

ПРИМЕНЕНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ ДЛЯ СЖАТИЯ СИГНАЛОВ ЭЭГ

Борн Р.С.¹, Гордеев К.Е.²

¹ *Томский политехнический университет, ИШИТР, 8В13, e-mail: rsb8@tpu.ru*

² *Томский политехнический университет, ИШИТР, 8В14, e-mail: keg6@tpu.ru*

Аннотация

Работа посвящена исследованию применения нейросетевых алгоритмов для сжатия сигналов электроэнцефалограмм с целью повышения эффективности их анализа и обработки. Мы использовали сверточные нейронные сети для изучения специфических паттернов в сигналах ЭЭГ и их последующего сжатия. После обучения нейросетевой модели на обширном наборе данных сигналов ЭЭГ, мы провели эксперименты по сжатию сигналов с различными уровнями компрессии. Результаты показали, что наш подход позволяет существенно сократить размер данных с минимальной потерей информации, что может значительно ускорить последующий анализ и обработку сигналов ЭЭГ, сохраняя при этом их существенные характеристики для дальнейших медицинских или исследовательских приложений.

Ключевые слова: электроэнцефалограмма, уменьшение размерности, многомерные временные ряды, автоэнкодер.

Введение

В последние годы активно развивается область применения нейронных сетей для сжатия данных. Исследование по сжатию сигналов ЭЭГ с использованием нейронных сетей стоит на перекрестке нескольких важных областей — от нейронауки до искусственного интеллекта, обладая значительной актуальностью. Рост объемов данных ЭЭГ, необходимость их обработки в реальном времени, сложность сигналов и потребность в эффективной передаче данных для мобильных и удаленных устройств делают эту тему особенно важной. Сжатие данных не только обеспечивает удобство хранения и передачи, но и может играть ключевую роль в получении признаков из исходных сигналов и их визуализации, что критично для многих приложений, включая мониторинг здоровья и нейрокомпьютерные интерфейсы. Прогресс в области нейронных сетей, включая разработку новых архитектур и алгоритмов обучения, расширяет возможности сжатия данных без потерь, обеспечивая новые методы обработки и анализа ЭЭГ. Это междисциплинарное направление исследований способствует инновациям и может привести к значительным достижениям в технологиях мониторинга здоровья и разработке нейрокомпьютерных интерфейсов. Для решения данной задачи представлены следующие нейросетевые алгоритмы: UMAP, t-SNE, PCA и Autoencoder.

Особое внимание уделяется разработке алгоритмов без потерь, которые позволяют восстанавливать исходные данные без искажений. В работе Иваськива Ю.Л., Левченко В.В. [1] рассматриваются особенности формирования нечетких обучающих множеств для нейронных сетей, что позволяет повысить эффективность сжатия данных без потерь. Авторы предлагают новый подход, который учитывает специфику потоковой передачи данных и обеспечивает высокую степень их сжатия.

В статье Булаева В.И., Мунасыпова Р.А. [2] обсуждается применение вейвлет-преобразований и нейронных сетей для сжатия геофизических данных. Использование этих технологий позволяет значительно уменьшить объем передаваемой информации, сохраняя при этом её ключевые характеристики. Такой подход находит широкое применение в области дистанционного зондирования Земли и других задачах, где важно максимально эффективно использовать ресурсы хранения данных.

Автушко Д.А., Скляр А.Я. [3] разработали алгоритм нейросетевого сжатия данных без потерь, который демонстрирует новые возможности для сокращения объема данных с максимальным сохранением их исходного качества. Исследование показывает, что нейронные сети могут эффективно адаптироваться к различным типам данных, предсказывая их структуру и минимизируя размер без потери содержания. Эти работы демонстрируют потенциал применения нейронных сетей в задачах сжатия данных, открывая новые перспективы для исследований в этой области.

Работа [4] описывает подход к анализу временных рядов, основанный на связывании одномерных представлений временных рядов с двумерными представлениями, полученными с помощью техник снижения размерности. Исследование обусловлено задачей эффективного выбора и маркировки паттернов в больших наборах данных временных рядов, что является общей задачей в

различных научных и аналитических областях. Используя техники, такие как UMAP, t-SNE, PCA и автокодировщики, исследование демонстрирует, что дополнение 1D представлений двумерным, уменьшенным по размерности, способствует более эффективному и точному выполнению задач по выбору и маркировке данных, улучшая как скорость, так и точность.

Экспериментальное исследование показало, что использование связанных 1D и 2D представлений, где 2D представление генерируется с помощью техник снижения размерности, значительно помогает в одновременном выборе данных временных рядов. Такой подход не только делает процесс выбора более эффективным, но и повышает точность выбора релевантных паттернов в данных. Исследование подчеркивает эффективность различных техник снижения размерности в облегчении этого процесса.

Описание алгоритма

Набор данных, используемый в работе, включает в себя данные ЭЭГ 28 человек с болезнью Паркинсона и 28 здоровых участников [5]. Осуществлено две сессии измерений из которых получено 168 наблюдений. Временные интервалы всех наблюдений отличаются между собой, исходя из этого было решено разбить данные на фиксированные интервалы длиной 1000 точек. Также были убраны 4 лишних канала, которые не имеют отношения к сигналам ЭЭГ. Таким образом входной сигнал можно представить в виде матрицы $X \in R^{T \times C}$, где T - количество временных точек в окне, а C - количество измерительных каналов.

Далее следует фаза обучения нейронной сети, в которой на основе отобранных сигналов ЭЭГ сеть учится выявлять важные характеристики и паттерны, оптимизируя процесс сжатия таким образом, чтобы максимально сохранять важную информацию при минимальном размере данных. Энкодер применяет последовательность функций преобразования $f_{enc}^{(i)}$ с параметрами $\theta_{enc}^{(i)}$ на каждом слое i , где $i=1, 2, \dots, N$, и N - количество слоёв в энкодере.

После обучения нейронная сеть применяется для сжатия новых ЭЭГ данных. В этой фазе алгоритм преобразует исходные сигналы в сжатое представление, значительно уменьшая их размер. Сжатие происходит за счет выделения и сохранения ключевых признаков сигналов, в то время как менее значимая информация может быть упрощена или исключена. При необходимости сжатые сигналы могут быть восстановлены до их исходного состояния или до состояния, достаточно близкого к оригиналу, для дальнейшего анализа или визуализации. Сжатое представление Z на выходе энкодера может быть выражено как композиция этих функций преобразования, применённых к входному сигналу X:

$$Z = f_{enc}^{(N)}(\dots(f_{enc}^{(2)}(f_{enc}^{(1)}(X; \theta_{enc}^{(1)}); \theta_{enc}^{(2)})\dots); \theta_{enc}^{(N)})$$

Каждая функция $f_{enc}^{(i)}$ может представлять собой операцию свёртки для извлечения признаков, с последующими слоями пулинга для уменьшения размерности, и полносвязные слои для получения окончательного сжатого представления.

Сверточная нейронная сеть состоит из двух блоков: первый из них отвечает за выделение признаков, а второй за реконструкцию исходных данных, разделение наглядно продемонстрировано на рис. 1.




Рис. 1. Архитектура автоэнкодера

Структура блока выделения признаков состоит из четырех слоев. Каждый слой – это группировка сверточного и дропаут слоев и пакетной нормализации, которые обрабатывают входной сигнал и передают его в полносвязный слой, который образует скрытое пространство (Bottleneck) размерностью 350 точек. Далее блок реконструкции восстанавливает данные в исходную размерность 64000 точек.

Набор данных, используемый в работе, был разделен на тренировочную и тестовую выборки.

Тренировочная выборка содержит в себе 12538 наблюдений размером (64, 1000). Тестовая выборка содержит в себе 5394 наблюдения размером (64, 1000). В качестве оптимизатора был выбран алгоритм Adam. Данный метод был выбран, основываясь на работе Diederik P. Kingma и Jimmy Ba [6].

Значения метрик, полученные в результате обучения, представлены в таблице 1.

Таблица 1

Результаты обучения по метрикам

	TRAIN SET	TEST SET
MSE	0,007	0,05
R2	0,99	0,94

На рис. 2 представлено сравнение исходной и восстановленной топологических карт активности мозга одного из пациентов. Представленная иллюстрация показывает визуальную схожесть, исходного сигнала и восстановленного, что подтверждает полученные в результате обучения модели метрики.




Рис. 2. Топологические карты активности мозга пациента.

Заключение

В данной работе был рассмотрен способ уменьшения размерности сигнала ЭЭГ на основе применения автоэнкодера. Полученные в результате обучения модели значения метрик (R2 и MSE) позволяют сделать вывод, что данный способ сжатия сигнала можно использовать для дальнейших исследований, передачи информации и других областей требуемых уменьшения объемов информации.

Список использованных источников

1. Иваськин Ю.Л., Левченко В.В. Формирование нечетких обучающих множеств для нейронных сетей в задачах сжатия данных без потерь. // Проблемы машиностроения и автоматизации. – 2009. – [Электронный ресурс]. – Режим доступа: <https://cyberleninka.ru/article/n/formirovanie-nechetkih-obuchayuschih-mnozhestv-dlya-neuronnyh-setey-v-zadachah-szhatiya-dannyh-bez-poter>.
2. Булаев В.И., Мунасыпов Р.А. Сжатие геофизических данных с применением вейвлет-преобразования и нейронных сетей. // Вестник Уфимского государственного авиационного технического университета. – 2008. – [Электронный ресурс]. – Режим доступа: <https://cyberleninka.ru/article/n/szhatie-geofizicheskikh-dannyh-s-primeneniem-veyvlet-preobrazovaniya-i-neuronnyh-setey>.
3. Автушко Д.А., Склад А.Я. Алгоритм нейросетевого сжатия данных без потерь. // Тенденции развития науки и образования. – 2022. – [Электронный ресурс]. – Режим доступа: <https://elibrary.ru/item.asp?id=49278525>.
4. Mohammed Ali, Rita Borgo, Mark W. Jones, Concurrent time-series selections using deep learning and dimension reduction // Knowledge-Based Systems. – 2021. – Vol. 233. – P. 107507. – ISSN 0950-7051, <https://doi.org/10.1016/j.knosys.2021.107507>.
5. Cavanagh J.F., Kumar P., Mueller A.A. et al. Diminished EEG habituation to novel events effectively classifies Parkinson's patients. Clin Neurophysiol. 2018;129(2):409-418. – PMID: 29294412 DOI: 10.1016/j.clinph.2017.11.023
6. Kingma D.P., & Ba J. Adam: A Method for Stochastic Optimization. CoRR. – 2014. – abs/1412.6980.