

ВЫЧИСЛИТЕЛЬНАЯ ТЕХНИКА И ИНФОРМАТИКА COMPUTER ENGINEERING AND INFORMATICS

Научная статья
УДК 004.891, 616.8-002
<https://doi.org/10.25686/2306-2819.2022.4.24>

Классификация фрагментов электроэнцефалограммы по степени патологической значимости с помощью последовательных нейронных сетей

К. О. Иванов

Поволжский государственный технологический университет,
Российская Федерация, 424000, Йошкар-Ола, пл. Ленина, 3
IvanovKO@volgatech.net

Аннотация. Исследована возможность классификации фрагментов электроэнцефалограммы как элементов нормальной, пограничной и патологической электроэнцефалограммы при помощи последовательных нейронных сетей. Для этого создана новая обучающая база данных, содержащая по 500 фрагментов сигналов нормальной, пограничной и патологической ЭЭГ. С использованием разработанной базы данных поставлен ряд экспериментов по обучению последовательных нейронных сетей с различным количеством слоёв и числом нейронов в слоях, при этом наибольшая точность классификации фрагментов электроэнцефалограммы составила 80,1 %. Для обеспечения возможности запуска и дообучения разработанных нейронных сетей на различных электронных устройствах выполнена реализация алгоритма обратного распространения ошибки.

Ключевые слова: алгоритм обратного распространения ошибки; глубокое обучение; искусственный интеллект; электроэнцефалограмма; классификация ЭЭГ; метод градиентного спуска

Введение. Человеческий мозг производит колебания электрических потенциалов в виде квазистационарных ритмов разной частоты. Зарегистрированные на поверхности головы человека эти потенциалы – электроэнцефалограмма (ЭЭГ) – служат объективным показателем работы его мозга, доступным для исследования в любых ситуациях: при бодрствовании, во время сна, активной нормальной деятельности и при патологических состояниях, вплоть до полного отсутствия сознания. Такие нарушения, как диффузные поражения мозга, опухоли височных и теменных долей, эпилепсия, сосудистые

заболевания находят свое отражение на ЭЭГ [1–3].

Основным способом интерпретации ЭЭГ в настоящее время продолжает оставаться визуальный анализ, когда врач субъективно оценивает форму волн, из которых состоит ЭЭГ [4]. При этом под волной понимается фрагмент ЭЭГ, ограниченный соседними точками глобально-локального минимума [5]. Участок ЭЭГ, подвергаемой анализу, называется эпохой. Эпоха ЭЭГ, как правило, имеет продолжительность от 2 до 8 с [2]. Вид эпохи ЭЭГ, состоящей из волн различных частотных диапазонов, представлен на рис. 1.

© Иванов К. О., 2023.

Для цитирования: Иванов К. О. Классификация фрагментов электроэнцефалограммы по степени патологической значимости с помощью последовательных нейронных сетей // Вестник Поволжского государственного технологического университета. Сер.: Радиотехнические и инфокоммуникационные системы. 2022. № 4 (56). С. 24-37. DOI: <https://doi.org/10.25686/2306-2819.2022.4.24>




Рис. 1. Эпоха ЭЭГ, содержащая различные паттерны

Fig. 1. EEG epoch containing various patterns

Визуальный анализ является достаточно трудоёмким, а его результаты в значительной степени зависят от профессионального опыта клинициста, проводящего обследование. Здесь используются способности врача к запоминанию колебаний, их визуальной оценке, сравнению и распознаванию форм [4].

Таким образом, актуальной задачей является разработка систем поддержки принятия решений, повышающих информационное обеспечение врача и позволяющих представить данные ЭЭГ обследований в более привычном и понятном врачу виде. В частности, в работах [6, 7], где выполнялась классификация отдельных волн ЭЭГ, показано, что подобные системы позволяют повысить достоверность поставленных по ЭЭГ клинических заключений.

Современные средства компьютерного анализа ЭЭГ в качестве дополнительной информации предоставляют врачу амплитудный спектр каждого отведения анализируемой ЭЭГ, ее фазовый спектр и спектр мощности и т.д. [8]. С использованием данных частотных характеристик могут быть определены обобщенные спектральные показатели в стандартных частотных диапазонах (дельта-, тета-, альфа-, бета-), и по ним оценены статистические различия спектров (между парами одноименных отведений двух записей или между всеми парами отведений одной записи) [9]. Далее полученные показатели всех отведений могут представ-

ляться в виде топографических карт, содержащих информацию о распределении какого-либо показателя по поверхности скальпа в виде многоцветной шкалы [2, 10, 11].

Для получения подобной информации о сигнале используются спектральный и корреляционные методы анализа [3, 8]. Однако из-за взвешенного усреднения отсчетов сигнала при использовании этих методов изменение формы отдельной волны ЭЭГ, которое может иметь диагностическое значение, способно оказывать лишь незначительное влияние на спектральные и корреляционные характеристики анализируемой эпохи. Очевидно, что для оценки влияния отдельных компонент ЭЭГ на клиническое заключение требуется осуществлять анализ сигнала во временной области. Для этого могут использоваться методы вейвлет-анализа сигналов, а по полученным частотно-временным характеристикам сигнала может выполняться классификация отдельных компонент ЭЭГ с применением распространённых методов распознавания образов [12–16].

Другим возможным подходом к распознаванию компонент ЭЭГ может выступить использование методов глубокого обучения [17–20]. Методы глубокого обучения в настоящее время находят применение во многих областях и показывают лучшую производительность во многих задачах, по сравнению с другими методами искусственного интеллекта [21]. Глу-

бокое обучение также существенно упрощает решение проблем, полностью автоматизируя важнейший шаг в машинном обучении, выполнявшийся раньше вручную, – конструирование признаков, что делает этот метод предпочтительным для исследований в случае наличия обучающей базы данных [22, 23].

Целью данной работы является повышение эффективности подходов к классификации электроэнцефалограмм по степени патологической значимости за счет использования методов искусственного интеллекта, в частности, последовательных нейронных сетей.

Классификация в электроэнцефалографии. Ввиду трудности определения формальной границы между нормой и патологией при анализе ЭЭГ в подавляющем большинстве систем классификации ЭЭГ все они подразделяются на три группы: патологические, пограничные (между нормой и патологией) и нормальные [2].

ЭЭГ в норме обладают пространственно-временными, частотными и амплитудными характеристиками, соответствующими функциональному состоянию и возрасту пациента. Как правило, нормальные ЭЭГ взрослого человека содержат α - и β -волны, амплитуда которых не превышает 100 и 15 мкВ соответственно. На этих ЭЭГ также могут присутствовать участки α - и β -ритмов, волны которых не носят характера билатерально-синхронных организованных разрядов или чёткой

локальности, не превышают по амплитуде 50 мкВ и занимают не более 15 % от общего времени записи ЭЭГ [5].

Пограничными называют ЭЭГ, выходящие за указанные рамки, но при этом не имеющие характера явной патологической активности. Руководства по клинической электроэнцефалографии не имеют чётких формальных критериев для классификации пограничной ЭЭГ. Это связано со сложностью их отделения от нормы и патологии. В частности, признаками отклонения ЭЭГ от нормы являются:

а) наличие на ЭЭГ нехарактерных δ - и θ -ритмов при изменении частоты доминирующего ритма, а также наличие различных видов эпилептиформной активности, таких как спайки, острые волны, спайк-волны и др.;

б) выход за пределы нормы размахов волн доминирующего ритма;

в) аномальная комбинация волн ЭЭГ;

г) аномальные реакции на функциональные пробы;

д) наличие на ЭЭГ компонент, не характерных для возрастной группы обследуемого.

Патологическими называют электроэнцефалограммы, выходящие за границы нормальных и пограничных.

Подробнее с параметрами нормальной, пограничной и патологической ЭЭГ можно ознакомиться в работах [2, 5]. Графики нормальной, пограничной и патологической ЭЭГ представлены на рис. 2.




Рис. 2. Эпоха пограничной ЭЭГ, содержащая θ -волну частотой 7 Гц и амплитудой более 50 мкВ (а); эпоха нормальной ЭЭГ, состоящая из следующих друг за другом α -волн частотой 10 Гц (б); эпоха патологической ЭЭГ, в состав сигнала входит острая волна частотой 20 Гц и амплитудой 55 мкВ (в)

Fig. 2. Borderline EEG epoch, containing a θ -wave with a frequency of 7 Hz and an amplitude of more than 50 μV (a); normal EEG epoch, consisting a successive α -waves with a frequency of 10 Hz (b); pathological EEG epoch, the signal includes a sharp wave with a frequency of 20 Hz and an amplitude of 55 μV (c)

База данных для проведения исследований. Нейронная сеть принимает на свой вход векторы фиксированной размерности. В данной работе на вход нейронной сети подавались ЭЭГ сигналы с одного отведения длительностью 0,5 с и с частотой дискретизации 500 Гц. Таким образом, каждый сигнал содержал 250 отсчётов. Фрагменты ЭЭГ выбирались под контролем практикующего врача-клинициста из записей электроэнцефалограмм, полученных в ГБУ РМЭ «Республиканская клиническая больница», а также из верифицированных, расположенных в открытом доступе в сети Интернет баз данных Темпльского [24] и Сиенского [25] университетов. Всего было выбрано 1500 фрагментов электроэнцефалограмм, 500 из которых являлись элементами нормальной ЭЭГ, 500 – элементами пограничной ЭЭГ и еще 500 – элементами патологической ЭЭГ. 1000 электроэнцефалограмм из этой базы данных использовались для обучения нейронной сети, 250 – для проверки и еще 250 – для тестирования.

Последовательные нейронные сети.

Последовательные искусственные нейронные сети представляют собой устройства параллельных вычислений, состоящие из множества взаимодействующих простых искусственных нейронов [26]. Как правило, нейронная сеть принимает на вход вектор числовых значений сигнала, подвергает его серии нелинейных преобразований и выдает на выход требуемое значение. Этим значением может быть вектор вероятностей принадлежности входного сигнала к распознаваемым образам в случае, если нейронная сеть решает задачу классификации, либо любым другим значением в зависимости от функции нейронной сети. Например, нейронная сеть может удалять помехи из звукового сигнала. Тогда на вход она будет принимать вектор числовых значений этого сигнала, а на выходе выдавать вектор значений модифицированного сигнала с уменьшенными шумами.

Минимальный структурный элемент искусственной нейронной сети – искусственный нейрон. Он является упрощённой моделью естественного нейрона, принимает на вход набор сигналов и с математической точки зрения представляет собой некоторую нелинейную функцию от линейной комбинации входных сигналов [27]. Данную функцию называют функцией активации, или функцией срабатывания, передаточной функцией. Полученный результат передается на единственный выход. Схематичное изображение искусственного нейрона представлено на рис. 3.




Рис. 3. Искусственный нейрон
Fig. 3. The concept of artificial neuron

Линейная комбинация входных сигналов (значение комбинированного ввода) определяется выражением

$$net = \sum_{i=0}^n x_i \omega_i, \quad (1)$$

где x_i – числовые значения, поступающие на вход искусственного нейрона; ω_i – весовые значения входов искусственного нейрона.

В свою очередь, значение на выходе нейрона определяется как

$$o = f(net), \quad (2)$$

где f – передаточная функция. Подробнее с типами передаточных функций можно ознакомиться в [28], здесь отметим, что в настоящее время наибольшее распространение получила передаточная функция ReLu, возвращающая значение комбинированного ввода net , если оно положительно, и ноль в противном случае.

Схематичное изображение многослойной последовательной нейронной сети представлено на рис. 4. Данная нейронная сеть состоит из трёх слоёв. Как правило, многослойные нейронные сети в каждом слое содержат ещё и элемент смещения. На рис. 4 он обозначен белым кружком. Элемент смещения не связан с нейронами из предыдущего слоя и всегда имеет единичное значение на входе. Начальный слой представленной нейронной сети содержит два входных нейрона и один элемент смещения, таким образом, данная нейронная сеть принимает на вход вектор, содержащий две компоненты. Нейроны входного слоя никак не модифицируют сигнал, а лишь передают его нейронам следующих слоёв, называемых скрытыми. Последний слой искусственной нейронной сети называется выходным. Таким образом, представленная на рис. 4 нейронная сеть содержит лишь один скрытый слой.




Рис. 4. Многослойная последовательная нейронная сеть

Fig. 4. Multilayer serial neural network

На рис. 4 каждый искусственный нейрон имеет свой порядковый номер $j = 0 \dots 8$. В соответствии с такой нумерацией сигнал на выходе j -го нейрона скрытого слоя будет равен

$$o_j = f(\text{net}_j) = f\left(\sum_i x_i \cdot \omega_{i,j}\right), \quad (3)$$

где i – порядковый номер нейрона из предыдущего слоя нейронной сети; x_i –

входной сигнал, который в зависимости от расположения нейрона в нейронной сети может быть равен либо входному отсчёту, либо значению с выхода нейрона предыдущего слоя.

Обучение нейронной сети. Задача обучения нейронной сети сводится к поиску значений весовых коэффициентов её нейронов, при которых она успешно решает требуемые задачи, т.е. на её выходе наблюдается требуемое значение. Обучение последовательной нейронной сети выполняется по алгоритму обратного распространения ошибки [23, 26, 28]. В общем случае для обучения нейронной сети формируется обучающая база данных в виде набора образцов (входных сигналов) и заранее известных для них целевых значений на выходе нейронной сети. На начальном этапе обучения весовые коэффициенты нейронной сети инициализируются случайными значениями из интервала $[-0.3, 0.3]$. Далее на вход нейронной сети в случайном порядке подаются обучающие образцы. Для каждого образца определяется значение на выходе нейронной сети и в соответствии с полученным значением и известным целевым значением определяется ошибка. При этом на каждой подобной итерации корректируются весовые коэффициенты нейронной сети с целью минимизации ошибки. Процесс, когда на вход нейронной сети были поданы все образцы из обучающей базы данных, называется эпохой [29]. Как правило, для качественного обучения нейронной сети требуется выполнить несколько эпох, их число может достигать 500 или даже нескольких тысяч.

Рассмотрим интерпретацию метода корректировки весовых коэффициентов нейронов, составляющих искусственную нейронную сеть, которая использовалась в нашей работе.

Сигнал на выходе j -го нейрона определяется выражением (3). Обозначим через t_j требуемое значение на выходе нейрона с индексом j . Тогда ошибка E_p

для p -го образца из обучающей базы данных может быть определена по формуле

$$E_p = \frac{1}{2} \sum_j (t_j - o_j)^2, \quad (4)$$

а полная ошибка будет равна $E = \sum E_p$.

Подставив выражение (3) в выражение (4), получим

$$E_p = \frac{1}{2} \sum_j \left(t_j - f \left(\sum_i x_i \cdot \omega_{i,j} \right) \right)^2. \quad (5)$$

Из полученного выражения видно, что ошибка нейронной сети зависит лишь от весовых коэффициентов её нейронов ω . Выражение (5) можно рассматривать как функцию, зависящую от переменных $\omega_0, \omega_1, \dots, \omega_{m-1}$, где m – количество связей в нейронной сети. Данная функция образует в m -мерном пространстве поверхность ошибок.

Поскольку обучение нейронной сети сводится к минимизации её ошибки, требуется определить точку минимума указанной функции. Это можно сделать численно, подавая на вход нейронной сети обучающие данные и каждый раз вычисляя градиент от выражения (5). Поскольку градиент представляет собой вектор, указывающий направление наибольшего роста функции, каждый раз необходимо изменять весовые коэффициенты нейронной сети $\omega_{i,j}$ на значения $\Delta \omega_{i,j} = -\frac{\partial E}{\partial \omega_{i,j}}$,

т. е. необходимо двигаться по поверхности ошибок в сторону, противоположную градиенту от функции (5).

Используя цепное правило [30] с учётом выражений (3) и (4), производную ошибки можно представить в виде

$$\frac{\partial E}{\partial \omega_{i,j}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial \omega_{i,j}}. \quad (6)$$

Вычислим компоненты выражения (6) по отдельности. С учетом выражения (4) можно записать:

$$\begin{aligned} \frac{\partial E}{\partial o_j} &= \frac{\partial \left(\frac{1}{2} (t_j - o_j)^2 \right)}{\partial o_j} = \\ &= \frac{\partial \left(\frac{1}{2} t_j^2 - t_j o_j + \frac{1}{2} o_j^2 \right)}{\partial o_j} = \\ &= -t_j + o_j = -(t_j - o_j). \end{aligned}$$

В свою очередь, с учётом (3)

$$\frac{\partial o_j}{\partial net_j} = f'(net_j),$$

а учитывая (1), получаем

$$\frac{\partial net}{\partial \omega} = x.$$

Подставляя полученные производные в выражение (6), получим

$$\frac{\partial E}{\partial \omega_{i,j}} = -(t_j - o_j) f'(net_j) x_i. \quad (7)$$

Обозначим ошибку на выходе j -го нейрона $\delta_j = (t_j - o_j) f'(net_j)$. Тогда с учётом того, что весовые коэффициенты нейронов должны изменяться в направлении, противоположном направлению градиента функции ошибок, изменение веса для каждого элемента должно выполняться по формуле

$$\Delta \omega_{i,j} = \eta \delta_j x_i, \quad (8)$$

где η – норма обучения (коэффициент, от которого зависит величина изменения веса при итеративной корректировке весовых коэффициентов нейронов, образующих нейронную сеть).

Указанную выше ошибку δ_j можно определить лишь для нейронов выходного слоя нейронной сети, поскольку только для них заранее известно целевое значение на выходе. Для нейронов скрытых слоёв ошибка определяется в зависимости от ошибок на выходах нейронов последующего слоя и весовых коэффициентов связи с этими нейронами. Весовые значения скрытого элемента следует скорректировать пропорционально его вкладу в

величину ошибки нейронов следующего слоя, с которыми он связан. В нейронной сети при распространении сигналов ошибок в обратном направлении ошибка каждого выходного элемента вносит свой вклад в ошибку каждого элемента скрытого слоя. Этот вклад для элементов скрытого слоя зависит от величины ошибки выходного элемента и весового коэффициента связи, соединяющей элементы. Следовательно, выходной элемент с большей ошибкой делает больший вклад в ошибку того элемента скрытого слоя, с которым он связан большим по величине весом [26]. Таким образом, ошибка нейрона скрытого слоя нейронной сети вычисляется по формуле

$$\delta_j = f'(net_j) \sum_k \delta_k \omega_{k,j}, \quad (9)$$

где k – индекс слоя, который посылает ошибку в обратном направлении.

С учётом описанного алгоритм обучения последовательной нейронной сети можно представить в виде блок-схемы, изображённой на рис. 6. Индекс k на этой блок-схеме соответствует предыдущему слою при движении в сети.

Чтобы уменьшить вероятность того, что изменения весов приобретут осциллирующий характер, вводится итерационный член α , добавляемый в пропорции, соответствующей предыдущему изменению веса:

$$\Delta \omega_{i,j}(n+1) = \eta \delta_j o_i + \alpha \Delta \omega_{i,j}(n). \quad (10)$$

Таким образом, изменение весов нейронов на шаге $n+1$ будет зависеть от изменения их весов на шаге n .




Рис. 6. Корректировка весовых значений нейронной сети по алгоритму обратного распространения ошибки для одной эпохи

Fig. 6. Correction of the weight values of the neural network using the backpropagation algorithm for one epoch

Как правило, при обучении нейронной сети её полная ошибка снижается с каждой эпохой, а точность распознавания при этом растёт. Однако модель, которая показывала хорошие результаты на обучающих данных, не обязательно будет показывать такие же хорошие результаты на данных, которые не видела прежде. В результате оптимизации параметров нейронной сети может возникнуть её переобучение. Это ситуация, когда модель показывает высокие результаты классификации или предсказания на обучающих данных, однако при этом совершенно не подходит для применения к новым данным ввиду низкой вероятности их классификации или предсказания. Чтобы избежать ситуации переобучения нейронной сети, после каждой эпохи её обучения добавляют этап проверки [22]. На этапе проверки не происходит корректировка весовых значений нейронной сети, а лишь вычисляются её точность и величина ошибки на выходе. При этом используются так называемые «проверочные» данные, которые не использовались при обучении нейронной сети. Ситуация, при которой точность нейронной сети на этапе проверки перестаёт расти, а ошибка принимает минимальное значение, является сигналом к остановке процесса обучения. Далее осуществляют итоговую оценку точности модели на тестовых данных, которые не использовались на этапе обучения и проверки.

Классификация электроэнцефалограмм с помощью последовательных нейронных сетей. Описанный алгоритм обучения последовательной нейронной сети был реализован на языке программирования C++. В отличие от использования популярных библиотек для глубокого обучения, таких как TensorFlow и PyTorch, это позволяет производить обучение и запуск нейронных сетей на микропроцессорах и микроконтроллерах раз-

личных архитектур и не привязываться к конкретным производителям микросхем, таким как Intel, AMD и NVidia.

В работе было реализовано несколько последовательных нейронных сетей с разным количеством скрытых слоёв и нейронов в этих слоях, а также с различными передаточными функциями. Точность классификации фрагментов ЭЭГ с помощью этих нейронных сетей представлена в таблице (см. с. 32).

Все модели исследованных нейронных сетей имеют по 256 нейронов во входном слое и по 3 – в выходном, поскольку нейронные сети принимают на вход сигналы, содержащие по 256 отсчётов, и относят их к одному из трёх классов. Из таблицы видно, что наилучшие результаты классификации показывает модель последовательной нейронной сети с одним скрытым слоем, содержащим 256 нейронов с функцией активации ReLu. Графики обучения этой нейронной сети представлены на рис. 7.

На рисунке видно, что переобучение нейронной сети наступает в районе 320 эпохи, поскольку при дальнейшем обучении точность нейронной сети на этапе проверки не растёт, а ошибка начинает увеличиваться. Подобным образом определялась точность для всех моделей нейронных сетей.

Дальнейшее увеличение количества нейронов в скрытых слоях ведёт к уменьшению точности классификации фрагментов ЭЭГ. Очевидно, что дальнейшее увеличение точности классификации за счёт увеличения сложности модели нейронной сети связано с увеличением объёма обучающей выборки. Аналогичная ситуация наблюдается при увеличении количества скрытых слоёв. Также данные таблицы показывают, что разные функции активации не оказывают значительного влияния на точность классификации фрагментов ЭЭГ.

Точность классификации фрагментов ЭЭГ по степени патологической значимости с помощью последовательных нейронных сетей

EEG fragments classification accuracy according to the degree of pathological significance using sequential neural networks

№ п/п	Количество скрытых слоев	Количество нейронов в скрытых слоях	Передаточная функция нейронов	Вероятность	Передаточная функция нейронов	Вероятность
1	1	128	ReLu	78,5	Sigmoid	78,6
2	1	256	ReLu	80,1	Sigmoid	80,0
3	1	512	ReLu	77,4	Sigmoid	77,2
4	1	1024	ReLu	78,8	Sigmoid	78,8
5	2	128, 128	ReLu	75,0	Sigmoid	75,0
6	2	256, 256	ReLu	77,2	Sigmoid	77,3
7	2	512, 512	ReLu	78,4	Sigmoid	78,3
8	2	1024, 1024	ReLu	76,9	Sigmoid	76,9
9	3	128, 128, 128	ReLu	77,0	Sigmoid	76,9
10	3	256, 256, 256	ReLu	78,0	Sigmoid	78,0
11	3	512, 512, 512	ReLu	77,5	Sigmoid	77,6




Рис. 7. Точность и потери последовательной нейронной сети с одним скрытым слоем из 256 нейронов при классификации фрагментов ЭЭГ

Fig. 7. Accuracy and loss of a sequential neural network with one hidden layer of 256 neurons in the classification of EEG fragments

Закключение. Описанный в статье подход к классификации фрагментов ЭЭГ с помощью последовательных нейронных сетей позволяет произвести на компьютере часть умозрительных операций, выполняемых врачом-клиницистом, и в автоматическом режиме обнаружить в электроэнцефалограмме фрагменты пограничных и патологических ЭЭГ.

В работе была сформирована новая верифицированная база данных фрагмен-

тов электроэнцефалограмм, содержащая по 500 сигналов пограничной, нормальной и патологической ЭЭГ в одном отведении. С использованием разработанной базы данных поставлен ряд экспериментов по обучению последовательных нейронных сетей с различным количеством слоёв и числом нейронов в слоях. При этом на языке программирования C++ выполнена самостоятельная реализация программных модулей для конструирования нейронных

сетей и алгоритма их обучения. Это позволяет осуществлять вычисления на процессорах различного назначения и с различными архитектурами.

Установлено, что наибольшая точность классификации фрагментов ЭЭГ достигается нейронной сетью с одним скрытым слоем, содержащим 256 нейронов, и составляет 80,1 %. Таким образом, показана принципиальная возможность использования последовательных нейронных сетей для классификации фрагментов ЭЭГ по степени патологической значимости. Кроме того, из полученных результатов видно, что для подобной классифика-

ции не обязательно использовать нейронные сети с большим количеством скрытых слоёв и нейронов. Оптимизация параметров нейронной сети в данном случае позволяет не только повысить точность классификации, но и значительно сократить количество арифметических операций, что положительно сказывается на скорости обучения.

Предложенный подход снижает объём умозрительных операций, выполняемых врачом-нейрофизиологом, и обеспечивает возможность более объективно, качественно и быстро выполнять интеллектуальную часть анализа ЭЭГ.

Список источников

1. Furman Ya. A., Sevastyanov V. V., Ivanov K. O. Modern Problems of Brain-Signal Analysis and Approaches to Their Solution // Pattern Recognition and Image Analysis. 2019. Vol. 29. No. 1. Pp. 99–119. DOI: 10.1134/S1054661819010103.
2. Кулаичев А. П. Компьютерная электрофизиология. М.: Изд-во Моск. ун-та, 2002. 640 с.
3. Биопотенциалы мозга человека. Математический анализ / В. С. Русинов, О. М. Гриндель, Г. Н. Болдырева и др. М.: Медицина. 1987. 256 с.
4. Зенков Л. Р. Клиническая электроэнцефалография. М.: МЕДпресс-информ, 2013. 356 с.
5. Цыган В. Н., Богословский М. М., Миролюбов А. В. Электроэнцефалография / под. ред. М. М. Дьяконова. СПб.: Наука, 2008. 192 с.
6. A Structural Approach to Computer Analysis of Brain Signals and Its Implementation in the Decision Support System / Ya. A. Furman, V. V. Sevastyanov, K. O. Ivanov et al. // Proceedings of the 6th International Young Scientists Conference on Information Technologies, Telecommunications and Control Systems (ITTCS 2019), Innopolis, 2019. URL: ceur-ws.org/Vol-2525/ITTCS-19_paper_10.pdf (дата обращения 16.11.2022).
7. Фурман Я. А., Севастьянов В. В., Иванов К. О. Структурные методы анализа электроэнцефалограмм при формировании медицинских заключений: монография / под. ред. Я. А. Фурмана. М.: КУРС, 2022. 272 с. (Серия «Наука»).
8. Динамика спектральных характеристик ЭЭГ у лиц с разной личностной тревожностью при когнитивной деятельности / Т. Д. Джебраилова, И. И. Коробейникова, Н. А. Каратыгин и др. // Физиология человека. 2021. Т. 47, №. 1. С. 20–30.
9. Связь спектральных характеристик тета-ритма ЭЭГ с результативностью выполнения когнитивного теста «n-back» / Н. А. Каратыгин, И. И. Коробейникова, Я. А. Венерина и др. // Экспериментальная психология. 2022. Т. 15, №. 2. С. 95–110.
10. Кропотов Ю. Д. Количественная ЭЭГ, когнитивные вызванные потенциалы мозга человека и нейротерапия. Донецк: Издатель Заславский А. Ю., 2010. 512 с.
11. Гнездицкий В. В. Обратная задача ЭЭГ и клиническая электроэнцефалография. М.: МЕДпресс-информ. 2004. 624 с.
12. A machine learning-based big EEG data artifact detection and wavelet-based removal: an empirical approach / Shalini Stalin, Vandana Roy, Prashant Kumar Shukla et al. // Mathematical Problems in Engineering. 2021. Vol. 2021. Pp. 1 - 11.
13. Automated characterization of cyclic alternating pattern using wavelet-based features and ensemble learning techniques with EEG signals / M. Sharma, V. Patel, J. Tiwari et al. // Diagnostics. 2021. Vol. 11, No. 8. Pp. 1380 - 1399.
14. EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier / A. Subasi, T. Tuncer, S. Dogan et al. // Biomedical Signal Processing and Control. 2021. Vol. 68. URL: <https://www.sciencedirect.com/science/article/pii/S1746809421002457> (дата обращения: 25.11.2022).
15. PrimePatNet87: Prime pattern and tunable q-factor wavelet transform techniques for automated accurate EEG emotion recognition / A. Dogan, M. Akay, P. D. Barua et al. // Computers in Biology and Medicine. 2021. Vol. 138. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0010019721002457> (дата обращения: 25.11.2022).
16. Zarei A., Asl B. M. Automatic seizure detection using orthogonal matching pursuit, discrete wavelet transform, and entropy based features of EEG signals // Computers in Biology and Medicine. 2021. Vol. 131. URL:

<https://www.sciencedirect.com/science/article/abs/pii/S0010482521000445> (дата обращения 25.11.2022).

17. Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review / H. Altaheri, G. Muhammad, M. Alsulaima et al. // *Neural Computing and Applications*. 2021. No. 16. Pp. 1-42.

18. Cooney C., Folli R., Coyle D. A bimodal deep learning architecture for EEG-fNIRS decoding of overt and imagined speech // *IEEE Transactions on Biomedical Engineering*. 2021. Vol. 69, No. 6. Pp. 1983-1994

19. Topic A., Russo M. Emotion recognition based on EEG feature maps through deep learning network // *Engineering Science and Technology: International Journal*. 2021. Vol. 24, No. 6. Pp. 1442-1454.

20. Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study / M. J. Rivera, M. A. Teruel, A. Mate et al. // *Artificial Intelligence Review*. 2022. Vol. 55, No. 2. Pp. 1209-1251.

21. Гудфеллоу Я., Бенджисо И., Курвиль А. Глубокое обучение. М.: ДМК-Пресс, 2018. 652 с.

22. Франсуа Ш. Глубокое обучение на Python. СПб.: Питер, 2018. 400 с.

23. Хайкин С. Нейронные сети. М.: Вильямс, 2019. 1104 с.

24. The TUH EEG Corpus dings collected at Temple University Hospital (TUH) from 2002 – present. URL: https://isip.piconepress.com/projects/tuh_eeg/downloads/tuh_eeg/ (дата обращения: 28.11.2022).

25. Siena Scalp EEG Database // Detti, P. (2020). Siena Scalp EEG Database (version 1.0.0). PhysioNet. <https://doi.org/10.13026/5d4a-j060>. URL: <https://physionet.org/content/siena-scalp-eeeg/1.0.0/> (дата обращения: 28.11.2022).

26. Каллан Р. Основные концепции нейронных сетей. М.: Вильямс, 2009. 288 с.

27. Николаенко С. И., Архангельская Е. О., Кадури А. А. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2022. 480 с.

28. Rao Delip, McMahan Brian. Natural Language Processing with PyTorch: Build Intelligent Language Applications Using Deep Learning. Boston, 2019. 256 p.

29. Pointer Ian. Programming PyTorch for Deep Learning: Creating and Deploying Deep Learning Applications. Boston, 2019. 220 p.

30. Тимофеев В. С., Сивак М. А. Робастная нейронная сеть с простой архитектурой // *Сибирский журнал промышленной математики*. 2021. Т. 24. № 4. С. 126–138.

Статья поступила в редакцию 06.11.2022; одобрена после рецензирования 28.11.2022; принята к публикации 15.12.2022

Информация об авторах

ИВАНОВ Константин Олегович – кандидат технических наук, доцент кафедры радиотехнических и медико-биологических систем, Поволжский государственный технологический университет. Область научных интересов – искусственный интеллект, глубокое обучение, цифровая обработка сигналов и изображений. Автор 40 научных публикаций. ORCID: <https://orcid.org/0000-0002-6395-4085>.

Автор заявляет об отсутствии конфликта интересов.

Автор прочитал и одобрил окончательный вариант рукописи.

Scientific article

UDC 004.891, 616.8-002

<https://doi.org/10.25686/2306-2819.2022.4.24>

Classification of Electroencephalogram Segments Based on Pathological Significance Using Sequential Neural Networks

K. O. Ivanov

Volga State University of Technology,
3, Lenin Square, Yoshkar-Ola, 424000, Russia Federation
IvanovKO@volgatech.net ✉

Keywords: *backpropagation algorithm; deep learning; artificial intelligence; electroencephalogram; EEG classification; gradient descent method*

ABSTRACT

Introduction. *Electroencephalography (EEG) is the primary method for diagnosing the functional state of the human central nervous system. Many conditions, such as epilepsy, brain tumors, cranial and cerebral injuries, vascular diseases, psychiatric disorders, and various forms of encephalopathy, can be reflected in EEG recordings. Despite its widespread use, EEG analysis is still mostly conducted visually by experienced clinicians, which is time-consuming and subjective. The need for more efficient and reliable EEG analysis has led to the development of decision support systems that use artificial intelligence technologies for EEG pattern classification. Neural networks have proven to be particularly effective in achieving high classification accuracy in many applications. The aim of this paper is to enhance the efficiency of automatic electroencephalogram (EEG) classification based on pathological significance through the application of artificial intelligence methods, particularly sequential neural networks. To achieve this goal, the following objectives are addressed in the study: 1) a review of computational EEG analysis methods; 2) creation of a training database of EEG fragments, including a sufficient number of normal, borderline, and pathological EEG signals; 3) implementation of a neural network training algorithm; 4) examination of the effect of sequential neural network parameters on the accuracy of EEG fragment classification. Results.* *A new training database consisting of 500 EEG fragments, including normal, borderline, and pathological signals, was created. The database was used to train sequential neural networks with varying numbers of layers and neurons, resulting in the highest classification accuracy of 80.1 %. The error back propagation algorithm was implemented to allow the developed neural networks to be run and retrained on various electronic devices. The practical value of this work lies in the reduction of speculative operations performed by neurophysiologists and the provision of a more objective, qualitative, and faster intellectual EEG analysis when used in medical decision support systems.*

REFERENCES

1. Furman Ya. A., Sevastyanov V. V., Ivanov K. O. Modern Problems of Brain-Signal Analysis and Approaches to Their Solution. *Pattern Recognition and Image Analysis*. 2019. Vol. 29, No. 1. Pp. 99-119. DOI: 10.1134/S1054661819010103.
2. Kulaichev A.P. Komp'yuternaja jelektrofiziologija [Computer Electrophysiology]. Moscow, Publishing House of Moscow State University, 2002. 640 p. (In Russ.).
3. Rusinov V.S., Grindel O.M., Boldyreva G.N., Vakar E.M. Biopotencijal mozga cheloveka. Matematicheskij analiz [Biopotentials of the human brain. Mathematical analysis]. Moscow, Medicina, 1987. 256 p. (In Russ.).
4. Zenkov L.R. Klinicheskaja jelektroencefalografija [Clinical electroencephalography]. Moscow, MEDpress-inform, 2013. 356 p. (In Russ.).
5. Tsygan V.N., Bogoslovsky M.M., Mirolyubov A.V. Jelektroencefalografija. Pod. red. M.M. D'jakonova [Electroencephalography. Under. ed. M.M. Dyakonova]. St. Petersburg, Nauka, 2008. 192 p. (In Russ.).
6. Furman Ya.A., Sevastyanov V.V., Ivanov K.O., Glazunova N.U. A Structural Approach to Computer Analysis of Brain Signals and Its Implementation in the Decision Support System. Proceedings of the 6th International Young Scientists Conference on Information Technologies, Telecommuni-

cations and Control Systems (ITTCS 2019), Innopolis, 2019. URL: ceur-ws.org/Vol-2525/ITTCS-19_paper_10.pdf (reference date 16.11.2022).

7. Furman Ya.A., Sevastyanov V.V., Ivanov K.O. Strukturnye metody analiza jelektroencefalogrammi pri formirovanii medicinskih zakljuchenij: monografija. Pod. red. Ja. A. Furmana. [Structural methods of analysis of electroencephalograms in the formation of medical conclusions: monograph. Under ed. Ya. A. Furman]. Moscow, KURS publishing house, 2022. 272 p. (Series "Science"). (In Russ.).

8. Dzhebrailova T.D., Korobeynikova I.I., Karatygin N.A., Biryukova E.V., Venerina Ya.A. Dinamika spektral'nyh harakteristik JeJeG u lic s raznoj lichnostnoj trevozhnost'ju pri kognitivnoj dejatel'nosti [Dynamics of EEG Spectral Characteristics in Subjects with Various Trait Anxiety Levels Performing Cognitive Tests]. *Fiziologija cheloveka* [Human Physiology]. 2021. Vol. 47, No. 1. Pp. 20-30. (In Russ.).

9. Karatygin N.A., Korobeynikova I.I., Venerina Ya.A., Venerin A.A., Alexandrov Yu.I. Svjaz' spektral'nyh harakteristik teta-ritma JeJeG s rezul'tativnost'ju vypolnenija kognitivnogo testa "n-back" [Spectral Characteristics of the EEG Theta-Band and Efficiency of Cognitive Test "n-back" Performing]. *Jeksperimental'naja psihologija* [Experimental Psychology]. 2022. Vol. 15, No. 2. Pp. 95-110. (In Russ.).

10. Kropotov Ju. D. Kolichestvennaja JeJeG, kognitivnye vyzvannye potencially mozga cheloveka i nejroterapija [Quantitative EEG, Event-Related Potentials and Neurotherapy]. Donetsk, Izdatel' Zaslavskij A. Ju., 2009. 542 p.

11. Gnezditsky V.V. Obratnaja zadacha JeJeG i klinicheskaja jelektroencefalografija [Inverse problem of EEG and clinical electroencephalography]. Moscow, MEDpress-inform. 2004. 624 p.

12. Shalini Stalin, Vandana Roy, Prashant Kumar Shukla, Atef Zaguia A machine learning-based big EEG data artifact detection and wavelet-based removal: an empirical approach. *Mathematical Problems in Engineering*. 2021. Vol. 2021. Pp. 1-11.

13. Sharma M., Patel V., Tiwari J., Acharya U.R. Automated characterization of cyclic alternating pattern using wavelet-based features and ensemble learning techniques with EEG signals. *Diagnostics*. 2021. Vol. 11, No. 8. Pp. 1380-1399.

14. Subasi A., Tuncer T., Dogan S., Tanko D., Sakoglu U. EEG-based emotion recognition using tunable Q wavelet transform and rotation forest ensemble classifier. *Biomedical Signal Processing and Control*. 2021. Vol. 68. URL: <https://www.sciencedirect.com/science/article/pii/S1746809421002457> (reference date: 25.11.2022).

15. Dogan A., Akay M., Barua P.D., Baygin M., Dogan S., Tuncer T., Dogru A.H., Acharya U.R.

PrimePatNet87: Prime pattern and tunable q-factor wavelet transform techniques for automated accurate EEG emotion recognition. *Computers in Biology and Medicine*. 2021. Vol. 138. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521000445> (reference date: 25.11.2022).

16. Zarei A., Asl B.M. Automatic seizure detection using orthogonal matching pursuit, discrete wavelet transform, and entropy based features of EEG signals. *Computers in Biology and Medicine*. 2021. Vol. 131. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0010482521000445> (reference date: 25.11.2022).

17. Altaheri H., Muhammad G., Alsulaima M., Amir S.U., Altuwaijri G.A., Abdul W., Bencherif M.A., Faisal M. Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: a review. *Neural Computing and Applications*. 2021. No. 16. Pp. 1-42.

18. Cooney C., Folli R., Coyle D. A bimodal deep learning architecture for EEG-fNIRS decoding of overt and imagined speech. *IEEE Transactions on Biomedical Engineering*. 2021. Vol. 69, No. 6. Pp. 1983-1994.

19. Topic A., Russo M. Emotion recognition based on EEG feature maps through deep learning network. *Engineering Science and Technology: International Journal*. 2021. Vol. 24, No. 6. Pp. 1442-1454.

20. Rivera M.J., Teruel M.A., Mate A., Trujillo J. Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study. *Artificial Intelligence Review*. 2022. Vol. 55, No. 2. Pp. 1209-1251.

21. Bengio Y., Goodfellow I., Courville A. Glubokoe obuchenie [Deep learning]. Moscow, DMK-press, 2018. 652 p.

22. Chollet F. Glubokoe obuchenie na Python [Deep learning with Python]. SPb, Piter, 2018. 384 p.

23. Haykin S. Nejronnye seti [Neural Networks]. Moscow, Vil'jams, 2019. 1104 p.

24. The TUH EEG Corpus dings collected at Temple University Hospital (TUH) from 2002 – present. Access: https://isip.piconepress.com/projects/tuh_eeg/downloads/tuh_eeg/ (date of reference: 28.11.2022).

25. Siena Scalp EEG Database. URL: <https://physionet.org/content/siena-scalp-eeeg/1.0.0/> (reference date: 28.11.2022).

26. Callan R. Osnovnye koncepcii nejronnyh setej [The Essence of Neural Networks]. Moscow, Vil'jams, 2009. 288 p.

27. Nikolaenko S.I., Arkhangelskaya E.O., Kadurin A.A. Glubokoe obuchenie. Pogruzhenie v mir nejronnyh setej [Deep learning. Immersion in the world of neural networks]. St. Petersburg, Piter, 2022. 480 p. (In Russ.).

28. Rao Delip, McMahan Brian. Natural Language Processing with PyTorch: Build Intelligent Language

Applications Using Deep Learning. Boston, O'Reilly Media, 2019. 256 p.

29. Pointer Ian. Programming PyTorch for Deep Learning: Creating and Deploying Deep Learning Applications. Boston, 2019. 220 p.

30. Timofeev V.S., Sivak M.A. Robastnaja nejronnaja set' s prostoj arhitekturoj [Simple robust neural network]. *Sibirskij zhurnal industrial'noj matematiki* [Siberian journal of industrial mathematics]. 2021. Vol. 24, No. 4. Pp. 126-138. (In Russ.).

The article was submitted 06.11.2022; approved after reviewing 28.11.2022;
accepted for publication 15.12.2022

For citation: Ivanov K. O. Classification of Electroencephalogram Segments Based on Pathological Significance Using Sequential Neural Networks. *Vestnik of Volga State University of Technology. Ser.: Radio Engineering and Infocommunication Systems*. 2022. No. 4 (56). Pp. 24–37. DOI: <https://doi.org/10.25686/2306-2819.2022.4.24>

Information about the author

Konstantin O. Ivanov – Candidate of Engineering Sciences, Associate Professor at the Department of Radio and Medical-Biological System Engineering at Volga State University of Technology. Research interests – artificial intelligence, deep learning, digital signal and image processing. The author of 40 scientific publications. ORCID: <https://orcid.org/0000-0002-6395-4085>.

Author declare that they have no conflict of interest.

Author read and approved the final manuscript.