

УДК 004.942
<https://doi.org/10.32362/2500-316X-2023-11-2-7-19>



НАУЧНАЯ СТАТЬЯ

Применение робастной нейросетевой фильтрации в задачах построения интеллектуальных интерфейсов

А.В. Васильев[@],
А.О. Мельников,
С.А. Лесько

МИРЭА – Российский технологический университет, Москва, 119454 Россия
[@] Автор для переписки, e-mail: bysslaev@gmail.com

Резюме

Цели. В последние годы возрос научный интерес к построению интеллектуальных интерфейсов для управления компьютером на основе биометрических данных. Одним из источников таких данных служит сигнал электромиографии (ЭМГ). Сигнал ЭМГ можно использовать для классификации жестов рук человека. Это позволяет организовать интуитивно понятный интерфейс «человек – компьютер». Основными проблемами при использовании сигналов ЭМГ являются наличие нелинейных шумов в сигнале и значительное влияние индивидуальных особенностей человека. Цель работы – исследование возможностей применения нейронных сетей для фильтрации индивидуальных компонент сигнала ЭМГ.

Методы. Используются математические методы обработки сигналов и методы машинного обучения.

Результаты. Проведен анализ исследований по теме обработки ЭМГ-сигналов. Предложена концепция интеллектуальной обработки биологических сигналов. Разработана модель фильтрации сигнала, построена структура сверточной нейронной сети на основе технологий Python 3, TensorFlow и Keras. Проведен эксперимент на наборе данных ЭМГ по фильтрации индивидуальных компонент сигнала.

Выводы. Продемонстрирована возможность применения искусственных нейронных сетей для выявления и подавления индивидуальных особенностей человека в биологических сигналах. При обучении сети основной упор делался на индивидуальные особенности, тестируя сеть на данных, полученных от субъектов, не участвующих в процессе обучения. Достигнуто уменьшение индивидуального шума в среднем на 5%. Для решения задачи классификации сигнала ЭМГ данный результат поможет избежать переобучения сети и повысить точность классификации жестов для новых пользователей.

Ключевые слова: цифровая обработка сигнала, частотная фильтрация, электромиография, машинное обучение, нейронные сети, интерфейсы, управление жестами

• Поступила: 17.06.2022 • Доработана: 22.09.2022 • Принята к опубликованию: 09.02.2023

Для цитирования: Васильев А.В., Мельников А.О., Лесько С.А. Применение робастной нейросетевой фильтрации в задачах построения интеллектуальных интерфейсов. *Russ. Technol. J.* 2023;11(2):7–19. <https://doi.org/10.32362/2500-316X-2023-11-2-7-19>

Прозрачность финансовой деятельности: Авторы не имеют финансовой заинтересованности в представленных материалах или методах.

Авторы заявляют об отсутствии конфликта интересов.

RESEARCH ARTICLE

Robust neural network filtering in the tasks of building intelligent interfaces

Anton V. Vasiliev[@],
Alexey O. Melnikov,
Sergey A. Lesko

MIREA – Russian Technological University, Moscow, 119454 Russia
[@] Corresponding author, e-mail: bysslaev@gmail.com

Abstract

Objectives. In recent years, there has been growing scientific interest in the creation of intelligent interfaces for computer control based on biometric data, such as electromyography signals (EMGs), which can be used to classify human hand gestures to form the basis for organizing an intuitive human-computer interface. However, problems arising when using EMG signals for this purpose include the presence of nonlinear noise in the signal and the significant influence of individual human characteristics. The aim of the present study is to investigate the possibility of using neural networks to filter individual components of the EMG signal.

Methods. Mathematical signal processing techniques are used along with machine learning methods.

Results. The overview of the literature on the topic of EMG signal processing is carried out. The concept of intelligent processing of biological signals is proposed. The signal filtering model using a convolutional neural network structure based on Python 3, TensorFlow and Keras technologies was developed. Results of an experiment carried out on an EMG data set to filter individual signal components are presented and discussed.

Conclusions. The possibility of using artificial neural networks to identify and suppress individual human characteristics in biological signals is demonstrated. When training the network, the main emphasis was placed on individual features by testing the network on data received from subjects not involved in the learning process. The achieved average 5% reduction in individual noise will help to avoid retraining of the network when classifying EMG signals, as well as improving the accuracy of gesture classification for new users.

Keywords: digital signal processing, frequency filtering, electromyography, machine learning, neural networks, interfaces, gesture manipulation

• Submitted: 17.06.2022 • Revised: 22.09.2022 • Accepted: 09.02.2023

For citation: Vasiliev A.V., Melnikov A.O., Lesko S.A. Robust neural network filtering in the tasks of building intelligent interfaces. *Russ. Technol. J.* 2023;11(2):7–19. <https://doi.org/10.32362/2500-316X-2023-11-2-7-19>

Financial disclosure: The authors have no a financial or property interest in any material or method mentioned.

The authors declare no conflicts of interest.

ВВЕДЕНИЕ

Одним из ключевых моментов при проектировании программного обеспечения является выбор способа коммуникации с человеком. Для этого используется набор унифицированных конструктивных, аппаратных и программных средств, необходимых для взаимодействия различных функциональных элементов системы. Набор таких элементов называется интерфейсом. Особенно важен интерфейс между человеком и программным обеспечением. Именно интерфейс стандартизирует взаимодействие

и определяет границы функциональных возможностей работы с программным обеспечением. Понятие «интерфейс» тесно связано с удобством использования (юзабилити) программных систем. В первую очередь такое удобство связано с графическим интерфейсом пользователя. Интерфейс считается удобным, если пользователю требуются наименьшие затраты времени на использование информационной системы. Второй параметр, влияющий на удобство использования, – это простота и время обучения нового пользователя работе с информационной системой. Хороший интерфейс должен быть интуитивно

понятным, иметь как можно меньше скрытых зависимостей. Время обучения пользователя взаимодействию с программным обеспечением должно быть минимальным. Помимо графического интерфейса, информационная система может иметь и некоторый командно-программный интерфейс, представляющий из себя набор сообщений (команд), которые могут восприниматься программной системой и обрабатываться с помощью программного интерфейса приложения (API). Удобство такого вида интерфейса оценивается количеством команд, которые требуется использовать, чтобы выполнить целевое воздействие на систему. При этом желательно, чтобы команды для разных целевых воздействий не дублировались. Перечисленные требования накладывают серьезную ответственность на разработчиков при проектировании интерфейсов программных продуктов и систем.

Человек в современном цифровом пространстве становится стремительно расширяющей свои возможности интерактивной системой. При этом диапазон интерактивности меняется от системы к системе. В ряде систем предполагается ограниченная интерактивность, например, в авиационной или аэрокосмической отрасли, где условия работы человека с информационной системой ограничены физическими условиями. С другой стороны, интерактивные системы повседневной жизни, такие как мультимедийные устройства и игровые комплексы, не накладывают существенных физических ограничений на набор взаимодействий человека (пользователя) с информационной системой.

Для повышения эффективности и удобства использования информационной системы ученые ищут новые способы организации интерфейсов. Среди факторов, снижающих качество использования информационных систем, можно выделить технические, физические и информационные. Под техническими факторами понимается качество технологий, применяемых как при разработке программного обеспечения (скорость сети, количество памяти), так и при создании аппаратного обеспечения (например, качество монитора компьютера или камеры). Физические факторы – это физические условия окружающей среды во время использования программной системы, такие как влажность, освещенность, видимость, возможность выполнения физических движений и т.д. Под информационными факторами понимается проработка интерфейса программной системы для удобства ее использования в целом, например, размер кнопок в графическом интерфейсе, возможность ввода текста, возможность сохранения данных и т.д.

Интерфейсы можно разделить на несколько крупных групп: текстовые, графические, голосовые, с использованием видео и гибридные. Для повышения

удобства использования следует рассматривать каждую из этих групп. В настоящее время активно развиваются интерфейсы на основе аудио- и видеоинформации, полученной от внешних сенсоров. Из сложностей использования видео можно выделить следующие факторы: посторонний шум, плохая видимость, физические препятствия между камерой и объектом съемки, отсутствие нужного ракурса для съемки или отсутствие возможности вербальной коммуникации (режим тишины). При этом интерфейсы на основе аудио- или видео расширяют зоны использования программных систем. Если при использовании систем с текстовым или графическим интерфейсом обязательно требуется консоль для ввода или экран плюс устройства ввода (клавиатура), то для интерфейса на основе аудио или видео требуется только микрофон и видеокамера. Это дает возможность человеку освободить руки и повысить качество пользовательского опыта при работе с системой, используя руки в качестве дополнительного канала управления. Для обхода перечисленных ограничений интерфейсов на основе видеоинформации и сохранения их преимуществ требуется использовать новый тип интерфейсов на основе гибридного или иного, биологического, типа. Биологические интерфейсы широко распространены в медицине. Только в медицине человек взаимодействует с информационными системами в основном пассивно, позволяя устройству извлекать и обрабатывать информацию, получаемую с помощью интерфейса. При этом потенциал использования биологических интерфейсов гораздо шире. Их можно применять для построения полноценных информационных систем с высоким уровнем удобства использования.

В качестве дополнительного канала обмена информацией могут использоваться измерения биологических сигналов, таких как электромиография (ЭМГ), электроэнцефалография (ЭЭГ) и т.п. В последние годы ведутся инновационные исследования по разработке и использованию одежды, снабженной разного рода сенсорами и датчиками [1, 2], которые позволяют регистрировать физиологическую активность человека. Наиболее популярно в подобных исследованиях использование элементов одежды, снабженных сенсорами для регистрации сигналов ЭМГ [3, 4]. Одежда, снабженная ЭМГ-датчиками, востребована во многих областях: от любой физически активной деятельности (строительные работы, спорт) до наиболее спокойной (офисная работа). ЭМГ позволяет регистрировать электрическую активность, возникающую при возбуждении мышечных волокон.

Сигнал ЭМГ используется для диагностики нервно-мышечных заболеваний, в психофизиологии, при изучении двигательной активности, в исследованиях

высшей нервной деятельности, для оценки результатов протезирования и ортопедии, в инженерной психологии. Помимо прочего, в последнее время набирает популярность исследования возможности организации безмолвного интерфейса – интерфейса, который не требует голосового ввода и позволяет управлять информационной системой путем артикуляции.

В данной работе внимание сконцентрировано на использовании ЭМГ-сигнала в качестве основы интерфейса «человек – компьютер». Множество исследований направлено на анализ ЭМГ-сигнала для построения систем умного протезирования [5, 6] и систем, управляемых жестами [7]. Помимо ЭМГ-сигнала для решения задач классификации жестов используются даже ультразвуковые сканеры [8]. В качестве основных проблем исследователи определяют сложность выделения конкретных управляющих единиц в ЭМГ-сигнале. Отмечается высокая зависимость точности классификации от конкретного человека, с которым проводится эксперимент [9, 10]. Для решения таких проблем используют методы декомпозиции [11] и кластеризации сигналов ЭМГ для выделения групп мышц, участвующих при конкретном жесте руки [3]. Для минимизации шумов используются такие методы преобразования сигнала как метод главных компонент, автоэнкодеры и др. [12, 13].

1. АНАЛИЗ ИССЛЕДОВАНИЙ

В ряде исследований, посвященных классификации ЭМГ-сигнала, поднимается проблема его фильтрации. В большинстве работ используется только частотная фильтрация, но исследователи применяют и другие подходы. Наиболее эффективным методом является предварительная кластеризация сигналов ЭМГ с целью выделения моторных единиц. Однако данный подход приводит к необратимому искажению сигнала и не относится к фильтрации.

В [14] авторами разработана система идентификации мышц с помощью игольчатой ЭМГ для задач протезирования. Основными характеристиками этой модели являются следующие: использование игольчатой ЭМГ (16 датчиков) и кинематических перчаток, предобработка сигналов фильтрами нижних (10 Гц) и верхних (100 Гц) частот, использование искусственных нейронных сетей. Набор данных состоит из 5 движений по 10 повторений каждого движения. Входными данными для нейронной сети являются корреляционные матрицы. Преимущество модели – компактность полносвязной нейронной сети (3 скрытых слоя). К недостаткам модели относится сравнительно низкая точность (90.1% на тестовом наборе) и необходимость использования кинематических перчаток. Негативное влияние при

оценке модели связано с низкой точностью распознавания сигналов от ряда мышц из набора данных. Авторы отмечают, что ошибки в классификации могут быть связаны с недостаточно точной маркировкой эталонных данных.

В [15] авторами проведен эксперимент по сравнению статистических подходов к классификации ЭМГ-сигнала с моделями машинного обучения. Задачей исследователей была бинарная классификация сигнала ЭМГ. Цель заключалась в распознавании промежутков приемов пищи в ежедневной деятельности человека. Сравнение проводилось между моделями SVM [16], RandomForest [17], LogisticRegression [18], XGBoost [19], LightGBM [20] и LSTM [21], Conv-LSTM [22]. К преимуществам работы стоит отнести обширное сравнение статистических методов и методов машинного обучения. Достигнута точность 94.76% на сбалансированном наборе данных для статистических методов и 95.35% – на несбалансированном наборе данных. Наиболее эффективным статистическим методом для классификации ЭМГ-сигнала оказался XGBoost. Использование нейронных сетей типа LSTM позволило улучшить точность классификации до 97%, однако исследователи отмечают проблему, связанную с необходимостью большого количества данных для обучения такого вида сетей, а также недостаточное количество данных для методов машинного обучения, загрязнение данных совокупными действиями, плохое подключение Bluetooth, особенности правшей и левшей.

В [3] авторами разработано устройство для считывания ЭМГ-сигнала с питанием от солнечной энергии. Основными характеристиками разработанной модели является сверхнизкое энергопотребление и интеллектуальная система локализации датчиков ЭМГ на запястье пользователя. Данные для эксперимента были собраны с 20 человек и включали 15 уникальных движений кисти руки. Достигнута точность 95.3% при классификации 15 жестов. Одной из проблем для подобного рода задач является положение сенсоров на запястье человека. Методы анализа ЭМГ-сигналов обладают высокой чувствительностью к положению сенсоров. Это приводит к тому, что модель необходимо каждый раз переобучать при изменении положения датчиков. Предлагается решить эту проблему с помощью локализации сенсоров на запястье с использованием интеллектуальной обработки данных от емкостных датчиков. Для анализа сигналов ЭМГ была проведена кластеризация всех мышц запястья на 8 групп. Чтобы регулировать положение браслета на запястье использовалась калибровка на основании данных от 15 сенсоров с применением свертки. Для классификации жестов была использована сверточная нейронная сеть с двумя слоями

свертки с активационной функцией ReLU (Rectified linear unit). Отмечается, что именно такое малое количество слоев позволяет решить проблему переобучения. Недостаток метода – значительное падение точности классификации движений в статичном положении (снижение точности на 3%). Кроме того, в работу не были включены жесты, описывающие мелкую моторику пальцев.

В [23] разработана модель классификации жестов на основе ультразвукового исследования. Для классификации жестов использовалось ультразвуковое представление мышц предплечья.

2. ПРИРОДА ЭМГ-СИГНАЛА

ЭМГ – метод исследования биоэлектрических потенциалов, возникающих в скелетных мышцах человека и животных при возбуждении мышечных волокон.

Существует три типа ЭМГ:

- 1) ЭМГ с использованием игольчатых электродов, которые вводятся в мышцу;
- 2) стимуляционная ЭМГ;
- 3) ЭМГ с использованием накожных электродов.

Игольчатая ЭМГ позволяет получить наиболее точное представление об электрической активности, возникающей во время мышечных возбуждений, но требует физического проникновения в мышечную ткань человека. Инвазивная природа метода является ограничением для использования в качестве основы для интерфейса информационной системы.

Стимуляционная ЭМГ – это вид неинвазивной ЭМГ, при котором применяются накожные поверхностные электроды, позволяющие оценить проводимость импульса по периферическим нервам в ответ на их стимуляцию электрическим током малой силы. Такой вид ЭМГ применяется, в частности, для диагностики заболеваний периферической нервной системы.

Поверхностная ЭМГ – вид ЭМГ, при котором применяются накожные поверхностные электроды. В отличие от стимуляционной ЭМГ, данный вид не предполагает стимуляции нервной системы, а наоборот, заключается только в регистрации электрической активности при активном возбуждении и расслаблении мышечных тканей.

При слабом сокращении мышц регистрируется или потенциал отдельной двигательной единицы, или потенциал многих двигательных единиц. При среднем по силе и сильном сокращении мышц наблюдается интерференционная ЭМГ, при которой практически невозможно выявить потенциалы отдельных двигательных единиц. В состоянии покоя у людей, не имеющих проблем в области нервной системы, обычно не выявляются какие-либо активности электрического потенциала либо регистрируются электрические потенциалы отдельных мышечных волокон.

В простом случае будем рассматривать следующий сценарий: на одиночное воздействие мышца реагирует одиночным сокращением. При этом можно выделить три фазы:

- латентный период (от 2–3 до 10 мс), длящийся от момента нанесения раздражения до начала сокращения;
- фаза укорочения или сокращения (40–50 мс);
- фаза расслабления (около 50 мс).

В состав устройства регистрации ЭМГ-сигнала входят электроды, которые отводят потенциалы мышцы, усилитель этих потенциалов и регистрирующее устройство.

Основными параметрами кривой ЭМГ-сигнала являются:

- амплитуда (1 мкВ – 50 мВ),
- частота (0.5 – 500 Гц).

Для более наглядного анализа ЭМГ-сигнал представляется в виде декомпозиции частот и амплитуд, полученных с помощью преобразования Фурье.

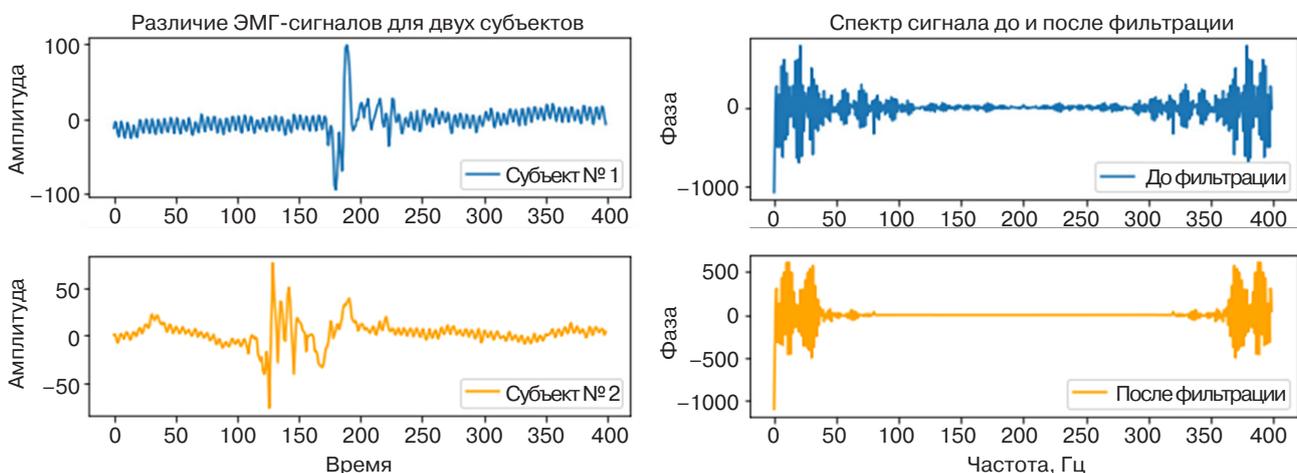


Рис. 1. Пример ЭМГ-сигнала во временной и частотной области

Любая часть мышцы может содержать мышечные волокна, принадлежащие 20–50 моторным клеткам. В результате движения происходит возбуждение множества моторных единиц. Совокупный потенциал действия может быть зарегистрирован с помощью оборудования ЭМГ и будет представлен во времени в следующем виде:

$$S(t) = \sum_j \text{ППДМК}_j(t) + n(t) = \sum_j \sum_i k_j f\left(\frac{t - \theta_{ij}}{a_j}\right) + n(t),$$

где ППДМК_{*j*} – последовательность потенциала действия моторной клетки; *k_j* – амплитудный фактор для мышцы *j*-й моторной клетки; *f* – форма потенциала действия; *θ_{ij}* – время возникновения ППДМК; *a_j* – изменение масштаба; *n(t)* – добавочный шум.

В данной работе используется сигнал, полученный при использовании поверхностной ЭМГ с одним каналом. Использование одноканальной системы позволяет упростить регистрацию сигнала, абстрагируясь от временной синхронизации данных с параллельных каналов ЭМГ.

Основной проблемой при использовании сигналов ЭМГ в качестве интерфейса управления является их изменчивость и неустойчивость, в первую очередь из-за внешних помех, смещения электродов, потливости кожи и утомляемости мышц.

Попытки устранить влияние мышечной утомляемости заключаются в использовании переключающих устройств при изменении сигнала либо в применении статических методов, например, фильтрации.

Успешность реализации интерфейса управления устройств определяется степенью достоверности расшифровки биопотенциалов мышц в зарегистрированном сигнале ЭМГ при планируемом движении. Точному определению типа движения препятствует низкое отношение сигнал/шум в измерительной системе.

Искажения сигнала могут возникать из-за побочного влияния сигналов электрической активности сердца, сдвигов электродов относительно назначенного положения, изменения биопотенциалов мышц, шумов электронных устройств, окружающего электромагнитного излучения и т.п.

На сегодняшний день популярным методом для определения типов движения является использование различных классификаторов.

3. ПОСТАНОВКА ЗАДАЧИ

Для построения эффективного интерфейса, основанного на сигналах ЭМГ, требуется решить ряд задач. Во-первых, необходимо обработать от шумов сигнал, регистрируемый при возбуждении мышц человека. Во-вторых, сигнал нужно каким-либо образом классифицировать, чтобы полученные действия

или шаблоны использовать для создания управляющих воздействий информационной системой. В данной работе мы будем решать задачу очистки сигнала от шумов. Основной проблемой является нелинейный характер шума. Под шумом мы будем понимать некоторую нелинейную компоненту сигнала, которая зависит от параметров регистрации сигнала ЭМГ с биологического объекта. Количество шума зависит от таких параметров, как уровень напряжения в сети ноутбука, параметры усилителя сигнала, качество электродов, качество подготовки поверхности кожи для установки электродов ЭМГ и т.д.

Сигнал **X** представляет собой последовательность отчетов *x_i*, *i* = $\overline{1, N}$. Предполагается, что данный сигнал может содержать нелинейный шум **Z**, который можно подавить с помощью фильтра:

$$\mathbf{I} = \mathbf{X} \times \mathbf{h},$$

где **I** – полезный сигнал, **X** – зашумленный сигнал, **h** – нейросетевой фильтр.

Мы сравнили данные для одного типа жеста, полученные от двух субъектов (рис. 2). Как видно из рисунка, эти сигналы отличаются друг от друга не только фазой сигнала, но и формой. Для минимизации данных различий применяется нейросетевая фильтрация.

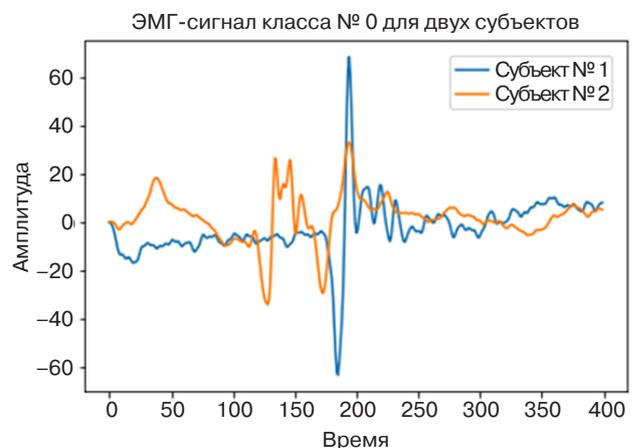


Рис. 2. ЭМГ-сигнал для одного жеста, полученный от двух разных субъектов

Цель нейросетевой фильтрации заключается в избавлении от индивидуальной компоненты сигнала, которая варьируется у разных людей. Такой вид искажений называется индивидуальным шумом. Под индивидуальным шумом понимается нелинейная компонента сигнала, которая может быть определена в следующем виде:

$$\mathbf{Z} = \mathbf{X} - \mathbf{I},$$

где **Z** – индивидуальный шум.

Сигнал от первого субъекта



Сигнал от второго субъекта

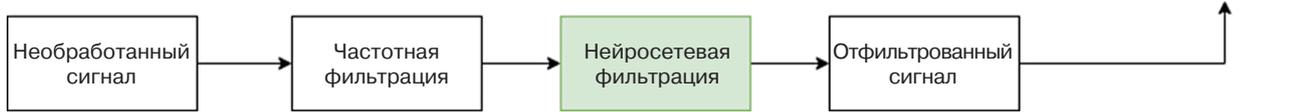


Рис. 3. Схема нейросетевой фильтрации

Задача состоит в нахождении параметров фильтра \mathbf{h} , который позволит минимизировать различие в сигналах, описывающих один и тот же класс жеста, но полученных от разных субъектов. Такую задачу можно описать в виде:

$$(\mathbf{X}_{i,k} \times \mathbf{h} - \mathbf{X}_{j,k} \times \mathbf{h}) \rightarrow \min,$$

где i – индекс субъекта, k – номер класса жеста.

3.1. Схема обработки сигнала

После получения сигнала ЭМГ с датчиков проводится фильтрация в два этапа. На первом этапе применяется фильтр нижних частот (до 50 Гц) и фильтр высоких частот (более 1.5 МГц). Эти фильтры позволяют избавиться от шума, создаваемого электронным оборудованием и внешним статическим электрическим полем. Схема обработки сигнала показана на рис. 3.

Сигнал, зарегистрированный при мышечной активности человека, обрабатывается частотным фильтром, затем он пропускается через нейронную сеть, которая компенсирует шум в сигнале. На выходе модели получаем очищенный сигнал, который может быть использован в задаче классификации.

3.2. Наборы данных

При планировании эксперимента были рассмотрены две базы данных, содержащие данные ЭМГ, подходящие для построения информационной системы с управлением на основе жестов. Для эксперимента требовался набор данных, содержащий сигналы ЭМГ, полученные с области предплечья при совершении набора жестов кистью руки. Каждый из жестов может использоваться в качестве управляющего воздействия при работе с информационной системой.

3.2.1. Ninapro Data

Эта база данных общедоступна для академических целей на специальном веб-сайте¹ [24]. Цель проекта заключается в разработке семейства алгоритмов, способных значительно увеличить ловкость и сократить время обучения для управляемого протеза sEMG. Задача проекта – обеспечение пациентов дешевым, простым и естественным способом управления протезом.

Набор данных состоит из биоэлектрических мышечных активностей, собранных в специальных условиях с использованием дифференциальных электродов sEMG. На данный момент доступны данные по 67 здоровым субъектам и 11 субъектам с ампутированными конечностями.

Процесс сбора данных Ninapro был спланирован таким образом, чтобы его можно было легко повторить и получить новые данные различными исследовательскими группами.

3.2.2. RF-Lab. Лаборатория цифровой обработки сигналов (ЦОС) РТУ МИРЭА

База проекта содержит сигналы ЭМГ, считанные с области предплечья. В сборе данных участвовали 6 субъектов. Каждый субъект последовательно повторял одно из 9 движений кистью (жест) по 79 раз. Сигналы, полученные для каждого жеста, были записаны в вектор длиной в 400 отсчетов. Общее количество сигналов равно 2820 [9]. Набор данных включают жесты следующих классов:

- кисть вверх (класс 0);
- кисть вниз (класс 1);
- сжатие всех пальцев (класс 2);
- сжатие указательного пальца (класс 3);
- сжатие среднего пальца (класс 4);
- сжатие безымянного пальца (класс 5);
- щелчок большого пальца со средним (класс 6);
- разжимание всех пальцев (класс 7);
- поворот кисти влево (класс 8).

¹ <http://ninapro.hevs.ch/>. Дата обращения 15.06.2022. / Accessed June 15, 2022.

Для регистрации сигналов были использованы следующие комплектующие: Arduino Leonardo, ECG-EMG Arduino Shield, одноканальные поверхностные электроды и USB Type-A / USB Micro-B.

В результате использовались 79 векторов длиной 400 единиц для каждого жеста, что предоставляло собой окно, в котором зафиксирован потенциал действия. Таким образом, в него входят только наиболее важные данные, которые необходимы для задачи классификации, тем самым уменьшая потребляемые вычислительные ресурсы и увеличивая точность.

В рамках данной работы использовался набор данных RF-Lab² из-за его направленности на построение человеко-машинного интерфейса с управлением жестами.

3.3. Оценка качества фильтрации

Для оценки качества сигнала используется анализ среднеквадратического отклонения ЭМГ-сигнала в зависимости от субъекта. Для каждого типа движения рассчитывается значение среднеквадратического отклонения сигнала между всеми субъектами (рис. 4).

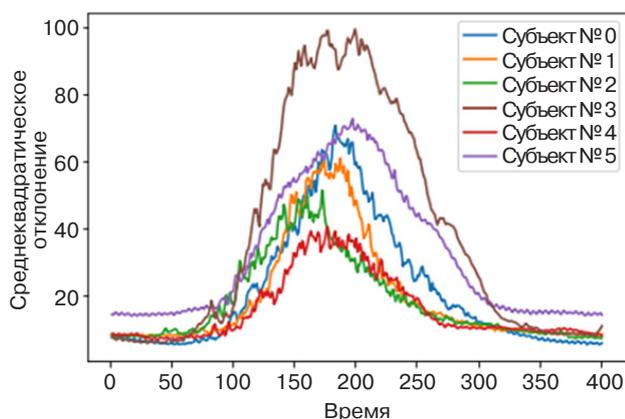


Рис. 4. Среднеквадратическое отклонение для классов жестов для каждого субъекта

При фильтрации сигнала нужно снизить среднеквадратическое отклонение ЭМГ-сигнала в рамках каждого класса жеста. В качестве примера было подсчитано среднеквадратическое отклонение для жеста класса 0 до и после фильтрации с использованием частотного фильтра (рис. 5).

Из рис. 5 видно, что частотная фильтрация снижает среднеквадратическое отклонение сигнала на всем отрезке, поэтому для оценки эффективности фильтрации сигнала в нашем эксперименте используется данный метод.

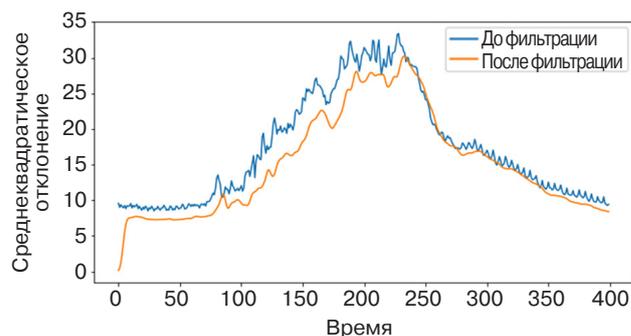


Рис. 5. Сравнение среднеквадратического отклонения амплитуды ЭМГ-сигнала до и после частотной фильтрации

4. РАЗРАБОТАННАЯ МОДЕЛЬ НЕЙРОННОЙ СЕТИ

Цифровые фильтры на сегодняшний день широко применяются в различных областях обработки сигналов, как технических, так и биологических, к которым относится ЭМГ-сигнал. Математические модели цифровых фильтров могут быть описаны с использованием векторов и числовых матриц. Для бинарного сигнала числа в матрицах могут быть двоичными. Существует два типа фильтров: с конечной импульсной характеристикой и с бесконечной импульсной характеристикой. Фильтр должен подавлять гармонические компоненты исходного сигнала в одной полосе частот (полоса подавления) и пропускать их в другой полосе частот (полоса пропускания). В большинстве случаев в крайне сложных задачах анализа сигналов для конструирования пространства признаков применяются классические приемы, основанные на преобразовании Фурье и вейвлет-преобразовании. Из-за сложности понимания природы сигнала признаки одной задачи могут абсолютно не подходить для другой задачи, и требуется с нуля конструировать пространство признаков. Сигнал ЭМГ попадает под категорию сигналов со сложной природой, для обработки которого не подходят стандартные фильтры. Он может быть представлен в виде временного ряда [25]. Поэтому для построения фильтра для сигнала ЭМГ может подойти использование интеллектуальных моделей. Одной из наиболее эффективных интеллектуальных моделей на данный момент являются нейронные сети.

Для решения задачи будем использовать тип нейронной сети, включающий слой свертки. Такие сети называются сверточными. В качестве активационной функции предлагается использовать функцию активации – параметризованный ReLU (PReLU). Применение данной функции активации является достижением в машинном зрении, позволившим

² <https://rf-lab.org/>. Дата обращения 01.06.2022. / Accessed June 01, 2022.

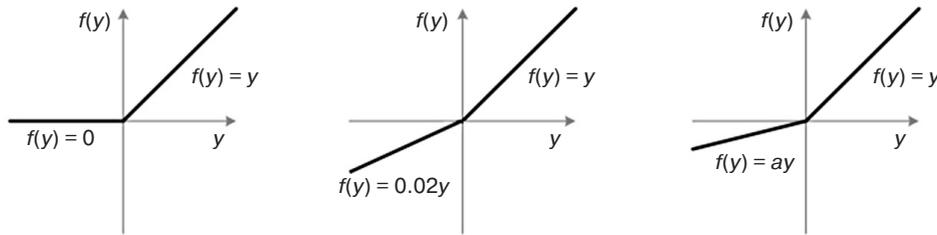


Рис. 6. Сравнение активационной функции ReLU (слева), LeakyReLU (в центре), PReLU (справа).
 a – параметр функции PReLU; y – значение входного сигнала

превзойти человеческий уровень в задачах распознавания изображений ImageNet³. Процесс обратного распространения ошибки и обновления для PReLU прост и похож на подобный процесс для традиционных ReLU. В отличие от ReLU функция PReLU не обнуляет отрицательные входные сигналы. Вместо этого отрицательные входные сигналы умножаются на некоторый ненулевой коэффициент, что позволяет учитывать отрицательные значения при обучении сети и обработке сигналов. Сравнение активационной функции PReLU с обычным ReLU продемонстрировано на рис. 6.

В рамках Kaggle-соревнования National Data Science Bowl функция активации PReLU позволила уменьшить переобучение благодаря элементу случайности в работе. При сравнении точности классификации двух сверточных искусственных нейронных сетей с различными функциями активации на наборах данных (изображений, используемых для тестирования качества алгоритмов распознавания образов) CIFAR-10, CIFAR-100⁴ и NDSB⁵ получены результаты, которые говорят о том, что для всех наборов модифицированные функции активации семейства ReLU превзошли традиционные функции. PReLU существенно превосходит другие функции активации на наборе данных NDSB, т.к. этот набор содержит меньше обучающих данных и функция активации позволяет избежать переобучения. Для обучения моделей машинного обучения применялись современные средства облачной инфраструктуры, такие как Docker⁶ и AmazonAzure⁷ [26].

Для проведения эксперимента использовался язык программирования Python 3.8 и библиотека Keras 2.9.0⁸ при построении модели нейронной сети. Разработанная

в ходе анализа архитектура нейронной сети для фильтрации сигнала ЭМГ представлена на рис. 7.

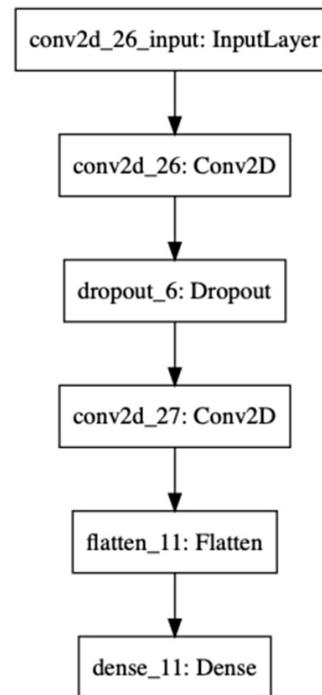


Рис. 7. Архитектура сверточной нейронной сети

Разработанная модель содержит два сверточных слоя. В качестве входных данных сети передается матрица размером 20×20 , представляющая собой необработанный сигнал ЭМГ, состоящий из 400 отсчетов. Первый слой содержит 64 карты признаков размером 5×5 и функцию активации PReLU (с параметром $a = 0.02$). Второй сверточный слой содержит 32 карты признаков размером 3×3 . Далее – слой выпрямления и полносвязный выходной слой размерностью 400, что соответствует размерности входного сигнала. Такая размерность на выходе сети позволяет использовать выходной сигнал наравне с входным, ожидая, что выходной сигнал сохранит полезную информацию о паттерне движения кисти субъекта. Для обучения модели использовались облачные вычислительные мощности MicrosoftAzure⁹ [26].

³ <https://www.image-net.org/>. Дата обращения 09.06.2022. / Accessed June 09, 2022.

⁴ <https://www.cs.toronto.edu/~kriz/cifar.html>. Дата обращения 10.06.2022. / Accessed June 10, 2022.

⁵ <https://www.kaggle.com/competitions/datasciencebowl/overview/about-the-ndsb>. Дата обращения 10.06.2022. / Accessed June 10, 2022.

⁶ <https://www.docker.com/>. Дата обращения 10.06.2022. / Accessed June 10, 2022.

⁷ <https://azure.microsoft.com/en-us>. Дата обращения 10.06.2022. / Accessed June 10, 2022.

⁸ <https://github.com/keras-team/keras/releases/tag/v2.9.0>. Дата обращения 10.06.2022. / Accessed June 10, 2022.

⁹ <https://azure.microsoft.com/en-us>. Дата обращения 01.06.2022. / Accessed June 01, 2022.

5. РЕАЛИЗАЦИЯ МОДЕЛИ И ОЦЕНКА ПОЛУЧЕННЫХ РЕЗУЛЬТАТОВ

Для эксперимента был использован набор данных RF-Lab, собранный командой Лаборатории ЦОС РТУ МИРЭА [9]. Набор содержит данные одного канала ЭМГ-сигнала, полученного от 6 субъектов. Каждый субъект выполнял 9 различных жестов рукой.

5.1. Структура эксперимента

Для обучения нейронной сети набор данных был преобразован следующим образом. Во-первых, он был разделен на 3 части: обучающая, валидационная и тестовая выборки. Обучающая выборка составляла 60% от общего объема данных и включала данные четырех из шести субъектов. Валидационная выборка содержала 20% данных, включая данные тех же самых четырех субъектов. Тестовая выборка содержала оставшихся 20% от общего объема данных и включала в себя данные двух субъектов, не участвующих в обучении. Такой подход использовался для демонстрации пригодности полученной модели на данных от субъектов, которые модель не видела во время обучения. Каждый обучающий пример состоял из исходного сигнала в качестве входных данных и парного сигнала в качестве целевого значения. Парный (целевой) сигнал подбирался таким образом, чтобы он принадлежал другому субъекту. Обучение нейронной сети проводилось с применением алгоритма оптимизации Adam [27], количество эпох обучения было равно 25. В качестве функции ошибки использовалась среднеквадратичная функция потерь (mean squared error) [28].

5.2. Полученные результаты

После обучения полученную модель оценили на оставшихся двух субъектах из набора данных. Отдельно были проведены сравнения каждого

класса сигнала (типа движения кистью). В качестве показателя эффективности разработанной модели измерялось среднеквадратичное отклонение сигнала до фильтрации и после. Его значения до и после фильтрации показаны на рис. 8. Измерения проводились для сигналов каждого класса отдельно. Как видно из рисунка, наибольшее отклонение имеют сигналы для жестов с классом 6 (сжатие безымянного пальца) и 8 (разжимание всех пальцев).

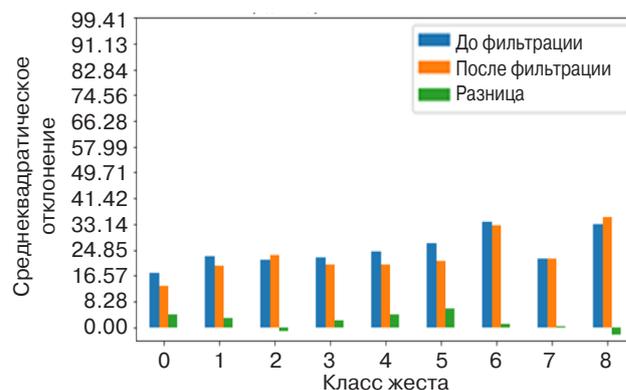


Рис. 8. Сравнение среднеквадратического отклонения ЭМГ-сигнала до и после нейросетевой фильтрации в зависимости от класса сигнала

В среднем снижение среднеквадратического отклонения составило 5% для сигналов, полученных при движении кистью. Наилучший результат был получен для движений с классом 4 и 5. Увеличение среднеквадратического отклонения зафиксировано для сигналов с классами 2 и 8. Снижение величины среднеквадратического отклонения было достигнуто для сигналов, относящихся к классам 0, 1, 3, 4, 5, 6, 7.

Полученные результаты позволяют говорить о возможности применения нейросетевой фильтрации в задачах очистки индивидуальных сигналов. Результат фильтрации для жеста класса 0 показан на рис. 9.

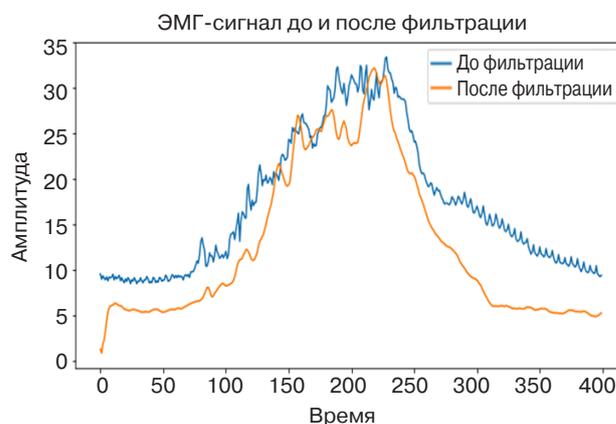


Рис. 9. Среднеквадратическое отклонение сигнала до и после нейросетевой фильтрации

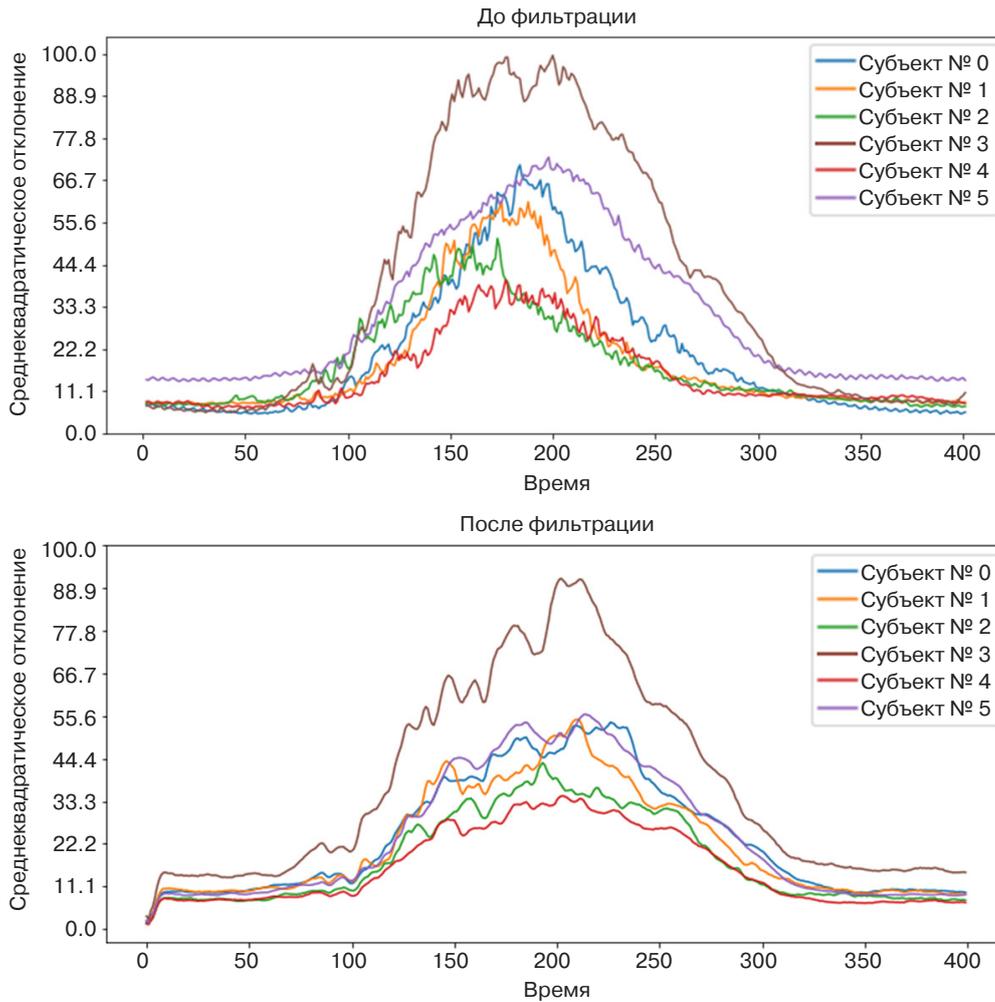


Рис. 10. Среднеквадратическое отклонение между разными жестами для каждого субъекта из выборки

Таблица 1. Сравнение результата фильтрации для разных классов сигнала

Класс сигнала	№ 0	№ 1	№ 2	№ 3	№ 4	№ 5	№ 6	№ 7	№ 8
Изменение величины среднеквадратического отклонения после фильтрации	3.93	3.1	-1.33	2.16	3.95	6.03	0.99	0.07	-2.41

Также проведено сравнение среднеквадратического отклонения между разными жестами для одного субъекта до и после фильтрации. Полученные данные показывают, что различие между жестами сохранилось почти на том же уровне (рис. 10).

Как видно из результатов, разработанная модель нейросетевой фильтрации способна компенсировать индивидуальные компоненты в сигнале ЭМГ. Достиженные показатели улучшения качества сигнала представлены в табл. 1.

ЗАКЛЮЧЕНИЕ

В рамках работы проведено исследование подходов и методов к разработке нейросетевых фильтров для биологических сигналов. Предложена схема

фильтрации биологических сигналов с учетом наличия в сигнале индивидуальных компонентов. Разработана модель и проведено обучение сверточной нейронной сети для интеллектуальной фильтрации. В ходе исследования была найдена эффективная архитектура сверточной нейронной сети для фильтрации сигнала ЭМГ.

Эксперимент по фильтрации одноканального ЭМГ-сигнала показал эффективность предложенной модели. Нейросетевая фильтрация позволяет снизить влияние индивидуального шума в сигнале ЭМГ в среднем на 5%.

В дальнейших исследованиях планируется оценить влияние нейросетевой фильтрации на точность классификации жестов с использованием ЭМГ-сигнала.

Вклад авторов

А.В. Васильев – подготовка алгоритмов, сбор данных, проведение исследования, написание текста статьи.

А.О. Мельников – идея исследования, развитие целей и задач, формулировка выводов.

С.А. Лесько – консультации по вопросам проведения исследования, научное редактирование статьи.

Authors' contributions

A.V. Vasiliev – preparing algorithms, data collection, conducting research, and writing the text of the article.

A.O. Melnikov – the research idea, developing objectives and aims, and formulating conclusions.

S.A. Lesko – consultations on research issues, scientific editing of the article.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Arruda L.M., Calado A., Boldt R.S., Yu.Y., Carvalho H., Carvalho M.A., Soares F., Matos D. Design and testing of a textile EMG sensor for prosthetic control. In: Garcia N.M., Rires I.M., Goleva R. (Eds.). *IoT Technologies for HealthCare: 6th EAI International Conference, HealthyIoT 2019. Lecture Notes of the Institute for Computer Sciences, Social Informatics and Telecommunications Engineering*. Springer; 2020;341:37–51. https://doi.org/10.1007/978-3-030-42029-1_3
2. Hu Y., Wang H., Sheikhejad O., Xiong Y., Gu H., Zhu P., Sun R., Wong C.P. Stretchable and printable medical dry electrode arrays on textile for electrophysiological monitoring. In: *IEEE 69th Electronic Components and Technology Conference (ECTC)*. 2019;243–248. <https://doi.org/10.1109/ECTC.2019.00043>
3. Truong H., Zhang S., Muncuk U., Nguyen P., Bui N., Nguyen A., Dinh T.N., Vu T. CapBand: Battery-free successive capacitance sensing wristband for hand gesture recognition. In: *Proceedings of the 16th ACM Conference on Embedded Networked Sensor Systems (SenSys '18)*. 2018;54–67. <https://doi.org/10.1145/3274783.3274854>
4. Goto D., Shiozawa N. Can textile electrode for ECG apply to EMG measurement? In: *World Congress on Medical Physics and Biomedical Engineering*. 2018;431–434. https://doi.org/10.1007/978-981-10-9038-7_81
5. Samuel O.W., Asogbon M.G., Geng Y., Al-Timemy A.H., Pirbhulal S., Ji N., Chen S., Li G. Intelligent EMG pattern recognition control method for upper-limb multifunctional prostheses: advances, current challenges, and future prospects. *IEEE Access*. 2019;7:10150–10165. <https://doi.org/10.1109/ACCESS.2019.2891350>
6. Raheema M.N., Hussain J.S., Al-Khazzar A.M. Design of an intelligent controller for myoelectric prostheses based on multilayer perceptron neural network. In: *IOP Conf. Ser.: Mater. Sci. Eng.* 2020;671(1):012064. <https://doi.org/10.1088/1757-899X/671/1/012064>
7. Sosa M., Oviedo G., Fontana J.M., O'Brien R., Laciari E., Molisani L. Development of a serious game controlled by myoelectric signals. In: *The 8th Latin American Conference on Biomedical Engineering and The 42nd National Conference on Biomedical Engineering. CLAIB 2019. IFMBE Proceedings*. 2019;75:1171–1177. https://doi.org/10.1007/978-3-030-30648-9_152
8. McIntosh J., Marzo A., Fraser M., Phillips C. EchoFlex: Hand gesture recognition using ultrasound imaging. In: *Proceedings of The 2017 CHI Conference on Human Factors in Computing Systems. (CHI '17)*. 2017; 1923–1934. <https://doi.org/10.1145/3025453.3025807>
9. Lukyanchikov A.I., Melnikov A.O., Lukyanchikov O.I. Algorithms for classification of a single channel EMG signal for human-computer interaction. In: *ITM Web of Conferences*. 2018;18:02001. <https://doi.org/10.1051/itmconf/20181802001>
10. Tavakoli M., Benussi C., Lopes P.A., Osorio L.B., de Almeida A.T. Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier. *Biomed. Signal Process. Control*. 2018;46: 121–130. <https://doi.org/10.1016/j.bspc.2018.07.010>
11. Chen C., Ma S., Sheng X., Zhu X. Continuous estimation of grasp kinematics with real-time surface EMG decomposition. In: *International Conference on Intelligent Robotics and Applications*. 2019;11744: 108–119. https://doi.org/10.1007/978-3-030-27541-9_10
12. Wang Y., Wang C., Wang Z., Wang X., Li Y. Hand gesture recognition using sparse autoencoder-based deep neural network based on electromyography measurements. In: *Nano-, Bio-, Info-Tech Sensors, and 3D Systems II*. 2018;105971D:163–169. <https://doi.org/10.1117/12.2296382>
13. Qi J., Jiang G., Li G., Sun Y., Tao B. Surface EMG hand gesture recognition system based on PCA and GRNN. *Neural Comput. Appl.* 2020;32(10):6343–6351. <https://doi.org/10.1007/s00521-019-04142-8>
14. Cappellari P., Gaunt R., Beringer C., Mansouri M., Novelli M. Identifying electromyography sensor placement using dense neural networks. In: *Proceedings of The 7th International Conference on Data Science, Technology and Applications*. 2018:130–141. <http://dx.doi.org/10.5220/0006912501300141>
15. Pal K.K., Banerjee P., Choudhuri S., Sampat S. *Activity classification using Myo Gesture Control Armband data through machine learning*. 2019. Available from URL: https://kuntalkumpal.github.io/files/MC_Report.pdf
16. Noble W. What is a support vector machine? *Nat. Biotechnol.* 2006;24:1565–1567. <https://doi.org/10.1038/nbt1206-1565>
17. Breiman L. Random forests. *Machine learning*. 2001;45:5–32. <https://doi.org/10.1023/A:1010933404324>
18. Wright R.E. Logistic regression. In: Grimm L.G., Yarnold P.R. (Eds.). *Reading and understanding multivariate statistics*. American Psychological Association; 1995. P. 217–244. <https://psycnet.apa.org/record/1995-97110-007>
19. Chen T., Guestrin C. XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*. New York, NY, USA: Association for Computing Machinery; 2016. P. 785–794. <https://doi.org/10.1145/2939672.2939785>

20. Ke G., Meng Q., Finley T., Wang T., Chen W., Ma W., Ye Q., Liu T.Y. LightGBM: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems (NIPS 2017)*. Long Beach, CA, USA: 2017;30. Available from URL: <https://proceedings.neurips.cc/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>
21. Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*. 2020 Mar. 1;404:132306. <https://doi.org/10.1016/j.physd.2019.132306>
22. Shi X., Chen Z., Wang H., Yeung D.Y., Wong W.K., Woo W.C. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in Neural Information Processing Systems (NIPS 2015)*. 2015;28. Available from URL: <https://papers.nips.cc/paper/2015/hash/07563a3fe3bbe7e3ba84431ad9d055af-Abstract.html>
23. Chen C., Yu Y., Ma S., Sheng X., Lin C., Farina D., Zhu X. Hand gesture recognition based on motor unit spike trains decoded from high-density electromyography. *Biomed. Signal Process. Control*. 2020;55:101637. <https://doi.org/10.1016/j.bspc.2019.101637>
24. Atzori M., Müller H. The Ninapro database: A resource for sEMG naturally controlled robotic hand prosthetics. In: *2015 The 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015:7151–7154. <https://doi.org/10.1109/EMBC.2015.7320041>
25. Андрианова Е.Г., Головин С.А., Зыков С.В., Лесько С.А., Чукалина Е.Р. Обзор современных моделей и методов анализа временных рядов динамики процессов в социальных, экономических и социотехнических системах. *Российский технологический журнал*. 2020;8(4):7–45. <https://doi.org/10.32362/2500-316X-2020-8-4-7-45> [Andrianova E.G., Golovin S.A., Zykov S.V., Lesko S.A., Chukalina E.R. Review of modern models and methods of analysis of time series of dynamics of processes in social, economic and socio-technical systems. *Rossiiskii tekhnologicheskii zhurnal = Russian Technological Journal*. 2020;8(4):7–45 (in Russ.). <https://doi.org/10.32362/2500-316X-2020-8-4-7-45>]
26. Никонов В.В., Горчаков А.В. Тренировка моделей машинного обучения с использованием современных средств контейнеризации и облачной инфраструктуры. *Промышленные АСУ и контроллеры*. 2021;6: 26–36. <https://doi.org/10.25791/asu.6.2021.1288> [Nikonov V.V., Gorchakov A.V. Train machine learning models using modern containerization and cloud Infrastructure. *Promyshlennye ASU i kontrolyery = Industrial Automated Control Systems and Controllers*. 2021;6:33–43 (in Russ.). <https://doi.org/10.25791/asu.6.2021.1288>]
27. Kingma D.P., Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014. <https://doi.org/10.48550/arXiv.1412.6980>
28. Wang Z., Bovik A.C. Mean squared error: Love it or leave it? A new look at signal fidelity measures. In: *IEEE Signal Processing Magazine*. 2009;26(1):98–117. <https://doi.org/10.1109/MSP.2008.930649>

Об авторах

Васильев Антон Владимирович, аспирант кафедры «Прикладные информационные технологии» Института кибербезопасности и цифровых технологий ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: bysslaev@gmail.com. SPIN-код РИНЦ 4562-5628, <https://orcid.org/0000-0001-6712-0072>

Мельников Алексей Олегович, к.т.н., доцент кафедры «Прикладные информационные технологии» Института кибербезопасности и цифровых технологий ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: melnikov.aleksey@gmail.com. <https://orcid.org/0000-0003-1980-2727>

Лесько Сергей Александрович, к.т.н., доцент, доцент кафедры «Прикладные информационные технологии» Института кибербезопасности и цифровых технологий ФГБОУ ВО «МИРЭА – Российский технологический университет» (119454, Россия, Москва, пр-т Вернадского, д. 78). E-mail: sergey@testor.ru. Scopus Author ID 57189664364, <https://orcid.org/0000-0002-6641-1609>

About the authors

Anton V. Vasiliev, Postgraduate Student, Department of Applied Information Technologies, Institute for Cybersecurity and Digital Technologies, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: bysslaev@gmail.com. RSCI SPIN-code 4562-5628, <https://orcid.org/0000-0001-6712-0072>

Alexey O. Melnikov, Cand. Sci. (Eng.), Associate Professor, Department of Applied Information Technologies, Institute for Cybersecurity and Digital Technologies, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: melnikov.aleksey@gmail.com. <https://orcid.org/0000-0003-1980-2727>

Sergey A. Lesko, Cand. Sci. (Eng.), Associate Professor, Department of Applied Information Technologies, Institute for Cybersecurity and Digital Technologies, MIREA – Russian Technological University (78, Vernadskogo pr., Moscow, 119454 Russia). E-mail: sergey@testor.ru. Scopus Author ID 57189664364, <https://orcid.org/0000-0002-6641-1609>