

Машинное обучение в реабилитационной медицине и пример классификатора движений пальцев для кистевого тренажера

И. Н. Стебаков, Д.В. Шутин, Н.А. Марахин

Орловский государственный университет имени И.С. Тургенева

Аннотация: В данной статье представлен обзор научных работ, в которых методы машинного обучения применялись для различных задач реабилитационной медицины. Для отдельных категорий технических и медицинских задач в этой области приведены примеры исследований и их основные результаты. Использование тренажеров для восстановления кисти может быть сопряжено с задачей определения движений пальцев здоровой руки. Такая задача требует классификации движений и также может решаться с использованием машинного обучения. В данной статье приводятся результаты разработки классификаторов движений пальцев с использованием таких методов, как логистическая регрессия, метод опорных векторов и нейронная сеть. Для обучения и тестирования моделей использовался ранее опубликованный набор данных, полученных с использованием электромиографических датчиков. Результаты классификации также сравниваются с результатами, полученными авторами использованных данных.

Ключевые слова: реабилитация, машинное обучение, нейронные сети, классификация движений, кистевой тренажер.

Введение

Системы машинного обучения находят широкое применение в различных направлениях медицины. На сегодняшний день таким системам не предоставляется полный доступ к лечению и восстановлению пациентов, и все процессы протекают под контролем специалистов и обычно решаются частные задачи. В восстановительной медицине методы машинного обучения помогают оценить эффективность проводимых мероприятий по реабилитации пациентов, диагностировать отклонения отдельных показателей от нормальных значений, а также используются для управления роботизированными тренажерами. Тренажеры для восстановления подвижности кисти являются одним из запросов современной медицины, и при их создании также возможно, а в отдельных случаях и целесообразно использовать методы машинного обучения. Ниже рассматриваются типичные категории задач, решаемые с их помощью, а также результаты применения отдельных методов для классификации движений кисти.

Машинное обучение в восстановительной медицине

Одним из основных приложений алгоритмов машинного обучения в восстановительной медицине является классификация набора данных по заданной разметке. Набор данных может представляться измерениями датчиков или физиологических параметров человека, рентгеновскими и другими снимками. Данные делятся на обучающие примеры, которые соответствуют определенному классу. Например, рентгеновские снимки кисти можно классифицировать в зависимости от повреждения. Таким образом, каждый снимок принадлежит определенному классу, а различные алгоритмы машинного обучения позволяют создать систему, которая будет выдавать принадлежность примера к какому-либо классу с точностью, которая рассчитывается при тестировании системы на новых данных.

Диагностирование заболеваний и двигательных нарушений при помощи машинного обучения позволяет отслеживать динамику проводимых восстановительных мероприятий, а также, при достаточной точности системы, может минимизировать количество неверных диагнозов. В статье [1] рассматривается проблема оценки тяжести дисбаланса и вестибулярной функции. Внедрена интерактивная программа реабилитации на основе виртуальной реальности, в которой используются упражнения Котторна-Кукси, и система измерения на основе датчиков. Для определения тяжести заболевания применяется классификатор, основанный на методе опорных векторов. Проведенные клинические исследования показали достоверность данных классификатора. Результаты последующей анкеты показывают, что использование новой технологии виртуальной реальности способствует восстановлению дисбаланса и вестибулярной дисфункции. В статье [2] предлагается использование методов машинного обучения для диагностирования синдрома запястного канала. В качестве входных данных используются изображения ультразвукового исследования кисти. Для

классификации применяется сверточная нейронная сеть ResNet. Точность классификации составила 90 %.

Распознавание движений различных частей тела человека наиболее часто применяется для выявления двигательных отклонений и систем захвата движений. Выявление двигательных отклонений может достигаться за счет того, что алгоритмы машинного обучения позволят отличать движения здорового человека от движения человека с двигательными расстройствами. Системы захвата движений позволяют распознавать несколько положений конечностей и используются для генерации движений на реабилитационных тренажерах. В статье [3] рассматривается проблема распознавания различных типов движения кисти. Был проведен эксперимент в лабораторной среде для сбора данных. Испытуемых просили выполнить три рисунка разной формы, используя левую и правую руки. Во время выполнения рисунков выполнялся сбор данных системой датчиков, состоящей из акселерометра и гироскопа. При применении метода главных компонент точность определения движения составила 80 %. Результат исследования может быть использован для оценки суставов при прогнозировании болезни Паркинсона, анализа походки, а также выявлять другие двигательные отклонения. В статье [4] рассматривается проблема разделения функционального и нефункционального использования верхних конечностей у людей, которые перенесли инсульт. Для классификации предлагается использование метода случайных деревьев. Данный классификатор может применяться для оценки функциональной реабилитации пациентов. Было проведено исследование, в ходе которого была получена точность классификации 94.80 % в среднем и 88.38 % для контрольной группы. В статье [5] представлено исследование, целью которого является разработка жевательного робота, который генерирует траектории в реальном времени, используя сигналы поверхностной электромиографии. Использовали концепцию центрального

генератора паттернов для создания плавных переходов от одного жевательного паттерна к другому во время упражнения. Средний показатель распознавания для всех классов жевания, временных окон, испытаний и субъектов составил $86.36\% \pm 5.2\%$. В статье [6] представлен обзор современных методов захвата движения. Подчеркивается актуальность применения методов машинного обучения и анализа данных для оценки выполнения различных движений в процессе функциональной реабилитации. Многочисленные исследовательские работы сообщают о высокой точности в прогнозировании уровня правильности работы пациента по сравнению с эталонными данными движения, собранными со здоровыми субъектами.

Помимо классификации в машинном обучении популярной задачей является регрессия, которая заключается в прогнозировании некоторого набора данных. В этом случае на выходе системы получается набор действительных чисел. Например, при определении положения кисти с помощью классификации алгоритм сможет определить одно из заданных распознаваемых положений, в то время как регрессия позволит получить углы отклонения кисти от некоторого начального положения. В статье [7] предлагается метод сбора и оценки фактических уровней вовлеченности пациента во время тренировочных упражнений путем анализа показателей, выявленных в различных аспектах. Для реализации применялись методы линейной регрессии, глубокие нейронные сети, а также наивный байесовский классификатор. Исследования показали, что использование наивного байесовского классификатора наиболее перспективно для данных целей. Исследование [8] посвящено использованию сигналов поверхностной электромиографии для прогнозирования движения верхних конечностей. В статье исследуются сравнительные характеристики поверхностной и силовой электромиографии при прогнозировании положения запястья, предплечья и локтя с использованием сигналов, извлеченных только из предплечья. При

перекрестной проверке классификатор метода опорных векторов получил усредненную точность в 84.3%, 82.4% и 71.0% соответственно для прогнозирования положения локтя, предплечья и запястья с использованием силовой электромиографии; в то время как поверхностная электромиография принесла 75.4%, 83.4% и 92.4% точности за то же предсказание соответствующих позиций. В статье [9] рассматривается тренажер для машинистов подвижного состава, основанный на искусственном интеллекте с использованием эвристических алгоритмов. Работа данного тренажера основана на искусственном интеллекте, так как он позволяет эффективно тренировать организм и улучшать основные характеристики его функционирования, которые важны при работе на железнодорожном транспорте. Авторы заключают, что описанный проект с точки зрения реализации намного выгоднее классических решений

С развитием информационных технологий становится возможным повсеместное внедрение методов машинного обучения в процесс лечения пациентов. Например, статье [10] авторами предлагается использование методов машинного обучения для прогнозирования процесса лечения восстановления пациентов, а также предсказания сопутствующих затрат. Также рассмотрены вопросы автоматизированного процесса мониторинга пациентов. В статье [11] освещены основные направления использования искусственного интеллекта в медицине, а также показаны преимущества его внедрения в систему здравоохранения, а именно повышение информационной осведомленности и квалификации врача, помощь в быстром и обоснованном принятии клинического решения путем предоставления экспертных мнений и рекомендаций. Авторами отмечается проблема того, что для эффективного расширения его применения необходимо решение ключевой проблемы: обеспечение возможности обучения ИИ-системы на основе качественных и выверенных данных.

Для методов машинного обучения необходима организация процесса сбора данных. В статье [12] предлагается информационная технология сбора информации о состоянии опорно-двигательной системы человека в процессе реабилитации после травмы. Предложен комплекс технических средств контроля состояния опорно-двигательной системы человека в процессе реабилитации после травмы для достижения целевой функции: автоматизации процесса сбора информации в реальном времени, передачи, обработки на ПЭВМ и визуализации для принятия решений. Предложенная разработка может быть рекомендована медицинским учреждениям для целей определения эффективности лечебных мероприятий.

Решаемая в настоящий момент задача по разработке нового тренажера для реабилитации кисти требует сбора данных о движениях здоровой кисти пациента для их воспроизведения на поврежденной кисти с помощью роботизированного устройства. Возможности применения отдельных методов машинного обучения для решения такой задачи рассмотрены в данной статье.

Подготовка данных о движениях кисти

Одним из наиболее перспективных источников информации для анализа движений человека является электромиография. Электромиография (далее ЭМГ) — метод исследования биоэлектрических потенциалов, возникающих в скелетных мышцах человека и животных при возбуждении мышечных волокон. Исследование проводится с помощью электромиографа или электроэнцефалографа, имеющего специальный вход для регистрации ЭМГ. Электромиограмма — кривая, записанная на фотопленке, на бумаге с помощью чернильно-пишущего осциллографа или на магнитных носителях. Амплитуда колебаний потенциала мышцы, как правило, не превышает нескольких милливольт, а их длительность — 20-25 мс.[13]

Поверхностный ЭМГ сигнал является не инвазивным способом извлечения данных о движении конечностей человека. В статье [14] рассматривается электромиографическая система управления реабилитационным роботом на основе сети мобильной связи. При помощи данной системы пациенты смогут активно участвовать в реабилитационном лечении. Была разработана конструкция механизма для восстановления подвижности верхних и нижних конечностей, а также решены задачи кинематики и динамики. На основе получения электро-миографических сигналов и нечетких нейронных сетей была получена система управления с возможностью самообучения и самоадаптации. В статье [15] рассматривается проблема непрерывной оценки кинетики запястья. Применяются глубокие нейронные сети на основе сложного автоэнкодера, использующие данные электромиограммы, полученные по нескольким каналам связи. Точность оценивалась посредством сопоставления записанных и рассчитанных данных. В качестве метода применялся коэффициент корреляции Пирсона, который составил 0.829. В статье [16] рассматривается проблема прогнозирования треморных всплесков. Предлагается использование метода скрытой модели Маркова на основе данных электромиограммы. Результаты исследования показали точность прогнозирования пределах от 75.85% до 97.47% в зависимости от полученных травм.

Для проведения анализа алгоритмов машинного обучения был взят набор данных из статьи [17]. Данный набор данных включает в себя измерения 8 каналов ЭМГ для 7 различных классов: 5 классов движений отдельных пальцев, 1 класс жест победы и 1 класс для расслабленной руки. Измерения были сгруппированы в некоторое количество примеров для каждого класса. Каждый пример содержит в себе по 150 измерений каждого из 8 каналов. Далее из каждого набора по 150 измерений необходимо извлечь признаки для обучения классификатора, в качестве которых были взяты

следующие величины: среднеквадратичное отклонение, среднеквадратичное значение, минимум, максимум, переходы через ноль, изменение средней амплитуды, амплитуда первого всплеска, средняя абсолютная величина, длина формы волны, амплитуда Уилсона. Итоговый набор данных включает в себя 6823 обучающих примеров, в каждом примере 80 признаков. Полученный набор данных был разделен на тренировочную, валидационную и тестовую выборки. Валидационная выборка служит для определения оптимальных параметров классификатора, а тестовая для последующей оценки работы алгоритма.

Классификация

Для сравнения были выбраны следующие методы классификации: логистическая регрессия, метод опорных векторов и нейронная сеть прямого распространения. Логистическая регрессия является наиболее простым из методов классификации данных и ее преимуществом является простота разработки и высокое быстродействие. Метод опорных векторов является более мощным инструментом для классификации, однако данный метод неустойчив к шуму в данных и требует подбора параметров. Нейронные сети позволяют достичь наивысшей точности, однако более сложны для вычислений. При внедрении классификатора для решения реальных задач выбирают тот, который отвечает требуемой точности и является более быстродействующим. Реализация данных методов была выполнена в программном обеспечении GNU Octave.

Для классификации с помощью логистической регрессии использовался подход один против всех. Также для предотвращения переобучения использовалась регуляризация. Точность классификации составила: 58.95% для тренировочной выборки, 60.45% для валидационной и 61.45% для тестовой.

Метод опорных векторов также подразумевает применение подхода один против всех и регуляризации. Точность классификации составила: 96.21% для тренировочной выборки, 83.5% для валидационной и 82.19% для тестовой.

Последним примененным методом является нейронная сеть прямого распространения. Архитектура включает в себя входной слой, размер которого равен числу признаков, скрытый слой и выходной слой с 7 нейронами, отдельный для каждого класса. Выходные нейроны выдают число от 0 до 1, которое является вероятностью того, что пример принадлежит данному классу. Для выбора размера скрытого слоя была использована валидационная выборка. На рис. 1 представлен график зависимости точности классификации от числа нейронов.

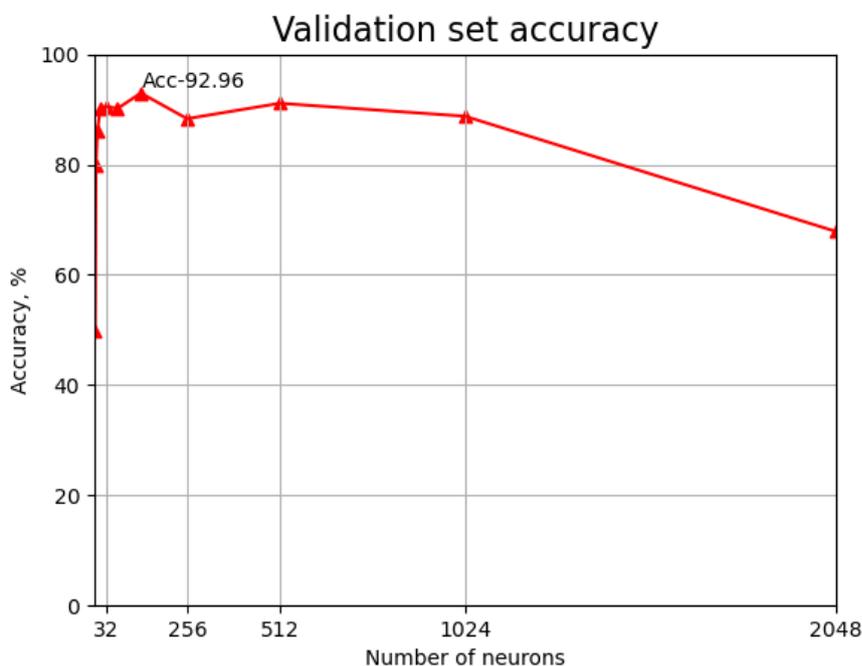


Рис. 1. – График зависимости точности классификации от числа нейронов

Лучший вариант наблюдается при 128 нейронах скрытого слоя. Точность классификации составила: 95.5% для тренировочной выборки, 92.1% для валидационной и 90.9% для тестовой. На рис. 2 представленная столбчатая диаграмма точности классификации зависимости от метода.

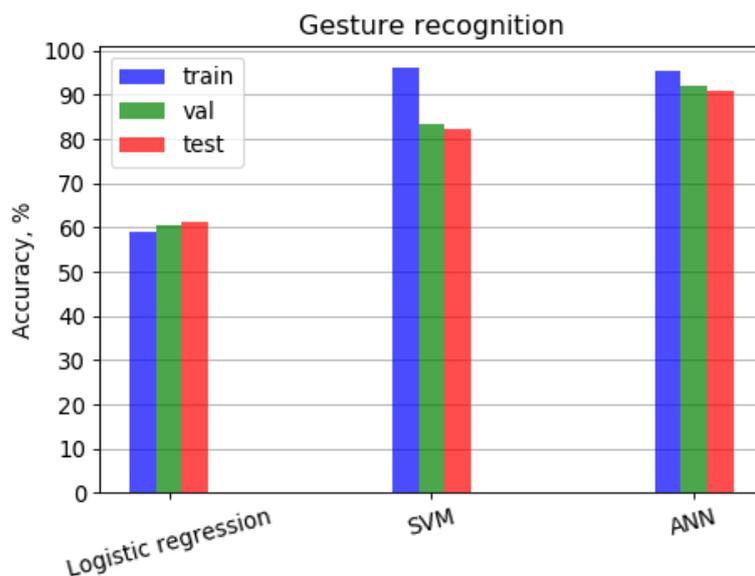


Рис. 2. – Точность классификации зависимости от метода

Таким образом, наибольшая тестовая точность была получена при использовании нейронной сети. Для определения дальнейших направлений увеличения точности полезно построить кривые обучения. Для их построения размер обучающей выборки постепенно увеличивается и записывается величина ошибки для тренировочной и валидационной выборки. На рис. 3 представлен график кривых обучения.

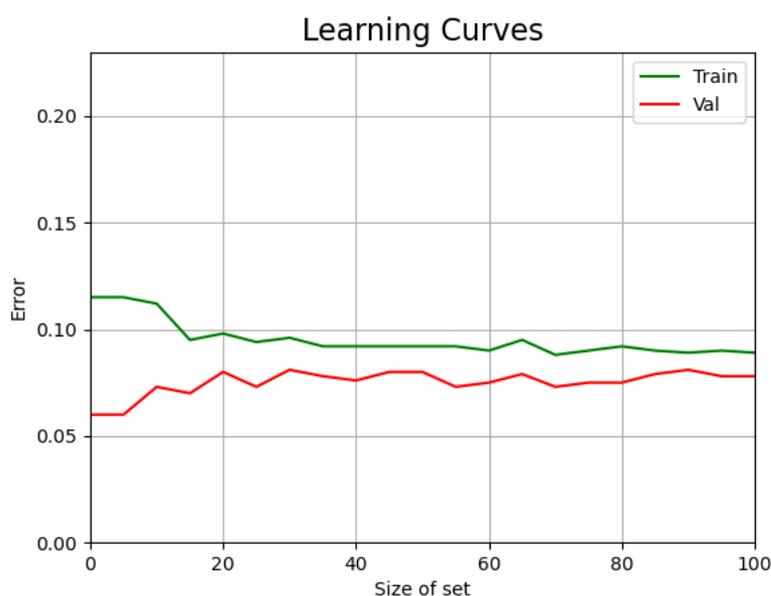


Рис. 3. – Кривые обучения

Как видно, после отметки в 40% величина ошибок перестает изменяться и разница между ними не существенна. Такая ситуация называется «low bias». В этом случае увеличение набора данных не принесет значимого увеличения точности. Среди путей увеличения точности выделяют следующие: извлечение дополнительных признаков, усложнение архитектуры сети, а также использование более сложных методов. Авторы рассматриваемого набора данных применяли метод опорных векторов, метод k-ближайших соседей и многослойную нейронную сеть [17]. Лучший результат также показала нейронная сеть. Была получена точность 95% при обучении и 92% при онлайн тестировании, что соответствует результатам, полученным в данной статье.

Заключение

Таким образом, алгоритмы машинного обучения являются мощным инструментом для решения многих задач восстановительного лечения и функциональных тренировок. Проведенный анализ литературы позволил сформировать общую картину применения методов машинного на сегодняшний день. Разрабатываемая система пассивно-активной разработки кисти на роботизированном тренажере реализуется с использованием сигналов ЭМГ датчиков. Применение типовых методов классификации данных для данных ЭМГ показало достаточно высокую точность распознавания различных движений, вплоть до 97%. Достигнутые показатели точности соразмерны наилучшим результатам иных исследователей в рассмотренной области. Вместе с тем, системы пассивно-активной разработки конечностей должны функционировать с особенно высокой степенью безопасности и бесперебойности. Это требует дальнейшего повышения точности классификации движений кисти с использованием более совершенных и точнее настроенных моделей на основе методов машинного обучения.

Литература

1. Shih-Ching Yeh, Ming-Chun Huang, Pa-Chun Wang, Te-Yung Fang, Mu-Chun Su, Po-Yi Tsai, Albert Rizzo Machine learning-based assessment tool for imbalance and vestibular dysfunction with virtual reality rehabilitation system // Computer Methods and Programs in Biomedicine. 2014. Volume 116, Issue 3. pp. 311-318. DOI:10.1016/j.cmpb.2014.04.014.
 2. You-Wei Wang, Ruey-Feng Chang, Yi-Shiung Horng, Chii-Jen Chen MNT-DeepSL: Median nerve tracking from carpal tunnel ultrasound images with deep similarity learning and analysis on continuous wrist motions // Computerized Medical Imaging and Graphics. 2020. Volume 80. DOI: 10.1016/j.compmedimag.2019.101687.
 3. Yong, Ching & Chew, Kim Mey & Sudirman, Rubita. Human wrist motion classification using decision tree and principle component analysis // Materials Today: Proceedings. 2019. Volume 16, Part 4. pp. 1750-1756. DOI:10.1016/j.matpr.2019.06.045.
 4. Bochniewicz, Elaine & Emmer, Geoff & McLeod, Adam & Barth, Jessica & Dromerick, Alexander & Lum, Peter Measuring Functional Arm Movement after Stroke Using a Single Wrist-Worn Sensor and Machine Learning // Journal of Stroke and Cerebrovascular Diseases. 2017. Volume 26, Issue 12. pp. 2880-2887. DOI:10.1016/j.jstrokecerebrovasdis.2017.07.004.
 5. Hadi Kalani, Sahar Moghimi, Alireza Akbarzadeh Toward a bio-inspired rehabilitation aid: sEMG-CPG approach for online generation of jaw trajectories for a chewing robot // Biomedical Signal Processing and Control. 2019. Volume 51. pp. 285-295. DOI: 10.1016/j.bspc.2019.02.022.
 6. Yalin Liao, Aleksandar Vakanski, Min Xian, David Paul, Russell Baker A review of computational approaches for evaluation of rehabilitation exercises // Computers in Biology and Medicine. 2020. Volume 119. DOI:10.1016/j.combiomed.2020.103687.
-

7. Chong Li, Zoltán Rusák, Imre Horváth, Linhong Ji Development of engagement evaluation method and learning mechanism in an engagement enhancing rehabilitation system // Engineering Applications of Artificial Intelligence. 2016. Volume 51. pp. 182-190. DOI:10.1016/j.engappai.2016.01.021.

8. Zhen Gang Xiao, Carlo Menon Performance of Forearm FMG and sEMG for Estimating Elbow, Forearm and Wrist Positions // Journal of Bionic Engineering. 2017. Volume 14, Issue 2. pp. 284-295. DOI: 10.1016/S1672-6529(16)60398-0.

9. Круглов В.А. Применение системы искусственного интеллекта на железнодорожных тренажерах // БРНИ. 2013. №1-2 (6-7). URL: cyberleninka.ru/article/n/primeneniye-sistemy-iskusstvennogo-intellekta-na-zheleznodorozhnyh-trenazherah (дата обращения: 10.04.2020).

10. Prem N. Ramkumar, Heather S. Haerberle, Michael R. Bloomfield, Jonathan L. Schaffer, Atul F. Kamath, Brendan M. Patterson, Viktor E. Krebs Artificial Intelligence and Arthroplasty at a Single Institution: Real-World Applications of Machine Learning to Big Data, Value-Based Care, Mobile Health, and Remote Patient Monitoring // The Journal of Arthroplasty. 2019. Volume 34, Issue 10. pp. 2204-2209. DOI:10.1016/j.arth.2019.06.018.

11. Манкибаев Булат Салимжанович Основные направления внедрения искусственного интеллекта в медицине // Наука, образование и культура. 2019. №3 (37). URL: cyberleninka.ru/article/n/osnovnyye-napravleniya-vnedreniya-iskusstvennogo-intellekta-v-meditsine (дата обращения: 14.04.2020).

12. Нестругина Е.С., Чичикало Н.И., Ларина Е.Ю. Информационная технология сбора информации о состоянии опорно-двигательной системы человека в процессе реабилитации после травмы // Сборник научных трудов ДНИЖТ. 2018. №48. URL: cyberleninka.ru/article/n/informatsionnaya-tehnologiya-sbora-informatsii-o-sostoyanii-oporno-dvigatelnoy-sistemy-cheloveka-v-protssesse-reabilitatsii-posle (дата обращения: 15.04.2020).

13. Николаев С. Г. Электромиография: клинический практикум. Иваново, 2013.
14. Fengmei Gao, Linhong Wang, Tao Lin Intelligent wearable rehabilitation robot control system based on mobile communication network // Computer Communications. 2020. Volume 153. pp. 286-293. DOI: 10.1016/j.comcom.2020.01.054.
15. Yang Yu, Chen Chen, Xinjun Sheng, Xiangyang Zhu Multi-DoF continuous estimation for wrist torques using stacked autoencoder // Biomedical Signal Processing and Control. Volume 57. 2020. DOI: 10.1016/j.bspc.2019.101733.
16. Saeedeh Samaee, Hamid Reza Kobravi Predicting the occurrence of wrist tremor based on electromyography using a hidden Markov model and entropy based learning algorithm // Biomedical Signal Processing and Control. 2020. Volume 57. DOI:10.1016/j.bspc.2019.101739.
17. Naseer, Noman & Ali, Faizan & Ahmed, Sameer & Iftikhar, Saad & Khan, Rayyan & Gilani, S. Hammad EMG Based Control of Individual Fingers of Robotic Hand // 2018 International Conference on Sustainable Information Engineering and Technology. 2018. pp. 6-9. DOI:10.1109/SIET.2018.8693177.

References

1. Shih-Ching Yeh, Ming-Chun Huang, Pa-Chun Wang, Te-Yung Fang, Mu-Chun Su, Po-Yi Tsai, Albert Rizzo. Computer Methods and Programs in Biomedicine. 2014. Volume 116, Issue 3. pp. 311-318. DOI:10.1016/j.cmpb.2014.04.014.
 2. You-Wei Wang, Ruey-Feng Chang, Yi-Shiung Horng, Chii-Jen Chen. Computerized Medical Imaging and Graphics. 2020. Volume 80. DOI: 10.1016/j.compmedimag.2019.101687.
-

3. Yong, Ching & Chew, Kim Mey & Sudirman, Rubita. *Materials Today: Proceedings*. 2019. Volume 16, Part 4. pp. 1750-1756. DOI:10.1016/j.matpr.2019.06.045.
 4. Bochniewicz, Elaine & Emmer, Geoff & McLeod, Adam & Barth, Jessica & Dromerick, Alexander & Lum, Peter. *Journal of Stroke and Cerebrovascular Diseases*. 2017. Volume 26, Issue 12. pp. 2880-2887. DOI:10.1016/j.jstrokecerebrovasdis.2017.07.004.
 5. Hadi Kalani, Sahar Moghimi, Alireza Akbarzadeh. *Biomedical Signal Processing and Control*. 2019. Volume 51. pp. 285-295. DOI: 10.1016/j.bspc.2019.02.022.
 6. Yalin Liao, Aleksandar Vakanski, Min Xian, David Paul, Russell Baker. *Computers in Biology and Medicine*. 2020. Volume 119. DOI:10.1016/j.combiomed.2020.103687.
 7. Chong Li, Zoltán Rusák, Imre Horváth, Linhong Ji. *Engineering Applications of Artificial Intelligence*. 2016. Volume 51. pp. 182-190. DOI:10.1016/j.engappai.2016.01.021.
 8. Zhen Gang Xiao, Carlo Menon. *Journal of Bionic Engineering*. 2017. Volume 14, Issue 2. pp. 284-295. DOI: 10.1016/S1672-6529(16)60398-0.
 9. Kruglov V.A. BRNI. 2013. №1-2 (6-7). URL: cyberleninka.ru/article/n/primenenie-sistemy-iskusstvennogo-intellekta-na-zheleznodorozhnyh-trenazherah (accessed: 10.04.2020).
 10. Prem N. Ramkumar, Heather S. Haeberle, Michael R. Bloomfield, Jonathan L. Schaffer, Atul F. Kamath, Brendan M. Patterson, Viktor E. Krebs. *The Journal of Arthroplasty*. 2019. Volume 34, Issue 10. pp. 2204-2209. DOI:10.1016/j.arth.2019.06.018.
 11. Nestrugina E.S., Chichikalo N.I., Larina E.Yu. *Sbornik nauchny`x trudov DonIzhT*. 2018. №48. URL: cyberleninka.ru/article/n/informatsionnaya-
-

tehnologiya-sbora-informatsii-o-sostoyanii-oporno-dvigatelnoy-sistemy-cheloveka-v-protssesse-reabilitatsii-posle (accesseda: 15.04.2020).

12. Nestrugina E.S., Chichikalo N.I., Larina E.Yu. Collection of scientific papers DonIZHT. 2018. №48. URL: cyberleninka.ru/article/n/informatsionnaya-tehnologiya-sbora-informatsii-o-sostoyanii-oporno-dvigatelnoy-sistemy-cheloveka-v-protssesse-reabilitatsii-posle (accessed: 04.15.2020).

13. Nikolaev S. G. E`lektromiografiya: klinicheskij praktikum [Electromyography: a clinical workshop]. Ivanovo, 2013.

14. Fengmei Gao, Linhong Wang, Tao Lin. Computer Communications. 2020. Volume 153. pp. 286-293. DOI: 10.1016/j.comcom.2020.01.054.

15. Yang Yu, Chen Chen, Xinjun Sheng, Xiangyang Zhu. Biomedical Signal Processing and Control. Volume 57. 2020. DOI: 10.1016/j.bspc.2019.101733.

16. Saeedeh Samaee, Hamid Reza Kobravi. Biomedical Signal Processing and Control. 2020. Volume 57. DOI:10.1016/j.bspc.2019.101739.

17. Naseer, Noman & Ali, Faizan & Ahmed, Sameer & Iftikhar, Saad & Khan, Rayyan & Gilani, S. Hammad. 2018 International Conference on Sustainable Information Engineering and Technology. 2018. pp. 6-9. DOI: 10.1109/SIET.2018.8693177.