

Ж.С. Афанасьева, П.А. Григоров

Иркутский национальный исследовательский технический университет (ИРНИТУ), г. Иркутск, Российская Федерация

КЛАССИФИКАЦИЯ ЖЕСТОВ РУКИ В СИГНАЛАХ ЭЛЕКТРОМИОГРАФИИ МЕТОДАМИ МАШИННОГО ОБУЧЕНИЯ

Аннотация. *Одной из ключевых проблем бионического протезирования, из-за которых они не отвечают желаемым критериям технологичности, является интерпретация и обработка данных поверхностной электромиографии. В данной статье представлено применение модели рекуррентной нейронной сети для классификации паттернов электромиографии 4-х жестов руки человека. Для обучения использовался существующий набор данных, записанный с помощью восьмиканального мио-браслета «Thalmic Labs Myo». Данный способ классификации имел точность на тестовых данных 98.3%. Результаты проведенного исследования могут послужить основой для разработки нейросетевой модели для управления бионическим протезом руки человека.*

Ключевые слова: *электромиография, бионическое протезирование, распознавание жестов, искусственный интеллект, рекуррентные нейронные сети, классификация.*

Z.S. Afanasyeva, P.A. Grigоров

Irkutsk National Research Technical University (INRTU), Irkutsk, the Russian Federation

CLASSIFICATION OF HAND GESTURES IN ELECTROMYOGRAPHY SIGNALS BY MACHINE LEARNING METHODS

Abstract. *One of the key problems of bionic prosthetics, because of which they do not meet the desired criteria of manufacturability, is the interpretation and processing of surface electromyography data. This article presents the application of a recurrent neural network model for the classification of electromyography patterns of 4 human hand gestures. For training, an existing data set recorded using an eight-channel myo-bracelet «Thalmic Labs Myo» was used. This classification method had 98.3% accuracy on test data. The results of the study can serve as a basis for the development of a neural network model for controlling a bionic prosthetic human hand.*

Keywords: *electromyography, bionic prosthetics, gesture recognition, artificial intelligence, recurrent neural networks, classification.*

Введение

На передовую научно-технического прогресса современной медицины выходит бионическое протезирование. Такие протезы помогают людям легче справляться с травмами, а также на порядок лучше манипулировать предметами и передвигаться в сравнении с традиционными протезами, за счёт своего способа управления – считывания с тела человека сигналов, чаще всего мышечной активности, специальными электромиографическими (ЭМГ) датчиками.

Однако существует ряд ограничений, из-за которых бионические протезы не отвечают желаемым критериям технологичности [1]:

- Отсутствие приспособляемости системы управления под изменение мышечной активности пользователя в течении дня;
- Сложность распознавания и фильтрации данных получаемых с датчиков управления на мышцах культи.
- Жёсткая система управления, позволяющая контролировать протез только заранее выбранными мышцами.

Одним из решений для вышеперечисленных проблем является применение методов машинного обучения для обработки данных, получаемых с электромиограммы. Это подтверждается исследованиями, которые проводятся по всему миру в данном направлении.

Например, благодаря обработке данных ЭМГ с помощью полносвязных нейронных сетей создаются программы управления манипуляторами [2].

В большом зарубежном исследовании [3] для выявления закономерностей в развитии заболеваний мышц человека, учёные предложили новый подход. Суть метода заключается в обработке сигналов электромиографии с помощью стандартного алгоритма графа видимости. На следующем шаге свойства полученных сетей-графов формировались в виде матрицы признаков и обрабатывались различными видами глубоких нейронных сетей. В результате модель смогла поставить диагноз тестовым пациентам с точностью 99,18%.

В другой работе [4] исследователи переосмыслиют сам способ управления протезом, и с помощью свёрточной модели нейронной сети обрабатывают изображение с камеры на кисти протеза, чтобы заранее подготовить жест для хватания предмета с точностью 93,7%.

Методы машинного обучения позволят не только упростить алгоритм обработки поступающих данных, но и расширить возможности в управлении протезом руки [5]. Кроме того, решение данной задачи имеет множество практических приложений. К примеру, это позволит улучшить программное обеспечение стационарных аппаратов для электромиографии, а также откроет возможности для дистанционного проведения подобных процедур.

Для полноценного управления искусственной конечностью нужно одновременно обрабатывать сигналы, поступающие от множества мышц на здоровой части руки, что является трудной задачей для классических методов машинного обучения. Для решения этих проблем нами было проведено предварительное исследование для улучшения существующих нейросетевых моделей для классификации жестов руки. Для обучения использовались существующие наборы данных.

Описание датасетов

Для формирования обучающей выборки на Kaggle был взят датасет emg-4, состоящий из записанных с помощью мио-браслета «Thalmic Labs Myo» четырёх классов движений кисти человека [6].

Для понимания сбора данных, рассмотрим принцип записи данных при помощи мио-браслета, который имеет 8 датчиков, прилегающих к поверхности кожи. Каждый из датчиков измеряет электрическую активность находящейся под ним мышцы. На рисунке 1 показан паттерн электромиографии во время сжимания кисти в кулак в течение 1-ой секунды, который позволяет увидеть задействованные мышцы. Высокая амплитуда сигнала указывает на напряжение мышцы, низкая - на расслабленность, во время выполнения жеста.

Датасет заранее размечен в соответствии четырём выполняемым жестам и включает почти одинаковое количество строк для каждого класса.

Значение меток и количество экземпляров следующее:

- 0 – жест «камень» - кисть сжата в кулак, 2910 строк;
- 1 – жест «ножницы» - разгибание указательного и среднего пальцев, сгибание остальных, 2903 строки;
- 2 – жест «бумага» - отведение всех пальцев, 2943 строки;
- 3 – жест «Ок», 2922 строки.

Каждый жест записывался 6 раз в течение 20 секунд. Запись начиналась в момент, когда жест был уже подготовлен и удерживался, и заканчивалась также пока жест был активен. В общей сложности каждый жест удерживается в фиксированном положении в течение 120 секунд. Жесты выполнялись правой рукой одного человека.

Используемый датасет представляет из себя набор csv файлов, каждый из которых содержит 65 столбцов, где столбцы от 1 до 64 содержат 8 последовательных показаний 8 ЭМГ датчиков, а последний содержит метки выполненного жеста.

Данные фиксировались с частотой 200 Гц, что означает, что каждая строка записана с интервалом в $8 \cdot (1/200)$ секунд = 40 мс.




Рис. 1. Сигналы с 8-ми каналов ЭМГ-браслета

Описанный выше датасет содержит данные с ЭМГ-датчиков, не прошедших какую-либо программную обработку. Разрабатываемая модель должна быть готова к обработке как данных, содержащих внешние шумы, так и отфильтрованных данных, поэтому сигнал, записанный в датасете, был скопирован и обработан программными фильтрами в программе MATLAB, после чего добавлен к исходному. Также это позволило увеличить объём обучающей выборки.

Подготовка данных для обучения модели

В используемой модели нейронной сети были использованы рекуррентные слои. Поэтому обучающие данные нужно представить в удобном формате для обучения модели.

Исходные файлы содержат в одной строке 8 измерений показаний с 8 датчиков и метку жеста. В начале от экземпляров был отделён последний столбец с метками, далее датасет был разделён на обучающую и тестовую выборки в соотношении 8:2. И затем уже каждую строку из 64-х измерений преобразовали к виду матрицы $n \times m$, где $n = 8$ – количество итераций фиксации данных для одной метки, $m = 8$ – количество опрашиваемых датчиков за одну итерацию. В результате каждой метке жеста, отделённой на первом шаге, соответствует одна матрица 8×8 , представляющая из себя паттерн того или иного жеста записанный на протяжении 40 мс.

Размер тренировочной выборки составил 17517 матриц 8×8 , а размер тестовой выборки 5839 матриц.

Архитектура нейронной сети

В качестве класса моделей машинного обучения были выбраны нейронные сети с рекуррентными слоями. Выбор был обоснован тем, что при применении обычных алгоритмов машинного обучения к задаче классификации паттернов электромиографии точность модели оказывается хуже, чем если применять нейронные сети.

Например, в исследовании [7], где использовали сверточную НС, это позволило эффективно определить характерные признаки в сигналах ЭЭГ без необходимости предварительного применения методов отбора и выделения признаков.

В другой работе [8] исследователи приводят объяснения того, что комбинация от 3-х и более сигналов от ЭМГ датчиков может быть очень сложна для обработки стандартными методами машинного обучения. Поэтому обработка этих данных нейронными сетями даст выигрыш в скорости работы алгоритма.

Использование именно рекуррентной модели обуславливается отказом от использования полносвязных НС, ввиду их большой ёмкости. Также имеется опыт применения сверточных НС для решения задачи классификации ЭМГ сигнала [9]. В результате классификации 3-х классов положений пальцев точность модели составила 89%, чего было бы недостаточно для наших целей, а также при увеличении количества классов точность модели только уменьшалась.

Исходные данные представляют из себя временной ряд, поэтому в каждый момент времени необходимо учитывать прошлые значения поступающих данных. Слои LSTM (Long short-term memory - долгая краткосрочная память), схема которых представлена на рисунке 2, разработаны специально, чтобы избежать проблемы долговременной зависимости, и нацелены на запоминание информации на долгие периоды времени. Слои LSTM являются наиболее подходящими для выдвинутой задачи, так как позволяют делать предсказание последовательности паттернов электромиографии, основываясь на предыдущих полученных данных, что потенциально обеспечит большую точность в сравнении с полносвязными моделями [10].




Рис. 2. Схема слоя LSTM

Основу сети составляют 4 рекуррентных слоя LSTM. Для предотвращения переобучения была выбрана техника регуляризации dropout с аргументом 50%.

Далее следует полносвязный классификатор из 3-х слоёв, последний из которых имеет 4 нейрона по количеству классифицируемых жестов. Модель нейронной сети представлена на рисунке 3.

В качестве метрики для сравнения результатов была использована Accuracy (точность). В качестве функции потерь была использована категориальная перекрёстная энтропия.

Результаты

Эксперименты проводились на языке Python. Для реализации нейронных сетей использовались библиотеки TensorFlow и Keras.

Модель обучалась в течении 35 эпох, после чего сработала функция ранней остановки, настроенная на прекращение обучения при отсутствии уменьшения ошибки в течении 5 эпох. Точность на проверочных данных составила 98.4%, на тестовых данных - 98.3%.

Были проведены эксперименты с dropout от 20 до 50 %. Наиболее эффективным оказалось значение 50%.

Анализ результатов классификации данных был выполнен с использованием метода classification_report библиотеки Scikit-learn, который позволил увидеть отчет о верных предсказаниях модели (рис.5) и построить матрицу путаницы (рис. 6).

Из графика точности (рис. 4) и отчета можно сделать вывод о точности предсказанных классов - выше 0.9, что свидетельствует о хорошем обучении модели, однако по матрице путаницы видно, что модель имеет затруднения в классификации жестов «бумага» (метка 2) и «Ок» (метка 3). Как видно из ячеек матрицы, модель путает эти жесты между собой чаще других, а также в 10 случаях отнесла жест «ножницы» (метка 1) к жесту «бумага».

Model: "sequential_1"

Layer (type)	Output Shape	Param #
lstm_4 (LSTM)	(None, 8, 50)	11800
dropout_4 (Dropout)	(None, 8, 50)	0
lstm_5 (LSTM)	(None, 8, 50)	20200
dropout_5 (Dropout)	(None, 8, 50)	0
lstm_6 (LSTM)	(None, 8, 50)	20200
dropout_6 (Dropout)	(None, 8, 50)	0
lstm_7 (LSTM)	(None, 50)	20200
dropout_7 (Dropout)	(None, 50)	0
dense_3 (Dense)	(None, 64)	3264
dense_4 (Dense)	(None, 128)	8320
dense_5 (Dense)	(None, 4)	516

=====
Total params: 84,500
Trainable params: 84,500
Non-trainable params: 0
=====

Рис. 3. Модель рекуррентной нейронной сети

Следует заметить, что мышцы разгибатели пальцев находятся в одной области предплечья и, по всей видимости, генерируют электрический потенциал в области действия одних и тех же датчиков, лишь слегка захватывая соседние. А мышца, отвечающая за приведение большого пальца, находится на достаточной глубине, в результате чего её активность почти не заметна для ЭМГ-датчиков [11].




Рис. 4. Результаты обучения модели в течение 35 эпох

	precision	recall	f1-score	support
0	0.99	0.99	0.99	1455
1	0.99	0.98	0.98	1452
2	0.97	0.97	0.97	1471
3	0.96	0.98	0.97	1461
accuracy			0.98	5839
macro avg	0.98	0.98	0.98	5839
weighted avg	0.98	0.98	0.98	5839

Рис. 5. Отчет о точности предсказаний классов на основе матрицы путаницы




Рис. 6. Матрица путаницы по результатам классификации на 4 класса

В результате вышеописанных причин возникает путаница в жестах с разным количеством отведённых пальцев, и чем больше различие в их количестве, тем меньше неправильно отнесённых друг к другу жестов. Так разницей между жестами «ножницы» и «бумага» являются 2 согнутых пальца, и в этом случае мы имеем $10 + 6 = 16$ ошибочно распознанных паттернов. Разницей между жестами «бумага» и «Ок» является только один согнутый палец, и в этом случае мы уже имеем $27 + 25 = 52$ ошибочно распознанных паттерна.

Заключение

В данной статье были представлены результаты исследования по применению рекуррентной нейронной сети для классификации паттернов электромиографии 4-х жестов. Данный способ классификации имел точность на тестовых данных 98.3%. Для задач по распознаванию движения отдельных пальцев следует самостоятельно осуществлять сбор данных с заранее определённых мышц на предплечье. Однако, полученных результатов достаточно для последующего применения модели в практических задачах.

Результаты проведенного исследования могут послужить основой для разработки нейросетевой модели для управления реальным бионическим протезом руки человека. Другим применением является разработка систем управления роботами общего и специального назначения, а также человеко-машинных интерфейсов бытового уровня.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Сафин Д.Р., Пильщиков И.С., Ураксеев М.А., Гусев В.Г., Оценка эффективности различных конструкций электродов и усилителей биосигналов в системах управления протезами // Известия высших учебных заведений. Поволжский регион. Технические науки.

- 2009. - № 2 (10). С. 88-101.

2. Будко Н.А., Будко Р. Ю., Медведев М.Ю., Биоэлектрическое управление 4DOF манипулятором // Информационные технологии, системный анализ и управление (итсау-2019). Сборник трудов XVII Всероссийской научной конференции молодых ученых, аспирантов и студентов. В двух томах. Том 2. Ростов-на-Дону - Таганрог, 2019. С.202-211.

3. Samaneh Samiei, Nasser Ghadiri, Behnaz Ansari. A complex network approach to time series analysis with application in diagnosis of neuromuscular disorders // 2021.

4. Ghazal Ghazaei, Ali Alameer, Patrick Degenaar, Graham Morgan, Kianoush Nazarpour, Deep learning-based artificial vision for grasp classification in myoelectric hands // J. Neural Engineering – 2017. Volume 14 - №3 DOI 10.1088/1741-2552/aa6802

5. Бошляков А.А. Поярков Г.А. Анализ алгоритмов для системы принятия решений // ДНЕВНИК НАУКИ – 2020. - №4 (40). С. 32

6. Drowsiness_dataset | Kaggle [Электронный ресурс]. - Режим доступа: <https://www.kaggle.com/datasets/sojanprajapati/emg-signal-for-gesture-recognition> - Заглавие с экрана. (дата обращения: 09.04.2023)

7. Попов Е. Ю., Фоменков С. А., Детектирование событий движения руки в сигналах ЭЭГ головного мозга с помощью сверточных нейронных сетей // ИЗВЕСТИЯ ВолгГТУ – 2016. - №3 (182). С. 62-67

8. Денис Грязнов, Вадим Жмудь, Демьян Малахов, Валерий Аврмачук, Ярослав Носек, Любомир Димитров, Перспективы расширения функционала индивидуальных недорогих протезов конечностей за счет применения интеллектуальных датчиков-командеров // АВТОМАТИКА И ПРОГРАММНАЯ ИНЖЕНЕРИЯ - 2019. - №2 (28) С. 10-17

9. Ботман С.А., Сапунов В.В., Савинов В.Б., Петров В.А., Камышов Г.В., Шушарина Н.Н., Определение степени сжатия пальцев руки по данным ЭМГ в случае сложных движений // ИННОВАЦИИ. НАУКА. ОБРАЗОВАНИЕ - 2020. - №20. С. 869-878

10. Будко Р.Ю., Чернов Н.Н., Будко Н.А., Будко А.Ю. Распознавание электромиограммы предплечья и выбор жестов для управления протезом / Р.Ю. Будко, Н.Н. Чернов, Н.А. Будко, А.Ю. Будко // Моделирование, оптимизация и информационные технологии – 2019. – Том 7. - №1 (24). С. 54-66

11. Perotto A. O. Anatomical guide for the electromyographer: the limbs and trunk. – Charles C Thomas Publisher. - 2011.

Информация об авторах

Григоров Павел Александрович – магистрант направления 09.04.01 «Информатика и вычислительная техника», профиль «Искусственный интеллект», институт информационных технологий и анализа данных, Иркутский национальный исследовательский технический университет, г. Иркутск, e-mail: grigorov-pl@mail.ru

Жанна Сергеевна Афанасьева – ст. преподаватель института информационных технологий и анализа данных, Иркутский национальный исследовательский технический университет, г. Иркутск, e-mail: afanasevajs@ex.istu.edu

Information about the authors

Grigorov Pavel Alexandrovich – master student of «Informatics and Computer Science» direction 09.04.01, profile «Artificial Intelligence», Institute of Information Technology and Data Analysis, Irkutsk National Research Technical University, Irkutsk, e-mail: grigorov-pl@mail.ru

Zhanna Sergeevna Afanasyeva – senior lecturer at the Institute of Information Technology and Data Analysis, Irkutsk National Research Technical University, Irkutsk, e-mail: afanasevajs@ex.istu.edu