

Московский государственный университет имени М. В. Ломоносова

Факультет вычислительной математики и кибернетики

Кафедра математических методов прогнозирования

Каюмов Эмиль Марселевич

Автоматическое выделение признаков в сигналах кардиограмм в задаче выявления болезней сердца

ВЫПУСКНАЯ КВАЛИФИКАЦИОННАЯ РАБОТА

Научный руководитель:

д.ф-м.н., профессор

А. Г. Дьяконов

Москва, 2017

Содержание

1	Введение	3
2	Постановка задач	4
2.1	Задача классификации	4
2.2	Задача извлечения признаков	4
2.3	Задача детектирования ишемической болезни сердца	4
3	Традиционные методы	6
3.1	Дискретное преобразование Фурье	6
3.2	Вейвлет-преобразование	7
3.3	Dynamic Time Warping	8
3.4	Эвристические подходы	9
4	Свёрточные нейронные сети	9
4.1	Общее описание	9
4.2	Извлечение признаков с помощью нейронной сети	11
4.3	Многомасштабная свёрточная нейронная сеть (MCNN)	12
5	Применение MCNN для классификации кардиограмм	13
5.1	Особенности и модификации MCNN	14
5.2	Извлечение признаков с помощью MCNN	15
5.3	Применение MCNN	15
6	Эксперименты	16
6.1	Данные и задача	16
6.2	Сравнение с традиционными методами	17
6.3	Полезность многомасштабности	19
6.4	Визуализация извлечённых признаков	20
6.5	Обсуждение и выводы	20
7	Заключение	21
	Список литературы	23

Аннотация

Свёрточные нейронные сети – мощные и гибкие алгоритмы машинного обучения, нацеленные на детектирование и классификацию объектов на изображениях. Недавних успех свёрточных нейронных сетей породил множество попыток применения этих инструментов в других задачах машинного обучения.

В данной работе предложена адаптация идеи многомасштабной свёрточной нейронной сети для извлечения признаков из сигналов кардиограмм в задаче детектирования болезней сердца. Проведено сравнение с традиционными подходами к задаче и показано, что многомасштабные свёрточные нейронные сети достигают более высокого качества при решении этой задачи.

1 Введение

Медицина – одна из сфер человеческой деятельности, в которой в современное время происходят активные попытки применить машинное обучение. При успешном решении задач детектирования различных болезней станет возможным диагностировать заболевания на ранних этапах развития и оказывать своевременную помощь большему числу людей. Примерами конкретных задач являются:

1. Детектирование рака лёгких по снимкам томографа [1].
2. Предупреждение эпилептических приступов по электроэнцефалограммам [2].
3. Распознавание диабетической ретинопатии на снимках [3], [4].
4. Детектирование болезней сердца [5],

Несмотря на возможные сложности внедрения автоматизированных и чаще всего неинтерпретируемых подходов, методы машинного обучения могут помочь людям узнать о возможном диагнозе, что позволит им быстрее пройти тщательное обследование и начать лечение, а врачам – помочь находить заболевания среди множества данных о пациентах из различных источников.

В данной работе рассмотрена задача детектирования ишемической болезни сердца по сигналам кардиограмм. Рассмотрены традиционные методы решения задачи, а также предложена адаптация недавно предложенной идеи многомасштабной свёрточной нейронной сети [6] для извлечения признаков из сигналов кардиограмм, которая сводит задачу классификации сигналов к классической задаче классификации в машинном обучении. Предложена конкретная архитектура нейронной сети и произведено сравнение различных методов. Выявлено, что предложенный подход с многомасштабной свёрточной нейронной сетью показывает более высокое качество детектирования болезней сердца по сравнению с традиционными подходами.

Значимость и научная новизна состоит в предложенной адаптации идеи многомасштабной свёрточной нейронной сети для задачи извлечения признаков из сигналов кардиограмм и в сравнении предложенного подхода с традиционными методами извлечения признаков из сигналов.

2 Постановка задач

Кратко приведем основные необходимые понятия машинного обучения. Подробнее можно найти в [7].

2.1 Задача классификации

S – множество описаний сигналов. Каждый сигнал $s \in S$ представляет собой последовательность измерений во времени $s = (s[1], \dots, s[n_s])$, $s[i] \in \mathbb{R}^d$, где n_s – длина сигнала s .

Y – конечное множество меток классов. Существует неизвестная целевая зависимость $y^* : S \rightarrow Y$, значения которой известны только на объектах конечной обучающей выборки $S^m = \{(s_1, y_1), \dots, (s_m, y_m)\}$.

Требуется построить алгоритм $a : S \rightarrow Y$, способный классифицировать произвольный объект $s \in S$.

2.2 Задача извлечения признаков

Пусть X – множество векторных описаний объектов (чаще всего фиксированной длины). Задачей извлечения признаков назовем поиск отображения $f : S \rightarrow X$.

Задача извлечения признаков возникает в случаях, когда исходные данные не позволяют использовать классические алгоритмы машинного обучения, так как большинство из них работает только с матрицами объекты-признаки. Например, в задачах, связанных с текстами, последовательность слов чаще всего необходимо кодировать в виде вектора чисел фиксированной длины.

2.3 Задача детектирования ишемической болезни сердца

Задача детектирования ишемической болезни сердца по сигналам кардиограмм – задача классификации на 2 класса, где объектами являются сигналы. Задача извлечения признаков из сигналов – поиск отображения из пространства сигналов (произвольной длины) в пространство векторных представлений объектов (фиксированной длины) для дальнейшего решения задачи классификации. Пример части кардиограммы можно увидеть на рис. (1).




Рис. 1: Пример кардиограммы




Рис. 2: Интервалы кардиоцикла

При анализе кардиограмм врач обращает внимание на различные интервалы сердечного цикла: их относительные длины, высоты, положение, характер зубцов [8]. На основе этих показаний могут быть диагностированы различные заболевания. На рис. (2) можно увидеть иллюстрацию кардиоцикла, разбитого на интервалы. Кроме этого, чаще всего производятся замеры с разных мест (отведений), каждое из которых обладает определёнными особенностями. В рамках данной работы рассмотрены только одноканальные (одномерные) кардиограммы.

Сложностью классификации по сырым данным кардиограмм является их нестабильность из-за шумов и трендов, разные длины сигналов и отсутствие привычного признакового описания.

3 Традиционные методы

В данном разделе рассмотрены классические методы извлечения признаков из кардиограмм и подходы к детектированию болезней по сигналам кардиограмм.

3.1 Дискретное преобразование Фурье

Для анализа сигналов часто используется преобразование Фурье. Это преобразование позволяет перейти из временной области в частотную, то есть избавиться от сдвигов сигнала во времени.

Для дискретных сигналов применяется дискретное преобразование Фурье (ДПФ). Для сигнала s длины N дискретное преобразование задаётся следующим образом:

$$\hat{s}[k] = \sum_{n=0}^{N-1} s[n] \exp^{-2\pi i k \frac{n}{N}}, 0 \leq k \leq N - 1.$$

Характеристики сигнала могут в значительной степени изменяться со временем. В таком случае его следует разбить на маленькие фрагменты, так чтобы параметры каждого фрагмента можно было считать стационарными (не зависящими от времени). Вычисление ДПФ от всей кардиограммы приводит к потере локальных особенностей сигнала (особенностями конкретных кардиоциклов). Чтобы сохранить локальную информацию используется оконное дискретное преобразование Фурье (ОДПФ). Фиксируется ширина окна (выбирается в зависимости от свойств сигнала, в данной задаче, например, примерно равная длине кардиоцикла). К скользящему окну применяется оконная функция w и вычисляются модули коэффициентов ДПФ. Процесс повторяется для всего сигнала вместе с движением окна. Оконное дискретное преобразование Фурье вычисляется следующим образом:

$$\tilde{s}[m, f] = \sum_{n=-\infty}^{+\infty} s[n] w[n - m] \exp^{-ifn}$$

Для получения агрегированных показателей всей кардиограммы коэффициенты, полученные с помощью оконного дискретного преобразования Фурье, можно усреднять по соответствующим частотам. В таком случае независимо от длины сигнала будем получать векторное описание кардиограммы фиксированной длины.

На полученных признаках можно применить большинство из алгоритмов машинного обучения, например, случайный лес или метод опорных векторов.

3.2 Вейвлет-преобразование

Альтернативой преобразованию Фурье служит вейвлет-преобразование, которое представляет собой свёртку вейвлет-функции с сигналом. Вейвлет-преобразование переводит сигнал из временного представления в частотно-временное.

Для дискретных сигналов применяется дискретное вейвлет-преобразование путём применения набора фильтров. Сначала сигнал пропускается через низкочастотный фильтр с импульсным откликом g :

$$\hat{s}[n] = \sum_{k=-\infty}^{+\infty} s[k]g[n - k]$$

Одновременно сигнал аналогично раскладывается с помощью высокочастотного фильтра h . В результате получаются детализирующие коэффициенты (после ВЧ-фильтра) и коэффициенты аппроксимации (после НЧ-фильтра). После отсчёты сигналов прореживаются в 2 раза. Это разложение можно повторить несколько раз для дальнейшего увеличения частотного разрешения с дальнейшим прореживанием коэффициентов после НЧ и ВЧ-фильтрации. Пример такого преобразования можно увидеть на рис. (3).




Рис. 3: Пример трёхуровневого гребёнки фильтров вейвлет-преобразования

Полученные таким образом коэффициенты разложения сигналов кардиограмм можно использовать в качестве признаков в задаче машинного обучения.

В статье [9] предлагается использовать детализирующие коэффициенты 1 – 4 порядков и аппроксимирующие коэффициенты 4-го порядка. В качестве вейвлет-функции предлагается использовать вейвлет Добеши 2-го порядка, так как он визуально похож на кардиоцикл.

3.3 Dynamic Time Warping

Альтернативой подходу с выделением признаков является вычисление схожести между сигналами кардиограмм [10]. Сравнивать поточечно два сигнала некорректно, так как при сдвиге одного сигнала относительно другого такие метрики, как евклидова, покажут значительные различия. Эту проблему решает алгоритм динамической трансформации временной шкалы, который позволяет найти оптимальное соответствие между временными последовательностями, не обращая внимание как на глобальные, так и на локальные сдвиги на временной шкале. Пример сопоставления двух сигналов можно увидеть на рис. (4).

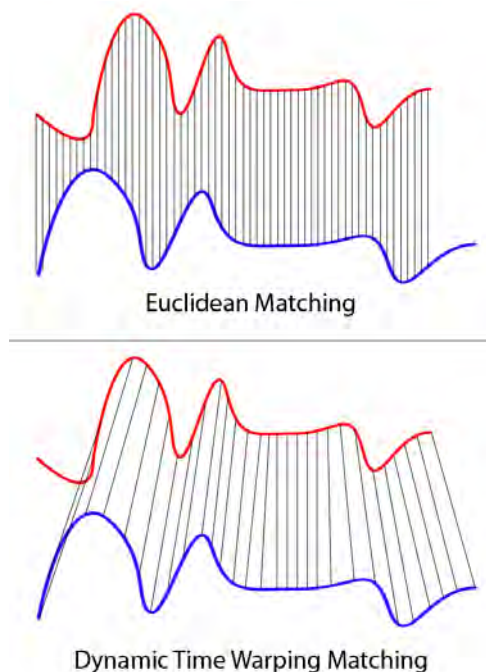


Рис. 4: Пример сопоставления двух сигналов

В процессе вычисления расстояния между сигналами сначала строится матрица расстояний D между точками сигнала порядка $m \times n$, где m, n – длины сигналов. Далее вычисляется матрица трансформаций:

$$K_{i,j} = D_{i,j} + \min(K_{i-1,j}, K_{i,j-1}, K_{i-1,j-1})$$

После заполнения матрицы деформации строится путь трансформации. Это последовательность элементов матрицы трансформации, которая минимизирует расстояние между сигналами, для которых должны выполняться условия непрерывности

и монотонности. Среди всех возможных путей трансформации, которые удовлетворяют условиям, выбирается минимальный. DTW расстояние между двумя последовательностями выражается через оптимальный путь трансформации.

Имея возможность вычислять попарные расстояния между сигналами кардиограмм можно применить алгоритм k-ближайших соседей для классификации кардиограмм. Несмотря на линейную сложность вычисления быстрого DTW-алгоритма, использование данного подхода значительно уступает по времени работы описанным ранее подходам с извлечением признаков.

3.4 Эвристические подходы

В некоторых работах предлагается использовать признаки, основанные на описании интервалов кардиоцикла, связанных с определёнными заболеваниями [11]. Примерами таких признаков являются: высота R пика, длина PR, RR, ST интервалов, их относительное местоположение (рис. (2)). К этому же разделу можно отнести признаки Успенского, которые считают как триграммы относительных изменений трёх характеристик соседних кардиоциклов.

Недостатком данного подхода является их подстройка под конкретную задачу и конкретные условия (данные). При небольшом изменении в данных эвристики по обнаружению интервалов кардиоцикла могут перестать работать корректно.

4 Свёрточные нейронные сети

4.1 Общее описание

Понятие искусственной нейронной сети было предложено в 1943 году У. Маккалоком и У. Питтсом [12].

Пусть $a(x, w) = f(\sum_{i=1}^D w_i x_i + w_0)$, где f – некоторая функция, называемая функцией активации. Модель такого вида называется нейроном. Нейронная сеть в общем случае строится как соединение множества нейронов, объединенных в уровни так, что выходы одного уровня являются входами следующего. Эти уровни нейронной сети называют слоями. Полносвязным (fully-connected layer) называют слой, в котором каждый нейрон связан с каждым нейроном предыдущего слоя. На




Рис. 5: Пример нейронной сети с 1 скрытым слоем

рис. (5) изображена нейронная сеть с 4 входами, 1 скрытым слоем из 5 нейронов и 1 выходным нейроном.

Появление свёрточных нейронных сетей было мотивировано биологическими визуальными системами. Главным отличием свёрточного слоя (convolutional layer) от полносвязного состоит в том, что в нём к каждому фрагменту входных данных применяется одна и та же свёртка (поэлементное умножение свёртки с фрагментом и суммирование полученных произведений), а результат записывается в соответствующую позицию выходных данных. В архитектуру свёрточной сети закладывается знание из компьютерного зрения: каждый пиксель изображения сильнее связан с соседними пикселями по сравнению с удалёнными, а объект на изображении может находиться в любом месте. В случае одномерных входных данных результат применения свёрточного слоя l с фильтром размера k в позиции i вычисляется следующим образом: $x_i^l = f(\sum_{j=1}^k w_j^l x_{i+j}^{l-1})$.

Кроме свёрточных слоёв используются субдискретизирующие слои (subsampling layer) для уменьшения размерности. В случае с max- или average- pooling каждый фрагмент входных для слоя данных заменяется на соответственно максимальное и среднее значение рассматриваемого фрагмента. В global-pooling описанная операция производится не для окрестности, а сразу всех входных данных.

Для уменьшения эффекта переобучения (чрезмерная подстройка алгоритма под обучающую выборку) нейронной сети используется dropout-регуляризация (dropout layer) [13]. Идея следующая: на каждом шаге обучения каждый нейрон исключается

из сети с некоторой вероятностью p . Это позволяет нейронам настраиваться независимо от друг друга.




Рис. 6: Пример свёрточной нейронной сети

Свёрточная нейронная сеть обычно представляет собой чередование свёрточных, субдискретизирующих и полносвязных слоёв. После каждого слоя может быть использован dropout слой. Обучение нейронной сети обычно производится стохастическим градиентным спуском при помощи метода обратного распространения ошибки [14] для вычисления градиента весов. В качестве функции активации могут использоваться: $ReLU(x) = \max(x, 0)$, $\sigma(x) = \frac{1}{1+\exp^{-x}}$, $\tanh(x) = \frac{\exp^x - \exp^{-x}}{\exp^x + \exp^{-x}}$.

На рис. (6) можно увидеть пример свёрточной нейронной сети для распознавания изображений.

4.2 Извлечение признаков с помощью нейронной сети

Рассмотрим структуру сети как набор слоёв от входа к выходу и активации, полученные с k -го скрытого слоя. Существует гипотеза, что активации обладают все большей дискриминативной способностью с увеличением k . Эксперименты показывают [15], [16], что активации слоёв нейронной сети, являются хорошими признаками для других алгоритмов машинного обучения.

Кроме этого, использование кросс-энтропийной функции потерь вместе с софтмакс активациями последнего слоя равноценно использованию логистической регрессии над активациями, полученными с последнего скрытого слоя нейросети.

Таким образом, если нейронная сеть показывает хорошую точность, можно считать, что активации последнего слоя являются хорошими дискриминативными признаками объектов, а нейронную сеть использовать в качестве преобразователя данных.

4.3 Многомасштабная свёрточная нейронная сеть (MCNN)

Многомасштабная свёрточная нейронная сеть (MCNN) для классификации временных рядов были предложены в статье [6] 2016-го года. Основной идеей является подача нейронной сети одного и того же ряда в разных масштабах для извлечения признаков на разных временных промежутках. В отличие от традиционных подходов для работы с временными рядами и сигналами процесс извлечения признаков и классификации решается одной нейронной сетью, обучение ведётся совместно. Это позволяет алгоритму учиться выделять полезные для конкретной задачи признаки.




Рис. 7: Общая схема многомасштабной свёрточной нейронной сети

Структура многомасштабной свёрточной нейронной сети состоит из трёх последовательных частей (рис. (7)):

1. Стадия трансформации (transformation stage). Идея в применении различных преобразований над входным временным рядом. Предлагается использовать тождественное преобразование (сохранение исходного временного ряда), сжатие по длине (прореживание) и сглаживание временного ряда с помощью низкочастотного фильтра для уменьшения шума. Ряд после каждого преобразования подаётся в отдельную ветвь сети.
2. Локальная свёрточная стадия (local convolution stage). С каждой ветвью производятся локальные преобразования нейронной сетью независимо от

других ветвей. Применение свёрточных фильтров одного размера во всех ветвях позволяет извлекать признаки на разных временных масштабах исходного сигнала за счёт использования разных длин входного сигнала. В отличие от подхода с использованием фильтров разного размера как, например, в архитектурах серии Inception, уменьшается количество обучаемых параметров сети и сложность применения свёрток. Кроме этого, предлагается использовать субдискретизирующий слой с размером окрестности действия и шагом сдвига вида $\frac{n}{p}$, где n – длина входа, $p \in \{2, 3, 5\}$, что заметно больше привычных параметров в задачах распознавания изображений. Это позволяет использовать большее количество фильтров, каждый из которых будет извлекать локальные признаки.

3. Полная свёрточная стадия (full convolution stage). Результаты локальных ветвей конкатенируются, далее применяются свёрточные и полносвязные слои, на выходе получают вероятности классов.

Описанный подход показал хорошие результаты в задаче классификации временных рядов, однако стоит заметить, что далеко не во всех случаях показал результат лучше, чем какой-либо из традиционных подходов. Многомасштабная свёрточная нейронная сеть показала результаты в большинстве случаев более высокие по сравнению с обычной свёрточной сетью.

5 Применение MCNN для классификации кардиограмм

Мотивацией для применения многомасштабных свёрточных нейронных сетей в задаче детектирования болезней сердца по сигналам кардиограмм являлись особенности задачи выявления болезней, связанные с поиском и анализом интервалов кардиоцикла. Объединение этапов извлечения признаков и обучения классификатора потенциально позволяет получить более высокое качество по сравнению с традиционными методами, в которых признаки извлекаются независимо от классификации и могут нести мало пользы в конкретной задаче машинного обучения.

5.1 Особенности и модификации MCNN

Опишем особенности и модификации многомасштабной свёрточной нейронной сети в задаче детектирования ишемической болезни сердца.

1. Основной единицей данных для кардиограммы является кардиоцикл, поэтому в качестве входа предлагается использовать срез сигнала длины, соответствующей одному кардиоциклу. Для данных, которые использовались в экспериментах, это соответствовало 1000 отсчётов, то есть на вход сети подаётся одномерный вектор длины 1000.
2. Абсолютные значения сигнала на кардиограммах могут заметно различаться во времени. Если нормализовать сигнал, используя максимальное значение всей кардиограммы, то есть риск из-за возможных шумовых значений и наличия тренда получить большую часть кардиограммы с абсолютными значениями близкими к нулю. Предлагается нормировать не всю кардиограмму, а только подаваемый на вход сети срез с помощью приведения среднего значения к нулю и деления на максимальное по модулю значение.
3. В качестве трансформации кроме тождественного преобразования предлагается уменьшать длину сигнала в 2 и 4 раза. В таком случае при использовании свёрточного фильтра размера 50 в каждой из ветвей фильтр будет наблюдать соответственно 20%, 10% и 5% сигнала. В экспериментах изменение длины сигналы производилось с помощью прямого и обратного дискретного преобразования Фурье путём восстановления сигнала по коэффициентам с удалением высоких частот.
4. Так как сеть получает срез кардиограммы, в которой положение кардиоцикла неизвестно, то место конкретных откликов фильтра не имеет значения, поэтому предлагается использовать вместо max-pooling слоя с большим размером области глобальный max-pooling (то есть max-pooling с размером области равной всему входу). Это позволит сети не обращать внимания на сдвиг сигнала по времени, а смотреть на максимальные отклики каждого фильтра по всему срезу сигнала.

Предложенную архитектуру сети можно увидеть на рис. (8). Подробнее описано в разделе с экспериментами.

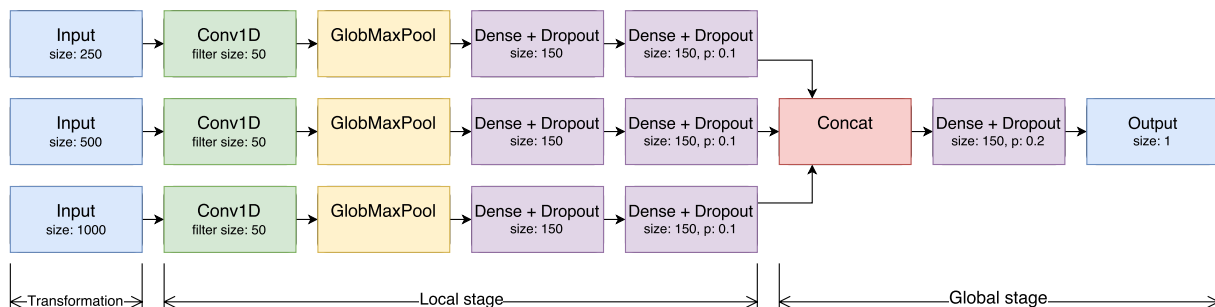


Рис. 8: Предложенная архитектура для классификации кардиограмм

5.2 Извлечение признаков с помощью MCNN

После обучения нейронной сети её можно использовать для извлечения признаков. Извлекая активации с последнего слоя, получим признаки, соответствующие срезу кардиограммы.

5.3 Применение MCNN

Обученную многомасштабную свёрточную нейронную сеть можно использовать в задаче детектирования ишемической болезни сердца несколькими способами:

1. Классифицировать кардиограммы самой сетью без извлечения признаков и применения классических алгоритмов машинного обучения. Для получения предсказания по всему сигналу кардиограммы можно усреднить вероятности по срезам, которые получены последовательным проходом по кардиограмме окном с определённым сдвигом.
2. Извлекать признаки сетью по окнам, далее обучать и применять на них другой алгоритм классификации. Предсказание для всей кардиограммы можно получать аналогично предыдущему пункту – усреднением вероятностей по каждому срезу сигнала.
3. Также можно перенести этап усреднения по окнам на этап извлечения признаков, если предположить, что получаемое описание объектов стабильно

в течение всей кардиограммы с точностью до шума. То есть усреднять соответствующие признаки при проходе окном по кардиограмме и только потом применять алгоритм классификации на полученных признаках. Результаты проверки этого предположения описаны в разделе с экспериментами.

В экспериментах будут проверены все варианты применения обученной сети.

6 Эксперименты

Реализацию подходов и код всех экспериментов можно найти [17].

В экспериментах использовалась архитектура сети, представленная на рис. (8). Все свёрточные слои содержали по 50 фильтров размером 50 с гиперболическим тангенсом в качестве функции активации и шагом сдвига 1. Полносвязные слои содержали по 150 нейронов, в качестве функции активации использовался гиперболический тангенс. В выходном слое использовалась сигмоидальная функция.

В качестве фреймворка для реализации и обучения нейронных сетей использовалась библиотека Keras с бэкендом Tensorflow. Обучение производилось на CPU, так как представленная модель имеет достаточный небольшой размер и не требует большого времени в процессе настройки. В качестве метода оптимизации использовался Adam [18] с логарифмической функцией потерь.

6.1 Данные и задача

В экспериментах решалась задача детектирования ишемической болезни сердца. Использовались 1797 кардиограмм от 279 людей. В среднем по 6.4 кардиограмм на человека длиной около 300 секунд, что соответствует 300000 отсчётам. В выборке 50% людей положительного класса, 41.3% кардиограмм положительного класса.

Оценивались функционалы качества: площадь под ROC-кривой, точность классификации (доля правильных ответов алгоритма). Так как все используемые алгоритмы выдают вероятность принадлежности к положительному классу, то точность измерялась как с порогом 0.5, так и с подобранным порогом, максимизирующем точность на отложенной выборке (для этого тестовая выборка делилась пополам, перекрёстно подбирался порог, с которым оценивалась точность на каждой

половине, результаты усреднялись). Для людей, имеющих более 1 кардиограммы, предварительно усреднялись вероятности по всем кардиограммам. Оценивалось выявление заболевания у человека. Все разбиения выборки на обучающее и тестовое подмножества производился по людям, то есть один человек не мог оказаться в обоих множествах.

6.2 Сравнение с традиционными методами

В экспериментах участвовали описанные ранее подходы:

1. Подход, основанный на Dynamic Time Warping с алгоритмом k-ближайших соседей. Из-за вычислительной сложности алгоритма его тестирование было проведено на уменьшенной выборке и не для всех из описанных подходов применения.
2. Подход, основанный на дискретном преобразовании Фурье с последующем применением случайного леса. Преобразовывался срез сигнала, считались модули коэффициентов Фурье.
3. Подход, основанный на вейвлет-преобразовании с последующим применением случайного леса. В качестве вейвлет-функции использовался вейвлет Добеши 2-го порядка, брались детализирующие коэффициенты 1 – 4 порядков и аппроксимирующие коэффициенты 4-го порядка. На извлечённых признаках применялся случайный лес.
4. Многомасштабная свёрточная нейронная сеть.
5. Многомасштабная свёрточная нейронная сеть для извлечения признаков с последующим применением случайного леса.

Во всех случаях использовались срезы сигнала длиной 1000 отсчётов. Номирование каждого среза проводилось путём вычитания среднего значения и деления на максимальное по модулю значение среза. Случайный лес использовался с 1000 деревьями и энтропийным критерием разбиения.

Проводились эксперименты по трём описанным ранее подходам:

Метод	AUC	Accuracy	Max accuracy
DTW + kNN	0.668	0.610	0.629
Fourier + RF	0.689	0.636	0.643
Wavlet + RF	0.702	0.642	0.658
MCNN	0.754	0.681	0.692
MCNN preprocess + RF	0.740	0.670	0.680

Таблица 1: Качество классификации на случайных срезах кардиограмм

1. Классификация случайного среза кардиограммы.
2. Классификация кардиограммы целиком путём усреднения вероятностей по срезам длиной 1000 с шагом 500.
3. Классификация кардиограммы на усреднённых признаках по срезам длиной 1000 с шагом 500.

Общая методика разделения выборки была следующей. Сначала выборка делилась на 2 части, на одной из которых обучалась нейронная сеть. Далее на второй части оценивались все методы с помощью 5-фолдовой кросс-валидации. Для эксперимента по классификации случайного среза генерировалась случайные обучающая и тестовая выборки размеров в 50000 срезов по следующей схеме: сначала выбирался человек, потом кардиограмма этого человека, далее брался случайный срез. Для двух других экспериментов использовались уже обученные на выборке с первого эксперимента модели. Результаты усреднялись для всех кардиограмм одного человека, проверялось качество детектирования болезни для конкретного человека. Итоговые результаты являются усреднением по 5 делениям выборки на две равных части для обучения нейронной сети результатов, полученных при усреднении результатов по 5 фолдам.

Результаты представлены на таблицах (1), (2), (3). Во всех экспериментах лучший результат показывает либо сама многомасштабная свёрточная нейронная сеть, либо случайных лес на извлечённых сетью признакам. Низкие результаты в третьем эксперименте подхода, основанного на вейвлет-преобразовании, можно объяснить тем, что структура вейвлет-преобразования не подходит под усреднение извлечённых признаков.

Метод	AUC	Accuracy	Max accuracy
Fourier + RF	0.752	0.680	0.701
Wavlet + RF	0.767	0.700	0.724
MCNN	0.816	0.712	0.738
MCNN preprocess + RF	0.811	0.717	0.757

Таблица 2: Качество классификации с оконным усреднением вероятностей по кардиограммам

Метод	AUC	Accuracy	Max accuracy
Fourier + RF	0.751	0.675	0.684
Wavlet + RF	0.485	0.506	0.565
MCNN preprocess + RF	0.775	0.679	0.704

Таблица 3: Качество классификации на усредненных признаках кардиограмм

6.3 Полезность многомасштабности

Для проверки гипотезы о том, что многомасштабность улучшает качество модели по сравнению с обычной свёрточной нейронной сетью, проведём следующий эксперимент. Возьмём активации с предпоследнего слоя сети после конкатенации результатов отдельных ветвей и проверим классификацию на случайных срезах кардиограмм со всеми активациями (450 признаков) и активациями с одной ветви (150 признаков). Полученные результаты можно увидеть в таблице (4). На признаках, полученных со всех 3 ветвей сети удаётся показать более высокое качество.

Метод	AUC	Accuracy	Max accuracy
MCNN 1 channel + RF	0.683	0.636	0.640
MCNN 3 channel + RF	0.744	0.681	0.687

Таблица 4: Качество классификации на усредненных признаках кардиограмм

6.4 Визуализация извлечённых признаков

Визуализируем признаки, получаемые с помощью сети, спроецировав их на плоскость, с помощью t-SNE и метода главных компонент. Для каждой кардиограммы усредним признаки по окнам длиной 1000 с шагом 500.

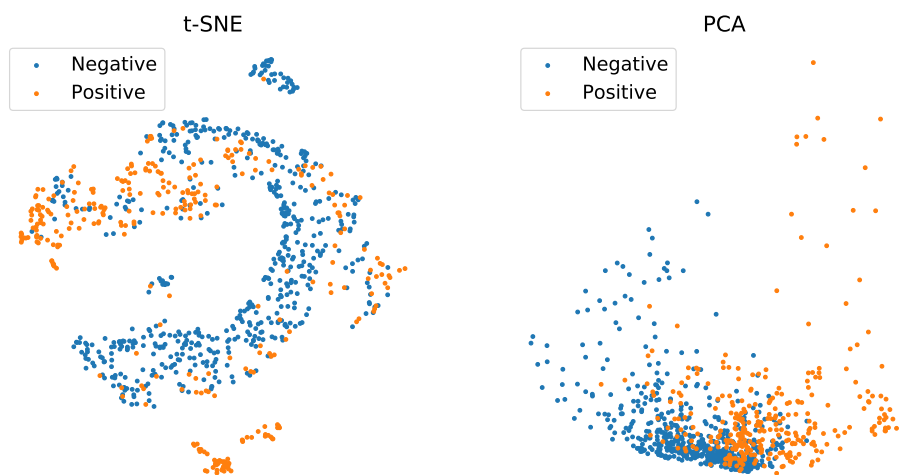


Рис. 9: Визуализация признаков по классам

Проекции разных классов можно увидеть на рис. (9). Заметим сгруппированность объектов каждого из классов. То есть извлекаемые признаки не получаются шумовыми.

Проекции нескольких людей с большим количеством кардиограмм можно увидеть на рис. (10). Заметим сгруппированность их кардиограмм.

6.5 Обсуждение и выводы

В результате экспериментов установлено следующее:

1. Предложенный подход по применению многомасштабной свёрточной нейронной сети показывает более высокие результаты по всем оценённым функционалам качества по сравнению с традиционными методами извлечения признаков из сигналов в задаче детектирования ишемической болезни сердца.

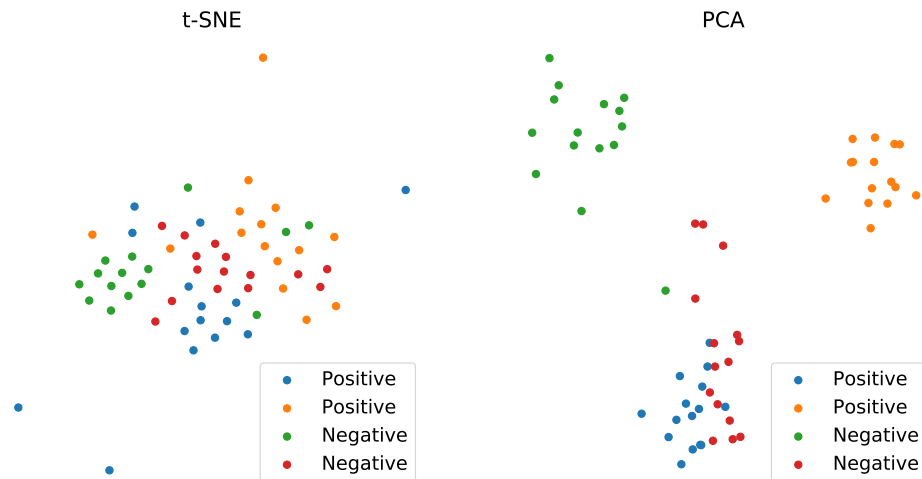


Рис. 10: Визуализация признаков по людям

2. Экспериментально показано, что многомасштабная свёрточная нейронная сеть показывает более высокое качество по сравнению с обычной свёрточной нейронной сетью.
3. Признаки извлекаемые многомасштабной свёрточной нейронной сетью не являются шумовыми, а характеризуют сигналы кардиограмм.
4. Подход с усреднением вероятностей показал более высокое качество на всех методах по сравнению с усреднением признаков.

7 Заключение

В данной работе были рассмотрены традиционные методы извлечения признаков из сигналов и предложена адаптация идеи многомасштабной свёрточной нейронной сети для задачи детектирования болезней сердца по сигналам кардиограмм.

Свёрточные нейронные сети, недавно показавшие своё высокое качество в задаче классификации изображений, в последнее время стали активно использоваться и для других задач машинного обучения.

В работе предложена конкретная архитектура сети, позволяющая как классифицировать сигналы кардиограмм, так и извлекать из сигналов признаки. Было показано, что

многомасштабная свёрточная нейронная сеть позволяет достигнуть более высокое качество в задаче детектирования болезней сердца по сигналам кардиограмм по сравнению с традиционными методами.

Список литературы

- [1] Turning Machine Intelligence Against Lung Cancer Challenge. — <http://www.datasciencebowl.com/competitions/turning-machine-intelligence-against-lung-cancer>. — 2017.
- [2] Crowdsourcing reproducible seizure forecasting in human and canine epilepsy / Benjamin H Brinkmann, Joost Wagenaar, Drew Abbot et al. // *Brain*. — 2016. — Vol. 139, no. 6. — Pp. 1713–1722.
- [3] Kaggle Diabetic Retinopathy Detection Challenge. — <https://www.kaggle.com/c/diabetic-retinopathy-detection>. — 2015.
- [4] Case for Automated Detection of Diabetic Retinopathy. / Nathan Silberman, Kristy Ahrlich, Rob Fergus, Lakshminarayanan Subramanian // AAAI Spring Symposium: Artificial Intelligence for Development. — 2010.
- [5] Atrial fibrillation detection using an iPhone 4S / Jinseok Lee, Bersain A Reyes, David D McManus et al. // *IEEE Transactions on Biomedical Engineering*. — 2013. — Vol. 60, no. 1. — Pp. 203–206.
- [6] Cui Zhicheng, Chen Wenlin, Chen Yixin. Multi-scale convolutional neural networks for time series classification // *arXiv preprint arXiv:1603.06995*. — 2016.
- [7] Воронцов К. В. Математические методы обучения по прецедентам (теория обучения машин). — <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf>.
- [8] Суворов А. В. Клиническая электрокардиография (с атласом электрокардиограмм). — Изд-во Нижегородской гос. мед. академии, 2004.
- [9] Das Manab Kumar, Ari Samit. ECG beats classification using mixture of features // *International Scholarly Research Notices*. — 2014. — Vol. 2014.
- [10] Cardiac arrhythmia detection using dynamic time warping of ECG beats in e-healthcare systems / BS Raghavendra, Deep Bera, Ajit S Bopardikar, Rangavit-

- tal Narayanan // World of Wireless, Mobile and Multimedia Networks (WoWMoM), 2011 IEEE International Symposium on a / IEEE. — 2011. — Pp. 1–6.
- [11] *Jambukia Shweta H, Dabhi Vipul K, Prajapati Harshadkumar B.* Classification of ECG signals using machine learning techniques: A survey // Computer Engineering and Applications (ICACEA), 2015 International Conference on Advances in / IEEE. — 2015. — Pp. 714–721.
- [12] *McCulloch Warren S, Pitts Walter.* A logical calculus of the ideas immanent in nervous activity // *The bulletin of mathematical biophysics.* — 1943. — Vol. 5, no. 4. — Pp. 115–133.
- [13] Dropout: a simple way to prevent neural networks from overfitting. / Nitish Srivastava, Geoffrey E Hinton, Alex Krizhevsky et al. // *Journal of Machine Learning Research.* — 2014. — Vol. 15, no. 1. — Pp. 1929–1958.
- [14] *Rumelhart David E, Hinton Geoffrey E, Williams Ronald J.* Learning internal representations by error propagation. — 1985.
- [15] CNN features off-the-shelf: an astounding baseline for recognition / Ali Sharif Razavian, Hossein Azizpour, Josephine Sullivan, Stefan Carlsson // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. — 2014. — Pp. 806–813.
- [16] *Athiwaratkun Ben, Kang Keegan.* Feature Representation in Convolutional Neural Networks // *arXiv preprint arXiv:1507.02313.* — 2015.
- [17] Реализация и эксперименты. — <https://github.com/emilkayumov/diploma-mcnn-cardio-feature-extraction>. — 2017.
- [18] *Kingma Diederik, Ba Jimmy.* Adam: A method for stochastic optimization // *arXiv preprint arXiv:1412.6980.* — 2014.