

МИНОБРНАУКИ РОССИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ИМЕНИ Н.Г.ЧЕРНЫШЕВСКОГО»

Кафедра физики открытых систем

**Применение нейросетевых методов для распознавания зашумленных
сигналов**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

Студента 4 курса 431 группы

Направления 09.03.02. «Информационные системы и технологии»

код и наименование направления

Факультета нелинейных процессов

наименование факультета


Гуйо Германа Александровича

фамилия, имя, отчество

Научный руководитель

профессор, д.ф.-м.н., профессор

должность, уч. ст., уч. зв.



личная подпись, дата

А.Н. Павлов

инициалы, фамилия

Заведующий кафедрой

д.ф.-м.н., профессор

должность, уч. ст., уч. зв.

личная подпись, дата

А.А. Короновский

инициалы, фамилия

Саратов 2020

ВВЕДЕНИЕ

Последние годы, развитие науки, техники и технологий совершили стремительный скачок, вследствие чего компьютеризация и автоматизация процессов затронула почти все сферы жизни современного человека. В основном автоматизация пришла в те области, где деятельность обуславливается некоторым алгоритмом, то есть заранее известна и понятна логика решения задач [1].

Но развитие технологий вышло на новый уровень, и появилась возможность с помощью машинного обучения и искусственных нейронных сетей решать задачи, не имеющих точного решения. Удаётся совершать анализ и распознавание образов, строить системы кластеризации и классификации. Например, задача классификации сводится к отнесению некоторого образца к какой-то определённой группе или множеству.

Машинное обучение – это область науки находящаяся на пересечении статистики, компьютерных наук и искусственного интеллекта. Применение нейросетевых методов становится обыденным явлением. Многие современные веб-сайты и устройства используют алгоритмы машинного обучения, начиная с автоматических рекомендаций по просмотру фильмов, заказа еды, и заканчивая распознаванием образов и различных сигналов [2]. Главной особенностью нейросетевых методов является обучение самого алгоритма на основе тренировочных данных, с помощью которых при классификации мы можем получить корректный результат.

Нейросетевые методы являются способом решения задачи распознавания, которая в настоящее время стала одним из разделов современных информационных технологий и смежных направлений. Проблема распознавания образов и сигналов приобрела решающее значение, когда общество оказалось под влиянием сильного информационного давления, так как человеку не удаётся последовательно понимать и обрабатывать потоки поступающей к нему информации.

Актуальность подтверждается тем, что анализ зашумлённых сигналов и их распознавание является интересной и важной задачей, имеющей прикладной характер [3]. Поэтому изучение возможности решения этой задачи с помощью алгоритмов машинного обучения, а также способов извлечения признаков из исходных данных, является необходимым направлением развития искусственного интеллекта.

Целью выпускной квалификационной работы является изучение возможности применения нейросетевых методов и алгоритмов машинного обучения для решения задач распознавания и классификации сигналов с помехами на примере сигналов внеклеточного потенциала 3-х близко расположенных нейронов.

Бакалаврская работа содержит 36 страниц, приведённый список литературы включает 23 наименования.

Основное содержание работы

В первой главе обоснована структура искусственного интеллекта, а также описаны основные типы обучения методов машинного обучения и их различие между собой. Обучение с учителем подразумевает обучение на основе предоставляемых человеком исходных данных. Машина учится на этих примерах различным типам ситуаций и обстоятельств, которые могут встретиться алгоритму в течение работы. Данный вид обучения в основном используется при реализации задач регрессии и классификации. Обучение без учителя функционирует по-другому – тут нет известных результатов. Часто экспериментальные данные не имеют никаких меток, по которым можно различить и характеризовать эти данные. Поэтому целью такого метода является определение связей и группировка данных по выявленным свойствам. Такое обучение применяется в решении задач кластеризации. Далее рассматриваются теоретические основы нейросетевых методов, которые могут быть использованы для распознавания сигналов: метод k-средних, метод сдвига среднего, метод ближайших соседей, метод главных компонент, метод

стохастического вложения соседей и алгоритм многослойного персептрона. Описание каждого метода происходит в отдельных подразделах.

k-средних (k-means) - это наиболее известный метод кластеризации. Сначала необходимо задать количество кластеров. Сама идея алгоритма такова: он стремится минимизировать суммарное квадратичное отклонение точек кластеров от центров этих кластеров. Расстояние между точками определяется по формуле:

$$p(x, x') = \sqrt{\sum_i^n (x_i - x'_i)^2}, \quad (1)$$

где x_i при $j = 1, 2, \dots, N$ – входные точки.

Это итеративный алгоритм, который делит данное множество точек на k кластеров, где точки являются максимально приближенными к их центрам, а сама кластеризация происходит за счет смещения этих же центров.

Метод сдвига среднего (Mean Shift) - это техника кластерного анализа признакового пространства для определения точки максимума плотности вероятности. Его цель также найти центры кластеров, но работает он иначе. Пространство интерпретируется как распределение вероятностей и, если есть k пиков распределения, то существует k кластеров. Далее делаем предположение о том, что локальные максимумы плотности вероятности являются центрами кластеров, т.е. соответствующим центроидам. Сдвиг среднего как раз и является процедурой поиска координат максимумов плотности. Оценка функции плотности вероятностей происходит с использованием ядра $K(x_i - x)$, которое определяет вес всех точек при вычислении среднего. Взвешенное среднее будет вычисляться по формуле:

$$m(x) = \frac{\sum_{x_i \in N(x)} (x_i - x) x_i}{\sum_{x_i \in N(x)} (x_i - x)}, \quad (2)$$

Метод k-ближайших (k Nearest Neighbors) – это метод обучения с учителем, где классификатор основан на определении сходства образов [3]. Идея метода заключается в следующем: классифицируемый сигнал относится к

тому классу, к которому принадлежит ближайший сигнал из обучающего набора данных. Расстоянием между образами берётся евклидова метрика.

Метод главных компонент (PCA) – это метод уменьшения размерности исходных данных, при этом сохраняя почти всю полезную информацию о сигнале [4]. Метод функционирует следующим образом: выбираются новые базисные векторы, вдоль которых происходит максимальное изменение данных. В методе главных компонент используются новые, формальные переменные t_a являющиеся линейной комбинацией исходных переменных. Получается новая система отсчёта, где коэффициент p_{aJ} - это расстояние от точки до новой оси.

$$t_a = p_{a1}x_1 + \dots + p_{aJ}x_J \quad (3)$$

Метод стохастического вложения соседей (t-SNE) - это алгоритм для понижения размерности исходных данных и их визуализации [5]. Алгоритм работает следующим образом: берутся две точки исходного пространства, определяется дистанция между ними, и преобразуется в условную вероятность, показывающая насколько одна точка близка к другой при нормальном распределении. Такую же условную вероятность задаём для точек низкой размерности, той размерности, которая нам нужна. Предполагается, что точки низкой размерности корректно отображают точки высокой размерности, если условные вероятности этих измерений равны.

Для описания сигналов традиционно используется преобразование Фурье. Такое преобразование помогает перейти в частотную область и избавиться от сдвигов сигнала по времени. В работе с дискретным сигналом или набором данных, может быть использовано дискретное преобразование Фурье (ДПФ). Оно задаётся для некоторого набора следующим образом:

$$s[k] = \sum_{n=0}^{N-1} s[n] \exp^{-2\pi i k \frac{n}{N}}, \quad 0 \leq k \leq N - 1 \quad (4)$$

Полученный коэффициент ДПФ характеризует исходный набор данных и можно использовать такой признак для классификации сигналов.

Многослойными персептронами называют глубокую искусственную нейронную сеть, включающую в себя несколько слоёв с N количеством узлов в каждом слое [6]. Многослойный персептрон состоит из входного слоя для приема сигнала, выходного слоя, который принимает решение или делает предсказание о входном образе или сигнале, а между ними – произвольное количество скрытых слоёв, которые выбираются из логики решаемой задачи и являются истинным вычислительным движком. Помимо выбора архитектуры нейронной сети выбирается одна из функций активации: сигмоида, гиперболический тангенс или ReLu.




Рисунок 1. Схема многослойного персептрона

Во второй главе дипломной работы совершается постановка задачи распознавания сигналов на примере внеклеточной записи электрического потенциала 3-х близко расположенных нейронов и реализация методов, которые могут решать проблему расшифровки сигналов нейробиологических систем. Так как амплитуда таких сигналов от расстояния, от нейронов до регистрирующего микроэлектрода, то такие сигналы будут немного отличаться по амплитуде, и однозначно идентифицировать каждый такой сигнал является важной задачей для развития искусственного интеллекта и информационных технологий. Используемые экспериментальные данные включают в себя более 10000 записей импульсов нейронов по 64 точки в каждой. Понятно, что такой набор данных тяжело использовать в разделении этих сигналов по группам.

Поэтому логично выделить из данных некоторые признаки, которые будут однозначно характеризовать каждый импульс. Такими признаками были выбраны коэффициенты дискретного преобразования Фурье и амплитуда сигнала. Именно к этим данным были применены нейросетевые методы, описанные ранее. В остальных подразделах второй главы диплома, были представлены результаты классификации и кластеризации данных, а также сравнение положительных и отрицательных сторон этих методов.

Первым шагом разделения сигналов на группы является метод k-средних.




Рисунок 2. Результат работы k-means

Разный фон на графике иллюстрирует границы действующих кластеров, а черные точки – центры кластеров. Метод очень быстро работает и качественно разделяет наши данные, но если мы не знаем приблизительно количество кластеров, то этот метод не очень удобен на практике.

В рамках метода сдвига среднего всё пространство интерпретируется как распределение вероятностей. При применении алгоритма мы получаем координаты центров кластеров, их количество, а также метки принадлежности к определенному кластеру для каждой точки, т.е. класс каждого сигнала. Изображение результата работы алгоритма:




Рисунок 3. Результат работы Mean Shift.

Цвет точек показывает принадлежность сигнала к разным кластерам.

Для определения категории входной точки данных метод KNN использует поиск ближайших точек из обучающего набора. Для такого набора был сгенерирован обучающий набор данных на основе усреднённых форм сигнала с добавлением нормального шума. Результат работы алгоритма был следующий:




Рисунок 4. Результат работы алгоритма KNN.

Цвет точек показывает принадлежность сигнала к разным классам.

Данный алгоритм хорошо работает с перекрытыми группами данных и точность определения класса для сгенерированных данных составила около 98%.

Также были рассмотрены методы понижения размерности данных, которые тоже могут служить для распознавания сигналов. Реализация алгоритмов PCA и t-SNE даёт следующие результаты:




Рисунок 5. Результат работы PCA с экспериментальными данными (3 сигнала).




Рисунок 6. Результат работы t-SNE с экспериментальными данными(3 сигнала).

Избавляясь от шума в исходных данных, методы PCA и t-SNE оставляют полезную информацию, которая как раз и отличает данные друг от друга. Метод t-SNE лучше разделят данные, чем PCA, но имеют разное время работы:

РСА за 0.157 секунды, а метод t-SNE за 57.6 сек. Несмотря на это, оба метода можно применять для улучшения работы алгоритмов классификации, т.к. они уменьшают размерность в 64 точки до 2 точек.

При реализации многослойного персептрона использовался набор данных из посчитанных ранее признаков для сигналов с нормальным шумом, который до этого использовали для проверки метода k ближайших соседей, чтобы сравнить их между собой. Была построена сеть с 2 скрытыми слоями по 128 нейронов каждый и с 2 нейронами на выходном слое, т.к. различаем два класса сигналов. Функцией активации являлась ReLu, так как у неё отсутствует разрастание и затухание градиента обратного распространения ошибки при этом обучение происходит достаточно быстро. На обучение выбрано 70 % случайно выбранных точек из 10000 возможных исходных данных. Остальные 30% были использованы как тест для нейросети.

```
Epoch 147/150
4689/4689 [=====] - 0s 66us/step - loss: 0.0432 - accuracy: 0.9827
y: 0.9823
Epoch 148/150
4689/4689 [=====] - 0s 66us/step - loss: 0.0432 - accuracy: 0.9823
y: 0.9827
Epoch 149/150
4689/4689 [=====] - 0s 66us/step - loss: 0.0432 - accuracy: 0.9821
y: 0.9827
Epoch 150/150
4689/4689 [=====] - 0s 66us/step - loss: 0.0432 - accuracy: 0.9827
y: 0.9827
3000/3000 [=====] - 0s 27us/step
Evaluation:
mean_squared_error : 0.04251572452237209
accuracy: 0.9833333492279053
```

Рисунок 7. Результат работы многослойного персептрона

Реализация показала, что многослойный персептрон может зашумлённые сигналы с точностью 96-98%, при этом работает в разы быстрее, чем KNN – в среднем 29.5 секунды у нейронной сети и 6 минут 37 секунд для метода ближайших соседей.

Заключение

В ходе бакалаврской работы протестированы основные методы кластеризации и классификации данных. Проведено сравнение алгоритмов PCA и t-SNE для распознавания сигналов, а также выявлена возможность использования этих методов в работе с другими схемами для улучшения классификации, посредством уменьшения размерности исходных данных. Изучена возможность применения алгоритмов для анализа и распознавания на примере сигналов внеклеточного электрического потенциала 3-х разных нейронов. В работе показано, что при правильном извлечении признаков из исходных данных, методы хорошо работают, но имеют разное время реализации. Исходя из этого, самым удобным оказался многослойный персептрон, так как на обучение и тестирование у него уходило в среднем 29.5 секунды, что в разы быстрее, чем у других алгоритмов. В будущем продолжится работа над изучением нейронных сетей с более сложной архитектурой и их комбинирование с различными алгоритмами машинного обучения для анализа зашумлённых сигналов.

Список использованных источников

- [1] Нейронные сети: история развития теории. Под общей ред. А.И.Галушкина, Я.З.Цыпкина. М., ИПРЖР, 2001.
- [2] Хайкин С. Нейронные сети: полный курс, 2-е издание. : Пер. с англ. – М.: Издательский дом «Вильямс», 2008. – 23с
- [3] Hastie, T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. — Springer-Verlag, 2001. — 533 p. [3] Caudill, M., Neural Networks Primer, San Francisco, CA: Miller Freeman Publications, 1989.
- [4] Айвазян С. А., Бухштабер В. М., Енюков И. С., Мешалкин Л. Д. Прикладная статистика: Классификация и снижение размерности. — М.: Финансы и статистика, 1989. — 607 с.
- [5] van der Maaten L.J.P., Hinton G.E. Visualizing Data Using t-SNE // Journal of Machine Learning Research. — 2008. — Ноябрь (т. 9).
- [6] Nishant Shakla, «Machine learning. TensorFlow», 2019. – с. 20-137.