

7. Лашков И.Б. Анализ поведения водителя при управлении транспортным средством с использованием фронтальной камеры смартфона. Информационно-Управляющие Системы 4(89)б 2017 с.7-17

8. Руководство пользователя FM4200 <https://www.euromobile.ru/upload/iblock/5c0/5c0e969470cfb9983dc220e54aabab50.pdf>

9. Global Positioning System: Papers Published in Navigation, Institute of Navigation, 1980.

10. ISO 11898-1:2015 Road vehicles. Controller area network (CAN) <https://www.iso.org/standard/63648.html>

11. WebAPI <https://probki.net/b2b/webapi.html>

12. Блог Лаборатории Умного Вождения <https://smartdriving.io/blog/kak-telematika-vliyaet-na-stil-vozhdeniya-avtomobilya/>

УДК 004.77

ВЫЯВЛЕНИЕ АНОМАЛИИ ВО ВРЕМЕННЫХ РЯДАХ ФИНАНСОВОЙ СФЕРЫ

А. О. Заречный, И. А. Иванищева

Брестский государственный технический университет, Брест, Беларусь,
adrian_zare@mail.ru

Time series data is a valuable resource for analyzing various processes but can be challenging to work with due to the presence of anomalies. Autoencoder neural networks offer an effective solution for detecting these outliers by compressing and reconstructing data, identifying deviations. This approach is particularly useful in fields like finance, where anomaly detection help manage risks and improve decision-making.

Введение

Временные ряды – вид информации, являющийся крайне информационно-емким ресурсом для изучения различных процессов. Их наличие можно обнаружить во многих, как научных, так и бытовых сферах деятельности. Временные ряды является отношением выборки n -мерных данных к изменению переменной времени [1].

Анализ и обработка данных временных рядов в некоторых случаях может быть трудоемким процессом. Существует множество статистических методов для преобразования временных данных в информацию и знания. Но не всегда временные данные отражают действительность. Одной из существенных помех являются выбросы(аномалии) данных, появляющиеся в следствии различных причин: от несовершенства измерительных приборов до геополитических влияния.

Основная часть (должна иметь название)

С точки зрения данных, аномалия – это значение, не подчиняющееся общему тренду на данном временном промежутке. Как бы не были совершенны алгоритмы анализа, не всегда представляется возможным отсеять аномалии.

В виду развития искусственных нейронных сетей, задача отсеивания выбросов, стала решаться проще. Так одной из возможностей автоэнкодерных нейронной сети является способность к обнаружению аномалий. Автоэнкодер – архитектура нейронной сети, характеризующаяся прямым и обратным преобразованием данных. Автоэнкодер состоит из энкодера и декодера. При прямом преобразовании данных происходит сжатие информации до необходимого количества компонент, которые позволяют вобрать в себя главные признаки, которые наиболее полно отображают сжимаемые данные. При обратном распространении происходит восстановление данных до исходного размера, которые с некоторой допустимой погрешностью отражают данные до сжатия [2, 3].

Преимущества автоэнкодера для анализа данных состоит в методе обучения – обучение без учителя. Данный метод подразумевает, что нам нет необходимости предварительно размечать данные, что существенно снижает требования к применению задачи на различных наборах данных. Архитектура, представленная на рис. 1, сжимающей и восстанавливающей части предполагает использование нелинейных преобразований, которые и позволяют наиболее точно сжимать данные в сравнении с статистическими методами, такими как, к примеру, метод главных компонент.

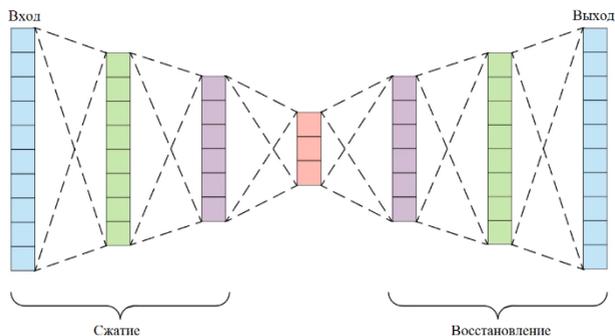


Рисунок 1 – Архитектура автоэнкодерной нейронной сети

Задача выявления аномалии при помощи автоэнкодера подразделяется на 2 глобальных этапа: обучение автоэнкодерной сети и выявление аномалий. Обучение производится на данных, не содержащих аномалии, что позволяет сети обучиться выявлять наиболее значимую информацию. Выявление аномалий же сводится к следующим шагам: сжатие входных данные, восстановление сжатых данных и сравнение их с исходными при помощи существующих метрик вычисления ошибки восстановления, к примеру, среднеквадратическое отклонение (1). Увеличение ошибки свидетельствует о наличии в

данных выбросов, что не свойственно данным, на которых происходило обучение.

$$E = \frac{1}{2} \sum_{i=1}^n (x_i - \bar{x}_i)^2, \quad (1)$$

где n – размер входных данных,

x_i – компонента образа, подаваемого на автоэнкодер,

\bar{x}_i – компонента образа, полученного на выходе автоэнкодера.

Важным примером применения методов выявления аномалий во временных рядах является работа с финансовыми данными. Финансовые временные ряды, такие как цены акций, валютные курсы или процентные ставки, подвержены существенным колебаниям из-за множества факторов: изменений на рынке, новостей, экономических событий и даже неожиданных кризисов. В таких данных выбросы могут свидетельствовать о значительных изменениях.

Применение автоэнкодеров для анализа финансовых временных рядов становится полезным инструментом для выявления этих аномалий. Важно не только распознать аномалии, но и правильно их интерпретировать. Это позволяет снизить риски и корректировать торговые стратегии. Анализ исторических данных позволяет выявлять потенциальные риски и отклонения от нормального тренда, которые могут сигнализировать о возможных проблемах или новых возможностях на рынке [4].

Преимущества: применение автоэнкодера для выявления аномалий позволяет отфильтровать данные для применения в дальнейшем, снижая возможности принятия нерациональных решений в виду нестабильности исходных данных. Так же позволяет выделять временные участки, на которых поведение данных не стабильно, что может быть полезно для выявления корреляции между различными процессами.

Недостатки: необходимо располагать достаточным объемом данных, не содержащих аномалии, что не всегда является возможным.

Заключение

Выбросы данных во временных рядах могут существенно влиять на анализ данных и игнорирование их обработку может кардинально поменять картину представления о ситуации, характеризуемой этими данными. Автоэнкодерные сети – один из возможных вариантов фильтрации данных, который уже на данный момент показывает хорошие результаты, хоть и имеет свои ограничения.

Список использованных источников

1. Михняев, А. Л. Обнаружение аномалий в данных технологического процесса / А. Л. Михняев, А. В. Пархоць, И. В. Абоимов, Д. А. Дворанинович // Цифровая среда: технологии и перспективы. DETP 2022, Брест, 31 октября 2022 / Министерство образования Республики Беларусь, Брестский государственный технический университет ; редкол.: Н. Н. Шалобыта [и др.]. – Брест : БрГТУ, 2022. – С. 62–65.

2. Головки В. А. Нейросетевые методы обработки хаотических процессов // VII Всероссийская научно-техническая конференция «Нейроинформатика. – 2005. – С. 43-91.

3. Головки, В. А. Нейросетевые технологии обработки данных : учебное пособие / В. А. Головки, В. В. Краснопрошин. – Минск : Белорусский государственный университет, 2017. – 263 с. – (Классическое университетское издание). – ISBN 978-985-566-467-4. – EDN GLVGIE.

4. Charu C. Aggarwal Outlier Analysis. - 2 изд. - New York: Springer International Publishing AG, 2017. - 465 с.

УДК 004.932

АНАЛИЗ КЛАССИЧЕСКИХ И НЕЙРОСЕТЕВЫХ МЕТОДОВ ОБНАРУЖЕНИЯ ДЫМА НА ВИДЕОИЗОБРАЖЕНИЯХ

Е. Р. Адамовский

Полоцкий государственный университет имени Евфросинии Полоцкой,
Новополоцк, Беларусь, e.adamovsky@psu.by

The paper reviews existing methods for detecting smoke in video images, taking into account accuracy and performance. Smoke images and their sequences have visual features: specific brightness and color characteristics, indefinite shape, directed low-speed movement, reduction in the energy of high-frequency background components. Approaches that use and combine these features to achieve high accuracy of smoke detection are analyzed, and their advantages and disadvantages are highlighted.

Компьютерное зрение широко применяется в различных прикладных направлениях и позволяет успешно автоматизировать многие задачи. Среди них высокую актуальность имеет автоматическое детектирование дыма, в том числе, в условиях открытого пространства, где применение традиционных датчиков дыма не представляется возможным. Для решения этой задачи перспективен анализ данных видеонаблюдения.

Дым визуально характеризуется: широким диапазоном яркостно-цветовых характеристик; различной плотностью, в зависимости от которой изменяется видимость объектов на динамической сцене; неопределенностью формы; медленным движением [1, 2]. При видеонаблюдении происходит преобразование трехмерного реального изображения в отображаемое на кадре двумерное, что приводит к потере важной информации при выделении признаков. Данные особенности и ограниченность вычислительных ресурсов аппаратных средств привели к созданию ряда подходов обнаружения с учетом анализируемой динамической сцены и решаемой задачи.