

ОБНАРУЖЕНИЕ АНОМАЛИЙ В ЭЛЕКТРОКАРДИОГРАММАХ МЕТОДАМИ ГЕНЕРАТИВНОГО ОБУЧЕНИЯ

Щетинин Е.Ю.

*Финансовый Университет при Правительстве РФ,
Россия, г. Москва ул. Щербаковская д.38
riviera-molto@mail.ru*

Аннотация Предложена модель обнаружения аномалий в электрокардиограммах на основе различных моделей автоматических кодировщиков. Компьютерные эксперименты по ее применению в задаче обнаружения аномалий в электрокардиограммах показали высокую эффективность в сравнении с другими известными моделями

Ключевые слова аномалии, электрокардиограмма, автоэнкодеры, генеративное обучение.

Введение

Обнаружение аномалий является важной областью применения искусственного интеллекта в различных областях анализа больших данных, таких как безопасность компьютерных систем, обнаружение мошенничества в банковских переводах, надежность систем компьютерного зрения и другие [1]. Выявление аномалий также является ключевой задачей анализа биомедицинской информации, поскольку нарушение устойчивости систем распознавания опасных заболеваний на основе анализа биомедицинских сигналов, МРТ, КТ-изображений, например, может привести к неверной диагностике пациентов.

Одной из главных проблем в задачах машинного обучения и анализа данных является их корректная разметка. В случае с обнаружением аномалий ее осуществление практически невозможно в силу как непредсказуемости и разнообразия их возникновения, так и искусственного происхождения. Поэтому одним из актуальных подходов решения поставленной задачи является использование методов машинного обучения без учителя [2], так как в этом случае предварительная разметка исходных данных на аномальные и нормальные данные не требуется. Существуют популярные методы решения задачи обнаружения аномалий, к числу которых относятся алгоритм изолированного леса, методы непараметрической статистики, кластерного анализа и другие [3]. Однако, на современном этапе развития методов анализа данных все более эффективными становятся методы машинного и глубокого обучения.

1 Методы глубокого обучения в задаче обнаружения аномалий

В данной работе предложен генеративный подход машинного обучения для поиска аномалий. Для этого разработаны модели автоэнкодеров, являющиеся представителями методов глубокого обучения без учителя [4]. Модель автоэнкодера состоит из кодера (encoder), скрытого слоя представления входных данных (latent representation), декодера (decoder). Входные данные высокой размерности преобразуются кодером в скрытые представления низкой размерности исходных данных. Размерность скрытых представлений меньше, чем входящие исходные данные. Задача декодера состоит в том, чтобы восстановить входные данные. Автоэнкодер принимает входные данные высокой размерности, сжимает их до представления в пространстве скрытого слоя. Затем декодер принимает скрытое представление данных в качестве входных данных для восстановления исходных входных данных. На выходе автоэнкодер представляет восстановленное изображение или сигнал. На Рис.1 приведена схема работы модели автоэнкодера.

В работе предложен следующий алгоритм разделения нормальных и аномальных наблюдений. Для каждого наблюдения из набора данных и его восстановленного вида вычисляется функция ошибки восстановления (RE)

$$RE = \sqrt{\frac{1}{M} \sum_{i=1}^M (x_i - \tilde{x}_i)^2}, \quad (1)$$

где x_i, \tilde{x}_i – характеристики реального и восстановленного наблюдений соответственно, M – количество анализируемых наблюдений. Аномальное наблюдение отличается от нормального тем, что ошибка его восстановления будет больше, чем нормальных наблюдений. Далее изображения сортируются по величине RE и классифицируются по максимальным значениям RE как аномалии на основе предварительно заданного порогового значения.

2. Компьютерные эксперименты

2.1 Описание данных

В работе проведены вычислительные эксперименты по тестированию предложенного метода обнаружения аномалий на наборе электрокардиограмм пациентов с различными заболеваниями сердца [6,7]. Исследуемый набор данных был создан и сбалансирован таким образом, что представляет собой 5000 записей электрокардиограмм, из которых доля нормальных сигналов составляет 58%, доля аномальных сигналов составляет 42%. Каждая строка соответствует одной полной записи ЭКГ пациента. Каждая электрокардиограмма состоит из 140 точек данных. Она обладает меткой, которая показывает, является ли ЭКГ нормальной или аномальной. Это категориальная переменная со значением 0 или 1. (Нормальная ЭКГ соответствует метке 0, аномальная ЭКГ соответствует метке 1). В качестве предварительной обработки ЭКГ-сигналы были нормализованы по формуле

$$data = \frac{(data - data_{min})}{(data_{max} - data_{min})}.$$

Далее, все данные были разделены на два набора: тренировочный $data_{train}$ и тестовый $data_{test}$. Размер тренировочного набора составил 4000 ЭКГ, тестового – 1000 ЭКГ.

2.2 Модель автоэнкодера

Для обнаружения аномальных ЭКГ-сигналов в работе предложена модель автоэнкодера на основе глубоких нейронных сетей. Модель автоэнкодера реализована на языке программирования Python с помощью фреймворка Keras [10]. Энкодер состоит из 5-х полносвязных слоев Dense(128), Dense(64), Dense(32), Dense(16), Dense(8) с функцией активации ReLU каждый. Декодер состоит из пяти полносвязных слоев Dense(16), Dense(32), Dense(64), Dense(128) с функцией активации ReLU и одного полносвязного слоя Dense(140) с сигмоидной функцией активации 'sigmoid'. Функция потерь при реконструкции сигналов задана среднеквадратической ошибкой между исходным изображением и обработанным нейросетью изображением (1). При обучении применялись метод оптимизации Adam, функция потерь MAE, скорость обучения составила 1E-04. Всего было проведено 500 эпох обучения модели, параметр bath_size=32.

3. Анализ производительности модели автоэнкодера

В процессе компьютерных экспериментов модель автоэнкодера вначале была обучена на нормальных ЭКГ-сигналах из обучающего набора с целью нахождения средней ошибки восстановления сигналов для этого класса и установления порога отсека сигнала, предположительно являющегося аномалией. Начальное значение порога отсека было выбрано в виде суммы среднеквадратической ошибки восстановления сигналов из обучающего набора и среднеквадратического отклонения этой ошибки $h = \text{MSE}(\text{data}_{train}) + \text{std}(\text{data}_{train})$. В результате расчетов средняя ошибка восстановления для сигналов из тренировочного набора составила 0.00758. При этом порог составил значение $h = 0.0116$. На Рис.2 а построен график нормальных ЭКГ-сигналов из обучающего набора, восстановленного сигнала, а также ошибка его реконструкции. Черным цветом обозначен исходный сигнал, красным цветом- восстановленный, площадь между ними – ошибка восстановления. Затем были проведены аналогичные расчеты для ЭКГ-сигналов из тестового набора аномальных электрокардиограмм. Значение ошибки восстановления для них оказалось равным 0.35. Результаты расчетов также представлены на Рис.2 б.

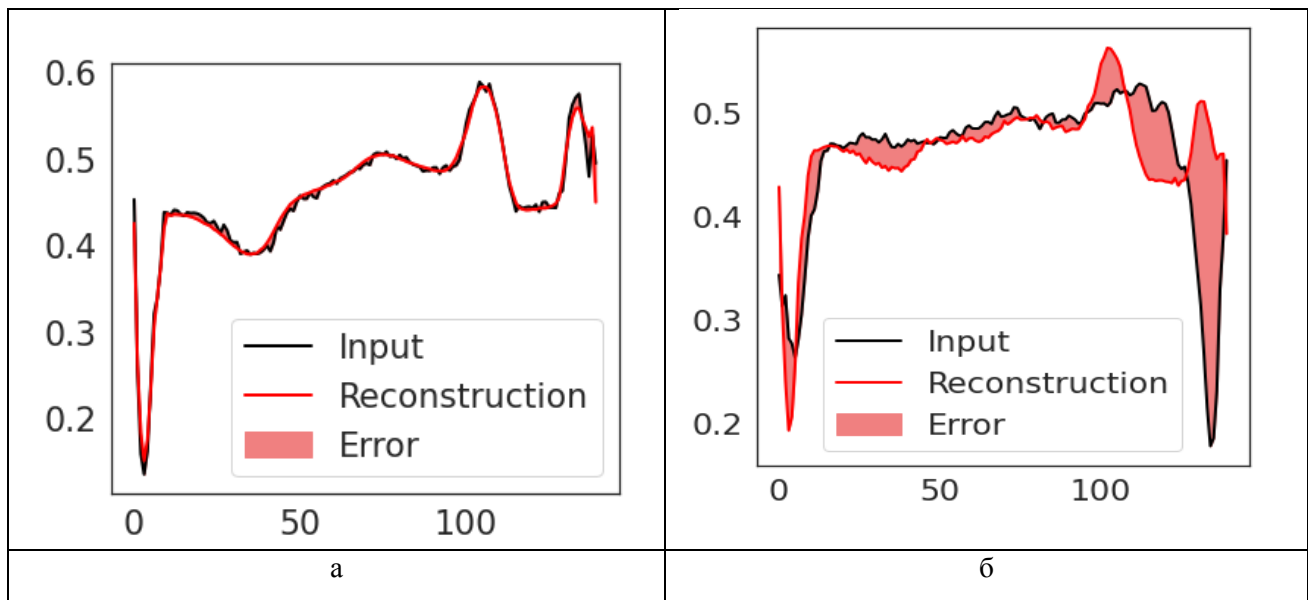


Рис. 2. Примеры восстановленных ЭКГ-сигналов: а) из обучающего набора нормальных ЭКГ-сигналов б) из тестового набора аномальных ЭКГ-сигналов

Если ошибка восстановления для тестируемого сигнала превышает одно стандартное отклонение от нормального сигнала, то такой сигнал был классифицирован как аномальный. При сравнении результатов можно увидеть, что ошибка восстановления аномальных сигналов превышает ошибку восстановления нормальных сигналов. Статистические характеристики распределения ошибки восстановления нормальных ЭКГ-сигналов из обучающего набора приведены на Рис.3. Также на нем построен график ядерной оценки эмпирической плотности распределения ошибки восстановления. Среднее значение ошибки восстановления аномальных сигналов составило значение 0.035. Его график показан вертикальной зеленой линией на Рис.3. На Рис.3 также построены график ошибки восстановления аномальных ЭКГ-сигналов из тестового набора данных и ядерная оценка ее эмпирической плотности распределения. Как видно из Рис.3, при выборе первоначально установленном пороге значительное количество нормальных сигналов ошибочно классифицировано как аномальные, что позволяет утверждать о выбранном низком значении порога отсечения аномальных сигналов.

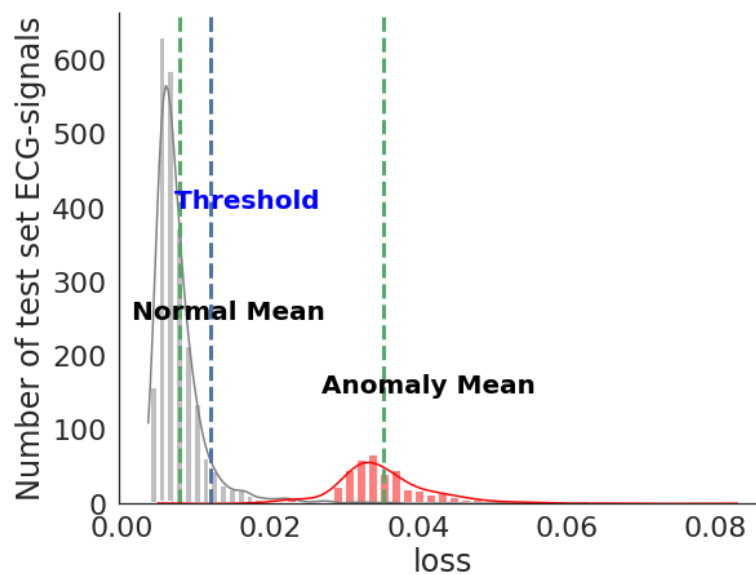


Рис. 3. Эмпирическое распределение ошибки восстановления для нормальных сигналов и аномальных сигналов из тестового набора при значении порога $h = 0.0116$

Для оценивания показателей производительности модели автоэнкодера в работе использованы показатели точности accuracy, precision, recall, f1-score, Area Under Curve (AUC) [3,7].

$$\text{Accuracy}=(\text{TP}+\text{TN})/(\text{TP}+\text{TN}+\text{FP}+\text{FN}) \quad (2)$$

$$\text{Precision}=\text{TP}/(\text{TP}+\text{FP}) \quad (3)$$

$$\text{Recall}=\text{TP}/(\text{TP}+\text{FN}) \quad (4)$$

$$\text{F1-score}= 2*\text{Precision}*\text{Recall}/(\text{precision}+\text{recall}), \quad (5)$$

где TP- истинно положительные случаи для данного класса (Normal), FN-ложно отрицательные случаи для данного класса (в частности, для класса Abnormal это число аномалий, ошибочно предсказанных моделью как не аномалии). TN-истинно отрицательные случаи (Abnormal). FP-ложно положительные случаи для данного класса (в частности, для класса Normal это число аномалий, ложно предсказанных моделью как Normal). Для вычисления показателей (2)-(5) используют матрицу неточностей (confusion matrix) [7]. Диагональные ячейки обозначают истинно положительные значения (TP, %) и истинно отрицательные значения (TN, %). В случае указания в ячейках процентов, считается, что в них указаны значения показателя точности (accuracy) для соответствующего класса. Остальные ячейки матрицы содержат процентное соотношение изображений, которые оценены моделью как ложно положительные (вертикальные элементы, FP, %) и ложно отрицательные (горизонтальные элементы, FN, %) изображения.

При первоначально заданном пороге $=0.0116$ показатели производительности составили accuracy=93.8%, precision=99.6%, recall=89.28%, f1-score=94.16%, AUC=94.44%. Точность классификации класса аномалий составила 87.86%. При выборе порога, равного среднему значению функции потерь на тестовом наборе аномальных электрокардиограмм 0.3524, показатели производительности составили accuracy=0.752, precision=0.693, recall=1, F1-score=0.8187, AUC=0.718. На Рис.4 построены графики с статистическими характеристиками распределения ошибки восстановления нормальных ЭКГ-сигналов из обучающего набора при пороге $h=0.035$. Также на нем построен график ядерной оценки эмпирической плотности распределения ошибки восстановления. Очевидно, что оптимальное значение порога находится между этими значениями, поскольку вместе со снижением показателя точности accuracy показатель recall вырос, что означает, что выросло число ложноотрицательных случаев.

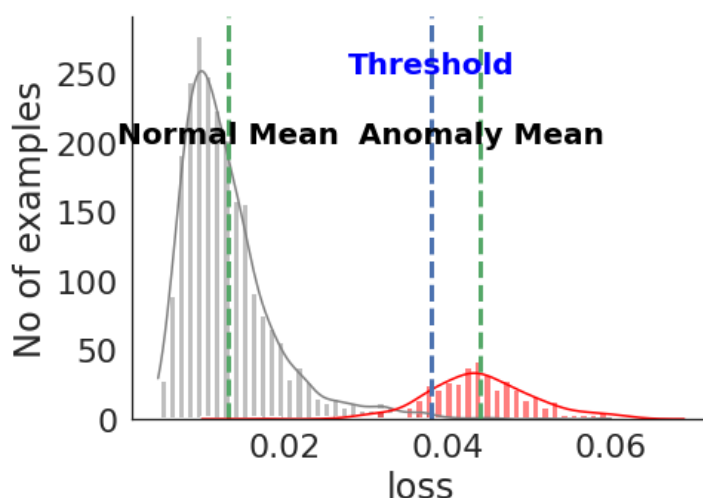


Рис. 4. Эмпирическое распределение ошибки восстановления для нормальных сигналов и аномальных сигналов из тестового набора при значении порога $h = 0.035$

Таким образом, очевидно, что показатели точности классификации аномалий чувствительны к выбору порога, и необходима разработка алгоритма его подбора. Для автоматизации выбора оптимального значения порога отсека аномалий предложено использовать методы тонкой настройки гиперпараметров модели автокодировщика [8]. Тонкая настройка параметров автоэнкодера показала, что оптимальный порог отсека достигнут при значениях гиперпараметров модели batch_size=32, epochs=500, скорости обучения модели lr=1e-04. В процессе компьютерных экспериментов были вычислены соответствующие показатели точности (2-5) для значений порога отсека из интервала [Normal Mean, Anomaly Mean] Их анализ показал, что при низком пороге модель автоэнкодера выявила большое количество ложных аномалий (False Negative, FN), которые в действительности являются нормальными ЭКГ-сигналами. При высоком пороге модель выявила большое количество ложных нормальных сигналов (False Positive, FP). Баланс этих величин достигнут при значении порога $h = 0.023$, соответствующие показатели точности обнаружения

аномалий составляют следующие значения: accuracy= 98.8, precision=98.7544, recall=99.1, f1-score=98.93, AUC=98.758. Можно также заметить, что при этом значении показатели точности accuracy, accuracy_anomaly также достигли своего оптимального значения. На Рис.5 построены графики функции ошибки реконструкции нормальных сигналов из обучающего набора, а также функции ошибки реконструкции сигналов из тестового набора. Здесь же построены графики непараметрических оценок плотности распределения функций ошибки реконструкции. Синим цветом указан порог отсеечения аномалий.

Заключение

В работе исследованы методы обнаружения аномалий методами машинного и глубокого обучения без учителя. В качестве данных выбран набор электрокардиограмм, содержащих как нормальные ЭКГ-сигналы, так и ЭКГ-сигналы людей с различными сердечно-сосудистыми заболеваниями. Для обнаружения аномальных электрокардиограмм предложено использовать методы машинного обучения без учителя и разработана модель автоматического кодировщика в виде глубокой нейронной сети с несколькими полносвязными слоями. Также для решения поставленной задачи предложен метод подбора порога отсеечения аномальных ЭКГ-сигналов от нормальных, состоящий в оптимизации соотношения показателей производительности модели автоэнкодера.

Результаты компьютерных экспериментов показали высокую эффективность предложенного подхода к обнаружению аномалий, по сравнению с другими моделями машинного обучения, такими как метод опорных векторов, логистическая регрессия и LGBM. В случае доступности меток классов предложенный метод может использоваться как метод бинарной классификации, а его результаты сравнимы по точности с методами классификации, такими как LGBM, SVM. В дальнейшем предложенную модель можно улучшить за счет увеличения числа полносвязных слоев, а также создания более продвинутых моделей автокодировщика на основе моделей рекуррентных и сверточных глубоких нейронных сетей. Также в будущем возможно разработать модели автокодировщика на основе предварительно обученных моделей глубоких нейронных сетей и самообучения. Все это представляет предмет для дальнейших наших исследований.

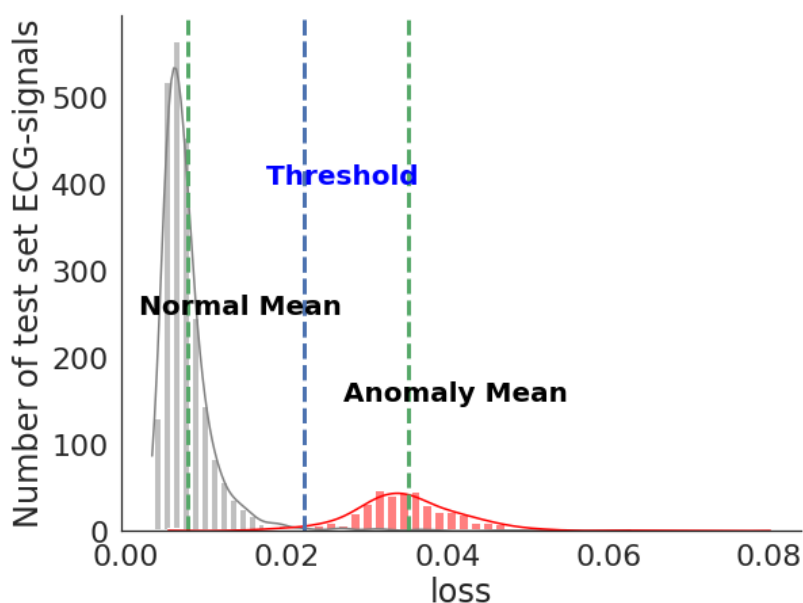


Рис.5. Результаты классификации нормальных и аномальных ЭКГ-сигналов из тестового набора ЭКГ-сигналов при оптимальном значении порога $h = 0.023$

Литература

1. *Azzedine Boukerche, Lining Zheng, Omar Alfandi.* 2020. Outlier Detection: Methods, Models and Classifications. Comput. Surveys.
2. *Раиша С., Мурджалили В.,* Python и машинное обучение. Машинное и глубокое обучение с использованием Python, scikit-learn и TensorFlow 2, М.: Диалектика-Вильямс, ISBN-978-5-907203-57-0. 2021, С.848.
3. *Щетинин Е. Ю.,* Автоматическое обнаружение нарушений сердечного ритма на основе анализа электрокардиограмм методами глубокого обучения, Вестник компьютерных и информационных технологий// 2021, т.18(5).- С.18-27.

4. *Щетинин Е.Ю., Севастьянов Л.А.* О методах повышения точности многоклассовой классификации на несбалансированных данных, Информ. и её применения. 2020. №14. С. 63–70.
5. *Bradsky G., Kaehler A.* Learning OpenCV. N.Y. O'Reilly, 2008. P.577.
6. *Шолле Ф.* Глубокое обучение на Python. Питер. 2018. С.400.
7. *Анкур Пател* Прикладное машинное обучение без учителя, М.: Диалектика, 2020, с. 432.
8. *Щетинин Е.Ю., Севастьянов Л.А.* О методах переноса глубокого обучения в задачах классификации биомедицинских изображений, Информатика и ее применения. 2021, 15(4), с.59-64.