

DOI: <https://doi.org/10.5281/zenodo.17724115>

## АНАЛИЗ СОВРЕМЕННЫХ МЕТОДОВ ОБРАБОТКИ ЭЛЕКТРОМИОГРАФИЧЕСКИХ СИГНАЛОВ

**Каххаров Аълохон Абборович**

кандидат технических наук Ташкентского университета информационных технологий  
имени Мухаммада Аль Хорезми

**Шукуров Санжар Фазлиддин угли**

магистр Ташкентского университета информационных технологий имени Мухаммада Аль  
Хорезми

E-mail: [sanjarshukurov0601@gmail.com](mailto:sanjarshukurov0601@gmail.com)

**Аннотация** - В статье рассмотрены современные подходы к обработке электромиографических (ЭМГ) сигналов, направленные на повышение точности и информативности анализа биоэлектрической активности мышц. Проведено систематическое сравнение временных, частотных и вейвлет-методов, а также гибридных алгоритмов, объединяющих их преимущества. Особое внимание уделено проблемам шумоподавления, извлечения информативных признаков и интерпретации результатов при исследовании мышечной активности в спорте и биомедицинской инженерии. На основе анализа отечественных и зарубежных источников выделены тенденции развития современных систем ЭМГ-анализа, включающие применение машинного обучения и адаптивных алгоритмов фильтрации.

**Ключевые слова:** электромиография, биосигналы, фильтрация, вейвлет-преобразование, извлечение признаков, машинное обучение, обработка сигналов.

### ВВЕДЕНИЕ

Электромиография (ЭМГ) является одним из важнейших инструментов в исследовании функционального состояния мышц и диагностике нейромышечных нарушений. Электромиографический сигнал представляет собой суммарную электрическую активность, возникающую при возбуждении мышечных волокон под действием потенциалов действия мотонейронов. При сокращении мышцы активируются моторные единицы — функциональные комплексы из мотонейрона и связанных с ним волокон. Каждая моторная единица генерирует кратковременный биоэлектрический импульс, который суммируется с другими, образуя колебательный сигнал сложной формы.

ЭМГ измеряет амплитуду и частотный спектр этих потенциалов, что отражает уровень мышечного напряжения, скорость рекрутирования моторных единиц и степень их синхронизации. При утомлении наблюдается снижение частотных компонентов и увеличение амплитуды низкочастотных составляющих. Таким образом, ЭМГ является объективным индикатором

функционального состояния мышц и позволяет оценивать их активность, координацию и утомляемость.

ЭМГ-сигнал отражает суммарную биоэлектрическую активность мышечных волокон, однако его структура сложна и подвержена влиянию множества внешних и внутренних факторов. Шумы, артефакты движения и перекрёстные наводки нередко искажают исходную форму сигнала, затрудняя получение достоверных данных. Эти обстоятельства делают задачу обработки ЭМГ-сигналов особенно значимой. Именно от эффективности методов обработки зависит точность последующего анализа и корректность выводов о физиологическом состоянии исследуемого объекта. Для этого применяются разнообразные математические подходы — от классических фильтров до современных нейросетевых моделей.

Таким образом, необходимость систематизации и сравнительной оценки существующих методов становится очевидной. В следующих разделах рассматриваются основные теоретические принципы анализа ЭМГ, проводится классификация подходов и даётся их сравнительная характеристика с точки зрения точности, вычислительной сложности и устойчивости к шумам.

## **ТЕОРИТИЧЕСКИЕ ОСНОВЫ ОБРАБОТКИ ЭЛЕКТРОМИОГРАФИЧЕСКИХ СИГНАЛОВ**

Электромиографический сигнал по своей природе является сложным, нестационарным и стохастическим процессом, отражающим суммарную биоэлектрическую активность множества моторных единиц мышцы [1].

Каждая моторная единица состоит из мотонейрона и группы иннервируемых им мышечных волокон. При передаче нервного импульса возникает электрический потенциал действия, который распространяется вдоль мембраны волокна [2]. Совокупность таких потенциалов формирует регистрируемый ЭМГ-сигнал, амплитуда и частотный спектр которого зависят от числа активированных моторных единиц, их синхронности и функционального состояния мышцы [3].

Основная задача обработки ЭМГ-сигналов заключается в выделении информативных признаков, позволяющих количественно оценить состояние мышечной системы — уровень активации, степень утомления, симметрию работы мышц или наличие патологических изменений [5]. Поскольку сигнал содержит значительное количество шумов и артефактов, этап предварительной обработки играет решающую роль: сюда входят фильтрация, подавление сетевых помех и нормализация данных [1]. После этого осуществляется анализ временной структуры, спектрального состава и статистических характеристик сигнала, позволяющий перейти от необработанных данных к физиологически осмысленным показателям [3].

Процесс анализа обычно завершается этапом интерпретации или классификации, когда на основании извлечённых признаков система принимает решение — например, определяет тип движения, уровень усталости или наличие

мышечного дисбаланса [8]. Таким образом, обработка ЭМГ-сигнала представляет собой многоэтапный процесс, объединяющий физические, математические и биоинженерные методы [1].

Понимание теоретических основ этого процесса необходимо для корректного выбора алгоритмов и интерпретации полученных данных. Различные подходы к обработке — от классических линейных фильтров до современных методов машинного обучения — опираются на те же базовые принципы, но реализуют их с различной степенью адаптивности и устойчивости [3].

## **КЛАССИФИКАЦИЯ СОВРЕМЕННЫХ МЕТОДОВ ОБРАБОТКИ ЭМГ**

Электромиографические сигналы анализируются с помощью широкого спектра методов, различающихся по математическому подходу, устойчивости к шуму и вычислительной сложности [7]. Эволюция обработки ЭМГ отражает общий переход от простых статистических процедур к адаптивным и интеллектуальным системам, способным учитывать нестационарность и индивидуальные особенности сигнала [8]. Условно все подходы можно разделить на четыре направления — временные, частотные, временно-частотные и интеллектуальные методы [3].

Временные методы являются наиболее простыми и интуитивно понятными. Они анализируют форму сигнала во временной области и позволяют оценивать активность мышцы по амплитудным и статистическим характеристикам [4]. Наиболее распространённые показатели — среднеквадратичное значение (RMS), средняя абсолютная амплитуда (MAV), число пересечений нуля (ZC) и количество поворотов сигнала (SSC) [5]. Эти признаки хорошо отражают уровень активации мышцы и динамику её работы, что делает их полезными для мониторинга базовой активности или обратной связи в системах реабилитации [11]. Однако временные методы не учитывают частотное распределение энергии и чувствительны к шуму, что ограничивает их применимость при сложных динамических движениях [11].

Частотные методы основаны на исследовании спектральных свойств сигнала. С помощью быстрого преобразования Фурье (FFT) вычисляются показатели средней частоты (MNF) и медианной частоты (MDF), которые коррелируют с физиологическими изменениями при мышечной усталости [6]. Эти методы позволяют количественно оценивать частотные сдвиги в спектре, возникающие при утомлении, однако их точность снижается при анализе коротких или нестационарных фрагментов сигнала [6].

Для решения этой проблемы применяются временно-частотные методы, обеспечивающие одновременную локализацию сигнала во времени и по частоте [1]. Наиболее известные из них — короткое преобразование Фурье (STFT) и вейвлет-анализ (Wavelet Transform) [7]. Вейвлет-преобразование использует масштабируемые базисные функции, например Морле и Добеши, что обеспечивает высокую чувствительность к кратковременным событиям [1].

Эмпирическая модовая декомпозиция (EMD) разлагает сигнал на адаптивные моды, выявляя скрытые частотные компоненты [7].

Интеллектуальные методы основаны на алгоритмах машинного обучения и нейросетевых моделях [9]. Метод опорных векторов (SVM) и случайный лес (Random Forest) позволяют классифицировать сигналы по заранее рассчитанным признакам [9]. Свёрточные (CNN) и рекуррентные (LSTM) сети способны автоматически извлекать признаки из необработанных данных, обучаясь на больших выборках [10,12]. Эти подходы обеспечивают высокую точность, но требуют больших объёмов данных и вычислительных ресурсов [9].

**СРАВНИТЕЛЬНЫЙ АНАЛИЗ МЕТОДОВ ОБРАБОТКИ ЭМГ**

Выбор метода обработки определяется балансом между точностью, вычислительной сложностью и устойчивостью к шуму [3]. Развитие технологий привело к появлению множества алгоритмов, и ни один из них не может считаться универсальным. Сравнение ключевых характеристик наиболее распространённых подходов представлено в таблице ниже.

**Таблица 1**

**Ключевые характеристики методов обработки ЭМГ**

Метод	Область анализа	Устойчивост ь к шуму	Сложност ь	Применимост ь в реальном времени	Краткий комментарий
RMS, MAV	Временная	Низкая	Низкая	Высокая	Просты и быстры, подходят для базового мониторинга активности
MDF, MNF	Частотная	Средняя	Средняя	Средняя	Эффективны при оценке усталости, но требуют стационарного сигнала
STFT	Временно- частотная	Средняя	Средняя	Средняя	Даёт динамическое представление, но ограничено фиксированным окном
Wavele t	Временно- частотная	Высокая	Средняя	Средняя	Устойчив к артефактам, подходит для нестационарны х биосигналов
EMD	Адаптивная	Высокая	Высокая	Низкая	Гибкий метод, но вычислительно

					трудоёмкий
ML (SVM, CNN)	Интеллектуальна я	Высокая	Высокая	Средняя	Высокая точность при больших данных, требуется обучения модели

Таблица (Таб. 1) отражает общий компромисс между точностью и скоростью. ростые временные методы (RMS, MAV) актуальны для систем, где важна оперативность — например, в устройствах биологической обратной связи [4] или портативных ЭМГ-модулях. Частотные подходы лучше справляются с анализом усталости, поскольку медианная и средняя частоты напрямую связаны с физиологическим состоянием мышцы [6]. Однако такие методы ограничены предположением о стационарности сигнала, что делает их менее надёжными при работе с динамическими движениями. Методы совместной локализации, такие как STFT и вейвлет-анализ, обеспечивают компромисс между информативностью и вычислительной нагрузкой [1]. Особенно перспективен вейвлет-подход: он способен адаптироваться к временным масштабам и эффективно выделять кратковременные события, что критично для спортивной биомеханики и реабилитационных исследований. В свою очередь, адаптивные и интеллектуальные методы, включая EMD и машинное обучение, позволяют достичь высокой точности и устойчивости, но требуют значительных вычислительных ресурсов и тщательно подобранных обучающих данных [9, 10].

Сравнение показывает, что в современных исследованиях всё чаще используются **гибридные подходы**, объединяющие преимущества временно-частотного анализа и машинного обучения. Такие решения демонстрируют оптимальный баланс между информативностью и скоростью, что делает их особенно ценными для задач мониторинга в реальном времени и автоматической классификации мышечных состояний [3,8].

**ЗАКЛЮЧЕНИЕ**

Анализ современных методов обработки электромиографических сигналов показывает, что развитие этой области движется в направлении комплексных и адаптивных решений, объединяющих преимущества различных подходов. Каждый класс методов обладает собственной областью эффективности: временные алгоритмы остаются незаменимыми для оперативного мониторинга активности мышц, частотные — для анализа усталости и оценки функционального состояния, временно-частотные — для изучения нестационарных процессов и кратковременных фаз сокращения, а интеллектуальные — для распознавания сложных паттернов и автоматической классификации движений.

Сравнение показало, что универсального метода, одинаково эффективного



для всех задач, не существует. Выбор подхода определяется целями исследования, требованиями к вычислительной скорости и устойчивости к шуму, а также особенностями экспериментальных данных. Вместе с тем наибольший научно-практический потенциал демонстрируют **гибридные системы**, в которых сочетаются методы временно-частотного анализа (в частности, вейвлет-преобразование) и алгоритмы машинного обучения.

Такое объединение позволяет не только повысить точность и устойчивость обработки, но и адаптировать систему под индивидуальные особенности испытуемого, что особенно важно для задач спортивной биомеханики, реабилитации и медицинской диагностики.

Дальнейшее развитие исследований в этой области связано с созданием открытых баз данных ЭМГ-сигналов, стандартизацией протоколов регистрации и разработкой алгоритмов, способных работать в режиме реального времени на ограниченных вычислительных ресурсах. Решение этих задач позволит сделать электромиографию не только инструментом научного анализа, но и надёжной технологической основой для систем мониторинга, управления и обратной связи в человеко-машинных интерфейсах нового поколения.

### СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Merletti R., Parker P.A. *Electromyography: Physiology, Engineering and Non-invasive Applications*. — New York: IEEE Press – Wiley-Interscience, 2004. — 494 p.
2. De Luca C.J. The use of surface electromyography in biomechanics // *Journal of Applied Biomechanics*, 1997. — Vol. 13, No. 2. — P. 135–163.
3. Farina D., Merletti R., Enoka R.M. The extraction of neural information from the surface EMG // *Journal of Applied Physiology*, 2004. — Vol. 96, No. 4. — P. 1486–1495.
4. Clancy E.A., Hogan N. Single-site electromyographic amplitude estimation // *IEEE Transactions on Biomedical Engineering*, 1994. — Vol. 41, No. 2. — P. 159–167.
5. Phinyomark A., Limsakul C., Phukpattaranont P. Feature extraction of EMG signals for pattern classification // *Measurement Science Review*, 2011. — Vol. 11, No. 2. — P. 45–52.
6. Dimitrov G.V., Arabadzhiev T.I., Mileva K.N. Muscle fatigue and EMG spectral changes // *Muscle & Nerve*, 2006. — Vol. 33, No. 6. — P. 760–773.
7. Сатторов М. Э., Собиров А. Б. Электромиография сигналларини қайта ишлаш: параметрлар ва усуллар таҳлили // *Илмий техника журналы «ФарПИ ахборотномаси»* (Fergana Polytechnic Institute Bulletin), 2023. — Т. 27, № 2. — С. 87–93.
8. Рахматов Б. М., Абдуллаев Ш. С. Аналитический обзор методов регистрации и обработки сигналов электромиографии // *International Journal of Digital Technology (IJDT, Узбекистан)*, 2025. — Т. 3, № 1. — С. 55–61.
9. Oskoei M.A., Hu H. Support Vector Machine-based classification scheme for myoelectric control // *IEEE Transactions on Biomedical Engineering*, 2008. — Vol. 55, No. 8. — P. 1956–1965.

10. Atzori M., Gijsberts A., Castellini C. et al. Deep learning for hand movement classification based on surface EMG // *Neural Networks*, 2016. — Vol. 88. — P. 60–68.
11. Tkach D., Huang H., Kuiken T.A. Study of stability of time-domain features for myoelectric pattern recognition // *Journal of NeuroEngineering and Rehabilitation*, 2010. — Vol. 7, Article