

МИНОБРНАУКИ РОССИИ

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

Кафедра радиофизики и нелинейной динамики

**Обработка артефактов записей ЭЭГ при помощи вейвлет-
анализа и машинного обучения.**

АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ

студента 4 курса 4061 группы
направления 11.03.02 Инфокоммуникационные
технологии и системы связи
Института физики
Попова Николая Алексеевича

Научный руководитель
доцент, к.ф.-м.н.

_____ К.С. Сергеев

Зав. кафедрой радиофизики
и нелинейной динамики,
д.ф.-м.н., доцент

_____ Г.И. Стрелкова

Саратов 2023 г.

Введение

Для исследования процессов, сопровождающих функционирование головного мозга млекопитающих, часто используется метод электроэнцефалографии (ЭЭГ). ЭЭГ - метод исследования электрической активности мозга путем размещения электродов в определенных зонах на поверхности головы. Запись ЭЭГ представляет собой оцифрованный сигнал электрической активности головного мозга. Основным интересом представляет диапазон от 0 до 30 Гц.

ЭЭГ является очень чувствительным инструментом; для подавления помех электромагнитной природы используются дифференциальные усилители, однако при движениях исследуемого объекта может меняться проводимость кожных покровов, смещаться или отклеиваться датчики. При записи сигналов с лабораторных животных (грызунов) из-за их перемещения по клетке могут возникать статические потенциалы. По перечисленным причинам на записях ЭЭГ возникают помехи специфического вида, называемые артефактами движения. Эти артефакты как правило имеют вид медленно меняющегося во времени отклонения основного тренда сигнала. Из-за различия их формы и амплитуды не представляется возможным установить простое условие (например, ограничить амплитуду), по которому можно их обнаруживать. Фильтрацию сигналов ЭЭГ можно применить далеко не во всех случаях, к тому же, артефакты движения могут различаться по спектру, что значительно усложнит АЧХ фильтра и может привести к потере полезных данных. Широко развивающиеся в последние годы методы автоматизированного анализа ЭЭГ часто очень чувствительны к наличию помех и артефактов движения [1].

С учетом перечисленных особенностей возникает необходимость поиска и исправления артефактов записей. В настоящей работе предлагается оригинальная методика поиска артефактов, основанная на методах машинного обучения (искусственных нейронных сетях). Цель работы формулируется следующим образом: разработка алгоритма автоматизированного поиска артефактов движения на записях ЭЭГ с применением методов машинного

обучения. Для достижения поставленной цели необходимо решить следующие задачи:

- составить обучающее множество на основе ручной «экспертной» разметки данных ЭЭГ
- построить пространство признаков для работы ИНС
- обучить ИНС и найти оптимальную конфигурацию как самой сети, так и пространства признаков.

Работа состоит из введения, теоретической части (содержит сведения о вейвлет-преобразовании, машинном обучении) и практической части (содержит описание используемой ИНС, пространства признаков, методов построения обучающего множества) и заключения.

1. Теоретические сведения об искусственных нейронных сетях

Исследования по искусственным нейронным сетям (далее — нейронные сети, ИНС) связаны с тем, что способ обработки информации человеческим мозгом в корне отличается от методов, применяемых обычными цифровыми компьютерами. Мозг представляет собой чрезвычайно сложный, нелинейный, параллельный процессор (систему обработки информации). Он обладает способностью организовывать свои структурные компоненты, называемые нейронами, так, чтобы они могли выполнять конкретные задачи (такие как распознавание образов, обработку сигналов органов чувств, моторные функции) во много раз быстрее, чем могут позволить самые быстродействующие современные компьютеры

В общем случае нейронная сеть представляет собой машину, моделирующую способ обработки мозгом конкретной задачи. Эта сеть обычно реализуется с помощью электронных компонентов или моделируется программой, выполняемой на компьютере. Для того чтобы добиться высокой производительности, нейронные сети используют множество взаимосвязей между элементарными ячейками вычислений — нейронами. Таким образом, можно дать следующее определение нейронных сетей, выступающих в роли

адаптивной машины: нейронная сеть — это распределенный параллельный процессор, состоящий из элементарных единиц обработки информации, накапливающих экспериментальные знания и предоставляющих их для последующей обработки.

Базовым элементом в искусственных нейронных сетях является искусственный нейрон. Под искусственным нейроном подразумевают узел искусственной нейронной сети, который представляет собой упрощенную математическую модель естественного нейрона. Математически нейрон представляет из себя некую нелинейную функцию единственного аргумента — линейной комбинации всех входных сигналов. Подобную функцию называют функцией активации или передаточной функцией. Результат, полученный после обработки исходных данных передаточной функцией, направляется на единственный выход, что позволяет объединять нейроны в сети путем соединения выходов одних нейронов с входами других. В результате образуется сложная пространственная структура связей, называемая нейронной сетью. По аналогии с биологическими прообразами, связи между входами одних и выходами других нейронов, называют синапсами. Каждая связь характеризуется своим весом и по характеру взаимодействия связи с положительным весом называют возбуждающим, а с отрицательным — тормозящими [2-4].

Модель нейрона изображена на рис. 1, и представляет собой взвешенный сумматор, значение на выходе которого определяется через его входы и матрицу весовых коэффициентов.

$$y = f(u); \quad u = \sum_{i=1}^n \omega_i x_i + \omega_0 x_0, \quad (1)$$

где: x_i — сигналы на соответствующих входах нейрона; $\omega_{i,j}$ — вес сигнала на соответствующем входе; $f(u)$ — передаточная функция нейрона; x_0 и ω_0 — активационное значение и вес, определяющие формирование порога чувствительности нейрона.




Рисунок 1 – Схема искусственного нейрона, где: 1 – нейроны вышестоящего слоя; 2 – сумматор входных сигналов; 3 – вычислитель передаточной функции; 4 – нейроны нижестоящего слоя; 5 – веса входных сигналов

В качестве сигналов на входе нейрона, могут использоваться как дискретные, так и аналоговые значения [2-4].

Нейроны принято делить на три основные категории:

1. Входные нейроны – принимают исходный вектор, кодирующий входной сигнал. Как правило, эти нейроны не выполняют вычислительных операций, а просто передают полученный входной сигнал на выход, возможно, усилив или ослабив его;
2. Выходные нейроны – представляют из себя выходы сети. В выходных нейронах могут производиться какие-либо вычислительные операции;
3. Промежуточные нейроны – выполняют основные вычислительные операции.

2. Теоретические сведения о вейвлет-преобразованиях

Существует дискретное вейвлет-преобразование (ДВП) и непрерывное вейвлет-преобразование (НВП), которые можно рассматривать фактически как разные методы анализа структуры сигналов. Непрерывное вейвлет-преобразование использует в качестве $\psi(t)$ функции, имеющие аналитическую форму записи и являющиеся бесконечно дифференцируемыми. Вследствие этого для них характерен экспоненциальный спад на бесконечности, и базис, построенный на основе таких вейвлетов, не является строго

ортонормированным. Данная особенность означает, что НВП является избыточным, и значения коэффициентов вейвлет-преобразования оказываются сильно коррелированными. Однако избыточность может быть и полезным свойством, позволяющим получать более наглядную и ясную интерпретацию результатов анализа структуры сигналов в виде картин «скелетонов» или «хребтов» поверхности вейвлет-коэффициентов. Информацию, которую можно извлечь из непрерывного вейвлет-преобразования, например, об изменении характерных частот и их взаимодействии, легче анализировать. Например, при использовании комплексных функций $\psi(t)$ НВП позволяет изучать динамику таких характеристик, как мгновенные частоты, мгновенные амплитуды и мгновенные фазы ритмических процессов, детектируемых в структуре анализируемого сигнала.

Такая возможность делает НВП крайне привлекательным инструментом исследования, применимым при решении многих задач.

Дискретное вейвлет-преобразование имеет существенные отличия. Оно может оперировать с неортонормальными базисными функциями (в этом случае говорят о так называемых фреймах). Однако чаще рассматривается случай ортонормированного базиса, что позволяет осуществлять более точное представление сигнала и значительно упрощает его восстановление по набору вейвлет-коэффициентов. В отличие от непрерывного преобразования, вейвлеты, используемые в рамках ДВП, не имеют аналитической формы записи (за исключением функции Хаара). Они задаются в виде таблицы численных коэффициентов, полученных путем решения некоторых уравнений. На практике в рамках ДВП конкретная форма функций $\psi(t)$ в явном виде не рассматривается, записываются только наборы чисел, с помощью которых задается тот или иной вейвлет. При проведении анализа структуры сигналов это приводит к различным операциям с матрицами. Базис строится на основе итерационного алгоритма, предусматривающего изменение масштаба и смещение единственной функции.

Детальное описание принципиальных различий ДВП и НВП приводится, например, в монографии [5-7].

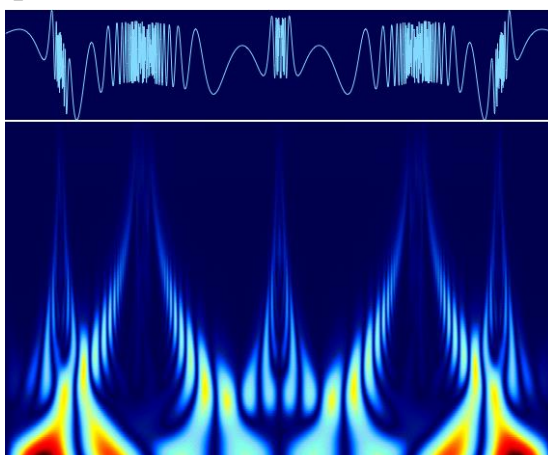


Рисунок 2 – Пример работы вейвлет-преобразования

В отличие от классического спектрального анализа, основанного на преобразовании Фурье и оперирующего с гармоническими функциями, вейвлет-анализ допускает значительное разнообразие выбора базиса, по которому проводится разложение сигнала. В рамках широко используемой интерпретации вейвлет-анализа как метода «математического микроскопа» можно говорить о том, что выбор функции $\psi(t)$, рассматриваемой в качестве базисной, аналогичен заданию разрешения для объектива микроскопа: если выбранное разрешение позволяет увидеть нужные детали, то вейвлет подходит для целей проводимого исследования. Более того, что немаловажно, последующий выбор объектива с лучшим разрешением уже не дает ничего нового.

В отличие от вейвлет-преобразования, гармонические функции, применяемые в классическом спектральном анализе, построенном на преобразовании Фурье, заданы в диапазоне $-\infty < t < \infty$ и не позволяют изучать локальные изменения структуры сигналов. Расчет спектра мощности сигнала $x(t)$ обеспечивает возможность определения частотного состава рассматриваемого процесса и выявления характерных ритмов колебаний. Такой расчет позволяет установить сам факт наличия колебаний определенной частоты, но не дает ответа на вопрос, когда существовали эти колебания – на протяжении всего времени регистрации сигнала или только на каком-то участке? Бесконечно

осциллирующие функции не могут использоваться при проведении локализованного спектрального анализа [5-7].

3. Результаты исследований

Изначально для вейвлет преобразования использовалась каждая двадцатая точка сигнала. При таких параметрах в строке преобразования получалось пятьдесят тысяч точек. Окно выглядит следующим образом (Рисунок 4).




Рисунок 3 – Окно с 50000 значений вейвлет-преобразования (Красным отмечен артефакт), частота дискретизации 100 Гц.

На первом канале, который расположен сверху, можно отчетливо увидеть артефакт, обозначенный красным, значение резко возросло по амплитуде выше тысячи. На втором канале не наблюдается такого искажения.

Таким образом оно сдвигается и анализируется вручную на наличие артефактов вдоль всего сигнала.

При обучении используется два слоя: входной на три нейрона и выходной на два нейрона. Опытным путем было выявлено, что такое количество слоев оптимально для представленной нейронной сети.

Было принято решения для обучения взять один из таких сигналов. После этого переобучение ушло и точность на искомым сигналах всегда была порядка девяноста пяти процентов, изредка снижаясь, но при повторном обучении повышалась.




Рисунок 4 – Сравнение результата работы ИНС (на верхнем графике оранжевым обозначено окно, в котором есть артефакт из результата ИНС) с фактическим артефактом (на нижнем графике синим обозначен артефакт в самом сигнале) в сигнале №1

При создании обучающих примеров для нейронной сети используется тот же самый код, что и для вейвлет-преобразования с небольшими правками. Перед поиском среднего стандартного отклонения нужно сделать нормировку каждого окна, потому что каждый сигнал имеет свои отклонения в полезном сигнале, чтобы нивелировать это используется нормировка.

После создания базы данных для нейронной сети, переходим к ее обучению. Сначала используя два слоя нейронов: входной три нейрона и выходной два нейрона.

На рисунке 7 нейронная сеть определила окно сигнала, в котором находится артефакт, но также дала несколько ложноположительных ответов.

Исследуя другой сигнал, в котором также артефакт находится в одном единственном окне, точность хуже. Но появились единичные ложноположительные ответы. Для того, чтобы постараться исключить их, при

обучении использовалось несколько сигналов, для увеличения количества данных.




Рисунок 5 - Сравнение результатов ИНС (на верхнем графике оранжевым обозначены окна, в которых есть артефакты из результата ИНС) с двумя слоями при обучающих примерах, используемых стандартное отклонение и среднее арифметическое с фактическим артефактом (на нижнем графике синим обозначен артефакт в самом сигнале) в сигнале №2

Вывод

Поставленная цель была выполнена: разработан алгоритм на основе искусственных нейронных сетей, позволяющий обнаруживать артефакты записей ЭЭГ с точностью до 98%. Были использованы разные наборы рассчитанных в скользящем окне признаков для создания обучающих примеров: результаты непрерывного вейвлет-преобразования, стандартное отклонение, стандартное отклонение вместе с средним арифметическим.

Было установлено, что использование строгого условия по амплитуде для детектирования артефактов невозможно, поскольку в результате получается множество ложно положительных ответов. Задача не столь проста для использования упрощенных методов анализа сигнала, таких как среднее стандартное отклонение и среднее арифметическое. Самым эффективным пространством признаков для решения задачи поиска артефактов с помощью

ИНС является непрерывное вейвлет-преобразование, которое позволяет точно детектировать артефакты в сигнале.

Работа имеет потенциал для дальнейшего развития, поскольку помимо детектирования есть необходимость исправлять участки сигнала с искажениями для лучшего анализа сигналов с биологической точки зрения.

Список используемых источников

1. МЕТОДИКА БЫСТРОГО АВТОМАТИЗИРОВАННОГО ДИСКРИМИНАНТНОГО АНАЛИЗА ЭЭГ ПРИ РАЗЛИЧЕНИИ В ДВА КЛАССА: [Электронный ресурс] // <https://cyberleninka.ru/article/n/metodika-bystrogo-avtomatizirovannogo-diskriminantnogo-analiza-eeg-pri-razlichenii-v-dva-klassa>
2. Нейронные сети : полный курс второе издание / Саймон Хайкин : Пер. с англ. – М. : Издательский дом “Вильямс”, 2006. – 1104 с. : ил. – Парал. тит. англ
3. Иванов, А.И. Нейросетевая биометрия для облаков. Российские стандарты для защиты цифровых прав граждан /А.И. Иванов// Системы безопасности. – 2018. – №3. – С.134–139
4. Давыдов, Д.А. Интеллектуальные системы управления дуговым переплавом. /Д.А. Давыдов, А.В. Попов// Вопросы электротехнологий. – 2019. - №1(22). – с.85-88.
5. Астафьева Н.М. Вейвлет-анализ: основы теории и примеры применения. УФН. - 1996. - Т. 166. - № 11.-С. 1145-1170.
6. Астафьева Н. М. Вейвлет-преобразований. Основные свойства и примеры применения. М.: ИКИ РАН. 1994. № 1891. 56 с.
7. Чуи К. Введение в вейвлеты. - М.: Мир, 2001, 412с.