

УДК 004.89
DOI 10.52575/2687-0932-2025-52-4-897-927
EDN SFNWSH

Обзор методов машинного обучения в протезировании

¹Арсёнов А.В., ²Моракс В.Д., ^{2,3}Донская А.Р., ²Ломакин А.С.

¹Национальный исследовательский университет "МЭИ"

Россия, 111250, г. Москва, ул. Красноказарменная, 14

²Волгоградский государственный технический университет

Россия, 400005, Волгоград, пр. им. Ленина, 28

³Волгоградский государственный медицинский университет Минздрава России

Россия, 400066, г. Волгоград, пл. Павших Борцов, 1

al.arsenov@mail.ru

Аннотация. Целью исследования является анализ современных методов машинного обучения для обработки электромиографических (ЭМГ) сигналов, применяемых в управлении технологичными протезами. Исследование направлено на сравнение эффективности классических и нейросетевых подходов, оценку их точности и выявление ключевых факторов, влияющих на результаты. В статье проведён обзор существующих исследований, посвящённых обработке ЭМГ-сигналов с использованием машинного обучения. Рассмотрены популярные наборы данных (например, NinaPro), а также различные методы обработки сигналов: классические (LDA, KNN) и современные нейросетевые архитектуры (EMGHandNet, CNN-RNN и др.). Особое внимание уделено сравнительному анализу точности моделей в зависимости от используемых данных, архитектур и параметров методов. Анализ показал, что современные нейросетевые модели (ConTraNet, CNN-RNN) демонстрируют более высокую точность по сравнению с классическими методами (SVM, LDA, RF и др.), однако их эффективность сильно зависит от качества и разнообразия данных. Выявлены ограничения, связанные с недостаточным тестированием на различных наборах данных, что указывает на необходимость стандартизации экспериментов. Также подтверждена важность предварительной обработки сигналов и качества ЭМГ-датчиков для достижения стабильных результатов. Применение методов машинного обучения, особенно нейросетевых архитектур, перспективно для создания более точных и адаптивных протезов. Однако для дальнейшего развития технологии требуется решение проблем универсализации моделей, расширения тестовых данных и улучшения их качества. Дополнительные исследования должны быть направлены на интеграцию систем в реальные условия эксплуатации и повышение интерпретируемости результатов.

Ключевые слова: машинное обучение в протезировании, электромиографические сигналы, нейронные сети, управление протезами, обработка ЭМГ-сигналов

Для цитирования: Арсёнов А.В., Моракс В.Д., Донская А.Р., Ломакин А.С. 2025. Обзор методов машинного обучения в протезировании. *Экономика. Информатика*, 52(4): 897–927. DOI 10.52575/2687-0932-2025-52-4-897-927; EDN SFNWSH

Overview of Machine Learning Methods in Prosthetics

¹Aleksei V. Arsenov, ²Viktor D. Moraks, ^{2,3}Anastasia R. Donskaia, ²Arseniy S. Lomakin

¹National Research University "Moscow Power Engineering Institute"

14 Krasnokazarmennaya St., Moscow 111250, Russia

²Volgograd State Technical University, 28 Lenin Ave., Volgograd 400005, Russia

³Volgograd State Medical University of Public Health Ministry of the Russian Federation

1 Pavshikh Bortsov Sq., Volgograd 400131, Russia

al.arsenov@mail.ru

Abstract. The purpose of the research is to analyze modern machine learning methods for processing electromyographic (EMG) signals used in the control of advanced prosthetics. The study aims to compare the

effectiveness of classical and neural network approaches, evaluate their accuracy, and identify key factors influencing the results. The article provides a review of existing research dedicated to the processing of EMG signals using machine learning. Popular datasets (e.g., NinaPro) as well as various signal processing methods were reviewed: classical ones (LDA, KNN) and modern neural network architectures (EMGHandNet, CNN-RNN, etc.). Special attention is given to the comparative analysis of model accuracy depending on the used data, architectures, and method parameters. The analysis showed that modern neural network models (ConTraNet, CNN-RNN) demonstrate higher accuracy compared to classical methods (SVM, LDA, RF, etc.), however, their effectiveness heavily depends on the quality and diversity of the data. Limitations have been identified related to insufficient testing on various datasets, indicating the need for standardization of experiments. The importance of signal preprocessing and the quality of EMG sensors for achieving stable results has also been confirmed. The application of machine learning methods, especially neural network architectures, is promising for creating more accurate and adaptive prosthetics. However, further development of the technology requires addressing the issues of model generalization, expanding test data, and improving their quality. Additional research should focus on integrating systems into real-world operating conditions and improving the interpretability of results.

Keywords: machine learning in prosthetics, electromyographic signals, neural networks, prosthetic control, EMG signal processing

For citation: Arsenov A.V., Moraks V.D., Donskaia A.R., Lomakin A.S. 2025. Overview of Machine Learning Methods in Prosthetics. *Economics. Information technologies*, 52(4): 897–927 (in Russian). DOI 10.52575/2687-0932-2025-52-4-897-927; EDN SFNWSH

Введение

Современное протезирование конечностей стремительно развивается, переходя от механических и пассивных конструкций к интеллектуальным системам, способным эффективно взаимодействовать с человеком и адаптироваться к его потребностям. Потеря конечности – это не только физическая, но и психологическая травма, поэтому одной из ключевых задач биомедицинской инженерии остается создание функциональных протезов, которые максимально могли бы воспроизвести естественные движения и вернуть пациенту нормальное качество жизни. Традиционные методы протезирования включают в себя как простые механические устройства, так и миоэлектрические системы, которые используют поверхностные сигналы электромиографии (ЭМГ) для управления протезами. В последние годы наблюдается бурный рост применения методов машинного обучения для анализа ЭМГ-сигналов и повышения точности управления. Эти методы могут помочь улучшить распознавание жестов пользователя протезом, учитывать индивидуальные особенности мышечной активности и обеспечивать более плавное и интуитивное управление. Целью работы является систематизирование и сравнение классических методов машинного обучения и нейронных сетей, используемых при обработке ЭМГ-сигналов для управления протезами, выделив наиболее перспективные подходы. Полученные выводы позволяют оценить текущее состояние технологий, связанных с использованием машинного обучения в протезировании, перспективы развития и общие проблемы исследований.

Классификация протезов

Протезы верхних и нижних конечностей классифицируются по следующим типам:

Косметические – предназначены для воссоздания внешнего (физического) вида конечности. Такие устройства (особенно заменители кисти) часто изготавливают из силикона как наиболее мягкого, упругого и естественно выглядящего материала [Коробенков и др., 2019].

Активные – протезы управляются тягами, которые приводятся в действие определёнными движениями человека или непосредственно за счёт движений культи или сегмента поражённой конечности.

Протезы с микропроцессорным управлением (бионические) – движения его исполнительными механизмами осуществляются за счёт электроприводов, управляются с помощью электронных устройств, с использованием микропроцессоров, датчиков ЭМГ-сигнала [Уразбахтина и др., 2022] или другими техническими компонентами.

Рабочие – протезы с приёмниками и различного рода насадками (например, под молоток, ключ, ножницы, зубило, зажим для отверток и т. п. [Коробенков и др., 2019]) для выполнения специализированных бытовых и рабочих операций. Количество насадок и их назначение зависят от пожеланий владельца.

Протезы существенно различаются по своей конструкции, уровню управления и функциональности – от простейших механических устройств до интеллектуальных миоэлектрических систем. Однако для современного технологичного протеза ключевым условием эффективного использования остается надежная система управления, способная точно интерпретировать намерения пользователя.

В этом контексте особую роль играют датчики электромиографии (ЭМГ), которые обеспечивают связь между мышечной активностью и движением протеза. Их точность, чувствительность и особенности размещения непосредственно влияют на качество управления. Далее рассмотрены характеристики ЭМГ-датчиков и их принцип работы, а также применение методов машинного обучения как ключевого инструмента для обработки ЭМГ-сигналов и построения интеллектуальных систем управления протезами.

ЭМГ-датчики

Электромиографические (ЭМГ) датчики используются для измерения электрической активности мышц, что позволяет применять их не только в медицине и реабилитации, но и в разработке протезов. В данный момент исследования сосредоточены на улучшении их функциональности, а также надежности и точности. В протезировании используются электрические сигналы, генерируемые во время сокращения остаточных мышц конечностей для управления сервоприводами [Kuiken et al., 2009; Resnik, 2011].

Наиболее часто используемыми являются поверхностные ЭМГ-датчики. Они представляют собой гибкие емкостные датчики, обеспечивающие неинвазивное измерение мышечной активности и обладают возможностью интеграции в носимые устройства для мониторинга состояния здоровья и управления протезами [Ng et al., 2024; Ng et al., 2023]. Их недостатками являются:

- ограниченное пространство для размещения и чувствительность к изменению положения электродов [Resnik, 2011; Персон, 1969];

- слабые сигналы для управления протезом.

Существуют также инвазивные, внутримышечные ЭМГ-датчики, которые устанавливаются с помощью иглы в целевую мышцу [Becerra-Fajardo et al., 2024]. Имплантируемые датчики обладают рядом преимуществ, заключающихся в:

- устойчивости к смещению и исключении необходимости замены перед каждым использованием (что требует перекалибровки системы) [Young et al., 2011];

- устранении перекрёстных помех и возможности управлять большим числом степеней свободы за счёт использования нескольких электродов [Dewald et al., 2019];

- осуществлении доступа к более изолированным и специфическим сигналам от отдельных мышц;

- присутствии меньшего количества артефактов и внешних помех при считывании сигнала.

Однако инвазивность процедуры установки, анатомические особенности людей, биосовместимость компонентов, способы передачи данных и энергопитания датчиков, находящихся внутри тела человека, становятся серьезными сложностями в протезировании.

Современные ЭМГ-системы используют множество различных технологий, включая многоканальные беспроводные системы, обеспечивающие высокую точность и низкое

энергопотребление, что позволяет сделать систему удобнее для использования людьми и упростить интеграцию в компоненты протезов. Новые разработки включают в себя использование многослойных сенсоров, которые позволяют одновременно измерять ЭМГ, механомиографию и ближнюю инфракрасную спектроскопию, что дает возможность более детально анализировать мышечную активность [Kimoto et al., 2023].

Применение машинного обучения для обработки ЭМГ-сигнала

Анализ исследований применения машинного обучения для обработки ЭМГ-сигналов представлен в виде трех таблиц. В табл. 1 указаны наборы данных и их составляющие, используемые в исследованиях, а также методы, их архитектура, параметры и гиперпараметры.

Таблица 1
Table 1

Наборы данных и методы, используемые в исследовании
Datasets and methods used in the research

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
An Improved Performance of Deep Learning Based on Convolution Neural Network to Classify the Hand Motion by Evaluating Hyper Parameter, 2020 [Triwiyanto et al., 2020]	EMG-сигналы (сырые), частота дискретизации 4000 Гц [Khushaba et al., 2012]	10 жестов: движения пальцев (сжатия: большой палец, указательный, средний, безымянный, мизинец; комбинированные сжатия: большого пальца с указательным, большого пальца со средним, большого пальца с безымянным, большого пальца с мизинцем, Сжатие кисти)	Каждый субъект: 2 канала, 10 движений, 20 000 выборок, 6 испытаний	CNN: Размер окна: 200 мс (800 выборок) Перекрытие окна: 100 выборок Фильтры: 100 Размер ядра: 8 Паддинг: 0 Шаг: 1 Функция активации: ReLU Оптимизатор: Adam Dropout: 0.5 SVM, KNN, LDA: Выделенные признаки: RMS, MAV, WL, ZC, SSC [Hudgins et al., 1993; Triwiyanto et al., 2017; Kilic, 2017] Оконная длина: 200 мс Перекрытие окна: 100 мс

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
A Novel Attention-Based Hybrid CNN-RNN Architecture for sEMG-Based Gesture Recognition, 2018 [Hu et al., 2018]	sEMG-сигналы (NinaPro DB1) [Atzori et al., 2014]	52	14040	Сеть состоит из семи слоев: два свёрточных слоя с 64 фильтрами 3×3, два локально-связанных слоя с 64 фильтрами 1×1, три полносвязных слоя (512, 512 и 128 нейронов), LSTM с 512 нейронами, механизм внимания, полносвязный слой G-way и Softmax
	sEMG-сигналы (NinaPro DB2) [Atzori et al., 2014]	50	12 000	
	sEMG-сигналы (BioPatRec26MOV) [Ortiz-Catalan et al., 2013]	26	1326	
	sEMG-сигналы (CapgMyo-DBa) [Geng et al., 2016]	8	1440	
	sEMG-сигналы (csl-hdemg) [Ammal et al., 2015]	27	1350	
Анализ эффективности методов машинного обучения в задаче распознавания жестов на основе данных электромиографических сигналов, 2021 [Козырь, Савельев, 2021] / Analysis of the Effectiveness of Machine Learning Methods in the Problem of Gesture Recognition Based on the Data of Electromyographic Signals	Электромиографические сигналы (ЭМГ)	Сжатие кулака, знак «большой палец», знак «Виктория», сжатие указательного пальца, взмах рукой справа налево	5000 жестов на эксперимент, три эксперимента	Метод опорных векторов (SVM): C=1.0, kernel=rbf, gamma=0.33 Дерево решений: criterion=gini, splitter=best, max_depth=None, min_samples_split=2 Наивный Байесовский классификатор (НБК): priors=None, var_smoothing=1e ⁻⁹ Случайный лес: n_estimators=100, criterion=gini, max_depth=None, min_samples_split=2 Метод k-ближайших

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				соседей (kNN): n_neighbors=3, weights=uniform, algorithm=auto, leaf_size=30, metric=minkowski, p=2 Градиентный бустинг (XGBoost): objective=multi:softprob, max_depth=6, subsample=1, tree_method=exact, booster=gbtrees, base_score=0.5 Ансамбли методов (разные комбинации НБК, дерева решений и градиентного бустинга) с voting=hard и weights от (1.1) до (2.1)
ConTraNet: A Hybrid Network for Improving the Classification of EEG and EMG Signals with Limited Training Data, 2023 [Ali et al., 2023]	MI-EEG (Physionet MI-EEG [Goldberger et al., 2000])	Левый кулак (L) или правый кулак (R) – воображаемое движение. Также три повторения задания MI для обоих кулаков (B) или обеих стоп (F).	Каждое повторение длится 120 секунд и содержит 14 испытаний MI, всего 42 испытания (21 испытание на класс) на участника.	ConTraNet: алгоритм оптимизации: Adam; Количество эпох: 100; Скорость обучения: 0.001 (эпохи 0–50), 0.0001 (эпохи 51–100); Количество свёрточных ядер: 16; Dropout в CNN-блоке: 0.5; Dropout в MLP-блоке: 0.7 CNN-LSTM: Один свёрточный слой с 32 ядрами размером (1.125). Шаг 1, padding 'valid'. Активация ReLU. Один слой LSTM с 200
	sEMG (Mendeley Data – sEMG [Ozdemir et al., 2022])	Покой (нейтральное состояние), разгибание запястья, сгибание запястья, локтевое отклонение запястья, лучевое отклонение	Каждый участник прошел пять повторяющихся циклов. Каждый цикл длится 104 секунды, каждое движение кисти –	

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
		запястья, хват, отведение всех пальцев, приведение всех пальцев, супинация и пронация.	6 секунд с 4 секундами отдыха между ними.	нейронами и один полносвязный слой с 100 нейронами.
	sEMG (Mendeley Data – sEMG V1 [Ozdemir, 2021])	Покой (нейтральное состояние), разгибание запястья, сгибание запястья, локтевое отклонение запястья, лучевое отклонение запястья, удар кулаком, открытая ладонь.	Каждый цикл длится 74 секунды, каждое движение кисти – 6 секунд с 4 секундами отдыха между ними.	
Classification of Electromyographic Hand Gesture Signals Using Machine Learning Techniques, 2020 [Jia et al., 2020]	Электромиографические (EMG) сигналы	10 жестов	480 записей (320 тренировочные, 160 тестовые), каждый сегмент 20000×2	CAE+CNN: 250 эпох, размер пакета 20, оптимизация: Adam, функция потерь: MSE, структура: свёрточный автоэнкодер (CAE) с Conv2D, BatchNormalization, ReLU, MaxPooling CNN: 100 эпох, размер пакета 15, оптимизация: Adam Нейронная сеть (NN): 3 скрытых слоя, 21 нейрон в каждом, оптимизация: LM, CGB, Adam К-ближайших соседей (KNN): Число соседей: 5, метрика:

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				Минковского, размер листа: 30 Метод случайного леса (Random Forest): Bootstrap: True, критерий: Gini, вес классов: 1.0 Решающее дерево (Decision Tree): Splitter: Best, критерий: Gini, вес классов: 1.0 Метод опорных векторов (SVM): Ядро: RBF, Coefficient: 0.0, Регуляризация: 1.0 Логистическая регрессия: Регуляризация: L2, Fit intercept: True, Cross-validation: Stratified K-Folds Наивный байесовский классификатор (Naive Bayes): Гладкость дисперсии: 10^{-9}
Classification of EMG Signals Using Convolution Neural Network, 2020 [Bakırcıoğlu, Ozkurt, 2020]	Электромиографические (EMG) сигналы	6 жестов: Cylindrical, Tip, Hook, Palmar, Spherical, Lateral	86 400 образцов окон размером 150 точек	Алгоритм SGD с моментом (SGDM), начальная скорость обучения 0.01, 6 эпох, данные перемешиваются в каждой эпохе. CNN1: input layer (2, 150); convolution layer (1, 50), 80; max pooling (1, 2); convolution layer (1, 60), 100; max

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				pooling (1, 2); convolution layer (1, 70), 120; fully connected layer (6). CNN2: input layer (2, 150); convolution layer (1, 10), 100; max pooling (1, 2); convolution layer (1, 20), 120; max pooling (1, 2); convolution layer (1, 30), 140; fully connected layer (6). CNN3: input layer (2, 150); convolution layer (1, 15), 80; max pooling (1, 2); convolution layer (1, 20), 100; max pooling (1, 2); convolution layer (1, 25), 120; fully connected layer (6). CNN4: input layer (6, 150); convolution layer (1, 50), 80; max pooling (1, 2); convolution layer (1, 60), 100; max pooling (1, 2); convolution layer (1, 70), 120; fully connected layer (6).
Intra-Subject Approach for Gait-Event Prediction by Neural Network Interpretation of EMG Signals, 2019 [Di Nardo, 2019]	sEMG-сигналы (электромиография)	Фазы походки: stance (опорная) и swing (маятниковая), моменты heel-strike (HS) и toe-off (TO) [Lerner et al., 2014]	Примерно 10 000 шагов, 10 sEMG сигналов на участника (5 мышц на каждую ногу)	Модель: многослойный персептрон (MLP) с 3 скрытыми слоями (512, 256, 128 нейронов) Функция активации: ReLU

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				Выходной слой: сигмоидная функция (порог 0.5) Оптимизатор: стохастический градиентный спуск (SGD) Функция потерь: бинарная кросс-энтропия Скорость обучения: 0.01 Ранняя остановка: прекращение обучения после 10 эпох без улучшений Количество эпох: до 100 Кросс-валидация: 10-кратная (intra-subject) и leave-one-out (inter-subject)
A Novel Channel Selection Method for Multiple Motion Classification Using High-Density Electromyography, 2014 [Geng et al., 2014]	Высокоплотные EMG-сигналы	21 движение руки и кисти, одно "без движения"	Каждое движение выполнялось в течение 6 секунд, повторялось 6 раз, всего 1524 элемента.	Linear Discriminant Analysis (LDA) и K-Nearest Neighbors (KNN). Параметры обработки: "скользящее окно анализа длиной 150 мс с шагом 100 мс (50 мс перекрытие)". Экстрагированы два набора признаков: 1) Четыре временных признака (TD) [Hudgins et al., 1993]: среднее абсолютное значение (MAV), количество пересечений нуля (ZC), количество

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				изменений знака наклона (SSC), длина волны (WL). 2) Шестипорядковая авторегрессионная модель (AR) [Graupe, Cline, 1975] и корень среднеквадратичного значения (RMS).
Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG, 2020 [Asif et al., 2020]	sEMG (электромиография)	10 жестов: открытая ладонь, закрытая ладонь, сгибание запястья, разгибание запястья, пронация предплечья, супинация предплечья, захват предмета перпендикулярно предплечью, тонкий захват, указательный палец вытянут, большой палец вверх	Массивы размером 6×1200 были получены, где 6 – количество каналов, а 1200 – количество выборок в каждом окне 150 мс ($8000 \text{ Гц} \times 0,15 \text{ с}$)	Архитектура сети: 15 слоев, 3 свёрточных слоя (16, 64, 32 фильтра 3×3), 3 слоя нормализации, 2 слоя пулинга (2×2 и 3×3), 3 слоя ReLU, полносвязный слой, SoftMax-классификатор, выходной слой. Алгоритм обучения: стохастический градиентный спуск с моментом (SGDM). Гиперпараметры: диапазон скоростей обучения (0.00001, 0.0001, 0.001, 0.01, 0.1), число эпох (20, 40, 60, 80, 100), размер мини-пакета – 128.
Cross-Domain MLP and CNN Transfer Learning for Biological Signal Processing: EEG and EMG, 2020 [Bird et al., 2020a]	EMG	Кулак сжат/разжат, пальцы разведены/сжаты, взмах вправо, взмах влево	EMG: 60 сек. \times 4 жеста \times 2 руки \times 10 участников	CNN: (слой, выходной размер, параметры): Conv2D (ReLU), (0, 14, 14, 32), 320; Conv2D (ReLU), (0, 12, 12, 64), 18496; Max Pooling, (0, 6, 6, 64), 0; Dropout

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				<p>(0.25), (0, 6, 6, 64), 0; Flatten, (0, 2304), 0; Dense (ReLU), (0, 512), 1180160; Dropout (0.5), (0, 512), 0; Dense (Softmax), (0, 3 или 4), 1539 [Ashford et al., 2019].</p> <p>Оптимизатор: Adam; функция потерь: Кросс-энтропия; количество эпох: до 100; dropout: 0.25 после сверточных слоев, 0.5 перед входным слоем.</p> <p>MLP: на основе алгоритма Devo [Bird et al., 2019b] была составлена топология: 5 скрытых слоёв (206, 226, 298, 167, 363 нейронов), функция активации – ReLU (для скрытых слоев), выходной слой – Softmax (для классификации). Оптимизатор: Adam; функция потерь: Кросс-энтропия; количество эпох: 100 для эволюционного поиска топологии; кросс-валидация: 10-fold (перемешивание данных перед обучением).</p>

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
Electromyogram-Based Classification of Hand and Finger Gestures Using Artificial Neural Networks, 2021 [Lee et al., 2021]	ЭМГ-сигналы (3 канала), 6 временных признаков на канал	10 жестов: 2 жеста всей рукой (камень, бумага), 7 жестов отдельными пальцами (ножницы, один, три, четыре, хорошо, окей, пистолет), состояние покоя	Использованы 5-секундные записи для каждого жеста, 5 повторений в сети, 4 раунда для каждого жеста, 90 % перекрытие окон (250 мс, шаг 25 мс)	Искусственная нейронная сеть (ANN): количество скрытых слоев (2, 3 и 4), нейроны в каждом слое (300, 600 и 1000), уровень dropout (0.2 и 0.3), использование batch normalization Метод опорных векторов (SVM): ядро (linear и rbf), C (1, 10, 100 и 1000), gamma (1, 0.1, 0.01, 0.001 и 0.0001) Случайный лес (RF): количество деревьев (100, 500, 1000) и вес классов balanced subsample и none Логистическая регрессия (LR): штраф (L1, L2, elasticnet и none), C (1, 0.1, 0.01, 0.001 и 0.0001), вес классов (balanced и none), решатель (lbfgs и saga)
EMGHandNet: A Hybrid CNN and Bi-LSTM Architecture for Hand Activity Classification Using Surface EMG Signals, 2022 [Karnam et al., 2022]	sEMG-сигналы (NinaPro DB1 [Atzori et al., 2014])	Упражнение «А» включает сгибание и разгибание отдельных пальцев, упражнение «В» включает множественные сгибания и разгибания пальцев, а также движения запястья,	Общее количество паттернов 14040	EMGHandNet (предложенная модель): реализована со следующими параметрами: Kernel initializer: he_normal; strides: 2; Kernel regularizer: 10^{-4} ; скорость обучения (l1) = 10^{-3} ; batch size = 16; optimizer: Adam b1 (0.9),

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
		упражнение «С» включает захват бытовых предметов.		Adam b2 (0.999); функции активации: Tanh, Relu; dropout: 0.2093; epochs: 200; Bi-LSTM: cells = 200 MsCNN: параметры использованы из исследования [Wei et al., 2019] EvCNN: параметры использованы из исследования [Olsson et al., 2020] CNNLM: параметры использованы из исследования [Chen et al., 2021]
	sEMG-сигналы (NinaPro DB2 [Atzori et al., 2014])	49 классов действий, объединённых в упражнения В, С и D. Упражнения В и С аналогичны NinaPro DB1. Упражнение D включает 9 паттернов силы, полученных при нажатии пальцами на датчики силы.	Общее количество паттернов 11760	
	sEMG-сигналы (NinaPro DB4 [Pizzolato et al., 2017])	Действия рук аналогичны NinaPro DB1, но данные записаны с более высокой частотой дискретизации.	Общее количество паттернов 3120	
	sEMG-сигналы (BioPatRec DB2 [Ortiz-Catalan et al., 2013])	Включает 6 основных движений руки (открытие/закрытие, пронация/супинация, сгибание/разгибание запястья) и 20 комбинаций этих движений.	Общее количество паттернов 1326	
	sEMG-сигналы (UCI Gesture [Lobov et al., 2018])	7 основных движений: сжатие кулака, сгибание/разгибание запястья, радиальное/ульнарное отклонение запястья,	Общее количество паттернов 864	

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
		раскрытая ладонь, состояние покоя.		
EMG-Driven Hand Model Based on the Classification of Individual Finger Movement, 2019 [Arteaga et al., 2019]	EMG-сигналы	6 жестов: 5 индивидуальных сгибаний/разгибаний пальцев и 1 жест закрытия руки	2400 событий (400 на жест)	k-NN : число соседей: Fine (1), Medium (10); метрики расстояния: Euclidean, Cosine, Weighted, Cubic
Design of a Flexible Wearable Smart sEMG Recorder Integrated Gradient Boosting Decision Tree Based Hand Gesture Recognition, 2019 [Song et al., 2019]	sEMG сигналы с 16 каналов	12 жестов (включая комбинации движений пальцев и жесты с участием запястья)	Каждый участник выполнил 12 жестов по 10 раз, каждый жест длился 5 секунд (частота дискретизации 500 S/s)	Gradient Boosting Decision Tree (GBDT) [Friedman, 2001]: максимальная глубина дерева: 5, количество деревьев для каждого жеста: 80, общее количество деревьев: $12 \times 80 = 960$, обучение с использованием библиотеки XGBoost [Chen, Guestrin, 2016], кросс-валидация: 70 % данных для обучения, 30 % для тестирования, использованы временные признаки (9 признаков на канал, всего 144 признака)
Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks, 2023 [Valdivieso et al., 2023]	EMG-сигналы	fist, wave in, open, wave out, pinch, relax (no gesture) [Benalcázar et al., 2020]	183,600 (300 на пользователя)	DQN [Vásconez et al., 2022]: архитектура: 40-50-50-6 нейронов (вход-скрытые-выход), скорость обучения: 0.0003, буфер опыта: 1×10^6 , размер батча: 64,

Название и год исследования / Name and year of the research	Тип данных в датасете / Type of data in the dataset	Жесты / Gestures	Оценка объема данных в датасете / Estimating the amount of data in a dataset	Параметры и архитектура решений / Parameters and architecture of solutions
				оптимизатор: Adam, γ : 0.99 DQN-LSTM : архитектура: 40-50-50-6 и LSTM (27 нейронов), α : 0.00009, Dropout в LSTM
Fully Embedded Myoelectric Control for a Wearable Robotic Hand Orthosis, 2017 [Ryser et al., 2017]	EMG-сигналы с Myo armband	rest, close, open, precision pinch, key pinch	5 жестов, удерживались по 60 секунд (здоровые); 3 жеста (rest, close, open), удерживались по 60 секунд (пациенты)	SVM с RBF-ядром [Englehart, Hudgins, 2003]: тип ядра: радиальное базисное (RBF), оптимизация γ и C методом grid search, длина окна обработки: 300 мс (офлайн), 150 мс (онлайн), шаг сдвига окна: 20 мс, нормализация по максимальному мышечному сокращению (MVC)
Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network, 2019 [Zhang et al., 2019]	sEMG-сигналы	Fist, Wave In, Wave Out, Fingers Spread, Double Tap	5 повторений \times 5 жестов \times 2 секунды (тренировка), 30 повторений \times 5 жестов \times 5 секунд (тест)	Искусственная нейронная сеть (ANN) : трехслойная сеть: входной слой, скрытый слой (число узлов = половина длины вектора признаков), выходной слой (6 узлов), функция активации: сигмоида, метод обучения: полный пакетный градиентный спуск, функция потерь: кросс-энтропия, скользящее окно: размер окна: 400 мс, шаг окна: 5 мс (1 точка), порог активации: 40.

Большинство исследований используют собранные авторами EMG-сигналы (82 %), это может подчёркивать:

- важность контроля параметров (частота дискретизации, тип электродов);
- узкую направленность задач (например, реабилитация или специфичные жесты).

Публичные наборы данных используются в 18 % работ, это может показывать, что:

- готовые наборы данных применяются в фундаментальных работах для сравнения алгоритмов;
- чаще встречаются в исследованиях с большим количеством участников или жестов;
- исследования методов и моделей машинного обучения проще сравнить с другими методами и моделями, так как набор данных одинаковый.

Среди исследований, где использовались наборы данных из открытого доступа, наиболее распространёнными являются NinaPro (особенно DB1 и DB2). Это может быть связано с их доступностью, разнообразием жестов и большим количеством участников. В исследованиях используются как простые жесты (например, сжатие кулака), так и сложные комбинации движений пальцев и запястья.

Касательно используемых методов стоит отметить, что в рамках данной комбинации исследований свёрточные нейронные сети (CNN) используются в 8 из 17 исследований (47 %), присутствуют также и объединение CNN с другими слоями (LSTM, механизмы внимания) для улучшения классификации временных последовательностей. В 6 исследованиях (35 %) используются и другие нейросетевые модели (MLP, ANN, DQN). Традиционные методы машинного обучения (SVM, KNN, LDA, RF) встречаются в 9 исследованиях (53 %), в некоторых исследованиях используются как нейросетевые методы, так и классические.

В статьях присутствует описание элементов использованных методов, анализ параметров, гиперпараметров и архитектуры решений может помочь определить, какие настройки метода дают преимущество в определенных задачах. А это, в свою очередь, может способствовать изучению отдельных элементов метода и, при необходимости, воспроизведению эксперимента.

Часто используемыми гиперпараметрами и настройками являются: оптимизаторы – Adam (5 исследований) и SGD (3 исследования); функции активации – ReLU (доминирует в CNN и MLP), Softmax – для классификации и сигмоида – для бинарных задач; регуляризация – Dropout 0.2 – 0.7. Обработка сигналов и признаки: оконная обработка имеет параметры: длины окна 150–400 мс, перекрытия 50–100 мс, признаки – временные (MAV, RMS, ZC, SSC, WL) в 2 исследованиях, либо без выделения признаков, нормализация сигналов ЭМГ выполнялась по максимальному добровольному сокращению (MVC), методом Z-нормализации, либо использовались сырые данные.

В табл. 2 представлены результаты средней точности моделей и их краткая характеристика.

Поскольку в исследованиях в основном используются разные наборы данных (собранные вручную и находящиеся в открытом доступе), прямое сравнение точности моделей затруднительно без учета контекста. На рис. 1 представлена общая тенденция методов. Из-за недостаточности тестовых данных таких методов, как деревья решений, случайный лес, линейный дискриминантный анализ, линейная регрессия, наивный байесовский классификатор их точность была объединена.

У нейросетевых методов наибольшая медианная точность (87,37 %) среди всех методов, что говорит об их высокой эффективности в среднем. KNN и SVM могут достигать точности, близкой к нейросетям, но их результаты менее стабильны. Градиентный бустинг – стабильный, но не всегда точный метод, узкий разброс может говорить о том, что градиентный бустинг менее чувствителен к вариациям данных, но и редко достигает высоких точностей. Другие методы имеют самую низкую медианную точность (78,13 %), а также большой разброс, данные методы хуже подходят для ЭМГ-сигналов.

Таблица 2
Table 2

Точность и краткая характеристика методов
Accuracy and brief description of methods

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
An Improved Performance of Deep Learning Based on Convolution Neural Network to Classify the Hand Motion by Evaluating Hyper Parameter	CNN: 86,3 %	Прямая обработка сырых EMG-сигналов без извлечения признаков, высокая точность классификации, возможность использования одного канала (CH2) без значительной потери точности, но большие вычислительные затраты на обучение (56.3 секунды для 100 фильтров) и длительное время обработки одного сегмента: 250.6 мкс.
	KNN: 60,4 %	Быстрое вычисление (до 50 мкс для одного сегмента), простота реализации, но требуется выделение признаков, ниже точность, плохая классификация некоторых жестов.
	SVM: 50,7 %	Средняя скорость обработки, хорошая точность для некоторых жестов, но общая точность является низкой
	LDA: 49,9 %	Быстрая обработка, хорошая точность для комбинированных признаков, но имеет самую низкую общую точность среди всех методов и неспособность классифицировать некоторые жесты
A Novel Attention-Based Hybrid CNN-RNN Architecture for sEMG-Based Gesture Recognition	CNN-RNN: 87,0 % (NinaPro DB1), 82,2 % (NinaPro DB2), 94,1 % (BioPatRec26MOV), 99,7 % (CapgMyo-DBa), 94,5 % (csl-hdemg)	Гибридная архитектура CNN-RNN объединяет пространственную и временную информацию, а механизм внимания улучшает фокусировку на значимых частях сигнала. Недостатки: вычислительная сложность и требование тонкой настройки параметров.
Анализ эффективности методов машинного обучения в задаче распознавания жестов на основе данных электромиографических сигналов / Analysis of the Effectiveness of Machine Learning Methods in the Problem of Gesture Recognition Based on the Data of Electromyographic Signals	НБК: 73,58 %	Из преимуществ можно выделить низкую временную сложность, малое время работы и возможность использования с данными большого объема. Недостатками являются низкая точность и не постоянное выполнение предположения о независимости признаков.
	Метод / k-ближайших соседей (kNN): 80,73 %	Обладает высокой точностью, но имеет значительную временную сложность
	Метод опорных векторов: 75,92 %	Эффективен для пространств высокой размерности, но долго обучается (для больших наборов данных)
	Градиентный бустинг: 80,32 %	Высокий баланс между точностью и скоростью, но требует больше вычислительных ресурсов и детальной настройки гиперпараметров

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
	Дерево решений: 79,12 %	Простота интерпретации и хорошая скорость, но уступает в точности и имеет нестабильность предсказаний
	Случайный лес: 81,19 %	Более высокая точность, но присутствует временная сложность
	Ансамбль НБК и градиентного бустинга: 81,55 %	Лучшая точность среди всех методов в исследовании. Требует больше времени для классификации, чем другие методы.
	Ансамбль (НБК, дерево решений): 80,60 %	Компенсация ошибок базовых методов, среднее время работы
	Ансамбль (градиентный бустинг, дерево решений): 79,56 %	Улучшение точности относительно базовых методов, но более высокая сложность и время работы
ConTraNet: A Hybrid Network for Improving the Classification of EEG and EMG Signals with Limited Training Data	ConTraNet (BCI Comp. IV, 2-классовый MI-EEG): 83,61 %	Хорошая обобщающая способность. Надежное извлечение признаков из EEG. Немного снижает точность на ограниченных данных.
	ConTraNet (sEMG, 10-классовый Mendeley Data): 77,15 %	Значительное улучшение по сравнению с CNN-LSTM. Хорошо справляется с шумными sEMG-данными.
	EEGNet (2-классовый MI-EEG) [Lawhern et al., 2018]: 81,81 %	Компактная архитектура, но проигрывает на сложных задачах.
	ShallowNet (2-классовый MI-EEG) [Schirrmeister et al., 2017]: 78,73 %	Простая архитектура, испытывает трудности с большим числом классов.
	CNN-LSTM _{1,32} (2-классовый MI-EEG): 64,31 %	Плохо обобщается, уступает другим методам. Вероятно, LSTM неэффективен для этой задачи
	CNN-LSTM _{1,32} (3-классовый MI-EEG): 46,61 %	Низкая точность. Не справляется с увеличением сложности задачи.
	CNN-LSTM _{1,32} (4-классовый MI-EEG): 34,50 %	Низкая точность.
	CNN-LSTM _{1,32} (10-классовый sEMG): 23,55 %	Крайне низкая точность для sEMG, не годится для практического применения.
	CNN-LSTM _{1,32} (7-классовый sEMG V1, 6 сек): 39,93 %	Точность лучше, чем у двух предыдущих моделей, но остается низкой, относительно других моделей.

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
	CNN-LSTM1,32 (7-классовый sEMG V1, 4 сек): 43,69 %	Точность немного лучше на коротких сигналах, но уступает другим методам.
Classification of Electromyographic Hand Gesture Signals Using Machine Learning Techniques	CAE+CNN: 99,38 %	Высокая точность в случаях (с) и (d), устойчива к шуму, но требует большого количества данных, имеет довольно низкую точность в случаях (a) и (b).
	CNN: 95,00 %	Имеет преимущество при обработке высокоразмерных данных, но удовлетворительную производительность и низкую точность в некоторых случаях (в исследовании в случае (a) и (b)).
	Нейронная сеть (NN): 86,88 %	Высокая точность в случаях (a), (с), (d), хорошая устойчивость, но требует большого количества оперативной памяти для обучения и имеет низкий уровень точности в случае (b).
	К-ближайших соседей (KNN): 38,42 %	Показал высокую точность в случаях (a) и (с), но крайне низкую точность в случаях (b) и (d).
	Метод случайного леса (Random Forest): 78,13 %	Хорошая точность в случаях (a), (с), (d), но низкая точность в случае (b).
	Решающее дерево (Decision Tree): 84,00 %	Быстрая интерпретируемая модель, показала высокую точность в случаях (a), (с), (d), но крайне низкую точность в случае (b).
	Метод опорных векторов (SVM): 16,25 %	Показал хорошую точность в случае (с), но крайне низкую точность в случаях (b) и (d).
	Логистическая регрессия: 23,12 %	Плохо подходит для сложных задач, не справляется с нелинейными зависимостями, показала плохую точность во всех случаях.
	Наивный байес (Naive Bayes): 17,50 %	Очень низкая точность во всех случаях.
Classification of EMG Signals Using Convolution Neural Network	CNN1 (Raw Signal): 90,62 % [Sapsanis et al., 2013]	Приемлемая точность даже без предобработки.
	CNN2 (FFT): 67,30 %	Низкая точность, метод не подходит для таких задач.
	CNN3 (RMS): 88,59 %	Хорошие результаты точности, но хуже, чем у CNN4.
	CNN4 (EMD): 95,90 %	Лучший результат, позволяет выделить значимые компоненты сигнала, что улучшает классификацию.
Intra Subject Approach for Gait Event Prediction by Neural Network Interpretation of EMG Signals	NN: 96,1 %	Из преимуществ можно выделить: высокую точность, сниженную ошибку (MAE) при прогнозировании событий HS и TO. Недостатки выражаются в требовании персонализированного обучения модели для каждого нового пациента и высокой вычислительной сложности.

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
A Novel Channel Selection Method for Multiple Motion Classification Using High-Density Electromyography	Linear Discriminant Analysis (LDA), в исследовании точное значение не указано, но исходя из представленных графиков: 91,5 % (18 монополярных ЭМГ-каналов) 93,3 % (18 биполярных ЭМГ-каналов)	Преимущества заключаются в простоте алгоритма и низкой вычислительной стоимости [Englehart et al., 1999], но метод имеет зависимость от признаков.
	K-Nearest Neighbors (KNN): 93,03 % (18 монополярных ЭМГ-каналов) 94,50 % (56 монополярных ЭМГ-каналов) 95,58 % (18 биполярных ЭМГ-каналов) 98,17 % (45 биполярных ЭМГ-каналов)	Присутствует толерантность к произвольному распределению данных [Nazarpour et al., 2007], но модель имеет высокую вычислительную сложность.
Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG	CNN: 92 %	Результаты показали, что скорость обучения 0.001 с 100 эпохами значительно превосходила ($p < 0.05$) другие параметры, относительно результатов точности. В результате исследования модель показала высокую точность. Из недостатков можно выделить высокую вычислительную сложность.
Cross-Domain MLP and CNN Transfer Learning for Biological Signal Processing: EEG and EMG	MLP (Random Init – EMG): 84,76 %	Хорошая базовая точность для классификации жестов EMG, но требуется ручная обработка признаков и ресурсоемкий поиск топологии через алгоритм DEvo.
	CNN (Random Init – EMG): 88,55 %	Наивысшая точность среди всех моделей и эффективная работа с 2D-представлением сигналов, но требуется преобразование сигналов в изображения.
	ResNet50 (ImageNet Init) [He et al., 2016]: 74,92 %	Наименьшая точность среди всех моделей и плохая адаптация к EMG-данным.
Electromyogram-Based Classification of Hand and Finger Gestures	ANN: 94 %	Лучшая точность среди использованных в исследовании методов, устойчивость к индивидуальным различиям в ЭМГ-сигналах,

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
Using Artificial Neural Networks		эффективность даже с малым числом каналов и только временными признаками. Но присутствует высокая вычислительная сложность (2000 эпох, большой размер сети), требование тщательного подбора гиперпараметров.
	SVM: 87,6 %	Хорошая обобщающая способность на данном наборе данных и эффективность на малых выборках, но требует ручного подбора ядра и параметров.
	RF: 83,1 %	Средняя точность, подходит для задач с большим количеством признаков. Из недостатков можно выделить более низкую точность, чем у ANN и SVM и более высокую дисперсию, чем у ANN.
	LR: 53,9 %	Из преимуществ можно выделить простоту алгоритма, а также быстрое обучение. Недостатки выражены в довольно низкой точности, плохой работе с нелинейными зависимостями в данных.
EMGHandNet: A Hybrid CNN and Bi-LSTM Architecture for Hand Activity Classification Using Surface EMG Signals	EMGHandNet: NinaPro DB1: 95,77 % NinaPro DB2: 95,9 % NinaPro DB4: 91,65 % UCI Gesture: 98,33 % BioPatRec DB2: 91,29 %	Гибридная архитектура CNN и Bi-LSTM позволяет извлекать кросс-канальные и временные признаки. Поддерживает end-to-end обучение. Двухнаправленный LSTM улучшает понимание динамики жеста. Но имеет высокую вычислительную сложность и нуждается в перенастройке под отдельные наборы данных.
	MsCNN [Wei et al., 2019]: NinaPro DB1: 74,25 % NinaPro DB2: 50,99 % NinaPro DB4: 34,1 % UCI Gesture: 95,58 % BioPatRec DB2: 66,18 %	Показал наихудшую производительность среди сравниваемых методов в данном исследовании
	EvCNN [Olsson et al., 2020]: NinaPro DB1: 68,06 % NinaPro DB2: 80,54 % NinaPro DB4: 22,3 %	Метод имеет автоматическую генерацию топологии CNN, имеет низкую вычислительную сложность, но уступает в точности и не оптимизирован для долгосрочных временных зависимостей.

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
	UCI Gesture: 45,55 % BioPatRec DB2: 84,19 %	
	CNNLM [Chen et al., 2021]: NinaPro DB1: 92,99 % NinaPro DB2: 87,17 % NinaPro DB4: 87,37 % UCI Gesture: 86,51 % BioPatRec DB2: 89,17 %	Близка к EMGHandNet по точности, но всё же уступает. Существует риск потери временной информации из-за плотных слоев. Имеет ограниченную способность к двунаправленному анализу.
EMG-Driven Hand Model Based on the Classification of Individual Finger Movements	Fine и Weighted k-NN: 98 %	Имеет высокую точность для всех жестов. Но чувствителен к выбору метрики и расстояния, а также числа соседей.
Design of a Flexible Wearable Smart sEMG Recorder Integrated Gradient Boosting Decision Tree Based Hand Gesture Recognition	GBDT: 91 %	Из преимуществ можно выделить: низкую задержку благодаря параллельной реализации GBDT на FPGA и хорошую точность для 12 жестов, низкую зависимость от выбора признаков, отсутствие необходимости в сложных вычислениях, но существует сложность аппаратной реализации.
Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks	DQN (без LSTM): 90,37 % (классификация), 82,52 % (распознавание)	Имеет лучшую точность в исследовании и подходит для онлайн-обучения, но присутствует зависимость от тщательной настройки гиперпараметров и ограниченная интерпретируемость.
	DQN-LSTM: 51,6 % (классификация), 26,6 % (распознавание)	Теоретически лучше для временных данных, но имеет крайне низкую точность в данном случае.
Fully Embedded Myoelectric Control for a Wearable Robotic Hand Orthosis	SVM (автономно, 5 жестов): 98,0 %	Высокая точность для 5 жестов и подходит для жестов, записанных вручную, но сильно зависит от качества тренировочных данных
	SVM (онлайн, 3 жеста): 94,3 %	Работает в реальном времени и интегрирован в портативную систему, но имеет задержку в 600 мс и ложные срабатывания (2.3–3.3 % для rest/open)
Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an	ANN (модель, разработанная в исследовании): 98,7 %	Высокая точность распознавания, реальное время отклика (227.76 мс), возможность распознавания до завершения жеста, но имеется зависимость от размера скользящего окна и порога активации.

Название исследования / Name of the research	Точность, указанная в исследованиях / Accuracy indicated in the research	Краткая характеристика / Brief description
Artificial Neural Network	ANN [He et al., 2016]: 90,7 %.	Простота архитектуры, но точность ниже и не учитывается отклик в реальном времени
	k-NN [He et al., 2016]: 90,54 %.	Время отклика в исследовании не измерялось или не удовлетворяет требованиям к реальному времени.
	SVM [Motoche, Benalcázar, 2018]: 93,99 %.	SVM имеет лучшую точность, чем k-NN, но все еще уступает ANN. В исследовании этот метод не рассматривается как подходящий для реального времени.




Рис. 1. Общая тенденция точности методов
Fig. 1. General trend of method accuracy

Также для определения точности моделей возможно использовать сравнение их результатов на открытых наборах данных, если такие проверки проводились в исследованиях. На рис. 2 изображены значения средней точности методов, если на одном наборе данных проверялось минимум 2 метода.

Модели, сочетающие CNN и RNN/Bi-LSTM, имеют преимущество в точности и стабильности в исследовании на открытых наборах данных. CNNLM, хотя и уступает гибридным методам, но имеет баланс между точностью и простотой. Простые архитектуры (MsCNN, EvCNN) показывают нестабильность и проявляют сильную зависимость результатов от наборов данных. ConTraNet демонстрирует хорошую обобщающую способность, но необходимо тестирование на большем количестве наборов данных.



Рис. 2. Средняя точность методов на открытых наборах данных ЭМГ-сигналов
Fig. 2. Average accuracy of the methods on open datasets of EMG signals

Заключение

Развитие современных протезов конечностей все чаще связано с внедрением интеллектуальных систем управления, в частности основанных на ЭМГ-сигналах и методах машинного обучения для их обработки. В ходе анализа существующих исследований и сравнительной оценки методов можно сделать ряд выводов.

Во-первых, современные нейросетевые архитектуры демонстрируют более высокую точность по сравнению с классическими методами (SVM, LDA, RF, DT, LR, NB), однако для более детального сравнения отсутствует достаточное количество тестовых данных.

Во-вторых, несмотря на успехи нейросетевого подхода, эффективность моделей во многом зависит от используемого набора данных. Некоторые методы (например, **ConTraNet** или **CNN-RNN**) показали хорошие результаты, но тестировались только на двух наборах данных, что ограничивает анализ их точности. Это подчеркивает необходимость стандартизации экспериментов и более широкого тестирования на разнообразных данных.

В-третьих, эффективное использование ЭМГ-датчиков и качественная предварительная обработка сигналов остаются критически важными элементами успешной работы системы. Это может проявляться в сильном разбросе значений точности по различным наборам данных из открытого доступа.

В данной статье были рассмотрены основные типы используемых протезов и их характеристики. Изучены исследования, применяющие технологии машинного обучения для обработки ЭМГ-сигнала, наборы данных, параметры и гиперпараметры используемых методов, а также точность каждого метода. В целом, анализ показывает, что применение методов машинного обучения, особенно нейросетевых моделей, открывает новые горизонты в создании более точных, адаптивных и «интуитивных» протезов. Однако для дальнейшего прогресса необходимо сосредоточиться на решении проблем универсализации моделей и наборов данных, более широком использовании моделей на открытых наборах данных, улучшении качества самих данных и интеграции систем в реальные условия использования.

Список литературы

- Козырь П.С., Савельев А.И. 2021. Анализ эффективности методов машинного обучения в задаче распознавания жестов на основе данных электромиографических сигналов. *Компьютерные исследования и моделирование*, 13(1): 175–194. DOI 10.20537/2076-7633-2021-13-1-175-194. – EDN OTBBNJ.
- Коробенков Н.О., Кочетов С.С., Григоров П.А. 2019. Бионическое протезирование конечности. *Сибирский медицинский журнал*, 158(3), 22–27.
- Персон Р.С. 1969. Электромиография в исследованиях человека. М.: Наука, 231.
- Уразбахтина Ю.О., Камалова К.Р., Морозова Е.С. 2022. Бионические протезы верхних конечностей: сравнительный анализ и перспективы использования. *Международный научно-исследовательский журнал*, 1-2(115): 125–130.
- Ali O., Saif ur R.M., Glasmachers T., Iossifidis I., Klaes C. 2023. ConTraNet: A hybrid network for improving the classification of EEG and EMG signals with limited training data. *Computers in Biology and Medicine*, 168. 107649. 10.1016/j.compbimed.2023.107649.
- Amma C., Krings T., Boer J., Schultz T. 2015. Advancing Muscle-Computer Interfaces with High-Density Electromyography. In: ACM Conference on Human Factors in Computing Systems. 929–938.
- Arteaga M., Castiblanco J., Mondragón I., Colorado Ju., Alvarado-Rojas C. 2020. EMG-driven hand model based on the classification of individual finger movements. *Biomedical Signal Processing and Control*, 58. 101834. 10.1016/j.bspc.2019.101834.
- Ashford J., Bird J.J., Campelo F., Faria D.R. 2019. Classification of EEG signals based on image representation of statistical features. Proc. UK Workshop Comput. Intell. Portsmouth, U.K.: Springer,
- Asif A.R., Waris M., Gilani S. Jamil M. Ashraf H., Shafique M. Niazi I. 2020. Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG. *Sensors*, 20. 10.3390/s20061642.
- Atzori M., Gijbarts A., Castellini C., Caputo B., Hager A.G.M., Elsig S., et al. 2014. Electromyography data for noninvasive naturally-controlled robotic hand prostheses. *Scientific data*, 1.
- Bakircioğlu K., Ozkurt N. 2020. Classification of Emg Signals Using Convolution Neural Network. *International Journal of Applied Mathematics Electronics and Computers*, 8. 10.18100/ijamec.795227.
- Becerra-Fajardo L., Minguillon Je., Krob M., Rodrigues de C.C., Gonzalez-Sanchez M., Megía-García Á., Galán C., Henares F., Comerma A., del-Ama A., Gil-Agudo A., Grandas F., Schneider-Ickert A., Barroso F., Ivorra A. 2024. First-in-human demonstration of floating EMG sensors and stimulators wirelessly powered and operated by volume conduction. *Journal of NeuroEngineering and Rehabilitation*, 21. 10.1186/s12984-023-01295-5.
- Benalcázar M., Barona L., Valdivieso L., Aguas X., Zea J. 2020. EMG-EPN-612 Dataset; CERN: Geneva, Switzerland.
- Bird J., Kobylarz Jh., Faria D, Ekárt A., Ribeiro E. 2020. Cross-domain MLP and CNN Transfer Learning for Biological Signal Processing: EEG and EMG. *IEEE Access*, 1-1. 10.1109/ACCESS.2020.2979074.
- Bird J.J., Faria D.R., Manso L.J., Ekárt A., Buckingham C.D. 2019. A deep evolutionary approach to bioinspired classifier optimisation for brain-machine interaction. *Complexity*, vol. 2019, 1–14, Mar.
- Chen T., Guestrin C. 2016. Xgboost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. *ACM*, 785–794.
- Chen X., Li Y., Hu R., Zhang X., Chen X. 2021. Hand gesture recognition based on surface electromyography using convolutional neural network with transfer learning method. *IEEE J Biomed Health Inform*, 25(4): 1292–1304.
- Dewald H.A., Lukyanenko P., Lambrecht J.M., Anderson J.R., Tyler D.J., Kirsch R.F., et al. 2019. Stable, three degree-of-freedom myoelectric prosthetic control via chronic bipolar intramuscular electrodes: a case study. *J Neuroeng Rehabil*, 16(1): 147.
- Di Nardo F. 2019. Intra-subject classification of gait phases by neural network interpretation of EMG signals.
- Englehart K., Hudgins B. 2003. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Bio-Medical Engineering*, 50(7): 848–854.
- Englehart K., Hudgins B., Parker P.A., Stevenson M. 1999. Classification of the myoelectric signal using time-frequency based representations. *Med. Eng. Phys.*, 21: 431–438
- Friedman J.H. 2001. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189–1232.

- Geng W., Du Y., Jin W., Wei W., Hu Y., Li J. 2016. Gesture recognition by instantaneous surface EMG images. *Scientific Reports*, 6: 36571.
- Geng Ya., Zhang X., Zhang Y.T., Li P. 2014. A novel channel selection method for multiple motion classification using high-density electromyography. *Biomedical engineering online*, 13: 102. 10.1186/1475-925X-13-102.
- Goldberger A.L., et al. 2000. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23): 215–220.
- Graupe D., Cline W.K. 1975. Functional separation of EMG signals via ARMA identification methods for prosthesis control purposes. *IEEE Trans Syst Man Cybern*, SMC-5: 252–259.
- He K., Zhang X., Ren S., Sun J. 2016. Deep residual learning for image recognition. Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2016, 770–778.
- Hu Yu., Wong Yo., Wei W., Du Yu., Kankanhalli M., Geng W. 2018. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PLOS One*, 13. e0206049. 10.1371/journal.pone.0206049.
- Hudgins B., Parker P., Scott R.N. 1993. A New Strategy for Multifunction Myoelectric Control. *IEEE Trans. Biomed. Eng.*, 40(1): 82–94.
- Jia G., Lam H.-K., Liao Ju., Wang R. 2020. Classification of Electromyographic Hand Gesture Signals using Machine Learning Techniques. *Neurocomputing*, 401. 10.1016/j.neucom.2020.03.009.
- Karnam N.K., Dubey Sh.R., Turlapaty A., Gokaraju B. 2022. EMGHandNet: A hybrid CNN and Bi-LSTM architecture for hand activity classification using surface EMG signals. *Biocybernetics and Biomedical Engineering*, 42. 10.1016/j.bbe.2022.02.005.
- Khushaba R.N., Kodagoda S., Takruri M., Dissanayake G. 2012. Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Syst. Appl.*, 39(12): 10731–10738, Sep.
- Kilic E. 2017. EMG based neural network and admittance control of an active wrist orthosis, *J. Mech. Sci. Technol.*, 31(12): 6093–6106.
- Kimoto A., Fujiyama H., Machida M. 2023. A Wireless Multi-Layered EMG/MMG/NIRS Sensor for Muscular Activity Evaluation. *Sensors*, 23. 1539. 10.3390/s23031539.
- Kuiken T.A., Li G., Lock B.A. et al. 2009. Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms. *JAMA*, 2009 Feb 11. 301(6): 619–628.
- Lawhern V.J., Solon A.J., Waytowich N.R., Gordon S.M., Hung C.P., Lance B.J. 2018. EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces, *J. Neural. Eng.*, (Oct. 2018), 15(5). 056013.
- Lee K.H., Min Ji., Byun S. 2021. Electromyogram-Based Classification of Hand and Finger Gestures Using Artificial Neural Networks. *Sensors*, 22: 225. 10.3390/s22010225.
- Lerner Z.F., Board W.J., Browning R.C. 2014. Effects of obesity on lower extremity muscle function during walking at two speeds. *Gait Posture*, 39(3): 978–984.
- Lobov S., Krilova N., Kastalskiy I., Kazantsev V., Makarov V.A. 2018. Latent factors limiting the performance of sEMG-interfaces. *Sensors*, 18(4): 1122.
- Motoche C., Benalcázar M.E. 2018. Real-time hand gesture recognition based on electromyographic signals and artificial neural networks. In Proceedings of the International Conference on Artificial Neural Networks, Rhodes, Greece, 4–7 October 2018; 352–361.
- Nazarpour K., Sharafat A.R., Firoozabadi S.M.P. 2007. Application of higher order statistics to surface electromyogram signal classification. *IEEE Trans. Biomed. Eng.*, 54:1762–1769.
- Ng C.L., Reaz M.B.I., Crespo M., Cicuttin A., Shapiai M., Ali S. 2024. A Versatile and Wireless Multichannel Capacitive EMG Measurement System for Digital Healthcare. *IEEE Internet of Things Journal*, 1-1. 10.1109/JIOT.2024.3370960.
- Ng Ch.L., Reaz M.B.I., Crespo M., Cicuttin A., Shapiai M., Ali S., Kamal N. 2023. A Flexible Capacitive Electromyography Biomedical Sensor for Wearable Healthcare Applications. *IEEE Transactions on Instrumentation and Measurement*, 1-1. 10.1109/TIM.2023.3281563.
- Olsson A.E., Bjorkman A., Antfolk C. 2020. Automatic discovery of resource-restricted convolutional neural network topologies for myoelectric pattern recognition. *Comput. Biol. Med.*, 120: 103723.
- Ortiz-Catalan M., Branemark R., Hakansson B. 2013. BioPatRec: A modular research platform for the control of artificial limbs based on pattern recognition algorithms. *Source Code Biol. Med.*, 8(1): 11.
- Ozdemir M.A. 2021. Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures, Mendeley, 15.

- Ozdemir M.A., Kisa D.H., Guren O., Akan A. 2022. Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures, *Data Brief*, 41. 107921.
- Pizzolato S., Tagliapietra L., Cognolato M., Reggiani M., Muller H., Atzori M. 2017. Comparison of six electromyography acquisition setups on hand movement classification tasks. *PLOS One*, 10; 12(10): 1–17.
- Resnik L. 2011. Development and testing of new upper-limb prosthetic devices: research designs for usability testing. *J. Rehabil. Res. Dev*, 48(6): 697–706.
- Ryser F., Butzer T., Held J.P., Lambercy O., Gassert R. 2017. Fully embedded myoelectric control for a wearable robotic hand orthosis. *IEEE Int. Conf. Rehabil. Robot.* 2017 Jul. 615–621. doi: 10.1109/ICORR.2017.8009316. PMID: 28813888.
- Sapsanis C., Georgoulas G., Tzes A., Lymberopoulos D. 2013. Improving EMG based classification of basic hand movements using EMD.
- Schirrmeister R.T., et al. 2017. Deep learning with convolutional neural networks for EEG decoding and visualization: convolutional Neural Networks in EEG Analysis, *Hum. Brain Mapp*, 38(11): 5391–5420.
- Song W., Wang A., Chen Ya., Bai Sh., Lin Zh., Yan N., Luo D., Liao Yi., Zhang M., Wang Zh., Xie X. 2019. Design of a Wearable Smart sEMG Recorder Integrated Gradient Boosting Decision Tree based Hand Gesture Recognition. *IEEE transactions on biomedical circuits and systems*, 10.1109/TBCAS.2019.2953998.
- Triwiyanto T., Wahyunggoro O., Nugroho H.A., Herianto H. 2017. An investigation into time domain features of surface electromyography to estimate the elbow joint angle. *Adv. Electr. Electron. Eng.*, 15(3): 448–458,
- Triwiyanto T., Pawana I., Purnomo M. 2020. An Improved Performance of Deep Learning Based on Convolution Neural Network to Classify the Hand Motion by Evaluating Hyper Parameter. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 1-1. 10.1109/TNSRE.2020.2999505.
- Valdivieso L., Váscquez H.Ju., Barona L., Benalcázar M. 2023. Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks. *Sensors*, 23. 10.3390/s23083905.
- Váscquez J.P., Barona L.L.I., Valdivieso C.A.L., Benalcázar M.E. 2022. Hand Gesture Recognition Using EMG-IMU Signals and Deep Q-Networks. *Sensors*, 22, 9613.
- Wei W., Wong Y., Du Y., Hu Y., Kankanhalli M., Geng W. 2019. A multi-stream convolutional neural network for sEMG-based gesture recognition in musclecomputer interface. *Pattern Recognit. Lett.*, 119: 131–138.
- Young A.J., Hargrove L.J., Kuiken T.A. 2011. The effects of electrode size and orientation on the sensitivity of myoelectric pattern recognition systems to electrode shift. *IEEE Trans. Biomed. Eng.*, 58(9): 2537–2544
- Zhang Ch., Shih Ya.-H., Qian Ji. 2019. Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network. *Sensors*, 19. 3170. 10.3390/s19143170.

References

- Kozyr P.S., Saveliev A.I. 2021. Analysis of the effectiveness of machine learning methods in the problem of gesture recognition based on the data of electromyographic signals. *Computer research and modeling*, 13(1): 175–194 (in Russian). DOI 10.20537/2076-7633-2021-13-1-175-194. EDN OTBBNJ.
- Korobnikov N.O., Kochetov S.S., Grigorov P.A. 2019. Bionic limb prosthetics. *Siberian Medical Journal*, 158(3), 22-27 (in Russian).
- Person R.S. 1969. Ehlektromiografiya v issledovaniyakh cheloveka [Electromyography in human research]. M.: Nauka, 231 (in Russian).
- Urazbakhtina Yu.O., Kamalova K.R., Morozova E.S. 2022. Bionic upper limb prostheses: comparative analysis and prospects of use. *International research journal*, 1-2(115): 125–130 (in Russian).
- Ali O., Saif ur R.M., Glasmachers T., Iossifidis I., Klaes C. 2023. ConTraNet: A hybrid network for improving the classification of EEG and EMG signals with limited training data. *Computers in Biology and Medicine*, 168. 107649. 10.1016/j.compbiomed.2023.107649.
- Amma C., Krings T., Boëer J., Schultz T. 2015. Advancing Muscle-Computer Interfaces with High-Density Electromyography. In: ACM Conference on Human Factors in Computing Systems. 929–938.
- Arteaga M., Castiblanco J., Mondragón I., Colorado Ju., Alvarado-Rojas C. 2020. EMG-driven hand model based on the classification of individual finger movements. *Biomedical Signal Processing and Control*, 58. 101834. 10.1016/j.bspc.2019.101834.
- Ashford J., Bird J.J., Campelo F., Faria D.R. 2019. Classification of EEG signals based on image representation of statistical features. Proc. UK Workshop Comput. Intell. Portsmouth, U.K.: Springer,

- Asif A.R., Waris M., Gilani S. Jamil M. Ashraf H., Shafique M. Niazi I. 2020. Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG. *Sensors*, 20. 10.3390/s20061642.
- Atzori M., Gijssberts A., Castellini C., Caputo B., Hager A.G.M., Elsig S., et al. 2014. Electromyography data for noninvasive naturally-controlled robotic hand prostheses. *Scientific data*, 1.
- Bakırcıoğlu K., Ozkurt N. 2020. Classification of Emg Signals Using Convolution Neural Network. *International Journal of Applied Mathematics Electronics and Computers*, 8. 10.18100/ijamec.795227.
- Becerra-Fajardo L., Minguillon Je., Krob M., Rodrigues de C.C., Gonzalez-Sanchez M., Megía-García Á., Galán C., Henares F., Comerma A., del-Ama A., Gil-Agudo A., Grandas F., Schneider-Ickert A., Barroso F., Ivorra A. 2024. First-in-human demonstration of floating EMG sensors and stimulators wirelessly powered and operated by volume conduction. *Journal of NeuroEngineering and Rehabilitation*, 21. 10.1186/s12984-023-01295-5.
- Benalcázar M., Barona L., Valdivieso L., Aguas X., Zea J. 2020. EMG-EPN-612 Dataset; CERN: Geneva, Switzerland.
- Bird J., Kobylarz Jh., Faria D, Ekárt A., Ribeiro E. 2020. Cross-domain MLP and CNN Transfer Learning for Biological Signal Processing: EEG and EMG. *IEEE Access*, 1-1. 10.1109/ACCESS.2020.2979074.
- Bird J.J., Faria D.R., Manso L.J., Ekárt A., Buckingham C.D. 2019. A deep evolutionary approach to bioinspired classifier optimisation for brain-machine interaction. *Complexity*, vol. 2019, 1–14, Mar.
- Chen T., Guestrin C. 2016. Xgboost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. *ACM*, 785–794.
- Chen X., Li Y., Hu R., Zhang X., Chen X. 2021. Hand gesture recognition based on surface electromyography using convolutional neural network with transfer learning method. *IEEE J Biomed Health Inform*, 25(4): 1292–1304.
- Dewald H.A., Lukyanenko P., Lambrecht J.M., Anderson J.R., Tyler D.J., Kirsch R.F., et al. 2019. Stable, three degree-of-freedom myoelectric prosthetic control via chronic bipolar intramuscular electrodes: a case study. *J Neuroeng Rehabil*, 16(1): 147.
- Di Nardo F. 2019. Intra-subject classification of gait phases by neural network interpretation of EMG signals.
- Englehart K., Hudgins B. 2003. A robust, real-time control scheme for multifunction myoelectric control. *IEEE Transactions on Bio-Medical Engineering*. 50(7): 848–854.
- Englehart K., Hudgins B., Parker P.A., Stevenson M. 1999. Classification of the myoelectric signal using time-frequency based representations. *Med. Eng. Phys.*, 21: 431–438
- Friedman J.H. 2001. Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189–1232.
- Geng W., Du Y., Jin W., Wei W., Hu Y., Li J. 2016. Gesture recognition by instantaneous surface EMG images. *Scientific Reports*, 6: 36571.
- Geng Ya., Zhang X., Zhang Y.T., Li P. 2014. A novel channel selection method for multiple motion classification using high-density electromyography. *Biomedical engineering online*, 13: 102. 10.1186/1475-925X-13-102.
- Goldberger A.L., et al. 2000. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*, 101(23): 215–220.
- Graupe D., Cline W.K. 1975. Functional separation of EMG signals via ARMA identification methods for prosthesis control purposes. *IEEE Trans Syst Man Cybern*, SMC-5: 252–259.
- He K., Zhang X., Ren S., Sun J. 2016. Deep residual learning for image recognition. Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jun. 2016, 770–778.
- Hu Yu., Wong Yo., Wei W., Du Yu., Kankanhalli M., Geng W. 2018. A novel attention-based hybrid CNN-RNN architecture for sEMG-based gesture recognition. *PLOS One*, 13. e0206049. 10.1371/journal.pone.0206049.
- Hudgins B., Parker P., Scott R.N. 1993. A New Strategy for Multifunction Myoelectric Control. *IEEE Trans. Biomed. Eng.*, 40(1): 82– 94.
- Jia G., Lam H.-K., Liao Ju., Wang R. 2020. Classification of Electromyographic Hand Gesture Signals using Machine Learning Techniques. *Neurocomputing*, 401. 10.1016/j.neucom.2020.03.009.
- Karnam N.K., Dubey Sh.R., Turlapaty A., Gokaraju B. 2022. EMGHandNet: A hybrid CNN and Bi-LSTM architecture for hand activity classification using surface EMG signals. *Biocybernetics and Biomedical Engineering*, 42. 10.1016/j.bbe.2022.02.005.
- Khushaba R.N., Kodagoda S., Takruri M., Dissanayake G. 2012. Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Syst. Appl.*, 39(12): 10731–10738, Sep.

- Kilic E. 2017. EMG based neural network and admittance control of an active wrist orthosis, *J. Mech. Sci. Technol.*, 31(12): 6093–6106.
- Kimoto A., Fujiyama H., Machida M. 2023. A Wireless Multi-Layered EMG/MMG/NIRS Sensor for Muscular Activity Evaluation. *Sensors*, 23. 1539. 10.3390/s23031539.
- Kuiken T.A., Li G., Lock B.A. et al. 2009. Targeted muscle reinnervation for real-time myoelectric control of multifunction artificial arms. *JAMA*. 2009 Feb 11. 301(6): 619–628.
- Lawhern V.J., Solon A.J., Waytowich N.R., Gordon S.M., Hung C.P., Lance B.J. 2018. EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces, *J. Neural. Eng.*, (Oct. 2018), 15(5). 056013.
- Lee K.H., Min Ji., Byun S. 2021. Electromyogram-Based Classification of Hand and Finger Gestures Using Artificial Neural Networks. *Sensors*, 22: 225. 10.3390/s22010225.
- Lerner Z.F., Board W.J., Browning R.C. 2014. Effects of obesity on lower extremity muscle function during walking at two speeds. *Gait Posture*, 39(3): 978–984.
- Lobov S., Krilova N., Kastalskiy I., Kazantsev V., Makarov V.A. 2018. Latent factors limiting the performance of sEMG-interfaces. *Sensors*, 18(4): 1122.
- Motoche C., Benalcázar M.E. 2018. Real-time hand gesture recognition based on electromyographic signals and artificial neural networks. In Proceedings of the International Conference on Artificial Neural Networks, Rhodes, Greece, 4–7 October 2018; 352–361.
- Nazarpour K., Sharafat A.R., Firoozabadi S.M.P. 2007. Application of higher order statistics to surface electromyogram signal classification. *IEEE Trans. Biomed. Eng.*, 54:1762–1769.
- Ng C.L., Reaz M.B.I., Crespo M., Cicuttin A., Shapiai M., Ali S. 2024. A Versatile and Wireless Multichannel Capacitive EMG Measurement System for Digital Healthcare. *IEEE Internet of Things Journal*, 1-1. 10.1109/JIOT.2024.3370960.
- Ng Ch.L., Reaz M.B.I., Crespo M., Cicuttin A., Shapiai M., Ali S., Kamal N. 2023. A Flexible Capacitive Electromyography Biomedical Sensor for Wearable Healthcare Applications. *IEEE Transactions on Instrumentation and Measurement*, 1-1. 10.1109/TIM.2023.3281563.
- Olsson A.E., Bjorkman A., Antfolk C. 2020. Automatic discovery of resource-restricted convolutional neural network topologies for myoelectric pattern recognition. *Comput. Biol. Med.*, 120: 103723.
- Ortiz-Catalan M., Branemark R., Hakansson B. 2013. BioPatRec: A modular research platform for the control of artificial limbs based on pattern recognition algorithms. *Source Code Biol. Med.*, 8(1): 11.
- Ozdemir M.A. 2021. Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures, Mendeley, 15.
- Ozdemir M.A., Kisa D.H., Guren O., Akan A. 2022. Dataset for multi-channel surface electromyography (sEMG) signals of hand gestures, *Data Brief*, 41. 107921.
- Pizzolato S., Tagliapietra L., Cognolato M., Reggiani M., Muller H., Atzori M. 2017. Comparison of six electromyography acquisition setups on hand movement classification tasks. *PLOS One*, 10; 12(10): 1–17.
- Resnik L. 2011. Development and testing of new upper-limb prosthetic devices: research designs for usability testing. *J. Rehabil. Res. Dev.*, 48(6): 697–706.
- Ryser F., Butzer T., Held J.P., Lambercy O., Gassert R. 2017. Fully embedded myoelectric control for a wearable robotic hand orthosis. *IEEE Int. Conf. Rehabil. Robot.* 2017 Jul. 615–621. doi: 10.1109/ICORR.2017.8009316. PMID: 28813888.
- Sapsanis C., Georgoulas G., Tzes A., Lymberopoulos D. 2013. Improving EMG based classification of basic hand movements using EMD.
- Schirrmester R.T., et al. 2017. Deep learning with convolutional neural networks for EEG decoding and visualization: convolutional Neural Networks in EEG Analysis, *Hum. Brain Mapp.*, 38(11): 5391–5420.
- Song W., Wang A., Chen Ya., Bai Sh., Lin Zh., Yan N., Luo D., Liao Yi., Zhang M., Wang Zh., Xie X. 2019. Design of a Wearable Smart sEMG Recorder Integrated Gradient Boosting Decision Tree based Hand Gesture Recognition. *IEEE transactions on biomedical circuits and systems*, 10.1109/TBCAS.2019.2953998.
- Triwiyanto T., Wahyunggoro O., Nugroho H.A., Herianto H. 2017. An investigation into time domain features of surface electromyography to estimate the elbow joint angle. *Adv. Electr. Electron. Eng.*, 15(3): 448–458.
- Triwiyanto T., Pawana I., Purnomo M. 2020. An Improved Performance of Deep Learning Based on Convolution Neural Network to Classify the Hand Motion by Evaluating Hyper Parameter. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 1-1. 10.1109/TNSRE.2020.2999505.
- Valdivieso L., Váscquez H.Ju., Barona L., Benalcázar M. 2023. Recognition of Hand Gestures Based on EMG Signals with Deep and Double-Deep Q-Networks. *Sensors*, 23. 10.3390/s23083905.

- Vásconez J.P., Barona L.L.I., Valdivieso C.A.L., Benalcázar M.E. 2022. Hand Gesture Recognition Using EMG-IMU Signals and Deep Q-Networks. *Sensors*, 22, 9613.
- Wei W., Wong Y., Du Y., Hu Y., Kankanhalli M., Geng W. 2019. A multi-stream convolutional neural network for sEMG-based gesture recognition in musclecomputer interface. *Pattern Recognit. Lett.*, 119: 131–138.
- Young A.J., Hargrove L.J., Kuiken T.A. 2011. The effects of electrode size and orientation on the sensitivity of myoelectric pattern recognition systems to electrode shift. *IEEE Trans. Biomed. Eng.*, 58(9): 2537–2544
- Zhang Ch., Shih Ya.-H., Qian Ji. 2019. Real-Time Surface EMG Pattern Recognition for Hand Gestures Based on an Artificial Neural Network. *Sensors*, 19. 3170. 10.3390/s19143170.

Конфликт интересов: о потенциальном конфликте интересов не сообщалось.

Conflict of interest: no potential conflict of interest related to this article was reported.

Поступила в редакцию 24.06.2025

Поступила после рецензирования 28.11.2025

Принята к публикации 02.12.2025

Received June 24, 2025

Revised November 28, 2025

Accepted December 02, 2025

ИНФОРМАЦИЯ ОБ АВТОРАХ

Арсёнов Алексей Владимирович, бакалавр по направлению «Информатика и вычислительная техника», Национальный исследовательский университет «МЭИ», г. Москва, Россия

Моракс Виктор Денисович, студент бакалавриата 2 курса кафедры «Программное обеспечение автоматизированных систем» по направлению «Программная инженерия», Волгоградский государственный технический университет, г. Волгоград, Россия

Донская Анастасия Романовна, старший преподаватель кафедры программного обеспечения автоматизированных систем, Волгоградский государственный технический университет; старший преподаватель кафедры клинической инженерии и технологий искусственного интеллекта, Волгоградский государственный медицинский университет Минздрава России, г. Волгоград, Россия

Ломакин Арсений Сергеевич, студент магистратуры 1 курса кафедры «Программное обеспечение автоматизированных систем», Волгоградский государственный технический университет, г. Волгоград, Россия

INFORMATION ABOUT THE AUTHORS

Aleksei V. Arsenov, Bachelor's student in Computer Science and Engineering, National Research University "Moscow Power Engineering Institute", Moscow, Russia

Viktor D. Moraks, 2nd year Bachelor's student Student of the Department of Software Engineering, Volgograd State Technical University, Volgograd, Russia

Anastasia R. Donskaia, Senior Lecturer at the Department of Software for Automated Systems, Volgograd State Technical University; Senior Lecturer of the Department of Clinical Engineering and Artificial Intelligence Technologies, Volgograd State Medical University of Public Health Ministry of the Russian Federation, Volgograd, Russia

Arseniy S. Lomakin, 1st year Master's student of the Department of Software for Automated Systems, Volgograd State Technical University, Volgograd, Russia