяти (Hochreiter, Schmidhuber, 1997; Sainath, 2015). В таких сетях не стоит проблема исчезающего градиента. LSTM хорошо подходит для классификации, обработки и прогнозирования временных рядов с учетом временных задержек неизвестной длительности. Сети LSTM, как и обычные РНС, обучаются с использованием обратного распространения. В такой сети присутствуют три «шлюза»:

1. Шлюз утраты – определяет, какую информацию нужно отбросить из памяти нейрона. «Лишняя» информация определяется сигмоидной функцией, которая просматривает предыдущее состояние  $H(n-1)$  и текущий вход сети  $X(n)$  и выводит число от 0 до 1, на которое затем домножается  $H(n-1)$  перед сложением с числом в входном шлюзе.

2. Входной шлюз - определяет, какое значение из ввода следует использовать для изменения памяти нейрона. Сигмоидная функция работает как своего рода фильтр с порогом срабатывания на 0.1, определяя какие значения стоит запоминать, затем гиперболический тангенс определяет вес переданных значений, назначая им уровень важности в диапазоне от -1 до 1.

3. Выходной шлюз – вход и память блока используются для определения выхода. Сигмоидная функция определяет какие значения пропустить через порог срабатывания и  $\tanh$  дает вес для значений, которые передаются, определяя их уровень важности в диапазоне от -1 до 1 и умножая на выход сигмоиды.



**Рис. 1.** Структура шлюзов нейрона в сети LSTM  
Источник: Google Images

Фактически, механизм работы памяти такого нейрона можно описать по принципу «Забудь старое, если новое было лучше». Этот принцип устраняет проблемы при использовании метода градиентного спуска, поскольку, когда значение ошибки распространяется в направлении, противоположном выходному слою сети, ошибка блокируется в памяти нейрона, который непрерывно возвращает её обратно каждому шлюзу, пока они не обучатся отбрасывать значение.

Таким образом, регулярное обратное распространение ошибки эффективно для обучения LSTM запоминанию значений в течение очень длинных временных интервалов.

Так же возможно применение эволюционного/генетического алгоритма при обучении, в случае, когда обычный метод тренировки сети зашел в тупик.

Из вышесказанного следует, что при анализе временных рядов сеть LSTM будет эффективно обрабатывать неструктурированную статистическую информацию, что делает ее пригодной к использованию для анализа больших данных. Сети LSTM применялись в подобных задачах, например в труде Malhotra (Malhotra et al., 2015).

### 3. Результаты

Представлен краткий обзор применения нейронных сетей в рамках задач поиска аномалий. Сформулирован обобщенный алгоритм работы рекуррентных сетей, указана проблема исчезающего градиента. Обосновано использование в качестве алгоритма обучения нейронной сети по поиску аномалий сети Long Short-Term Memory.

### 4. Заключение

Данная работа посвящена рассмотрению алгоритмов обучения нейронных сетей, которые могут быть использованы для детектирования аномалий в потоках данных, а также обзору существующих методов и подходов к их поиску. Было проведено сравнение рекуррентной архитектуры и парадигмы обучения с LSTM-парадигмой, приведены краткие описания алгоритмов.

### 5. Благодарности

Исследование выполнено при финансовой поддержке РФФИ в рамках научного проекта № 19-01-00370.

### Литература

Горбань, 1998 – Горбань А.Н. Обобщенная аппроксимационная теорема и вычислительные возможности нейронных сетей // *Сибирский журнал вычислительной математики*. 1998. Т. 1. № 1. С. 11-24.

Осипов, 2010 – Осипов В.Ю. Рекуррентная нейронная сеть с управляемыми синапсами // *Информационные технологии*. 2010. № 7. С. 43-47.



Созыкин, 2017 – Созыкин А.В. Обзор методов обучения глубоких нейронных сетей // Вестник Южно-Уральского государственного университета. Серия: Вычислительная математика и информатика. 2017. Т. 6. № 3.

Федосин и др., 2010 – Федосин С.А., Ладяев Д.А., Марьина О.А. Анализ и сравнение методов обучения нейронных сетей // Вестник Мордовского университета. 2010. № 4.

Haykin, 1994 – Haykin, S. Neural networks: a comprehensive foundation. Prentice Hall PTR 1994.

Hochreiter, Schmidhuber, 1997 – Hochreiter S., Schmidhuber J. Long short-term memory // Neural computation. 1997. Т. 9. №. 8. Pp. 1735-1780.

Malhotra et al., 2015 – Malhotra P. et al. Long short term memory networks for anomaly detection in time series / Proceedings. Presses universitaires de Louvain, 2015. P. 89.

Sainath, 2015 – Sainath T.N. et al. Convolutional, long short-term memory, fully connected deep neural networks / 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2015. Pp. 4580-4584.

## References

Fedosin i dr., 2010 – Fedosin, S.A., Ladyaev, D.A., Mar'ina, O.A. (2010). Analiz i sravnenie metodov obucheniya neironnykh setei [Analysis and comparison of training methods for neural networks]. Vestnik Mordovskogo universiteta. № 4. [in Russian]

Gorban', 1998 – Gorban', A.N. (1998). Obobshchennaya approksimatsionnaya teorema i vychislitel'nye vozmozhnosti neironnykh setei [Generalized approximation theorem and computational capabilities of neural networks]. Sibirskii zhurnal vychislitel'noi matematiki. Т. 1. № 1. Pp. 11-24. [in Russian]

Haykin, 1994 – Haykin, S. (1994). Neural networks: a comprehensive foundation. Prentice Hall PTR.

Hochreiter, Schmidhuber, 1997 – Hochreiter, S., Schmidhuber, J. (1997). Long short-term memory. Neural computation. Т. 9. №. 8. Pp. 1735-1780.

Malhotra et al., 2015 – Malhotra, P. et al. (2015). Long short term memory networks for anomaly detection in time series. Proceedings. Presses universitaires de Louvain. P. 89.

Osipov, 2010 – Osipov, V.Yu. (2010). Rekurrentnaya neironnaya set' s upravlyaemyimi sinapsami [Recursive neural network with controlled synapses]. Informatsionnye tekhnologii. № 7. Pp. 43-47. [in Russian]

Sainath, 2015 – Sainath, T.N. et al. (2015). Convolutional, long short-term memory, fully connected deep neural networks. 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE. Pp. 4580-4584.

Sozykin, 2017 – Sozykin, A.V. (2017). Obzor metodov obucheniya glubokikh neironnykh setei [A review of teaching methods for deep neural networks]. Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Vychislitel'naya matematika i informatika. Т. 6. № 3. [in Russian]

## Алгоритм машинного обучения для детектирования выбросов и аномалий

Максим Сергеевич Василенко <sup>а, \*</sup>, Андрей Сергеевич Копырин <sup>а</sup>

<sup>а</sup> Сочинский государственный университет, Российская Федерация

**Аннотация.** Исследования по обнаружению аномалий во временных рядах являются важной темой в современной науке об аналитике данных – data science.

Существующие решения обнаружения аномалий в основном ищут отклонения в значениях параметров, которые фиксируют свойства известных (или предполагаемых известными) процессов, а это означает, что они используют так называемые числовые признаки. Следовательно, их возможности по обнаружению аномалий и отклонений в

\* Корреспондирующий автор

Адреса электронной почты: [renxi@yandex.ru](mailto:renxi@yandex.ru) (М.С. Василенко), [kopyrin\\_a@mail.ru](mailto:kopyrin_a@mail.ru) (А.С. Копырин)

априорно неизвестных процессов ограничены, так как трудно определить их числовые характеристики. Для решения данной проблемы, авторы предлагают использовать технологию машинного обучения для обнаружения аномалий наряду с мягкими вычислениями на основе нечеткой логики.

В современных искусственных нейронных сетях обычно используется большое количество нейронов, работающих параллельно и расположенных по слоям, но из-за проблемы исчезающего градиента большая рекуррентная нейронная сеть (РНС) не будет эффективно обучаться.

Предлагается использование сети с долгой краткосрочной памятью (Long Short-Term Memory, LSTM), так как, регулярное обратное распространение ошибки эффективно для обучения LSTM запоминанию значений в течение очень длинных временных интервалов.

Сделан вывод о том, что при анализе временных рядов сеть LSTM будет эффективно обрабатывать неструктурированную статистическую информацию, что делает ее пригодной к использованию для анализа больших данных.

**Ключевые слова:** поиск аномалий, нейронные сети, LSTM.