

МИНОБРНАУКИ РОССИИ

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

Кафедра радиофизики и нелинейной динамики

**Восстановление временных рядов с применением методов
машинного обучения**

АВТОРЕФЕРАТ МАГИСТЕРСКОЙ РАБОТЫ

студента 2 курса 2232 группы
направления 03.04.03 Радиофизика
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 2025 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 исправления артефактов записей. В настоящей работе предлагается оригинальная методика восстановления артефактов, основанная на методах машинного обучения (искусственных нейронных сетях). Цель работы формулируется следующим образом: разработка алгоритма восстановления

части сигнала на записях ЭЭГ с применением методов машинного обучения. Для достижения поставленной цели необходимо решить следующие задачи:

- Подготовка данных для обучения модели.
- Разработка гибридной архитектуры нейронной сети, сочетающей свёрточные и рекуррентные слои.
- Обучение модели на реальных записях ЭЭГ.
- Тестирование её способности восстанавливать сигналы с высокой точностью.
- Анализ качества восстановления во временной и частотной областях.

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; ω_{ij} — 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. Архитектура LSTM нейронной сети

В современных задачах обработки временных рядов, таких как анализ электроэнцефалографических (ЭЭГ) сигналов, одним из наиболее эффективных инструментов являются рекуррентные нейронные сети (Recurrent Neural Networks, RNN). Однако стандартные RNN сталкиваются с проблемой исчезающих и взрывающихся градиентов при обучении на длинных последовательностях, что делает их неэффективными для захвата долгосрочных зависимостей.

Для решения этой проблемы была предложена архитектура LSTM (Long Short-Term Memory), которая является разновидностью рекуррентных сетей и позволяет сохранять информацию на длительное время благодаря специальному механизму ячеек памяти и управляющих вентилей.

Основные элементы LSTM-ячейки

LSTM-ячейка состоит из следующих компонентов:

1. Ячейка памяти (Cell state)

Это основной поток информации, который проходит через всю цепочку LSTM-слоёв. Cell state напоминает конвейерную ленту — данные могут передаваться по нему почти без изменений, что позволяет сохранять информацию на длительное время.

2. Вентили (Gates)

Вентили — это структуры, которые регулируют поток информации. Они состоят из сигмоидного слоя и операции поэлементного умножения. Сигмоидный слой выводит значения от 0 до 1, где 0 означает "ничего не пропускать", а 1 — "полностью пропустить".

У LSTM три основных вентиля:

1) Забывание (Forget gate)

Определяет, какие данные из cell state нужно удалить.

Формула:

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (2)$$

- f_t — выход вентиля забывания на шаге t ,
- σ — сигмоидная функция,
- W_f — веса вентиля,

- h_{t-1} — скрытое состояние предыдущего шага,
- x_t — входной сигнал на текущем шаге.

2) Ввод (Input gate)

Определяет, какие новые данные будут добавлены в cell state. Сначала сигмоидный слой решает, какие значения будем обновлять:

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (3)$$

Затем тангенсоидальный слой создаёт вектор кандидатов:

$$\tilde{C}_t = \tanh(W_C * [h_{t-1}, x_t] + b_C) \quad (4)$$

3) Обновление состояния ячейки

Новое состояние ячейки рассчитывается как:

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (5)$$

где $\odot$ — поэлементное умножение.

4) Выход (Output gate)

Определяет, какое значение будет отправлено на выход. Сначала вычисляется сигмоидный вентиль:

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (6)$$

Затем содержимое cell state пропускается через tanh:

$$h_r = o_t \odot \tanh(C_t) \quad (7)$$

h_t — это выход текущей LSTM-ячейки.




Рисунок 2 – Схема архитектуры LSTM нейронной сети

3. Результаты исследований

В представленной работе исследовались два подхода к обучению LSTM-модели для восстановления ЭЭГ-сигнала коры головного мозга крысы. Первый подход предполагал использование «сырых данных», то есть исходных сигналов без дополнительной предобработки, за исключением нормализации. Модель обучалась на сигнале с частотой дискретизации 2 кГц, при этом архитектура сети включала сверточные и рекуррентные слои, что позволило модели эффективно улавливать как локальные особенности сигнала, так и долгосрочные зависимости. Было показано, что модель способна точно восстанавливать форму сигнала, особенно на относительно стабильных участках.




Рисунок 3 – Пример восстановления сигнала нейронной сетью обученной на «сырых» данных

Второй подход был основан на использовании отфильтрованного сигнала. Перед обучением на сигнал были применены децимация (понижение частоты дискретизации до 200 Гц) и полосовой фильтр Баттерворта в диапазоне 0.5–50 Гц, что позволило удалить шумы и оставить только биологически значимые ритмы мозга (дельта, тета, альфа, бета). Такая предварительная обработка повысила качество входных данных и помогла модели сосредоточиться на наиболее информативных компонентах сигнала. Обучение проводилось на тех же архитектурных принципах, что и в первом случае, однако благодаря фильтрации модель стала более устойчивой и точной в воспроизведении ключевых частотных характеристик.




Рисунок 3 – Пример восстановления сигнала нейронной сетью обученной на отфильтрованных данных

Сравнение результатов показало, что оба подхода обеспечивают высокую точность восстановления сигнала, однако использование сырых данных дало лучшие результаты по стабильности и соответствию спектральных характеристик оригинальному сигналу.

Вывод

Поставленная цель была выполнена: разработан алгоритм на основе искусственных нейронных сетей, позволяющий восстанавливать утраченные участки сигнала.

Таким образом, LSTM (Long Short-Term Memory) представляет собой одну из наиболее эффективных и мощных архитектур рекуррентных нейронных сетей, предназначенную для обработки временных последовательностей. Благодаря своей уникальной структуре, включающей ячейки памяти и управляющие вентили, LSTM способна сохранять важную информацию на длительные промежутки времени, что делает её особенно подходящей для задач, где необходимо учитывать контекст и долгосрочные зависимости.

Традиционные методы фильтрации не всегда позволяют точно отделить полезный сигнал от помех, тогда как LSTM демонстрирует способность восстанавливать истинную структуру сигнала даже в условиях значительных искажений.

Применение LSTM в этой области открывает широкие возможности:

- Автоматизация анализа данных ЭЭГ, включая выделение ключевых ритмов мозга (дельта, тета, альфа, бета).
- Восстановление повреждённых участков сигнала, что особенно важно при работе с данными, записываемыми у свободно передвигающихся животных.
- Повышение точности диагностики и снижение влияния помех без потери важной информации.

Итоговое применение LSTM в задачах обработки ЭЭГ-сигналов позволяет значительно повысить качество анализа данных, автоматизировать процесс обработки и минимизировать влияние артефактов. Это делает LSTM ценным инструментом как в научных исследованиях нейронной активности, так и в клинической практике, связанной с диагностикой состояний центральной нервной системы.