

Володин, М. В. Оценка применения ConvLSTM-нейронной сети для прогнозирования эпилептических припадков / М. В. Володин, И. А. Седых // Прикладная математика и вопросы управления. – 2023. – № 3. – С. 55–66. DOI 10.15593/2499-9873/2023.3.04

Библиографическое описание согласно ГОСТ Р 7.0.100–2018

Володин, М. В. Оценка применения ConvLSTM-нейронной сети для прогнозирования эпилептических припадков / М. В. Володин, И. А. Седых. – Текст : непосредственный. – DOI 10.15593/2499-9873/2023.3.04 // Прикладная математика и вопросы управления / Applied Mathematics and Control Sciences. – 2023. – № 3. – С. 55–66.



ПРИКЛАДНАЯ МАТЕМАТИКА
И ВОПРОСЫ УПРАВЛЕНИЯ
№ 3, 2023

<https://ered.pstu.ru/index.php/amcs>



Научная статья

DOI: 10.15593/2499-9873/2023.3.04

УДК 004.032.26



Оценка применения ConvLSTM-нейронной сети для прогнозирования эпилептических припадков

М.В. Володин, И.А. Седых

Липецкий государственный технический университет, Липецк, Российская Федерация

О СТАТЬЕ

Получена: 07 июля 2023
Одобрена: 07 сентября 2023
Принята к публикации:
18 сентября 2023

Финансирование

Исследование не имело спонсорской поддержки.

Конфликт интересов

Авторы заявляют об отсутствии конфликта интересов.

Вклад автора

равноценен.

Ключевые слова:

нейронные сети, эпилепсия, свертка, LSTM, ConvLSTM, электроэнцефалограмма, классификация, эпилептические приступы, машинное обучение, рекуррентные нейронные сети.

АННОТАЦИЯ

Эпилепсия является одним из наиболее распространенных неврологических заболеваний. Эпилептические приступы крайне негативно влияют на жизнь людей, в том числе могут стать причиной смерти человека. В связи с этим разработка эффективных методов прогнозирования эпилептических припадков стала актуальной задачей в медицинской области. Одним из подходов к прогнозированию эпилептических припадков является использование нейронных сетей. В данной работе рассматривается ConvLSTM (Convolutional Long Short-Term Memory) – модель, объединяющая сверточные нейронные сети CNN и долгосрочную память рекуррентных LSTM-нейронных сетей. ConvLSTM позволяет моделировать пространственно-временные зависимости в данных, что особенно важно для анализа временных рядов, таких как электроэнцефалограмма. В данной работе исследуется применение ConvLSTM для прогнозирования эпилептических припадков на основе ЭЭГ-сигналов. Процесс подготовки модели можно разделить на три основных этапа: предварительную обработку входных сигналов, разделение и нормализация данных на обучающую, валидационную и тестовую выборки, а также обучение и тестирование модели на полученных выборках с целью выявления закономерностей и паттернов, характерных для эпилептических припадков. Для оценки качества прогнозирования используются универсальная для задач классификации ROC AUC-метрика. Полученные результаты анализируются и сравниваются с другими методами прогнозирования, чтобы определить эффективность ConvLSTM в данной задаче. Исследование показывает, что ConvLSTM демонстрирует высокую точность и надежность в прогнозировании эпилептических припадков на основе сигналов электроэнцефалограммы. Этот подход может быть полезным инструментом для врачей и специалистов в области эпилепсии, позволяя предупреждать припадки и принимать соответствующие меры заблаговременно.

© ПНИПУ

© Володин Максим Владимирович – студент бакалавриата, кафедра высшей математики, e-mail: faxtro@icloud.com, ORCID: 0009-0009-6542-2195.

Седых Ирина Александровна – доктор технических наук, доцент, профессор, кафедра высшей математики, e-mail: sedykh-irina@yandex.ru, ORCID: 0000-0003-0012-8103.



Эта статья доступна в соответствии с условиями лицензии Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

Perm Polytech Style: Volodin M.V., Sedykh I.A. Evaluation applying ConvLSTM neural network for the prediction of epileptic seizures. *Applied Mathematics and Control Sciences*. 2023, no. 3, pp. 55–66. DOI: 10.15593/2499-9873/2023.3.04

MDPI and ACS Style: Volodin, M.V.; Sedykh, I.A. Evaluation applying ConvLSTM neural network for the prediction of epileptic seizures. *Appl. Math. Control Sci.* **2023**, *3*, 55–66. <https://doi.org/10.15593/2499-9873/2023.3.04>

Chicago/Turabian Style: Volodin, Maksim V., and Irina A. Sedykh 2023. "Evaluation applying ConvLSTM neural network for the prediction of epileptic seizures". *Appl. Math. Control Sci.* no. 3: 55–66. <https://doi.org/10.15593/2499-9873/2023.3.04>



APPLIED MATHEMATICS
AND CONTROL SCIENCES
№ 3, 2023
<https://ered.pstu.ru/index.php/amcs>



Article

DOI: 10.15593/2499-9873/2023.3.04

UDC 004.032.26



Evaluation applying ConvLSTM neural network for the prediction of epileptic seizures

M.V. Volodin, I.A. Sedykh

Lipetsk State Technical University, Lipetsk, Russian Federation

ARTICLE INFO

Received: 07 July 2023

Approved: 07 September 2023

Accepted for publication:

18 September 2023

Funding

This research received no external funding.

Conflicts of Interest

The authors declare no conflict of interest

Author Contributions

equalent.

Keywords:

neural networks, epilepsy, convolution, LSTM, ConvLSTM, electroencephalogram, classification, epileptic seizures, machine learning, recurrent neural networks.

ABSTRACT

Epilepsy is one of the most common neurological diseases. Epileptic seizures have an extremely negative impact on people's lives, including the possibility of causing human death. In this connection, the development of effective methods of predicting epileptic seizures has become an urgent task in the medical field. One approach to the prediction of epileptic seizures is the use of neural. This paper considers ConvLSTM (Convolutional Long Short-Term Memory), a model combining convolutional neural networks CNN and long-term memory of LSTM recurrent networks. ConvLSTM allows modeling spatio-temporal dependencies in data, which is especially important for the analysis of time series, such as electroencephalogram. This paper explores the use of ConvLSTM to predict epileptic seizures based on EEG signals. The process of model preparation can be divided into three main stages: pre-processing of the input signals, data separation and normalization into training, validation, and test samples, and training and testing the model on the obtained samples in order to identify patterns and patterns characteristic of epileptic seizures. The universal ROC AUC metric for classification tasks is used to assess the quality of prediction. The results are analyzed and compared with other prediction methods to determine the effectiveness of ConvLSTM in this task. The study shows that ConvLSTM demonstrates high accuracy and reliability in predicting epileptic seizures based on electroencephalogram signals. This approach can be a useful tool for clinicians and epilepsy specialists to prevent seizures and take appropriate measures in advance

© PNRPU

© **Maksim V. Volodin** – Bachelor Student, Higher Mathematics Department, e-mail: faxtro@icloud, ORCID: 0009-0009-6542-2195.
Irina A. Sedykh – Doctor of Technical Sciences, Associate Professor, Professor of the Higher Mathematics Department, e-mail: sedykh-irina@yandex.ru, ORCID: 0000-0003-0012-8103.



This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0)

Введение

Эпилепсия – одно из наиболее распространенных неврологических заболеваний во всем мире. Основным симптомом являются эпилептические приступы, представляющие серьезную опасность из-за их внезапности и возможности причинить травмы, которые могут быть фатальными [1–3]. Поэтому важной задачей современной медицины является предотвращение этих приступов. На основе анализа научных публикаций можно выделить следующие направления исследований в данной области:

- применение методов машинного обучения, таких как метод опорных векторов и метод случайного леса [4–6]. В данных исследованиях удалось достичь среднего значения чувствительности (также значение AUC) 70 %;
- применение сверточных нейронных сетей [7]. В данном исследовании среднее значение чувствительности составило 75 %;
- комбинация байесовских моделей, в том числе байесовская сверточная нейронная сеть [8]. Среднее значение чувствительности в данном исследовании составило 71 %.

Среднее значение чувствительности классификаторов (также значение AUC) в приведенных выше исследованиях не превышает 75 %. Наибольшей чувствительности удалось достигнуть в исследовании применения сверточных нейронных сетей для прогнозирования эпилептических припадков [7].

Не менее важным аспектом являются методы предварительной обработки данных, которые сходятся к следующему подходу: данные обрабатываются с помощью оконного преобразования Фурье, далее логарифмируются для повышения низкочастотной компоненты сигнала и нормализуются [9].

Целью данной работы является разработка архитектуры нейронной сети на основе ConvLSTM [10] для классификации входных сигналов на предприступные и межприступные участки ЭЭГ, а также сравнение полученных результатов с результатами исследований, основанных на иных подходах.

1. Сверточная Long Short-Term Memory-нейронная сеть

ConvLSTM сочетает в себе преимущества LSTM [11; 12] и сверточных нейронных сетей. Главной особенностью является использование операции свертки как во входных, так и в рекуррентных преобразованиях.

Математическая модель ConvLSTM:

$$c'_t = \tanh(W_{xc} \cdot x_t + W_{hc} \cdot h_{t-1} + b_{c'}), \quad (1)$$

$$i_t = \sigma(W_{xi} \cdot x_t + W_{hi} \cdot h_{t-1} + b_i), \quad (2)$$

$$u_t = \sigma(W_{xu} \cdot x_t + W_{hu} \cdot h_{t-1} + b_u), \quad (3)$$

$$o_t = \sigma(W_{xo} \cdot x_t + W_{ho} \cdot h_{t-1} + b_o), \quad (4)$$

$$c_t = u_t \odot c_{t-1} + i_t \odot c'_t, \quad (5)$$

$$h_t = o_t \odot \tanh(c_t). \quad (6)$$

В данной модели в качестве функций активации используются:

- гиперболический тангенс (\tanh) в формуле (1);
- сигмоидальная функция (σ) в формулах (2)–(4).

Коэффициенты b с различными индексами используются для обозначения свободных членов (смещений). Операция свертки обозначена символом $*$, а произведение Адамара, в формулах (5) и (6), обозначено символом \odot .

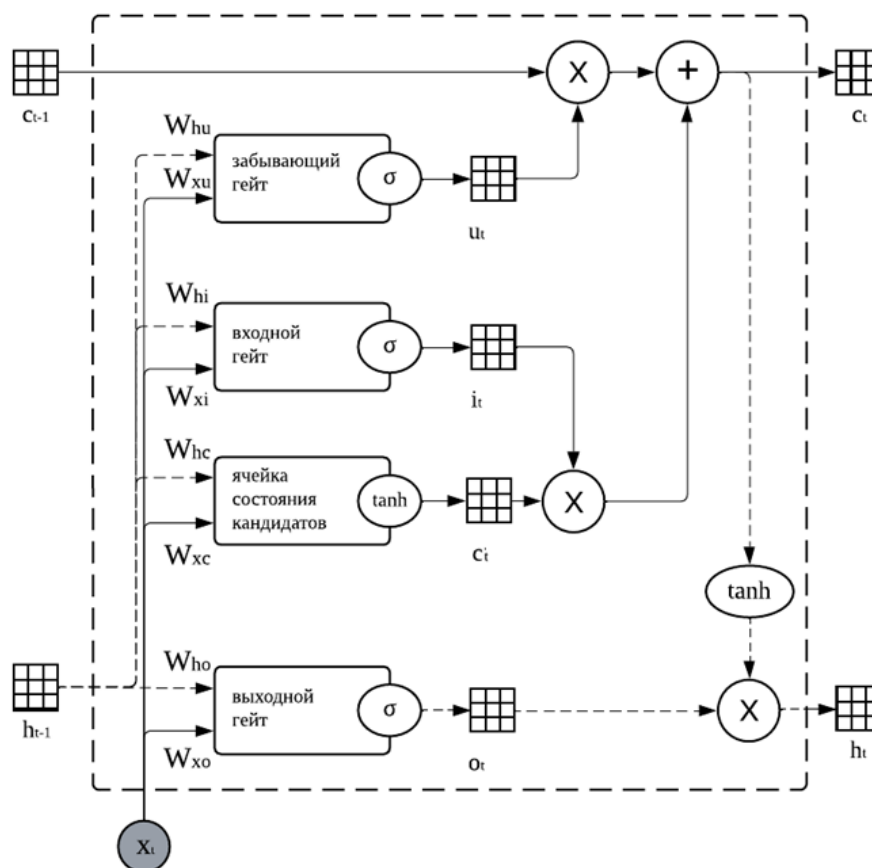


Рис. 1. Схема блока сверточной LSTM-нейронной сети

Принцип работы ConvLSTM (рис. 1) заключается в подаче на вход двух векторов: нового вектора входных сигналов x_t и вектора скрытого состояния предыдущей ячейки на предыдущем шаге h_{t-1} . Оба вектора перед прохождением каждого из гейтов умножаются на соответствующие веса W_x и W_h . Кроме того, внутри каждого блока ConvLSTM есть ячейка состояния кандидатов значений (ячейка памяти), которая выполняет функции запоминания значений. Также на вход подается вектор значений кандидатов c_{t-1} на предыдущем шаге.

В гейтах (рис. 2) по формулам (1)–(4) вычисляются значения соответствующих им скрытых состояний:

- вектор состояния выходного гейта o_t ;
- вектор ячейки состояния кандидатов c'_t ;
- вектор выходного гейта i_t ;
- вектор забывающего гейта u_t .

С помощью полученных скрытых состояний забывающего гейта u_t и входного i_t по формуле (6) отсеиваются предыдущие значения кандидатов c_{t-1} и вычисляются новые значения кандидатов c_t . С помощью функции активации (гиперболического тангенса) и коэффициента o_t вычисляется скрытое состояние h_t по формуле (6).

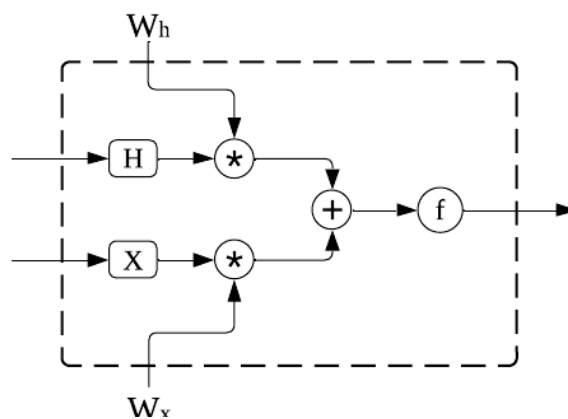


Рис. 2. Структура гейта ConvLSTM

Таким образом, данные, проходящие через ячейки ConvLSTM, являются не просто одномерным вектором признаков, а сохраняют размерность входа, что можно использовать для проектирования сложной архитектуры сети.

2. Анализ исходных данных

Для реализации программы прогнозирования эпилептических припадков была использована выборка [13] которая содержит данные сигналов ЭЭГ для трех собак и двух людей.

Данные разделены на предприступные, межприступные и тестовые. В табл. 1 представлены данные о количестве таких сегментов для каждого из пациентов.

Таблица 1

Количественные характеристики выборки для каждого пациента

Пациент	Предприступные сегменты	Межприступные сегменты	Тестовые сегменты
Dog_1	24	480	502
Dog_2	42	500	1000
Dog_3	30	450	191
Patient_1	50	18	195
Patient_2	42	18	150

При анализе исходных данных было установлено количество приступов для каждого пациента, а также общее количество приступных сегментов. Исходя из этого, была сформирована табл. 2, содержащая данные о количестве приступных и бесприступных сегментов, а также количество приступов для каждого пациента.

Таблица 2

Анализ исходных данных

Пациент	Кол-во электродов	Кол-во приступных эпизодов	Кол-во бесприступных эпизодов	Кол-во приступов
Dog_1	16	178	418	4
Dog_2	16	172	1148	7
Dog_3	16	480	4760	12
Patient_1	68	70	104	3
Patient_2	16	151	2990	3

По данным, представленным в табл. 2, вычисляется значение отношения приступных к бесприступным по формуле

$$ratio = \frac{ictal}{interictal},$$

где $ratio$ – отношение приступных к без приступным, $ictal$ – количество приступных сегментов, $interictal$ – количество бесприступных сегментов.

Также вычисляется значение перекрытия:

$$overlap = \frac{seizures}{ictal},$$

где $overlap$ – значения перекрытия событий приступов приступными сегментами, $seizures$ – количество приступов.

Полученные значения занесены в табл. 3.

Таблица 3

Значения $ratio$ и $overlap$

Пациент	$Ratio$	$Overlap$
Dog_1	0,425837321	0,025
Dog_2	0,149825784	0,045
Dog_3	0,100840336	0,025
Patient_1	0,673076923	0,07
Patient_2	0,050501672	0,08

3. Обработка исходных данных

Загружаются ЭЭГ-файлы, а каждый файл разбивается на сэмплы (отрезки сигнала). Для оптимизации был произведен ресэмплинг с понижением частоты дискретизации: 200 Гц для собак, 1000 Гц для людей.

Так как в данном исследовании используется размер кадра 15 секунд, то необходимо найти длину такого кадра в семплах, так как для собак и людей используются различные значения окна дискретизации.

ConvLSTM способно выделять признаки из пространственной информации, следовательно, данные необходимо преобразовать в вид, подходящий для сверточного слоя с двумя измерениями. Таким образом, данные следует представить в виде матриц, имеющих схожую структуру с обычным изображением.

Для извлечения частотных признаков использовано оконное преобразование Фурье (также ОПФ) с размером кадра 15 секунд [14–16]. Полученная таким образом спектрограмма является двумерной матрицей, измерениями которой являются время и частота сигнала. Полученные данные обрабатываются функцией $\log_{10}(x)$ для выделения амплитудных характеристик. Далее значения приводятся к виду, удобному для подачи на вход сверточного слоя с двумя измерениями. Затем данные будут представлены в виде особого математического объекта – тензора.

Полученные данные можно представить в графическом виде – в виде спектрограмм (рис. 3).

Для увеличения количества обучающих данных, относящихся к классу предприступных сигналов, были получены дополнительные сегменты (рис. 4).

Полученные дополнительные сегменты группируются с ранее полученными последовательно, согласно времени их записи.

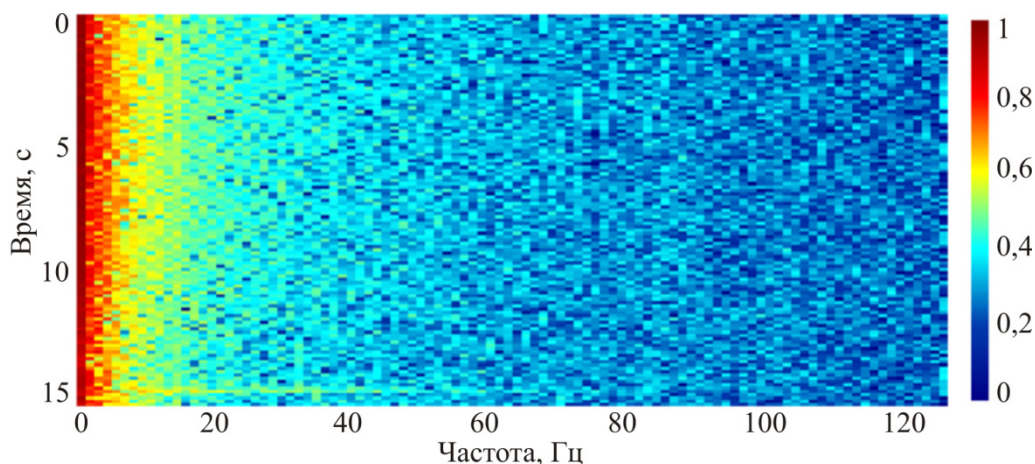


Рис. 3. Пример полученной спектрограммы

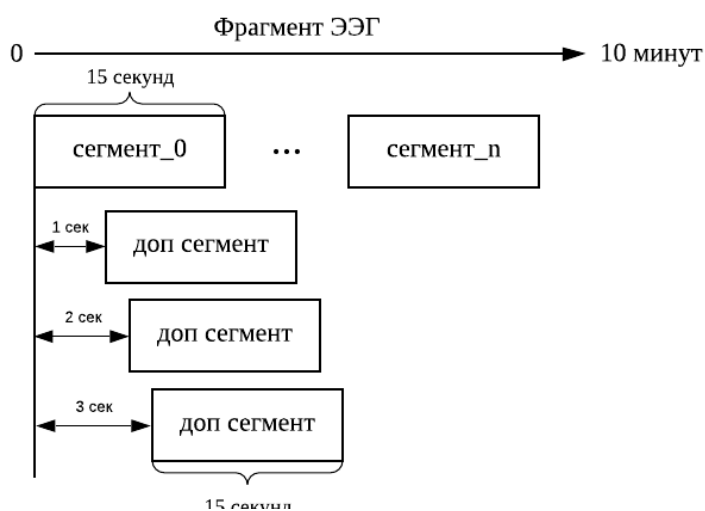


Рис. 4. Отбор дополнительных сегментов

Далее полученные данные нормализуются и делятся на обучающую, валидационную и тестовую выборки, согласно значению *ratio*, представленному в табл. 3. Каждая из выборок отличается по временному периоду, что исключает ошибку переобучения в процессах валидации и тестирования модели.

4. Архитектура нейронной сети

Рассмотрим архитектуру нейронной сети (рис. 5).

Входной слой модели принимает данные в виде пятимерных тензоров, полученных в ходе предварительной обработки. Для ускорения обучения и классификации, а также в качестве нормализации используется слой пакетной нормализации. Далее используется двумерный слой ConvLSTM с параметрами: 32 фильтра, размер ядра 4×4 и функцией активации ReLU.

Для увеличения количества обучающих параметров далее параллельно вычисляются три слоя, состоящие из двумерного ConvLSTM и трехмерного MaxPooling-слоя.

Параллельные слои конкатенируются, и к ним применяется *dropout* с шансом отбрасывания 35%. Следующий слой – слой выравнивания (*flatten*).

Далее следуют полносвязные слои для классификации данных, для предотвращения переобучения количество нейронов для каждого слоя было ограничено 32 и 16 нейронами соответственно, в качестве функции активации для каждого слоя была выбрана ReLU.

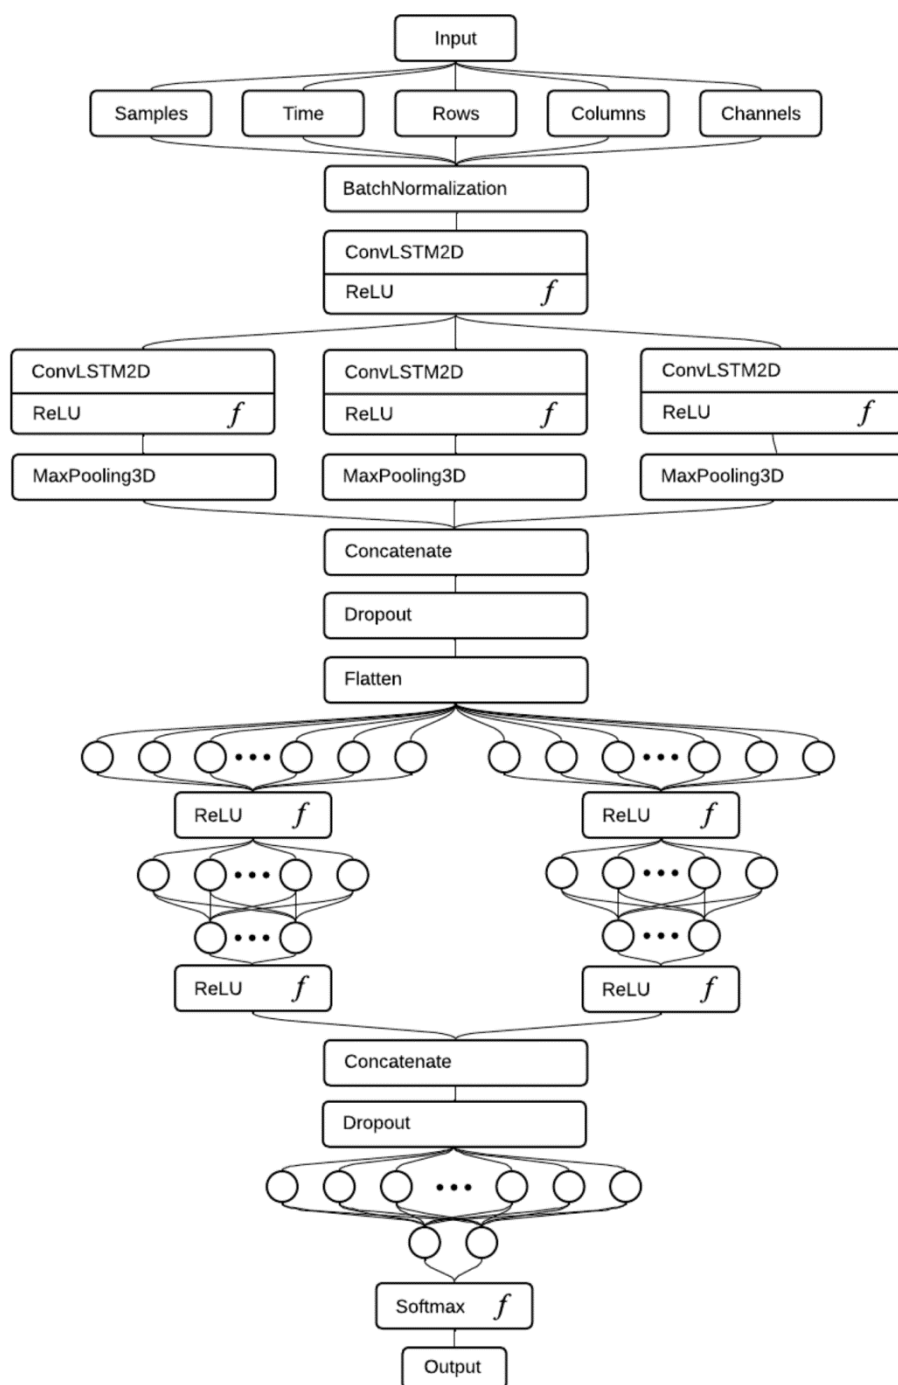


Рис. 5. Архитектура нейронной сети

Параллельные полносвязные слои конкатенируются, и к ним применяется *dropout* с шансом отбрасывания 35 %. Финальным слоем является полносвязный слой с двумя нейронами для классификации с функцией активации для этого слоя *softmax*. Таким образом, выходом модели будет вероятность принадлежности данных к каждому из двух классов – предприсутному и межприсутному.

В качестве оптимизатора модели был выбран оптимизатор AMSgrad [17]. Он является логическим продолжением идей Adam по комбинации стохастического градиентного спуска и адаптивного градиента. Но, в отличие от него, не позволяет градиенту расти слишком быстро, использует более консервативную оценку второго момента градиента, что позволяет ему более стабильно работать в таких ситуациях.

В качестве метрики для анализа точности прогнозов выбрана ROC AUC (Receiver Operating Characteristic Area Under the Curve), широко используемая в задачах бинарной и многоклассовой классификации. Метрика AUC представляет собой численное значение ROC-кривой, являясь площадью под этой кривой.

5. Обучение и валидация

Обучение модели проходило в течение 10 эпох отдельно для каждого пациента. Лучшие результаты для каждого из пациентов представлены в табл. 4.

Таблица 4

Данные обучения и валидации

Метрика	Пациент				
	Dog_1	Dog_2	Dog_3	Patient_1	Patient_2
loss	0,06	0,05	0,01	0,15	0,01
accuracy	0,97	0,98	0,99	0,94	0,99
val_loss	2,83	0,34	0,17	0,18	1,6
val_accuracy	0,52	0,89	0,95	0,92	0,72

По данным валидации, а именно по валидационной точности, можно сделать вывод о том, что представленная выше модель работает в качестве случайного предиктора для Dog_1. Что свидетельствует о возможно недостаточном количестве данных обучения или об иных проблемах в данных данного пациента, которые оказывают воздействие на сигнал электроэнцефалограммы.

6. Тестирование модели

Тестирование модели проводилось с помощью метрик ROC AUC, данные по каждому пациенту по метрике AUC представлены в табл. 5.

Таблица 5

Значения AUC для каждого пациента

Метрика	Пациент				
	Dog_1	Dog_2	Dog_3	Patient_1	Patient_2
AUC	0,5012	0,9844	0,4985	0,9606	0,8045

По метрикам AUC, представленным в табл. 5, можно сделать вывод, что для обоих пациентов и одной из трех собак классификатор намного лучше предсказывает эпилептические приступы, чем случайный предиктор.

Однако в процессе валидации модель показала хорошие результаты для пациента Dog_3. Также форма ROC-кривой (рис. 6) показывает, что для пациента Dog_3 при достаточном количестве данных обучения классификатор мог бы показать лучшую точность.

Заключение

Так как среднее значение чувствительности для данной модели приблизительно равно 75 %, данная нейросетевая модель показала себе более эффективной, чем модели, представленные в исследованиях [4–6; 8].

Результаты, полученные в ходе исследования, коррелируют с результатами исследования [7]. Из этого можно сделать вывод об эффективности использования сверточных слоев при работе со схожими по структуре данными. Так как результаты вышеупомянуто-

го [7] и проведенного в ходе данной работы исследований имеют схожие результаты, можно сделать вывод, что нейронная сеть, основанная на LSTM-блоках со сверткой, не дает весомого преимущества над классической сверточной архитектурой при прогнозировании эпилептических припадков. Однако это означает, что она также может использоваться в качестве классификатора мозговой активности на основе ЭЭГ. Таким образом, задачей дальнейших исследований может являться улучшение блоков ConvLSTM, например, интеграция механик обучения с вниманием [18].

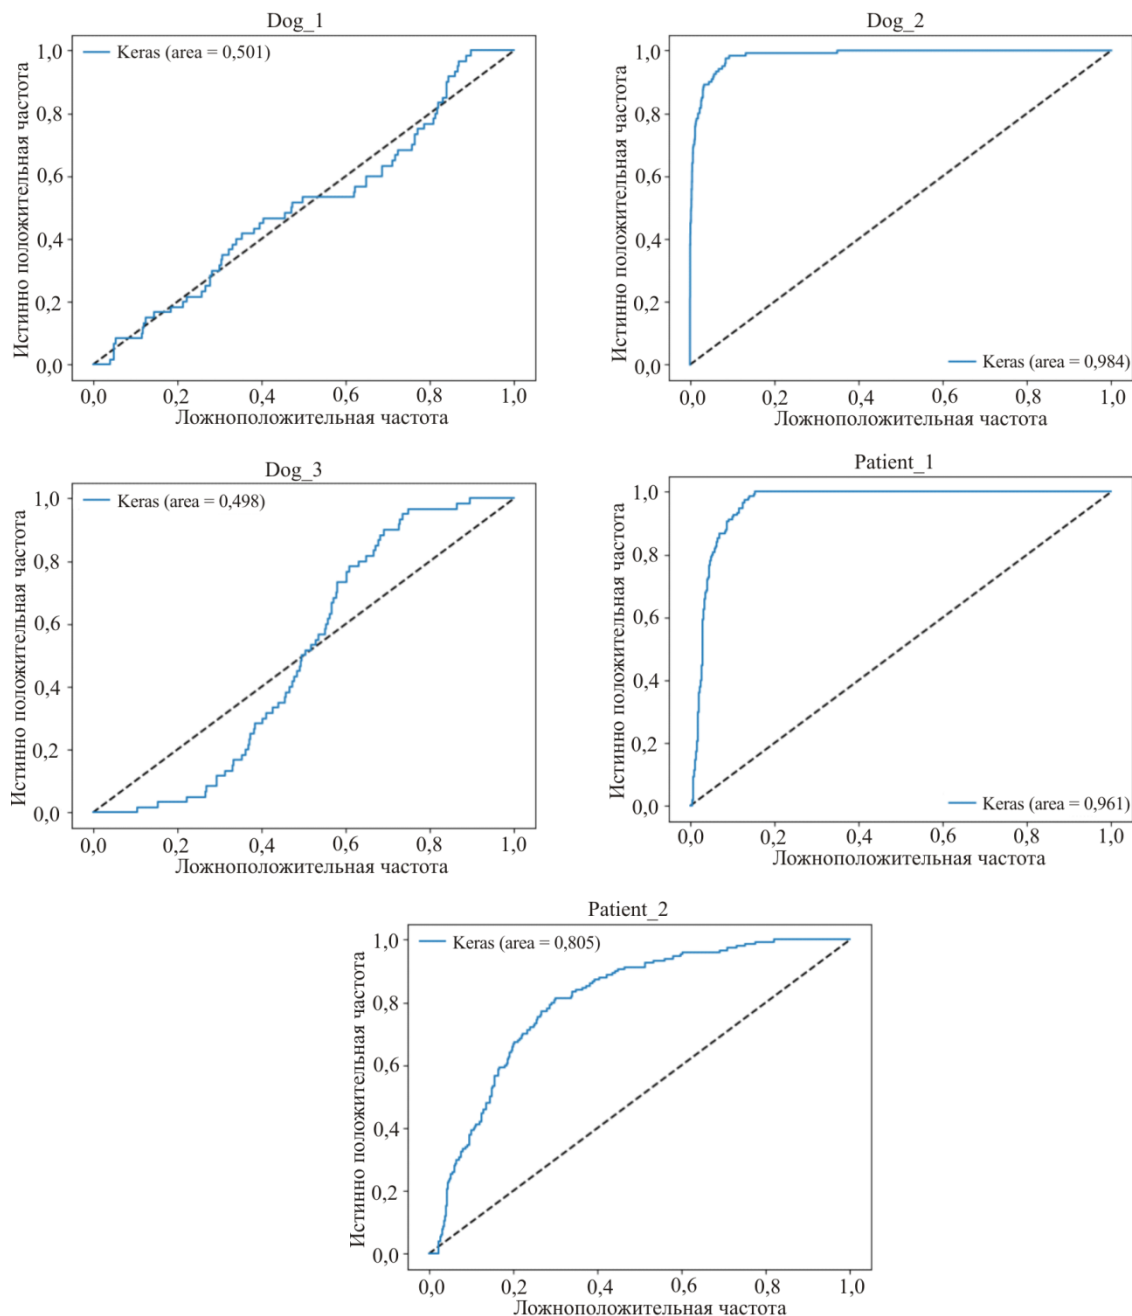


Рис. 6. Кривые ROC

Имеющаяся точность предсказания, хоть и не является высокой, может быть полезной для пациентов. Люди, больные эпилепсией, могли бы получать своевременные уведомления о возможном возникновении припадка, чтобы они могли принять соответствующие меры для обеспечения собственной безопасности.

Список литературы

1. Epilepsy across the spectrum: Promoting healthand understanding. A summary of the institute of medicine report / M.J. England, C.T. Liverman, A.M. Schultz, L.M. Strawbridge // *Epilepsy & Behavior*. – 2012. – Vol. 25, iss. 2. – P. 266–276.
2. Weyhenmeyer J., Gallman E.A. *Rapid Review Neuroscience E-Book*. – Philadelphia: Elsevier Health Sciences, 2006. – 320 p.
3. Lieberman M.D. Intuition: a social cognitive neuroscience approach // *Psychological bulletin*. – 2000. – Vol. 126, iss. 1. – P. 109–112.
4. Ben Messaoud R., Chavez M. Random Forest Classifier for EEG-based Seizure Prediction // *arXiv*. 2021. DOI 10.48550/arXiv.2106.04510
5. Usman S.M., Usman M., Fong S. Epileptic Seizures prediction using machine learning methods // *Computational and Mathematical Methods in Medicine*. – 2017. – Vol. 2017. – Art. 9074759. DOI 10.1155/2017/9074759.
6. Ouichka O., Ecthioui A., Hamam H. Deep Learning Models for Predicting Epileptic Seizures Using iEEG Signals // *Electronics*. – 2022. – Vol. 11, № 4. – Art. 605. DOI 10.3390/electronics11040605
7. A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis / N. D. Truong, A. D. Nguyen, L. Kuhlmann, M. R. Bonyadi, J. Yang, O. Kavehei // *arXiv*. 2017. DOI 10.48550/arXiv.1707.01976.
8. Seizure Susceptibility Prediction in Uncontrolled Epilepsy / N.D. Truong, Y. Yang, C. Maher, L. Kuhlmann, A. McEwan, A. Nikpour, O. Kavehei // *Frontiers in Neurology*. – 2021. – Vol. 12. – Art. 721491. DOI 10.3389/fneur.2021.721491.
9. Sejnowski T.J., Koch C., Churchland P.S. Computational neuroscience // *Science*. 1988. – Vol. 241, iss. 4871. – P. 1299–1306. DOI 10.1126/science.3045969.
10. Convolutional LSTM network: A machine learning approach for precipitation nowcasting / X. Shi, Z. Chen, H. Wang, D. Y. Yeung, W.K. Wong, W.C. Woo // *Advances in Neural Information Processing Systems* 28, 7–12 December 2015, Montreal, Quebec, Canada, 2015. – P. 802–810.
11. LSTM: A search space odyssey / K. Greff, R.K. Srivastava, J. Koutník, B.R. Steunebrink, J. Schmidhuber // *IEEE transactions on neural networks and learning systems*. – 2017. – Vol. 10. – P. 2222–2232. DOI 10.1109/TNNLS.2016.2582924
12. Hochreiter S., Schmidhuber J. Long short-term memory // *Neural computation*. – 1997. – Vol. 9, iss. 8. – P. 1735–1780. DOI 10.1162/neco.1997.9.8.1735.
13. American Epilepsy Society Seizure Prediction Challenge / Kaggle [Электронный ресурс]. – URL: <https://www.kaggle.com/competitions/seizure-prediction> (дата обращения: 01.06.2023).
14. Seizure prediction in EEG signals using STFT and domain adaptation / P. Peng, Y. Song, L. Yang, H. Wei // *Frontiers in Neuroscience*. – 2022. – Vol. 15. – Art. 825434. DOI 10.3389/fnins.2021.825434
15. Epileptic Seizure Forecasting with Generative Adversarial Networks / N.D. Truong, L. Kuhlmann, M.R. Bonyadi, D. Querlioz, L. Zhou, O. Kavehei // *IEEE Access*. – 2019. – Vol. 7. – P. 143999–144009. DOI 10.1109/ACCESS.2019.294469
16. Classification of EEG Signals for Prediction of Epileptic Seizures / M. Aslam, S.M. Usman, S. Khalid, A. Anwar, R. Alroobaea, S. Hussain, A. Yasin // *Applied Sciences*. – 2022. – Vol. 12, iss. 14. – P. 7251. DOI 10.3390/app12147251
17. Reddi S., Satyen K., Sanjiv K. On the convergence of Adam and Beyond // *arXiv*. – 2019. DOI 10.48550/arXiv.1904.0923
18. Liu B., Lane I. Attention-Based Recurrent Neural Network Models for Joint Intent Detection and Slot Filling // *arXiv*. – 2016. DOI 10.48550/arXiv.1609.01454

References

1. England M.J., Liverman C.T., Schultz A.M., Strawbridge L.M. Epilepsy across the spectrum: Promoting health and understanding. A summary of the institute of medicine report. *Epilepsy & Behavior*, 2012, vol. 25, iss. 2, pp. 266–276.
2. Weyhenmeyer J., Gallman E. A. Rapid Review Neuroscience E-Book. Philadelphia, United States of America: Elsevier Health Sciences, 2006, 320 p.
3. Lieberman M. D. Intuition: a social cognitive neuroscience approach. *Psychological bulletin*, 2000, vol. 126, iss. 1, pp. 109–112.
4. Messaoud R. B., Chavez M. Random Forest classifier for EEG-based seizure prediction. *arXiv e-prints*, 2021. DOI 10.48550/arXiv.2106.04510
5. Usman S.M., Usman M., Fong S. Epileptic seizures prediction using machine learning methods. *Computational and mathematical methods in medicine*, 2017, vol. 2017, art. 9074759. DOI 10.1155/2017/9074759
6. Ouichka O., Echioui A., Hamam H. Deep Learning Models for Predicting Epileptic Seizures Using iEEG Signals. *Electronics*, 2022, vol. 11, no. 4, art 605. DOI 10.3390/electronics11040605
7. Truong N.D., Nguyen A.D., Kuhlmann L., Bonyadi M.R., Yang J., Kavehei O. A Generalised Seizure Prediction with Convolutional Neural Networks for Intracranial and Scalp Electroencephalogram Data Analysis. *arXiv*, 2017. DOI 10.48550/arXiv.1707.01976
8. Truong N.D., Yang Y., Maher C., Kuhlmann L., McEwan A., Nikpour A., Kavehei O. Seizure Susceptibility Prediction in Uncontrolled Epilepsy. *Frontiers in Neurology*, 2021, vol. 12, art. 721491. DOI 10.3389/fneur.2021.721491
9. Sejnowski T.J., Koch C., Churchland P.S. Computational neuroscience. *Science*, 1988, vol. 241, iss. 4871, pp. 1299–1306. DOI 10.1126/science.3045969
10. Shi X., Chen Z., Wang H., Yeung D. Y., Wong W. K., Woo W. C. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems 28 (NIPS 2015)*, 7–12 December 2015, Montreal, Quebec, Canada, 2015, pp. 802–810.
11. Greff K., Srivastava R.K., Koutník J., Steunebrink B.R., Schmidhuber J. LSTM: A search space odyssey. *IEEE transactions on neural networks and learning systems*, 2017, vol. 10, pp. 2222–2232. DOI 10.1109/TNNLS.2016.2582924
12. Hochreiter S., Schmidhuber J. Long short-term memory. *Neural computation*, 1997, vol. 9, iss. 8, pp. 1735–1780. DOI 10.1162/neco.1997.9.8.1735
13. American Epilepsy Society Seizure Prediction Challenge [Predict seizures in intracranial EEG recordings]. available at: <https://www.kaggle.com/competitions/seizure-prediction> (Accessed 01 July 2023).
14. Peng P., Song Y., Yang L., Wei H. Seizure prediction in EEG signals using STFT and domain adaptation. *Frontiers in Neuroscience*, 2022, vol. 15, art. 825434. DOI 10.3389/fnins.2021.825434
15. Truong N.D., Kuhlmann L., Bonyadi M.R., Querlioz D., Zhou L., Kavehei O. Epileptic Seizure Forecasting with Generative Adversarial Networks. *IEEE Access*, 2019, vol. 7, pp. 143999–144009. DOI 10.1109/ACCESS.2019.294469
16. Aslam M., Usman S. M., Khalid S., Anwar A., Alroobaea R., Hussain S., Yasin A. Classification of EEG Signals for Prediction of Epileptic Seizures. *Applied Sciences*, 2022, vol. 12, iss. 14, art. 7251. DOI 10.3390/app12147251
17. Reddi S., Satyen K., Sanjiv K. On the convergence of Adam and Beyond. *arXiv*, 2019. DOI 10.48550/arXiv.1904.0923
18. Liu B., Lane I. Attention-Based Recurrent Neural Network Models for Joint Intent Detection and Slot Filling. *arXiv*, 2016. DOI 10.48550/arXiv.1609.01454