

МИНИСТЕРСТВО НАУКИ И ВЫСШЕГО ОБРАЗОВАНИЯ
РОССИЙСКОЙ ФЕДЕРАЦИИ

Федеральное государственное автономное
образовательное учреждение высшего образования
«ЮЖНЫЙ ФЕДЕРАЛЬНЫЙ УНИВЕРСИТЕТ»

На правах рукописи



КИРИЛЕНКО Николай Евгеньевич

**МЕТОД ЧАСТОТНО-ВРЕМЕННОЙ ЛОКАЛИЗАЦИИ
АПРИОРНО НЕОПРЕДЕЛЕННЫХ ПАТТЕРНОВ В СОСТАВЕ
ЗАШУМЛЕННЫХ СИГНАЛОВ НЕЙРОКОМПЬЮТЕРНОГО
ИНТЕРФЕЙСА**

Специальность: 2.3.1. Системный анализ, управление
и обработка информации, статистика

ДИССЕРТАЦИЯ

на соискание ученой степени
кандидата технических наук

Научный руководитель:

доктор технических наук, доцент

Щербань Игорь Васильевич

Таганрог – 2025

ОГЛАВЛЕНИЕ

ВВЕДЕНИЕ.....	4
ГЛАВА 1. АНАЛИЗ МЕТОДОВ ПОИСКА ПАТТЕРНОВ В СОСТАВЕ ЭЛЕКТРОЭНЦЕФАЛОГРАММЫ И ИХ ОГРАНИЧЕНИЯ.....	16
1.1. Методы поиска паттернов во временной области	16
1.2. Методы поиска паттернов в частотной области	23
1.3. Методы поиска паттернов в частотно-временной области	25
1.4. Выводы к главе 1	34
ГЛАВА 2. РАЗРАБОТКА МЕТОДА И КРИТЕРИЕВ ОПТИМАЛЬНОСТИ ЧАСТОТНО-ВРЕМЕННОЙ ЛОКАЛИЗАЦИИ ПАТТЕРНОВ ЗАШУМЛЕННЫХ СИГНАЛОВ ЭЛЕКТРОЭНЦЕФАЛОГРАММЫ	39
2.1. Математическая постановка задачи и требования к разрабатываемому методу частотно-временной локализации паттернов.....	39
2.2 Разработка метода частотно-временной локализации априорно неопределенных паттернов	45
2.3 Дополнительные критериальные функции с использованием трансформант Фурье	52
2.4 Критерии оптимальности для многомерного случая	56
2.5. Выводы ко второй главе	57
ГЛАВА 3. РАЗРАБОТКА АЛГОРИТМОВ ЧАСТОТНО-ВРЕМЕННОЙ ЛОКАЛИЗАЦИИ ПАТТЕРНОВ В СОСТАВЕ ЗАШУМЛЕННЫХ СИГНАЛОВ ЭЛЕКТРОЭНЦЕФАЛОГРАММЫ И МОДЕЛИРОВАНИЕ..	59
3.1. Алгоритм и программная реализация частотно-временной локализации на основе непрерывного вейвлет-преобразования	59
3.2. Апробация алгоритма частотно-временной локализации паттернов на основе непрерывного вейвлет преобразования с использованием модельных данных. 64	

3.3. Алгоритм и программная реализация частотно-временной локализации на основе трансформант Фурье	70
3.4. Апробация алгоритма частотно-временной локализации паттернов на основе трансформант Фурье с использованием модельных данных	72
3.5. Выводы к третьей главе	79
ГЛАВА 4. ЭКСПЕРИМЕНТАЛЬНАЯ АПРОБАЦИЯ	80
4.1. Апробация к задаче поиска двигательных паттернов электроэнцефалограммы человека	80
4.2. Апробация к задаче поиска вербальных речевых паттернов электроэнцефалограммы человека	88
4.3. Выводы к четвертой главе	97
ЗАКЛЮЧЕНИЕ	98
СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ	101
СПИСОК ЛИТЕРАТУРЫ	102
ПРИЛОЖЕНИЕ А.....	117
Блок-диаграмма виртуального прибора в среде LABVIEW NI спектральной энтропии с использованием частотной-локализации.....	117
Блок-диаграмма виртуального прибора в среде LABVIEW NI вейвлет энтропии с использованием частотной-локализации	118
ПРИЛОЖЕНИЕ Б.....	119
Код программы вычисления спектральной энтропии и разработанных критериев оптимальности	119
ПРИЛОЖЕНИЕ В.....	125
Акты о внедрении результатов работы	125
ПРИЛОЖЕНИЕ Г	127
Свидетельства о регистрации программ для ЭВМ по теме исследования	127

ВВЕДЕНИЕ

Актуальность темы исследований. Технология интерфейсов «мозг-компьютер» (ИМК), позволяющая оперировать невербальными и немышечными каналами коммуникации и управления, находит на сегодняшний день не только исследовательское, но и медицинское применение. Подобная система нейрокоммуникации способна функционировать в тех случаях, когда у пользователей наблюдаются тяжелые двигательные нарушения, вызванные нейродегенеративными заболеваниями или травмами спинного мозга [1-6]. Неинвазивный способ реализации каналов нейрокоммуникации на основе интерпретации сигналов электроэнцефалограммы (ЭЭГ) обеспечивает связь с внешним миром парализованных или обездвиженных пациентов. Подобные ИМК могут обеспечить управление внешними устройствами в реальном масштабе времени. Одним из наиболее перспективных является ИМК, адаптирующийся к функциональному состоянию пациента. Важным преимуществом такого ИМК является то, что исчерпывающих знаний о механизмах обработки моторной и когнитивной информации популяциями нейронов и мозгом в целом не требуется, а достаточным является лишь определение корреляций между нейрональной активностью и намерением человека реализовать соответствующее движение.

Несмотря на то, что ИМК активно разрабатывается на протяжении ряда последних лет, проблема обеспечения требуемой его эффективности все еще является актуальной. В первую очередь, для надежной классификации команд нейроуправления необходимо существенное повышение точности детектирования и идентификации паттернов ЭЭГ. Точная локализация по оси времени границ паттернов невербальной и немышечной коммуникации человека предопределяет правильность идентификации и точность классификации команд нейроуправления [7–8].

Высокоточная классификация паттернов, в итоге, обуславливает требуемую эффективность ИМК. Под паттерном при этом понимается уникальная

биоэлектрическая активность головного мозга, сопряжённая с произвольной двигательной или идеомоторной деятельностью человека, отражаемая в соответствующей совокупности пространственных, временных и частотных характеристик сигналов ЭЭГ. Сигналы ЭЭГ представляют собой многомерную последовательность многократных измерений биоэлектрической активности мозга человека в одноименные моменты времени на большом количестве электродных пар. На каждой электродной паре измеряется напряжение между определенной областью головного мозга и референтным электродом. Разность потенциалов между электродными парами отражает динамику изменения биоэлектрической активности различных пространственных областей головного мозга.

Несмотря на значительный объем публикаций по названной тематике, на сегодняшний день проблемы высокоточной классификации ЭЭГ паттернов команд нейроуправления в ИМК объясняется следующим. Свойства биоэлектрических паттернов определяются текущим психофизиологическим состоянием человека, а также тем, к какому типу движения ведётся подготовка – реальному или мысленному, произвольному или баллистическому (спонтанному). Поэтому их энергетические спектры изменчивы во времени и априорно неизвестны. Кроме того, модальные частоты различных ритмов мозга могут демонстрировать весьма высокую вариативность, в том числе, в связи с развитием эффектов утомления человека, или монотонии. Это обуславливает непредсказуемую вариативность во времени частотных границ паттернов. Также следует учитывать, что высокая зашумленность сигналов ЭЭГ объясняется не только шумами электронных трактов измерительной и регистрирующей аппаратуры, но и шумами, связанными с принципиально неизвестными исследователю физическими, а, в ряде случаев, и физиологическими процессами. К подобного рода процессам, можно отнести так называемые артефакты – паттерны спонтанной активности мозга, частотные спектры которых могут быть близкими к спектрам искомым паттернов.

Соответственно, реализация новых методов и средств, обеспечивающих высокую точность классификации команд нейроуправления в составе многомерных сигналов ЭЭГ в ИМК, **является важной и актуальной задачей.** В

работе рассмотрен новый метод решения этой задачи, основанный на точном определении частотно-временных границ паттернов биоэлектрической активности мозга человека. Вследствие априорной неопределенности границ паттернов мысленных команд управления выборки для их классификации содержат, в том числе, неинформативную фоновую активность, что снижает точность классификации и идентификации моделей машинного обучения. Соответственно, решение задачи частотно-временной локализации паттернов команд нейроуправления обеспечивает формирование репрезентативной выборки для их последующей точной классификации.

Степень разработанности темы исследования. Для детектирования и идентификации паттернов в составе сигналов ЭЭГ широко используются статистические методы [2,9-16]. Однако, их главными недостатками являются низкая чувствительность, в ряде случаев требуется наличие репрезентативной выборки примеров, отсутствие частотной локализации. Подобного рода недостатками также обладают методы на основе теории вероятностей [17-22] и методы на основе применения теории информации [23-30]. Вклад в развитие данных методов внесли такие ученые как Капралов Н. В., Щербань И. В., Arzate-Mena J. D., Dehais F., Wang K., Xu M..

К широко распространённым методам локализации ЭЭГ-паттернов, помимо статистических, вероятностных и энтропийных, можно отнести и методы на основе алгоритмов машинного обучения [30-39], которые лишены большинства недостатков предыдущих, но данные методы также требуют наличия репрезентативной выборки примеров, что в ряде случаев невозможно. Наибольший вклад внесли следующие ученые: Брагин А. Д., Лебедева Н. Н., Суворов А. В., Jing J., Oliva J. T., Zhu C. и другие.

Еще одной группой методов, получившей широкое распространение, являются методы локализации ЭЭГ-паттернов на основе спектрального анализа Фурье [40-44], позволяющие произвести поиск в частотной области. Однако, недостатки данной группы методов обусловлены особенностями преобразования Фурье, а именно, низкое частотное разрешение, а также отсутствие разрешения по

оси времени. Также к ограничениям стоит отнести проблемы, с тем, что в большинстве случаев ЭЭГ нестационарна во времени, что делает применение методов на основе анализа спектра неприменимыми в классическом виде.

Недостатки методов локализации ЭЭГ-паттернов на основе кепстрального анализа [45-49] аналогичны, что и для методов на основе анализа Фурье. Наибольший вклад в разработку подобного рода методов внесли Woo S., Chen K., Rashid N., Tajadini B. и другие.

Существует также большое количество методов локализации ЭЭГ-паттернов и их модификаций для поиска в частотно-временной области. К таким методам относятся методы на основе анализа Фурье, вычисляемые в скользящем временном окне [50-53]. Однако данные методы по-прежнему обладают низким разрешением по частоте и времени. Более точными являются методы на основе вейвлет-анализа [54-68], которые лишены аналогичных недостатков, присущих БПФ. Но при этом, известно, что данные методы обладают большей вычислительной мощностью, а также не позволяют произвести поиск паттернов, характеристики которых сопоставимы с характеристиками шумов и фоновой активностью исследуемой системы. Подобного рода недостатками обладают также методы на основе разложения на эмпирические моды [69-78], методы на основе сингулярного спектрального анализа (SSA) [79-84]. К авторам, внесшим большой вклад в развитие подобных методов, относятся Gosala B., Savadkoohi M., Thangarajoo R. G., и другие.

Одним из наиболее точных методов, позволяющих провести локализацию паттернов на оси времени, являются энтропийные методы поиска в частотно-временной области [85-126]. Данные методы предполагают оценку неравномерности частотного состава исследуемого временного ряда в скользящем временном окне. При этом ядром метода может являться как БПФ, так и ДВП. Таким образом, данные методы при использовании ДВП могут иметь высокое разрешение как по частоте, так и по времени. Помимо этого, для применения данных методов нет необходимости в наличии репрезентативной выборки. Среди

авторов внесших большой вклад в развитие данных методов выделяются Сидоров К. В., Ji N., Sun J., Zeng W. и другие.

Все рассмотренные методы позволяют производить локализацию паттернов в частотной, во временной или частотно-временной областях, но при этом имеют различные ограничения. Так, например, важным условием применения современных методов является наличие информации о частотном составе искомого паттерна, его интенсивности. Также для некоторых методов требуется наличие репрезентативной выборки. Таким образом, вышеперечисленные ограничения не позволяют существующим методам обеспечить достижение требуемых показателей качества нейрокомпьютерного интерфейса, что является решающим фактором широкого внедрения технологии нейроуправления на потребительском рынке. В связи с вышесказанным, разработка новых методов частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса, является **актуальной и важной** задачей.

Объектом исследования диссертационной работы являются зашумленные многомерные сигналы электроэнцефалограммы мозга человека, связанные с технологией нейроуправления в интерфейсе «мозг-компьютер».

Предметом исследования являются методы и алгоритмы частотно-временной локализации априорно неопределенных паттернов биоэлектрической активности мозга человека в составе зашумленных сигналов многомерных ЭЭГ, отражающих реализацию человеком команд нейроуправления.

Цель работы заключается в повышении точности классификации команд нейроуправления нейрокомпьютерного интерфейса на основе решения задачи определения частотных и временных границ паттернов в составе многомерных сигналов ЭЭГ.

Для достижения поставленной цели в рамках диссертационной работы требуется решить следующие **основные задачи**:

- 1) провести системный анализ методов поиска и идентификации априорно неопределенных структур неизвестных временных флуктуаций

частотных осцилляторов разной интенсивности в составе зашумленных многомерных временных последовательностей;

2) разработать критерии оптимальности для поиска границ энергетического частотного спектра паттерна биоэлектрической активности в условиях его маскирования шумами иной физиологической природы с близкими или частично совпадающими энергетическими спектрами;

3) разработать и исследовать новые алгоритмы поиска временных границ ЭЭГ паттернов биоэлектрической активности мозга человека с априорно неизвестными параметрами;

4) разработать новый метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса, включающий в себя разработанные алгоритмы и критерии оптимальности;

5) провести экспериментальную апробацию разработанного метода частотно-временной локализации паттернов команд нейроуправления в составе многомерных сигналов ЭЭГ, обосновано решение задачи повышения точности их классификации в ИМК.

Диссертационная работа направлена на разработку новых критериев, алгоритмов и нового метода определения частотных и временных границ априорно неизвестных паттернов биоэлектрической активности мозга человека в составе сигналов многомерных ЭЭГ и, таким образом, повышения точности классификации команд нейроуправления в составе нейрокомпьютерного интерфейса.

Научной новизной обладают следующие результаты работы:

1) **предложен новый метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов ЭЭГ**, отличающийся от известных методов тем, что обладает свойством робастности к неизвестной вариативности текущего функционального состояния человека и к типу подготавливаемого человеком движения – реальному или мысленному,

произвольному или баллистическому (п. 4 паспорта специальности, стр. 43–49 диссертации);

2) предложены новые критерии оптимальности для поиска границ энергетического частотного спектра паттерна биоэлектрической активности, рассчитываемого для трансформант непрерывного вейвлет преобразования и трансформант преобразования Фурье сигнала ЭЭГ, отличающиеся от имеющихся тем, что применимы в условиях маскирования паттерна шумами с близкими или частично совпадающими энергетическими спектрами (п. 3 паспорта специальности, стр. 49–63 диссертации);

3) разработаны алгоритмы для нейрокомпьютерного интерфейса, отличающиеся от имеющихся тем, что реализуют разработанный метод (п. 5 паспорта специальности, стр. 65–77 диссертации).

Новые результаты, полученные в ходе выполнения диссертационного исследования, соответствуют паспорту научной специальности 2.3.1 «Системный анализ, управление и обработка информации, статистика».

Теоретическая значимость работы заключается в развитии теории анализа зашумленных сигналов, разработке нового метода частотно-временной локализации паттернов в составе многомерных зашумленных сигналов, синтезе новых критериев оптимального поиска границ локального частотного диапазона структурных особенностей в составе зашумленных сигналов, разработке новых алгоритмов.

Практическая значимость результатов работы заключается в разработке программно-алгоритмического обеспечения, реализующего новый метод частотно-временной локализации ЭЭГ-паттернов биоэлектрической активности мозга человека, повышении точности классификации команд нейроуправления в ИМК.

Методы исследования и достоверность полученных результатов. Основные результаты, полученные в диссертационной работе, опираются на использование фундаментальных положений теории алгоритмов, теории оптимального оценивания, теории информации и математической статистики, а их корректность подтверждена в ходе экспериментальных исследований с

использованием технологий объектно-ориентированного программирования, современных пакетов прикладных программ *LabVIEW*, *Statistica*, *MATLAB*, *Python*.

Положения, выносимые на защиту:

1) предложенный в работе новый метод частотно-временной локализации ЭЭГ-паттернов биоэлектрической активности мозга человека, позволяющий повысить точность классификации команд нейроуправления в компьютерном интерфейсе (пункт 4 паспорта специальности 2.3.1. Системный анализ, управление и обработка информации, статистика);

2) предложенные новые критерии оптимальности для поиска границ локального частотного диапазона, максимально соответствующего частотному диапазону искомого паттерна биоэлектрической активности мозга человека, что позволяет определять временные границы паттернов команд нейроуправления (пункт 3 паспорта специальности 2.3.1. Системный анализ, управление и обработка информации, статистика);

3) разработанное алгоритмическое и программное обеспечение для нейрокомпьютерного интерфейса, позволяющее повысить точность классификации команд нейроуправления в нейрокомпьютерном интерфейсе (пункт 5 паспорта специальности 2.3.1. Системный анализ, управление и обработка информации, статистика).

Достоверность и обоснованность полученных автором теоретических и практических результатов вытекает из корректного использования и непротиворечивости фундаментальным положениям теории алгоритмов, теории оптимального оценивания, математического аппарата теории информации, непротиворечивостью полученных результатов к устоявшимся подходам анализа сигналов и теории оптимального оценивания, с подтверждением теоретических выводов и предположений, полученных в результате имитационного моделирования.

Реализация и внедрение результатов работы. Результаты диссертационной работы реализованы при непосредственном участии автора в рамках выполнения научно-исследовательских работ: по гранту Российского

Научного Фонда N20-19-00627 на тему "Разработка стимул-независимой модели интерфейса "Мозг-компьютер" для реабилитации людей с ограниченными возможностями", 2020-2022 г.; по проекту в интересах развития кооперации российских высших учебных заведений и организаций, реализующих комплексные проекты по созданию высокотехнологичного производства, на тему "Создание программного комплекса для управления человеческим капиталом на основе нейротехнологий для предприятий высокотехнологичного сектора Российской Федерации", Постановление Правительства РФ N218.

Апробация работы. Основные положения и научные результаты исследований докладывались и обсуждались на следующих научно-технических конференциях и семинарах: XVIII международной научно-практической конференции «Приоритетные направления развития науки и технологий», 16.10.2020 г., г. Тула; X и XII международных научно-практических конференциях «ИНФОКОМ», 16-18 мая 2017 г. и 29-30 апреля 2019 г. соответственно, г. Ростов-на-Дону; 17 Международной молодежной научно-практической конференции «Фундаментальные исследования, методы и алгоритмы прикладной математики в технике, медицине и экономике», 6-7 сентября 2018 г., г. Новочеркасск; международной научно-практической конференции «Концепции фундаментальных и прикладных научных исследований», 9.12.2017 г., г. Уфа; международной научно-практической конференции «Актуальные проблемы науки на современном этапе развития», 18 ноября 2015 г., г. Екатеринбург.

Исследования были направлены на оценку качества, работоспособности, а также на универсальность и практическую применимость разработанных критериев оптимального выбора, методов и методик частотно-временной локализации паттернов в составе зашумленных сигналов.

Соответствие паспорту специальности. Исследования, выполненные в диссертационной работе, соответствуют формуле и пунктам 3, 4 и 5 паспорта специальности 2.3.1 Системный анализ, управление и обработка информации, статистика:

П. 3. Разработка критериев и моделей описания и оценки эффективности решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.

П. 4. Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.

П. 5. Разработка специального математического и алгоритмического обеспечения систем анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта.

Публикации. Основное содержание диссертации изложено в 22 печатных работах, в том числе: 4 публикации в научных журналах, включенных ВАК РФ в перечень рецензируемых научных изданий, в которых должны быть опубликованы основные научные результаты диссертаций на соискание учёной степени кандидата наук (в том числе три из них в квартиле K1); 1 публикация в зарубежном издании, входящих в международную реферативную базу данных и систему цитирования *Scopus* с квартилем Q2; 1 монография; 6 публикаций в сборниках трудов конференций, в том числе зарубежных и международных; 4 свидетельства о государственной регистрации программы для ЭВМ.

Личный вклад соискателя заключается в постановке задачи исследования, в разработке метода частотно-временной локализации паттернов в составе ЭЭГ, в разработке критериев оптимальности для поиска частотных границ энергетического спектра паттернов, в разработке алгоритмов, проведении численных исследований, результатов натуральных экспериментов, обобщении полученных результатов, в разработке программного обеспечения, реализующего разработанный метод.

Структура и краткое содержание диссертации по главам. Диссертация состоит из введения, четырех глав, заключения и приложений. Общий объем диссертации составляет 128 страниц текста с 31 рисунком, 3 таблицами и 3 приложениями. Список литературы содержит 126 наименований.

Во введении обоснована актуальность диссертационных исследований, изложены цель и основные задачи исследований, их научная новизна и практическая значимость, отмечены основные положения, выносимые на защиту.

В первой главе диссертационной работы выполнен системный анализ методов поиска и локализации паттернов разной интенсивности с априорно неизвестными параметрами в составе зашумленных многомерных временных последовательностей. Показано каким образом в настоящее время используется математический аппарат на основе оконного преобразования Фурье и пространственной фильтрации осциллирующих компонентов, дискретного или непрерывного вейвлет-преобразований, за счет чего осуществляется переход из временного представления многомерных данных к частотно-временному для последующего поиска различных паттернов с применением всевозможных критериальных функций. Приведены примеры успешной апробации на основе классических подходов методов автоматизированного детектирования специфических паттернов, сопряжённых с эпилептическими очагами головного мозга. Даны ссылки на известные многочисленные попытки использования методов разложения спектральной плотности для оценки эффектов синхронизации/десинхронизации ЭЭГ с целью выделения паттернов, которые в свою очередь после идентификации используются в качестве управляющих команд в составе ИМК. Далее доказано, что специфичность отображения ЭЭГ-паттернов обуславливает существенные ограничения на использование классических подходов к решению задачи их автоматической детекции. Вариативность искомым ЭЭГ-паттернов, а также априорная неопределенность их параметров требуют разработки новых адаптивных подходов для автоматизированной детекции управляющих команд ИМК, извлекаемых из спонтанной ЭЭГ. Следовательно, ряд проблем, связанных с детекцией, интерпретацией и классификацией специфических ЭЭГ-паттернов, сопровождающих произвольную двигательную и идеомоторную активность человека, до сих пор не решены. Окончательно сделан вывод, что достижение требуемых показателей точности классификации команд нейроуправления в составе нейрокомпьютерного интерфейса может быть

реализовано на основе нового метода локализации по оси времени ЭЭГ-паттернов биоэлектрической мозга человека.

Вторая глава диссертации посвящена разработке метода частотно-временной локализации паттернов на основе вейвлет-энтропии с применением непрерывного вейвлет-преобразования, а также разработке критерия оптимального выбора диапазона масштабов базисной вейвлет-функции. Выполнена математическая формализация задачи частотно-временной локализации в составе нейроинтерфейсов специфических априорно неизвестных многомерных ЭЭГ-паттернов, отражающих реализацию человеком речевой или двигательной активности. Сформулирована критериальная функция и критерий поиска оптимального локального диапазона масштабов базисной вейвлет-функции, максимально соответствующего частотному диапазону искомого паттерна.

Третья глава посвящена разработке алгоритмов, реализующих новые критериальные функции и метод частотно-временной локализации паттернов с априорно неопределёнными параметрами в составе зашумленных сигналов ЭЭГ.

В четвертой главе приведены результаты моделирования, которые подтвердили повышение точности и чувствительности частотно-временной локализации ЭЭГ-паттернов. Также были представлены результаты экспериментальных исследований, подтвердивших корректность принятых решений при разработке метода. Помимо этого проведено сравнение с традиционным методом поиска паттернов, которое показало преимущества разработанного метода

В заключении изложены основные выводы и результаты диссертационной работы.

В приложениях приведены блок-диаграммы NI LabVIEW и программный код python, реализующие разработанный метод, свидетельства об официальной регистрации программ для ЭВМ и копии актов внедрения.

Глава 1. Анализ методов поиска паттернов в составе электроэнцефалограммы и их ограничения

1.1. Методы поиска паттернов во временной области

Разработка и реализация ИМК, в том числе, содержит в себе ряд задач связанных с локализацией на временной оси структурных особенностей сигнала ЭЭГ головного мозга человека — паттернов. Ввиду того, что искомые паттерны в ИМК представляют собой команды управления, то важной задачей является поиск и идентификация таких команд управления. Среди наиболее распространенных методов локализации паттернов сигналов ЭЭГ в составе нейроинтерфейсов, является поиск структурных особенностей зашумленных сигналов на основе оценки статистических данных о параметрах исследуемого сигнала, например, оценка центральных моментов случайной величины: средней амплитуды сигнала (электрограммы) [12] и его дисперсии [13].

Подобного рода методы по-прежнему актуальны в анализе ЭЭГ и прочих биоэлектрических сигналов, однако обладают низкой точностью, особенно в тех случаях, когда локальные структурные особенности имеют те же (или близкие) амплитудные характеристики, что и несущий сигнал (или фоновая активность исследуемой системы).

Так, например, одним из видов локальных структурных особенностей сигналов считается всплеск, превышающий определенное значение (уровень) или определенный процент от среднего значения сигнала или выход за пределы динамического диапазона измерительной аппаратуры. В большинстве случаев такой метод используют в скользящем временном окне с постоянным сдвигом по оси времени.

Другим распространенным методом локализации ЭЭГ-паттернов является вычисление дисперсии (или СКО) сигнала. Данный метод обладает в ряде случаев большей точностью, т.к. позволяет находить не только высокоамплитудные всплески, интенсивность которых значительно выше среднего значения, но и

высокочастотные осцилляции. Недостаток данного метода заключается в отсутствии тонкой настройки и не позволяет точно выделить ритм, в котором отражена информация о локальных структурных особенностях, что в ряде случаев, существенно снижает точность. Такой недостаток также присущ методам, основанным на вычислении коэффициента эксцесса, коэффициента асимметрии, таблиц частот и т.д..

Еще одним методом локализации ЭЭГ-паттернов, получившим широкое распространение в различных задачах поиска структурных особенностей сигнала, выступает статистический анализ на основе сравнения временных характеристик, например, с помощью использования доверительных интервалов, а также на основе статистических критериев принадлежности к генеральной совокупности [14]. Среди недостатков данных методов можно выделить требования к качеству и объему выборки (примеров), помимо этого, в ряде случаев даже наличие достоверного отличия между эталонной и исследуемой выборками не всегда позволяет точно идентифицировать единичные образцы.

Нередко для поиска паттернов применяют методы локализации ЭЭГ-паттернов, основанные на анализе трендов, полученных путем вычисления среднего (усеченного среднего и т.д.) значения в «скользящем» временном окне, с помощью интерполяции или на основе выделения различных компонент исследуемого сигнала [14]. Однако данные методы позволяют производить поиск структурных особенностей лишь для низкочастотных альфа, бета, дельта ритмов, обладающих высокой интенсивностью. В случае же с паттернами в области гамма ритмов, имеющих низкую интенсивность применение данных методов, не имеет практического смысла, т. к. методы на основе вычисления трендов не позволяют качественно выделить высокочастотные составляющие в исследуемом временном ряде.

В качестве альтернативы статистическим методам поиска паттернов во временной области, принято применять методы на основе вероятностного анализа и поиска. Широкое распространение получили методы на основе поиска паттерна, построенного с помощью характерных точек, например, с помощью кусочно-

линейной сегментации [16]. Для использования таких методов необходимо иметь репрезентативную выборку с малым количеством аномалий, для которой на основе вероятностного анализа выделяется модель искомого паттерна. В данном случае модель паттерна представляет собой отношения между характерными точками, которые описываются коэффициентами. Полученные таким образом коэффициенты описывают расстояния и отношения между экстремумами данного паттерна. После выделения модели паттерна производится ее поиск во временной области на основе различных метрик, таких как корреляции, евклидово и манхэттенское расстояние и т.д. Такой метод обладает достаточно высокой точностью, но при этом требует наличия эталонной выборки или заранее заданной формы искомого паттерна.

Среди вероятностных методов локализации паттернов в задачах анализа сигналов ЭЭГ во временной области, особое место занимают методы на основе оценки функции плотности вероятности. При этом существуют параметрические и непараметрические методы.

Суть использования параметрических методов локализации ЭЭГ-паттернов на основе оценки функций плотности вероятностей заключается в априорном анализе эталонной выборки, согласно которому определяются характерные временные интервалы, поиск которых необходимо произвести. Это, в свою очередь, является аналогом определения классов в методах машинного обучения. Следующим шагом производится оценка функций плотности распределения для каждого класса (набора паттернов). Затем для исследуемого (тестового) сегмента сигнала со сдвигом по временной оси определяется его принадлежность к генеральной совокупности на основе правил «ближайших соседей» или решающих деревьев [16].

Непараметрические методы поиска паттернов принято использовать в тех случаях, когда плотности распределения исследуемых данных многомодальные (имеют несколько локальных экстремумов). Для непараметрических методов поиск структурных особенностей исследуемых сигналов отличается от описанных ранее параметрических методов применением процедур, преобразующих

пространство признаков. Данные процедуры позволяют преобразовать пространство признаков так, чтобы к ним можно было использовать параметрические методы, например, линейный дискриминант Фишера [17-22].

Основной недостаток параметрических и непараметрических методов поиска паттернов заключается в необходимости наличия эталонной выборки, что в случае недостаточного количества образцов не позволит получить качественный результат.

Среди методов поиска паттернов во временной области широко распространены методы на основе понятия энтропии из теории информации. Подобного рода методы основаны, в первую очередь, на вычислении энтропии Шеннона [23–30]. Энтропия Шеннона представляет меру неопределенности распределения значений временного ряда. В основе анализа лежит предположение, что искомый паттерн является причиной или следствием изменения состояния системы, и его наличие характеризуется изменением энтропии исследуемого сигнала ЭЭГ. Поиск паттернов осуществляется по численным значениям энтропии Шеннона, полученным путем ее вычисления в скользящем временном окне. При этом, в зависимости от характера паттерна, выбираются максимумы или минимумы значения энтропии Шеннона. Это обусловлено тем, что некоторые паттерны могут иметь регулярную, периодическую структуру (максимальные значения энтропии), другие в свою очередь имеют хаотическую и нерегулярную структуру (минимальные значения энтропии).

Так как использование метода предполагает вычисление энтропии Шеннона в скользящем временном окне, размер временного окна обычно используют соизмеримый с размерами паттерна на временной оси. При этом, в случае поиска паттернов с априорно неизвестной длительностью, вопрос выбора размера временного окна остается неизвестным.

Недостаток методов локализации ЭЭГ-паттернов на основе энтропии Шеннона заключается в слабой чувствительности к импульсным значениям исследуемого сигнала, а также отсутствие возможности определения конкретного частотного диапазона, в котором искомые паттерны могут иметь наибольшую

интенсивность, что снижает точность определения положения ЭЭГ-паттерна на временной оси при реализации нейроинтерфейсов.

Другим примером использования методов локализации ЭЭГ-паттернов на основе энтропии выступает выборочная энтропия [30]. Для вычисления выборочной энтропии используется стандартная формула энтропии Шеннона, но алгоритм расчета вероятностной меры выборочной энтропии основан на подходе, предложенном Больцманом для термодинамической энтропии. Согласно такому алгоритму, временной ряд разбивается по частоте встречаемости значений, результатом такого разбиения является получение численного индекса, характеризующего наличие в сигнале высокоамплитудных всплесков, аналогичных импульсным. Минимальное значение выборочной энтропии, указывает на наличие неравномерности распределения значений временного ряда, и тем самым свидетельствует о наличии паттерна нерегулярной структуры.

Среди энтропийных методов поиска паттернов во временной области существует вариация энтропии Колмогорова в виде ее приближенной оценки, которая определяется как скорость потери информации о состоянии динамической системы с течением времени и называется аппроксимированной энтропией [26]. Стоит отметить, что применение непосредственно энтропии Колмогорова невозможно на временных интервалах конечной длины. При этом максимальное значение аппроксимированной энтропии показывает наличие нерегулярности в исследуемом временном ряде.

Недостатками выборочной и аппроксимированной энтропии, как и в случае с энтропией Шеннона, является отсутствие выбора частотного диапазона и зависимость от временного интервала поиска паттерна.

Альтернативными энтропийными методами локализации ЭЭГ-паттернов в задачах разработки нейроинтерфейсов, в том числе, являются методы на основе энтропии Реньи [23,28] и энтропии Цаллиса [27]. Энтропия Реньи является обобщением энтропии Шеннона, и по сути, определяет вероятность того, что траектория изменения временного ряда в последовательные моменты времени проходит через уровни с номерами от $0, \dots, N$. Если все вероятности прохождения

траектории через определенный уровень одинаковые, то все распределения энтропии Реньи равны, в противном случае, энтропия уменьшается как функция от параметра q . Высокие значения параметра q задают энтропию Реньи, которая в большей степени определена через рассмотрение только самых высоких вероятностей событий. Более низкие значения q задают энтропию Реньи, которая взвешивает все возможные события более равномерно, независимо от их вероятностей.

Другим методом является вычисление энтропии Цаллиса [27], которая является обобщением энтропии Больцмана-Гиббса, также имеющая параметр q , который определяет показатель динамического порядка в сложной системе.

Недостатками применения методов, основанных на вычислении энтропии Реньи и энтропии Цаллиса, является их вычислительная сложность, тонкая настройка параметров q , а также, как и в случае с энтропией Шеннона, и аппроксимированной энтропией — отсутствие возможности выбора частотного диапазона и зависимость от выбора временного интервала для анализа.

В последнее время для поиска локальных структурных особенностей во временной области активно используются методы на основе алгоритмов машинного обучения. При этом все методы поиска, основанные на алгоритмах машинного обучения, базируются на двух основных вариантах анализа исследуемого сигнала.

Первая и наиболее распространенная группа методов основана на алгоритмах классификации [31-39]. Согласно стратегии применения данной группы методов на первом этапе формируется репрезентативная обучающая выборка исходных данных. В качестве обучающих примеров используются прецеденты, представляющие собой отрезки исследуемого сигнала (электрограммы), разбитые на два и более классов. Согласно концепции применения таких методов, на первом этапе выборку разделяют на некоторую фоновую активность исследуемой системы, представленную соответствующими временными интервалами и интервалами, содержащими искомый паттерн. В случае, когда паттернов несколько и необходимо также идентифицировать тот или иной паттерн, выборку разделяют на несколько классов.

Следующим шагом является обучение классификатора на «размеченных» данных с помощью различных алгоритмов машинного обучения (в основном используются алгоритмы обучения «с учителем»). Затем обученный классификатор применяют для определения класса в некотором временном окне со сдвигом. В результате чего, в простейшем случае, формируется временной ряд в виде ответов классификатора, сигнализирующих о наличии или отсутствии паттерна.

Другим, набирающим популярность методом, является детектирование структурных особенностей на основе прогнозирования временного ряда [32,39]. Для реализации данного метода используется модель машинного обучения, прогнозирующая несколько последующих значений временного ряда. При этом каждый раз вычисляется метрика, количественно показывающая различия между спрогнозированным временным интервалом и реальным (например, евклидово расстояние). Согласно данному методу, достижения используемой метрики определенного значения будет соответствовать наличию структурной аномалии в исследуемом сигнале, что в свою очередь свидетельствует об обнаружении паттерна, структура которого существенно отличается от фоновой активности системы. Подобного рода методы позволяют выявить заведомо неизвестные структурные изменения временного ряда.

Недостатком методов на основе машинного обучения является требование к наличию репрезентативной выборки, включающей множество прецедентов для обучения. Таким образом, в случае неполноты информации или в случае отсутствия обучающей выборки, например, при наличии одного или нескольких прецедентов, использование таких методов невозможно.

В общем случае наиболее распространенные методы поиска паттернов во временной области, обладают низкой точностью за счет необходимости наличия репрезентативной выборки с примерами искомых паттернов ЭЭГ, или же достаточно большого объема априорной информации, позволяющей определить весовые коэффициенты или пороговые значения при поиске. В задачах разработки нейроинтерфейсов, в том числе, получение такой информации затруднено в виду

того, что искомый паттерн может быть маскирован шумами различного характера, а также имеет изменчивые во времени характеристики как временные, так и частотные. В свою очередь, выделяют отдельную группу методов на основе поиска паттернов в частотной области.

1.2. Методы поиска паттернов в частотной области

Широкое применение в решении задач поиска структурных особенностей зашумленных электрограмм в составе нейроинтерфейсов и анализа биоэлектрических сигналов получили методы поиска на основе спектрального анализа. Подобного рода методы основаны на вычислении различных вариаций преобразования Фурье, среди которых наиболее распространены методы, базирующиеся на вычислении быстрого преобразования Фурье (БПФ) [40-47].

В простейшем случае исследуемый отрезок ЭЭГ сигнала разбивается на временные интервалы, для которых вычисляется БПФ. Так, например, при анализе вещественной части БПФ можно использовать амплитудный спектр, или функцию спектральной плотности мощности и их модификации, которые отражают амплитуды или мощности различных гармоник в составе исследуемого сигнала. Таким образом, появление определенных спектральных составляющих в различных временных интервалах исследуемой электрограммы может свидетельствовать о наличии паттерна.

Анализ изменения спектральных составляющих для различных отрезков исследуемого сигнала (электрограммы) обладает рядом недостатков. Во-первых, низкая точность, которая обусловлена большим количеством спектральных составляющих и их вариабельности. Во-вторых, важно отметить, что классические методы поиска локальных структурных особенностей на основе преобразования Фурье не предназначены для анализа нестационарных во времени сигналов. В-третьих, все методы на основе БПФ имеют существенную зависимость от границ временного окна (эпохи анализа). Так, например, когда границы временного окна не совпадают с количеством полных периодов всех гармоник, присутствующих в

исследуемом временном ряде, возникает явление, называемое «растеканием» спектра. Также в ряде случаев возникают «паразитные» гармоники и алиасные эффекты.

Для уменьшения влияния граничных эффектов принято применять различного рода оконные функции [40]. Однако недостатки, связанные с высокой степенью изменчивости спектральных составляющих, возникают даже при использовании оконных преобразований.

Для анализа спектральных коэффициентов исследуемого сигнала используют статистические методы и методы на основе алгоритмов машинного обучения. Недостатком применения такого рода методов является искажение результатов анализа при наличии различного рода шумов и артефактов в регистрируемой электрограмме, не связанных с наличием искомым паттернов, а также появление искажений из-за неправильно выбранных границ временного окна.

В задачах поиска паттернов в частотной области также применяются методы на основе кепстрального анализа [48]. Кепстральные коэффициенты получают путем применения обратного БПФ к логарифмированному энергетическому спектру сигнала (электрограммы) и позволяют, в ряде случаев, выделить наиболее выраженные частотные диапазоны сигнала. Что, в свою очередь, позволяет провести анализ и выделить только те частотные диапазоны, интенсивность паттерна в которых максимальна и тем самым снизить размерность признакового пространства. Над полученными кепстральными коэффициентами применяют аналогичные методы анализа, что и для спектральных составляющих, а именно методы на основе алгоритмов машинного обучения и статистического анализа [68].

Недостатком применения такого метода является низкая точность, обусловленная тем, что на первом этапе вычисления кепстральных коэффициентов используется БПФ, недостатки которого были кратко описаны ранее. Также в ряде случаев, могут возникать паразитные «рагмоники» (аналог гармоники для кепстрального преобразования), которые также влияют на точность определения локальных структурных особенностей.

В общем виде частотный анализ, направленный на поиск паттернов сигналов ЭЭГ в составе нейроинтерфейсов, обладает недостатками, связанными в первую очередь с выбором временного интервала для анализа, а также низкой чувствительностью и неприменимостью в задачах с использованием нестационарных временных рядов, которыми, в свою очередь, являются сигналы ЭЭГ. Для повышения точности локализации паттернов, широкое распространение получили методы на основе частотно-временном анализе ЭЭГ.

1.3. Методы поиска паттернов в частотно-временной области

Задачи локализации ЭЭГ-паттернов в большинстве случаев требуют производить поиск в частотно-временной области. Такие методы анализа позволяют повысить точность определения местоположения паттернов на временной оси в заданном частотном диапазоне. Данное усложнение обусловлено тем, что исследуемый сигнал наряду с искомыми структурными особенностями, может содержать в себе различного рода шумы (измерительной аппаратуры, внешних воздействий и другого рода шумы, не связанные с функционированием исследуемой системы), ввиду наличия которых точность поиска паттернов во всем частотном диапазоне существенно снижается.

Для реализации поиска паттернов ЭЭГ в составе зашумленных сигналов нейроинтерфейсов в частотно-временной области наиболее распространены методы на основе спектрального анализа. Суть данных методов основывается на вычислении БПФ (или амплитудного/энергетического спектра) в «скользящем» по оси времени временном окне [49-53]. При этом для всех временных окон выбирается одинаковый заранее заданный диапазон частот, соответствующий тому, в котором искомые паттерны имеют наибольшую интенсивность.

Таким образом, получается трехмерное разложение сигнала (мощность-частота-время), отражающее информацию об изменении мощности различных частотных составляющих с течением времени [53].

Для полученного трехмерного разложения исследуемого сигнала принято применять различного рода методы локализации ЭЭГ-паттернов на основе визуального и статистического анализа, а также методы на основе машинного обучения.

В простейшем случае визуальный анализ частотно-временного представления сигнала позволяет определить характерные всплески и структуру сигнала [53], оценить изменение спектральных составляющих с течением времени. Однако недостатком такого анализа, помимо «человеческого фактора», является низкая точность в ряде случаев, когда локальные структурные особенности исследуемого сигнала имеют низкую интенсивность.

В тех случаях, когда искомые локальные структурные особенности исследуемого сигнала имеют низкую интенсивность, применяют статистические методы [53], которые по аналогии с временными методами поиска паттернов могут включать вычисление статистических характеристик [52], например, корреляции и вычисление различного рода статистических тестов. Такой подход обладает рядом преимуществ, так как позволяет в ряде задач производить поиск паттернов низкой интенсивности.

Однако в случае с использованием статистических характеристик данный подход имеет низкую точность, которая зависит от высокоамплитудных всплесков и шумов, обусловленных функционированием исследуемой системы. А при использовании проверки статистических гипотез требуется объемная выборка, репрезентативность которой влияет на точность, и данный метод по-прежнему зависим от искажений исследуемого сигнала и шумов, в результате чего точность определения местоположения структурных особенностей существенно снижается.

Широкое применение в задачах поиска локальных структурных особенностей ЭЭГ получили методы на основе вейвлет-анализа [54-67], которые представляют собой свертку исследуемого сигнала с вейвлет-функцией. Благодаря компактности вейвлет-функции на временной оси и ее локальному спектру, вейвлет-разложение позволяет получить частотно-временное представление сигнала, которое при этом отражает некоторые локальные особенности сигналов.

Для частотно-временной локализации паттернов на основе вейвлет-преобразования используются методы статистического анализа и алгоритмов машинного обучения.

Использование вейвлет-анализа для частотно-временной локализации паттернов подразделяется на два направления, соответствующих типам вейвлет-преобразования: методы на основе непрерывного вейвлет-преобразования (НВП) и дискретного вейвлет-преобразования (ДВП).

Реализация методов на основе НВП предполагает декомпозицию сигнала в виде разложения по масштабам базисного вейвлета с непрерывным шагом, как по времени, так и по масштабу (аналог частоты для вейвлет-преобразования) [54-60]. НВП в свою очередь, в дискретном виде более имеет более точное название, как непрерывное вейвлет-преобразование дискретного времени, и в отличие от ДВП, не предполагает децимации по частоте. Такой вид преобразования позволяет получить высокое разрешение как по частоте, так и по времени. В большинстве случаев масштаб и сдвиг базисного вейвлета при использовании НВП изменяются на единицу.

Применение НВП, как и в случае с БПФ в «скользящем» временном окне, позволяет получить трехмерное разложение сигнала в виде амплитуда-масштаб-время, или при пересчете масштабирующего коэффициента в частоту, получить представление исследуемого временного ряда в виде — амплитуда-частота-время.

Преимуществом применения такого метода является более точное, по сравнению с БПФ, выделение локальных структурных особенностей сигналов [60]. При этом к полученному разложению сигнала применяют методы на основе вычисления статистических характеристик, проверки статистических гипотез и машинного обучения. Данные методы имеют большую точность по сравнению с использованием частотно-временными методами на основе БПФ, так как коэффициенты вейвлет-преобразования обладают меньшей зависимостью от шумов присутствующих в измерительном сигнале.

Однако использование вейвлет-анализа требует качественного подбора базисной вейвлет-функции, так как базисные вейвлет-функции предполагают

выделение различных по своей форме локальных структурных особенностей сигналов, а также различное разрешение как по частоте, так и по времени.

При этом точного математического аппарата для выбора базисного вейвлета, наиболее подходящего к исследуемому сигналу, не существует и возможны лишь эмпирические методы поиска оптимального базисного вейвлета.

Методы локализации ЭЭГ-паттернов на основе ДВП отличаются от методов на основе НВП рядом особенностей, в том числе, типом преобразования. Преимуществами ДВП является меньшая вычислительная нагрузка ввиду того, что ДВП по сравнению с НВП выполняется за меньшее количество операций, а также позволяет сжать признаковое пространство. ДВП предполагает разложение сигналов на несколько уровней декомпозиции, каждый уровень представляет собой прореженный по времени (децимированный) сигнал в определенном диапазоне частот, который определяется выбранным базисным вейвлетом.

Методы поиска паттернов, основанные на ДВП, в ряде случаев, значительно точнее методов на основе БПФ, однако имеют меньшую точность по сравнению с методами на основе НВП, что обусловлено более низким разрешением как по частоте, так и по времени.

Для повышения точности методов поиска локальных структурных особенностей сигналов в частотно-временной области на основе ДВП также применяются методы на основе анализа статистических характеристик, проверки гипотез и машинного обучения, которые позволяют повысить точность, но как и в случае со статистическими характеристиками, существенно зависимы от шумов и искажений исследуемого сигнала, а при использовании методов проверки статистических гипотез и алгоритмов машинного обучения, требуют наличия репрезентативной выборки.

Среди аналитических методов локализации ЭЭГ-паттернов в частотно-временной области, наибольшую популярность получили методы на основе разложения исследуемого сигнала на эмпирические моды (empirical mode decomposition, EMD) и анализ независимых компонент (АНК, ICA, independent component analysis) [68-77]. Главное отличие данной группы методов от методов на

основе БПФ и вейвлет анализа, заключается в том, что эмпирические моды (компоненты сигнала) не задаются непосредственно перед анализом, а определяются аналитически, таким образом, базисные функции формируются в ходе анализа сигнала.

Преимуществом методов на основе EMD является их высокая точность, а также качественное выделение локальных структурных особенностей исследуемых сигналов. В процессе применения EMD сигнал разделяется на несколько эмпирических мод (компонент сигнала), каждая из которых описывает определенную полосу частот и ее локальные особенности, что является в свою очередь частотно-временным разложением сигнала.

К полученным коэффициентам разложения EMD принято применять методы на основе статистических характеристик (скользящее среднее, корреляции, дисперсии и т. д.), проверки статистических гипотез и машинного обучения.

Данный метод локализации ЭЭГ-паттернов, в ряде случаев, обладает высокой точностью, однако при использовании его для поиска паттернов в составе сложных зашумленных сигналов ЭЭГ нейроинтерфейсов, с наличием высокоамплитудных всплесков, возможно дублирование некоторых эмпирических мод, которые необходимо группировать для точного выделения локальных структурных особенностей сигналов. При этом нет точного алгоритма или некоторого критерия для описания процедуры объединения полученных дублирующих эмпирических мод, что иногда может привести к снижению точности. При этом EMD подвержено искажениям на границах временного окна, что также влияет на точность локализации искомых паттернов.

В последнее время, также получили распространение методы локализации ЭЭГ-паттернов на основе сингулярного спектрального анализа (singular spectrum analysis, SSA) [78-83], который является аналитическим разложением сигнала. В процессе применения методов на основе SSA, исследуемый сигнал преобразуется в многомерный временной ряд с помощью вычисления собственных векторов, после чего к ним применяется метод главных компонент. Таким образом данный метод локализации ЭЭГ-паттернов позволяет получить частотно-временное

разложение, путем декомпозиции сигнала на компоненты, каждая из которых отражает структуру сигнала в определенном диапазоне частот. Как и в случае с методами на основе эмпирических мод, компоненты сигнала определяются аналитически в процессе анализа.

Преимуществами данного метода являются высокая точность, по сравнению с методами на основе БПФ и вейвлет-анализа, особенно в случае поиска паттернов в низкочастотной области, а также устойчивость к высокоамплитудным всплескам. При этом методы на основе SSA [83] не требуют стационарности исследуемого временного ряда и представляют сигнал в виде аддитивных компонент. Полученные компоненты сигнала используются не только для вычисления статистических характеристик, но и в качестве признаков для алгоритмов машинного обучения.

Главными недостатками SSA является отсутствие модели, что не позволяет проверять гипотезы о наличии в исследуемом временном ряде той или иной компоненты, вычислительная сложность и отсутствие точного выбора временного окна для формирования матрицы собственных векторов, что также влияет как на точность, так и на количество найденных компонент сигнала.

Среди методов локализации ЭЭГ-паттернов в частотно-временной области особую роль играют энтропийные методы [84–126]. Существует два основных вида: методы на основе спектральной энтропии и на основе вейвлет-энтропии. Подобные методы существенно точнее, чем методы осуществляющие поиск во временной области за счет использования частотно-временного разложения сигнала, более устойчивы к всплескам и шумам по сравнению с энтропийными методами позволяющими производить поиск во временной области. При этом такого рода методы по-прежнему имеют временное разрешение, что значительно повышает точность в сравнении с частотными методами поиска. В отличие от частотно-временных методов на основе спектрального анализа, вейвлет-анализа, EMD, SSA направлены непосредственно на поиск структурных особенностей (нерегулярных составляющих). При этом данные методы не требуют наличия

какой-либо репрезентативной выборки или эталонных образцов паттерна для поиска.

Энтропийные методы поиска в частотно-временной области устойчивы к шумам и высокоамплитудным всплескам за счет выбора локального диапазона частот, что делает данные методы высокоточным инструментарием для частотно-временной локализации структурных особенностей сигналов.

В задачах частотно-временной локализации ЭЭГ-паттернов широкое распространение получил метод на основе спектральной энтропии [82-93]. Суть данного метода заключается в разделении сигнала на временные интервалы с помощью «скользящего» временного окна, и, как правило, с перекрытием. Для каждого, полученного таким образом временного интервала, вычисляется функция спектральной плотности мощности (СПМ) на основе БПФ. Затем, в заданном интервале частот производится нормировка СПМ. На следующем шаге вычисляется вероятность появления (или, как сказано в ряде источников «доля») энергии на заданной частоте, после чего, для каждого временного интервала вычисляется энтропия Шеннона для полученных значений вероятности в заданном диапазоне частот. Таким образом, для каждого временного интервала в составе исследуемого ряда вычисляется значение спектральной энтропии. При этом минимум полученной функции будет соответствовать расположению паттерна на временной оси.

Преимуществом данного метода локализации ЭЭГ-паттернов является использование определенного частотного диапазона для последующего поиска структурных особенностей по оси времени, что значительно точнее, чем использование стандартных временных методов поиска локальных структурных особенностей. По сравнению с использованием частотно-временных методов локализации на основе спектрального анализа, данный энтропийный метод направлен на поиск структурных особенностей, и в меньшей степени подвержен влиянию высокоамплитудных всплесков (распространяющихся на все спектральные составляющие) и шумов.

Однако данный метод локализации ЭЭГ-паттернов имеет важный недостаток, связанный с выбором локального диапазона частот. Он обусловлен тем, что точность применения метода на основе спектральной энтропии существенно зависит от точности выбора диапазона частот. И в ряде задач, когда характеристики и частотный состав паттерна априорно неизвестен, например, в силу неполноты информации об исследуемой системе, может снижаться точность определения местоположения паттерна в составе зашумленных сигналов.

Альтернативной группой методов частотно-временной локализации ЭЭГ-паттернов является использование вейвлет-энтропии. Суть метода вейвлет-энтропии [93-126] заключается в разделении сигнала на временные интервалы с помощью «скользящего» временного окна, и, как правило, с перекрытием. Для каждого полученного таким образом временного интервала вычисляется дискретное или непрерывное вейвлет-преобразование. Далее, в случае использования ДВП, производится вычисление энергии коэффициентов детализации на каждом выбранном уровне разложения, которые соответствуют определенной полосе частот, определяемой базисным вейвлетом. Затем, вычисляется относительная вейвлет-энергия на каждом уровне разложения, путем возведения коэффициентов ДВП в квадрат с последующим их суммированием и нормировкой по количеству коэффициентов на данном уровне. На следующем шаге вычисляются вероятности появления (доля) энергии на заданном уровне декомпозиции, после чего для полученных вероятностей вычисляется энтропия Шеннона. Данный метод обладает высоким быстродействием, но меньшим разрешением по частоте, что загроубляет поиск паттернов, за счет меньшего описания частотных свойств исследуемого сигнала.

Другой вариацией метода является использование НВП, которое обладает высоким разрешением по частоте. Данный метод подразумевает применение НВП для каждого временного интервала. Затем для каждого интервала в выбранном диапазоне масштабов (частот) вычисляется энергия на текущем масштабе, путем возведения в квадрат и суммирования всех коэффициентов для данного масштаба. В большинстве случаев, на данном этапе не производится нормировка по

количеству коэффициентов на данном масштабе, так как в случае с НВП количество коэффициентов на всех масштабах одинаково. После чего вычисляется относительная вейвлет-энергия (relative wavelet-energy), путем нормировки энергии для всех масштабов относительно суммарной. Далее для полученных значений вероятности вычисляется вейвлет-энтропия, по формуле энтропии Шеннона.

Данный вариант метода локализации ЭЭГ-паттернов на основе НВП имеет более высокую точность, по сравнению с энтропийным методом на основе ДВП, так как обладает более высоким разрешением как по частоте, так и по времени. Однако данный метод, как и все предыдущие энтропийные методы частотно-временной локализации требует точного выбора локального диапазона частот, от которого существенно зависит точность поиска паттерна. Также для энтропийных методов на основе вейвлет-преобразования требуется качественный выбор базисного вейвлета, от которого зависит более точное описание определенных локальных особенностей сигнала.

Таким образом, в процессе анализа методов частотно-временной локализации паттернов в составе зашумленных сигналов ЭЭГ нейроинтерфейсов, в том числе, выявлены недостатки, связанные с выбором частотного диапазона для анализа (в случае отсутствия информации об исследуемой системе), а также отсутствие алгоритмов выбора базисной функции, например, в случае применения методов на основе вейвлета анализа. Также важным недостатком при применении методов на основе декомпозиции сигнала, таких как SSA, EMD, ICA появление паразитных и частично дублирующих мод.

Ввиду вышеперечисленного, наиболее перспективной группой методов частотно-временной локализации паттернов в составе зашумленных сигналов ЭЭГ, представляются методы на основе спектральной и вейвлет энтропии, однако они требуют существенной доработки и модификации.

1.4. Выводы к главе 1

В рамках диссертационной работы в первой главе выполнен анализ современных и наиболее распространенных методов частотно-временной локализации паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса. Главным недостатком которых является необходимость наличия априорной информации об искомым паттернах, например локального диапазона частот. Также в главе выполнены следующие этапы анализа:

1. Проведен анализ методов локализации ЭЭГ-паттернов в составе ИМК, который выявил ряд ограничений, представленный в таблице 1.

Таблица 1. Ограничения методов локализации ЭЭГ-паттернов

Группа методов	Область поиска	Ограничения
Статистические и вероятностные методы поиска	Временная область	- низкая устойчивость к шумам; - требуется репрезентативная выборка; - невозможность применения в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - отсутствие частотного разрешения и выбора частотного диапазона для анализа;
Методы на основе теории информации	Временная область	- низкая устойчивость к шумам; - низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - отсутствие частотного разрешения и выбора частотного диапазона для анализа;
Методы на основе машинного обучения	Временная область	- низкая устойчивость к шумам; - требуется репрезентативная выборка;

		- невозможность применения в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются;
Методы на основе спектрального анализа	Частотная область	- низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - существенная зависимость от выбора временного интервала для анализа; - отсутствие разрешения на оси времени; - невозможность применения к нестационарным сигналам;
Частотно-временные методы на основе спектрального анализа	Частотно-временная область	- низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - невозможность применения к нестационарным сигналам; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;
Методы на основе вейвлет-анализа	Частотно-временная область	- низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; ; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;

<p>Методы на основе разложения на эмпирические моды</p>	<p>Частотно-временная область</p>	<ul style="list-style-type: none"> - отсутствие возможности априорного выбора частотного диапазона для анализа; - обладают эффектом появления дублирующих компонент; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;
<p>Методы на основе сингулярного спектрального анализа</p>	<p>Частотно-временная область</p>	<ul style="list-style-type: none"> - отсутствие возможности априорного выбора частотного диапазона для анализа; - обладают эффектом появления дублирующих компонент; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;
<p>Энтропийные методы поиска на основе спектральной энтропии</p>	<p>Частотно-временная область</p>	<ul style="list-style-type: none"> - низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - невозможность применения к нестационарным сигналам; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;
<p>Энтропийные методы поиска на основе вейвлет-энтропии</p>	<p>Частотно-временная область</p>	<ul style="list-style-type: none"> - низкая чувствительность при применении в случаях, когда амплитудно-частотные характеристики искомым ЭЭГ-паттернов и шумов частично пересекаются; - отсутствие критериев определения локального диапазона частот искомого ЭЭГ-паттерна;

2. Проведенный анализ методов локализации ЭЭГ-паттернов показал, что большинство методов не обладает наличием критериев выбора локального диапазона частотно-искomых ЭЭГ-паттернов, который бы отражал их наибольший вклад в общую мощность исследуемого сигнала и тем самым повышал бы точность частотно-временной локализации.

3. Согласно концепции построения нейроинтерфейсов, методы локализации специфических (инвариантных) ЭЭГ-паттернов используются с целью выделения временных границ по оси времени. Решение задачи точного определения временных границ паттернов биоэлектрической активности мозга в составе непрерывно регистрируемой ЭЭГ обеспечивает, в свою очередь, формирование репрезентативной выборки для их эффективной классификации. Высокоточная классификация типов паттернов в итоге и обуславливает высокие показатели точности и надёжности функционирования нейроинтерфейсов «мозг-компьютер».

4. Следовательно, реализация научно-методического аппарата поиска и высокоточной локализации по оси времени паттернов биоэлектрической активности мозга человека в составе многомерных ЭЭГ обеспечивает достижение требуемых показателей качества нейрокомпьютерного интерфейса и является решающим фактором широкого внедрения технологии нейрoуправления на потребительском рынке. Нестационарность искомых ЭЭГ-паттернов, априорная неопределенность их параметров требуют разработки новых адаптивных методов для их автоматизированной частотно-временной локализации. Использование подобных методов позволит формировать репрезентативные выборки для эффективной классификации целевых ЭЭГ-паттернов в итоге обеспечит требуемые для практического применения показатели качества ИМК.

Учитывая вышесказанное, определены задачи, которые необходимо решить в настоящей работе:

1. Разработать метод частотно-временной локализации ЭЭГ-паттернов биоэлектрической активности мозга человека, отличающийся от традиционных

методов тем, что может быть использован в контуре нейрокомпьютерного интерфейса.

2. Разработать критерии оптимальности для поиска границ энергетического частотного спектра паттерна биоэлектрической активности, отличающиеся тем, что применимы в условиях маскирования паттерна шумами с близкими или частично совпадающими энергетическими спектрами.

3. Разработать алгоритмическое и программное обеспечение для нейрокомпьютерного интерфейса, реализующее разработанный метод.

4. Провести экспериментальные исследования разработанного метода частотно-временной локализации ЭЭГ-паттернов, выполнить верификацию репрезентативности сформированных выборок в задаче классификации типов паттернов в составе нейроинтерфейса.

Глава 2. Разработка метода и критериев оптимальности частотно-временной локализации паттернов зашумленных сигналов электроэнцефалограммы

2.1. Математическая постановка задачи и требования к разрабатываемому методу частотно-временной локализации паттернов

В первую очередь для разработки метода необходимо провести формализацию задачи, а также сформулировать требования к разрабатываемому методу частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса.

Пусть существует возможность одновременной регистрации в одноименные моменты времени $t \in [t_0; T]$ на J сенсорах многомерной электроэнцефалограммы (ЭЭГ), представляющую собой временную функцию многократной последовательности измерений

$$X(t) = (x_1(t) \ x_2(t) \ \dots x_j(t) \ \dots \ x_J(t))^T,$$

где T – знак транспонирования; J – количество сенсоров, $j=1,2,\dots,J$ – номер сенсора, $x_1(t) \ x_2(t) \ \dots x_j(t) \ \dots \ x_J(t)$ – сенсоры регистрирующие ЭЭГ $X(t)$, t_0 – начальный момент времени наблюдений, в общем случае равный нулю. Вследствие дискретности процедуры измерений ЭЭГ $X(t)$ на интервале времени наблюдений T с постоянным шагом по времени Δt , и, соответственно, частотой дискретизации $f_d = \frac{1}{\Delta t}$. Таким образом, рассматривается конечная многомерная последовательность многократных измерений

$$\{\bar{X}\}_{k=1}^K = \left(\{x_{1,k}\}_{k=1}^K, \{x_{2,k}\}_{k=1}^K, \dots, \{x_{j,k}\}_{k=1}^K, \dots, \{x_{J,k}\}_{k=1}^K \right)^T$$

объемом K чисел, где $k = 1, 2, \dots, K$. Тогда каждую j -ю компоненту ЭЭГ $x_j(t)$ запишем в форме (1) как

$$t_k = t_0 + (k-1)\Delta t: x_{j,k} = x_j(t)|_{t=t_k}, \quad k=1,2,\dots,K, \quad (1)$$

где k – номер отсчета, t_0 – начальный момент времени наблюдений, в общем случае равный нулю. Согласно (1) каждая j -я компонента теперь представляется ЭЭГ $\{x_{j,k}\}_{k=1}^K$ (Рисунок 1).




Рисунок 1 – Дискретная многомерная последовательность многократных измерений ЭЭГ $\{\bar{X}\}_{k=1}^K$

Предполагается наличие в составе ЭЭГ (1) паттерна ответной биоэлектрической активности на действие внешнего воздействия, относительно исследуемой системы, существующего на коротком временном интервале $\Delta T_p \in [t_0; T]$, существенно меньшем времени наблюдения ЭГ, $\Delta T_p \ll T$. Временное положение паттерна в составе ЭГ (1) неизвестно.

В рассматриваемом классе задач ЭЭГ сигнал каждого из j -сенсоров $\{x_{j,k}\}_{k=1}^K$ традиционно разбивается на $L > 1$ перекрывающихся или неперекрывающихся временных окон, представляющих собой разбиение исходной последовательности на набор интервалов меньшей длины и осуществляется поиск того временного окна, в котором с максимальной вероятностью присутствует паттерн ответной биоэлектрической активности. Для непересекающихся эпох объемом $\tilde{K} < K$ чисел значения каждого \tilde{k} -го отсчета l -й временной выборки $\{(x_j)_{l,\tilde{k}}\}_{\tilde{k}=1}^{\tilde{K}}$ из ряда $\{x_{j,k}\}_{k=1}^K$ определяются как

$$\tilde{k} = k - (l-1) \tilde{K},$$

где $l = 1, 2, \dots, L$ – номер окна, $l = \lceil K/\tilde{K} \rceil$; $\tilde{k} = 1, 2, \dots, \tilde{K}$; $\tilde{K} = \langle K/L \rangle$, квадратные скобки подразумевают выполнение процедуры округления до большего целого значения, а треугольные – до меньшего, а для пересекающихся – уравнением

$$\tilde{K} = K - (l-1) \Delta\tilde{K},$$

где $\Delta\tilde{K}$ – число отсчетов для сдвига скользящего временного окна (Рисунок 2).




Рисунок 2 – j -я компонента $\{x_{j,k}\}_{k=1}^K$ ЭЭГ $\{\tilde{X}_k\}_{k=1}^K$ с разделением на

L -перекрывающихся временных окон

В соответствии с существующими методами частотно-временной локализации предполагается, что путем вычисления определенных критериев оптимальности,

экстремум критериальной функции, вычисляемой в l -ом временном окне, отражает наличие основной интенсивности паттерна.

Исследуемые методы поиска априорно неопределенных паттернов в составе сигналов ЭЭГ нейроинтерфейсов в общем случае предполагают использовать некоторую декомпозицию сигнала, например, на аддитивные компоненты. При этом, полученные аддитивные компоненты отражают локальные частотные характеристики исследуемого сигнала, из которых выбираются те, что соответствуют частотным особенностями искомого паттерна. Однако в таком случае обычно исследователю заведомо известен локальный частотный диапазон искомого паттерна.

Распространено, например, использование дискретного вейвлет-преобразования (ДВП). В общем случае, согласно концепции многоуровневого анализа, исследуемый сигнал на основе дискретного вейвлет-преобразования (ДВП) разбивается на грубую низкочастотную компоненту и высокочастотную, уточняющую ошибки низкочастотного разбиения, компоненту [8] следующим образом:

$$x_{j,k} = \sum_{k=1}^{m_a} A_{j,m}(k) \phi_{j,m,k}(t) + \sum_{m=1}^M \sum_{k=1}^{m_j} D_{j,m}(k) \psi_{j,m,k}(t); k=1,2,\dots,N. \quad (2)$$

Уравнение (2) образовано сверткой коэффициентов аппроксимации и коэффициентов детализации $\{A,D\}$, полностью описывающих исследуемый временной ряд в частотно-временной области, а также функций масштабирования $\phi_{j,m,k}(t) = 2^{-m/2} \phi(2^{-m}t - k)$ и базисной вейвлет-функции $\psi_{j,m,k}(t) = 2^{-j/2} \psi(2^{-j}t - k)$. Уровень декомпозиции сигнала $m=1,2,\dots,M$, при этом количество уровней разложения M ограничено верхним пределом отсчетов сигнала N . Таким образом, $M_{\max} = \lceil \log_2 N \rceil$, также подразумевается округление до меньшего целого значения; m_a – количество коэффициентов аппроксимации на уровне разложения M ; m_j – количество детализирующих коэффициентов на уровне разложения M . Согласно условию о финитности энергии множества $\{x\}$, которое отражает исследуемый сигнал $x_j(t)$ с дискретностью $\Delta t=1$, т.е. $\sum_k |x_k| < \infty$, и согласно аналогу теоремы

Парсевалю о равенстве энергии непрерывного вейвлет-разложения и энергии сигнала $x(t)$

$$\int_{-\infty}^{\infty} |x_j(t)|^2 dt = C^{-1} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} |W(a,b)|^2 \frac{da db}{a^2}; \quad a, b \in \mathbf{R}, a \neq 0, \quad (3)$$

где C – коэффициент нормировки; $W(a,b) = |a|^{-1/2} \int x(t) \psi^*\left(\frac{t-b}{a}\right) dt$ – вейвлет-преобразование функции в интегральном виде $x_j(t) \in L^2(\mathbf{R})$ (* – процедура комплексного сопряжения), возможно аппроксимирующее равенство для дискретного вейвлет-преобразования:

$$\int_{-\infty}^{\infty} |x_j(t)|^2 dt \cong \sum_k |x_k|^2, \quad (4)$$

где $\bar{E} = \sum_k |x_k|^2$ – полная энергия декомпозиции на основе вейвлет преобразования сигнала x_k . Определив вейвлет-энергию сигнала на уровне разложения m , как суммарную энергию всех детализирующих коэффициентов $E_m^{DWT} = \sum_{k=1}^{m_j} |D_m(k)|^2$, его полную вейвлет-энергию \bar{E}^{DWT} из равенства (4) находят как

$$\bar{E}^{DWT} = \sum_{m=1}^M \sum_{k=1}^{m_j} |D_m(k)|^2 = \sum_{m=1}^M E_m.$$

После выполнения процедуры нормализации $p_m = E_m / \bar{E}$ ($m=1, 2, \dots, M$), определяют вероятности p_m распределения вейвлет-энергии (4) по уровням разложения, при этом $\sum_{m=1}^M p_m = 1$, и вводят понятие вейвлет-энтропии (wavelet entropy, WE)

$$H^{DWT}(l) = - \sum_{m=1}^M p_m(l) \log_2(p_m(l)). \quad (5)$$

Так как вейвлет-энтропия $H^{DWT}(l)$ (5) вычисляется для каждого l -го временного окна, то можно говорить о переходе к временному анализу энтропии с дискретностью N/n отсчетов.

Известно, что максимальные значения энтропии достигаются для сигнала, представляющего собой белый шум, так как в этом случае спектральные

составляющие равномерно распределены по всему диапазону задействованных частот и относительные энергии практически равномерны на всех уровнях разрешения. Относительный же энергетический вклад случайного паттерна концентрируется вокруг некоторого уровня разложения, спектральные составляющие распределяются по частотам неравномерно, энтропия на временном интервале существования этого паттерна принимает низкое значение и, следовательно, функция стоимости определяется из условия поиска минимума $H^{DWT}(l)$ (5).

Основной недостаток приведенной группы методов проявляется тогда, когда характеристики искомого паттерна – частота и интенсивность соответствующих осцилляторов, близки к характеристикам шумовых составляющих сигнала, а его локализация во времени априорно неизвестна. В подобных случаях оказывается, что критерий (5) имеет низкую чувствительность и, зачастую, не позволяет определить временную локализацию паттерна. В виду вышеперечисленного, основными предпосылками к разработке нового метода частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса является отсутствие критериев выбора локального частотного диапазона, что существенно позволит повысить точность локализации, также необходимость выбора ядра метода и/или его базисной функции, которые бы позволили точнее отражать локальные структурные особенности исследуемого сигнала и/или давать более подробное описание сигнала.

Таким образом, в первую очередь, основным требованием к разрабатываемому методу является использование критериев оптимального выбора локального частотного диапазона (частотной локализации) с последующей временной локализацией в найденном частотном диапазоне. И, соответственно, при наличии в составе метода подобного критерия, позволило бы его применять в условиях отсутствия или неполноты априорной информации об искомым паттернах.

Вторым важным требованием к разрабатываемому методу частотно-временной локализации априорно неопределенных паттернов является применение трансформант сигнала, обладающих большей в сравнении с ДВП и БПФ точностью восстановления сигнала. Другими словами, разрабатываемый метод должен содержать в себе способ декомпозиции сигнала, который бы с высокой точностью отражал локальные особенности исследуемого сигнала.

2.2 Разработка метода частотно-временной локализации априорно неопределенных паттернов

Широкое практическое применение ДВП объясняется их эффективностью с вычислительной точки зрения, так как коэффициенты частотного масштабирования a и временного сдвига b принимают здесь лишь значения, кратные степени двойки, т.е. $a = 2^m$, $b = k2^m$. В то же время известно, что непрерывное вейвлет-преобразование (НВП), в рассматриваемом классе задач иногда оказывается более эффективным инструментарием. Во-первых, избыточность НВП, связанная с непрерывным изменением параметров a и b , позволяет более четко и полно представить и, затем, проанализировать содержащуюся в сигнале информацию, четче выявить его структуру и осуществить поиск паттернов. Во-вторых, природа интегрального вейвлет-преобразования (3) такова, что имеет право на существование понятие локальности его энергетического спектра. Так, одной из особенностей НВП является возможность получения локализованных характеристик и изучения локальных свойств процессов. Соответственно, плотность спектра вейвлет-энергии

$$E_w^{CWT}(a,b) = |W(a,b)|^2 \quad (6)$$

из равенства (3), называемая еще локальным спектром энергии и характеризующая энергетические уровни функции $x(t)$ в частотно-временном пространстве, может быть определена как для фиксированного масштаба a , так и для конкретного коэффициента b . Глобальным спектром энергии, отражающим распределение энергии по масштабам на всем временном интервале, называют величину

$$\bar{E}_w^{CWT}(a) = \int_{-\infty}^{+\infty} |W(a,b)|^2 db, \quad (7)$$

а полную энергию функции $x(t)$ в этом случае находят из уравнения

$$\bar{E}_x = C_\psi^{-1} \int \bar{E}_w(a) \frac{da}{a^2}. \quad (8)$$

Известно, что при непрерывном изменении параметров a и b множество вейвлет-функций $\psi(t)$ оказывается избыточным, а большие вычислительные затраты – нецелесообразными. Поэтому при соблюдении условия о возможности последующего восстановления сигнала из его трансформант проводится дискретизация параметров $a = a_\alpha$, $b = b_\beta$ и вместо интегрального вейвлет-преобразования $W(a,b)$ (9) используется его оценка

$$W_A(a_\alpha, b_\beta) = \frac{1}{\tilde{n}(a_\alpha, b_\beta)} \sum_{k=1}^N x_k \psi^* \left(\frac{t_k - b_\beta}{a_\alpha} \right); \quad \tilde{n}(a_\alpha, b_\beta) = \sum_{k=1}^N \exp \left(-\frac{1}{B} \left(\frac{t_k - b_\beta}{a_\alpha} \right)^2 \right),$$

вычисляемая на дискретном множестве значений аргументов a_α, b_β для конечной последовательности измерений ЭЭГ $\{x_k\}_{k=1}^N$ и называемая амплитудной вейвлет-функцией (АВФ), где $\alpha = 0, 1, \dots, (N_\alpha - 1)$, $\beta = 0, 1, \dots, (N_\beta - 1)$; B – коэффициент, определяемый типом базисного вейвлета ψ . Дискретизации параметров a_α, b_β , выбора их диапазонов N_α, N_β используется в соответствии с основными трудами по вейвлет анализу сигналов.

Далее необходимо использование дискретной оценки локального спектра энергии $E_w^{CWT}(a,b)$ (6) – скалограммой

$$E_S^{CWT}(a_\alpha, b_\beta) = |W(a_\alpha, b_\beta)|^2, \quad (9)$$

которая отражает отражающей распределение энергии $\{x_k\}_{k=1}^N$ по дискретным параметрам "масштаб-время" и скейлограммой

$$\bar{E}_S^{CWT}(a_\alpha) = \frac{1}{N_S} \sum_{\beta=0}^{N_\beta-1} E_S^{CWT}(a_\alpha, b_\beta), \quad (10)$$

представляющей собой оценку глобального спектра энергии $\bar{E}_w^{CWT}(a)$ (7). В формуле (10) N_S – число точек, по которому осуществляется усреднение. Скейлограмма

$\bar{E}_S^{CWT}(a_\alpha)$ (10) отражает распределение вейвлет-энергии для масштаба a_α на всем наборе K наблюдений сигнала x_k . Учитывая, что, согласно (8), величина полной энергии сигнала пропорциональна площади под кривой $\bar{E}_w^{CWT}(a)/a^2$, а также равенство (8), оценку полной вейвлет-энергии $\{x_k\}_{k=1}^N$ представим теперь как

$$\bar{E}_x \cong \sum_{i_a=0}^{N_a-1} \bar{E}_S^{CWT}(a_\alpha). \quad (11)$$

Так как скалограмма $E_S^{CWT}(a_\alpha, b_{j_b})$ (9) выявляет локальное частотно-временное распределение энергии процесса, то, по аналогии с изложенным выше традиционным подходом, введем в рассмотрение вероятности распределения вейвлет-энергии сигнала по масштабам a_α , рассчитываемые для каждого l -го ($l=1, 2, \dots, n$) временного окна,

$$\hat{p}_\alpha(l) = \bar{E}_S^{CWT}(a_\alpha, l) / \bar{E}_x(l), \quad \sum_{\alpha=0}^{N_a-1} \hat{p}_\alpha = 1, \quad (12)$$

а уравнение вейвлет-энтропии теперь запишем следующим образом:

$$H^{CWT}(l) = - \sum_{\alpha=0}^{N_a-1} \hat{p}_\alpha(a_\alpha, l) \log_2(\hat{p}_\alpha(a_\alpha, l)). \quad (13)$$

Необходимо еще раз отметить, что энтропия (13) отражает распределение вейвлет-энергии сигнала во времени. Так, если в l -м окне в составе сигнала присутствовала структурная особенность, какие-либо особенные флуктуации частотных осцилляторов, что-либо, отличающее состояние динамической системы на этом временном интервале наблюдений от всех иных состояний, то энтропия $H^{CWT}(l)$ принимает сравнительно низкое значение. В силу упомянутой выше возможности использовать НВП для оценивания локализованных энергетических характеристик ЭЭГ, будем проводить анализ ряда $\{x_k\}_{k=1}^N$ не в полном диапазоне $\alpha=0, 1, \dots, (N_a-1)$ масштабов a_α (не во всем частотном диапазоне), а исследовать его в узком диапазоне, интересующем нас с точки зрения проблемы поиска флуктуаций соответствующих частотных осцилляторов. Тогда в (9), (10) будем рассматривать лишь диапазон масштабов $[a_{\alpha_{\min}}; a_{\alpha_{\max}}]$, а формулы (11)-(13) перепишем следующим образом:

$$\bar{E}_x^{CWT}(l) = \sum_{\alpha=\alpha_{\min}}^{\alpha_{\max}} \bar{E}_S^{CWT}(a_\alpha, l); \quad \hat{p}_\alpha(l) = \bar{E}_S^{CWT}(a_\alpha, l) / \bar{E}_x^{CWT}(l), \quad \sum_{\alpha=\alpha_{\min}}^{\alpha_{\max}} \hat{p}_\alpha = 1; \quad (14)$$

$$\tilde{H}^{CWT}(l) = - \sum_{\alpha=\alpha^{\min}}^{\alpha=\alpha^{\max}} \hat{p}_{\alpha}(l) \log_2(\hat{p}_{\alpha}(l)). \quad (15)$$

Неясным при этом остается выбор минимального a_{α}^{\min} и максимального a_{α}^{\max} значений в случае поиска флуктуаций осцилляторов заранее неизвестных частот. Необходимо отметить, что проведенные практические исследования показали существенную зависимость и, фактически, работоспособность критерия оптимальности $\tilde{H}^{CWT}(l)$ именно лишь при точном задании этих значений. Схема вычисления функции $\tilde{H}^{CWT}(l)$ представлена на рисунке 3.

Однако же понятно, что исходя из особенностей исследуемой осцилляторной системы, расширенные границы частотного спектра искомого паттерна в каждом практическом случае априорно известны. Поэтому такие расширенные оценки граничных значений коэффициентов масштабирования могут быть заданы из условий $\hat{a}_{\alpha^{\min}} < a_{\alpha^{\min}}$, $\hat{a}_{\alpha^{\max}} > a_{\alpha^{\max}}$. Для окончательного разрешения проблемы предлагается ввести в рассмотрение дополнительную критериальную функцию. Будем определять $\hat{a}_{\alpha^{\min}}$, $\hat{a}_{\alpha^{\max}}$ из условия минимума вейвлет-энтропии

$$h^{CWT}(a_{\alpha}) = - \sum_{l=1}^L \tilde{p}_l(a_{\alpha}) \log_2(\tilde{p}_l(a_{\alpha})), \quad (16)$$

рассчитываемой теперь отдельно для каждого масштаба расширенного диапазона (рисунок 4) $a_{\alpha} \in [\hat{a}_{\alpha^{\min}}; \hat{a}_{\alpha^{\max}}]$ на всем наборе K наблюдений сигнала x_k , где $e_s(a_{\alpha}) = \sum_l E_s^{CWT}(a_{\alpha}, l)$ – распределения вейвлет-энергий по окнам, рассчитываемые отдельно для каждого масштаба из расширенного диапазона; $\tilde{p}_l(a_{\alpha}) = E_s^{CWT}(a_{\alpha}, l) / \bar{e}_s(a_{\alpha})$ – вероятности распределений вейвлет-энергий по временным окнам для каждого масштаба в отдельности.

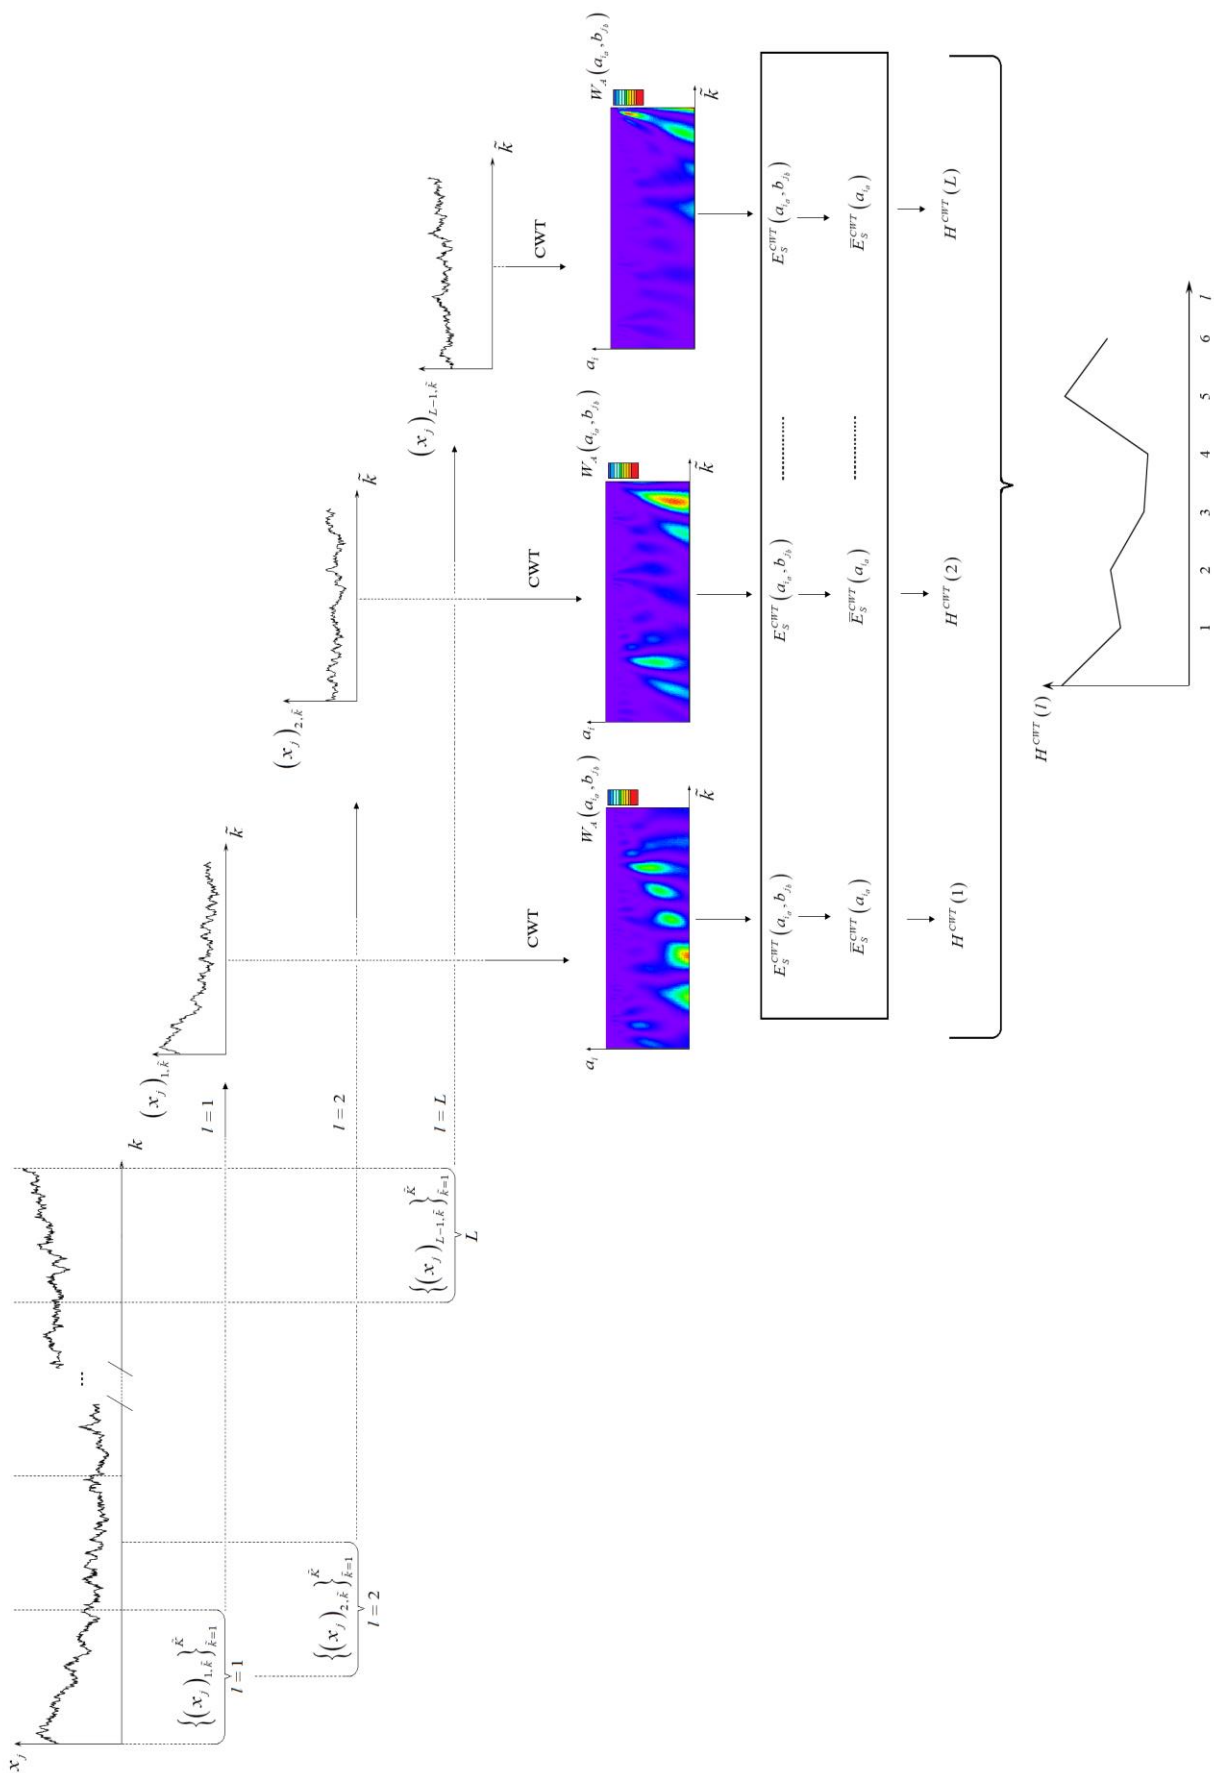


Рисунок 3 – Схема вычисления вейвлет-энтропии на основе НВП

Для окончательного разрешения проблемы предлагается ввести в рассмотрение дополнительную критериальную функцию. Будем определять $\hat{a}_{\alpha_{\min}}$, $\hat{a}_{\alpha_{\max}}$ из условия минимума вейвлет-энтропии

$$h^{CWT}(a_\alpha) = -\sum_{l=1}^L \tilde{p}_l(a_\alpha) \log_2(\tilde{p}_l(a_\alpha)), \quad (17)$$

рассчитываемой теперь отдельно для каждого масштаба расширенного диапазона (рисунок 4) $a_\alpha \in [\hat{a}_{\alpha_{\min}}; \hat{a}_{\alpha_{\max}}]$ на всем наборе K наблюдений сигнала x_k , где $e_s(a_\alpha) = \sum_l E_s^{CWT}(a_\alpha, l)$ – распределения вейвлет-энергий по окнам, рассчитываемые отдельно для каждого масштаба из расширенного диапазона; $\tilde{p}_l(a_\alpha) = E_s^{CWT}(a_\alpha, l) / \bar{e}_s(a_\alpha)$ – вероятности распределений вейвлет-энергий по временным окнам для каждого масштаба в отдельности.

Энтропия (14) отражает распределение вейвлет-энергии по масштабам (частотам). То есть, в пределах масштабов, соответствующих спектру частот искомого паттерна, если он присутствует в любой момент времени наблюдений в составе сигнала x_k , энтропия $h^{CWT}(a_\alpha)$ (18) будет принимать сравнительно низкое значение.

В процессе разработки вышеописанного метода возникла задача его реализации с использованием относительно дешевых низкопроизводительных процессоров и вычислителей. Однако для ряда современных моделей низкопроизводительных процессорных систем, использование вычисления НВП в режиме реального времени является сложной проблемой.

Для решения подобного рода проблем были разработаны дополнительные критериальные функции с использованием трансформант БПФ, которые в виду своей относительно невысокой вычислительной нагрузке позволили бы реализовать частотно-временную локализацию априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса с использованием низкопроизводительных процессорных систем.




Рисунок 4 – Схема вычисления функции $h_s^{CWT}(a_{\alpha})$

2.3 Дополнительные критериальные функции с использованием трансформант Фурье

Положим, что повысить чувствительность критериальных функций спектральной энтропии (СЭ) возможно, если использовать в расчетах не расширенный диапазон частот $[f^{\min}; f^{\max}]$, а более узкий в сравнении с ним диапазон

$$[\hat{f}^{\min}; \hat{f}^{\max}]: (\hat{f}^{\max} - \hat{f}^{\min}) \ll (f^{\max} - f^{\min}).$$

Очевидно, что выбор оценок \hat{f}^{\max} , \hat{f}^{\min} при этом должен производиться из условия, что в узком частотном диапазоне в общую мощность спектра максимальный вклад вносят именно спектральные составляющие искомого паттерна.

Также ясно, что в составе зашумленной ЭГ на любых частотах из расширенного частотного диапазона могут также присутствовать по тем или иным причинам различные спонтанные осцилляции – локальные особенности, никак не связанные с искомыми паттернами. Эти локальные осцилляторные структуры будут приводить к тем же эффектам, что и искомые паттерны – минимизировать функцию $H^{FFT}(l)$. Подобные эффекты могут привести к искажению искомого паттерна путем наложения различных осцилляций, которые также могут быть частично в противофазе. Таким образом возможно изменение спектрального состава искомого паттерна, что в свою очередь влияет на точность определения временной локализации.

Известно, что максимальные значения энтропии достигаются для сигнала, представляющего собой белый шум, так как в этом случае спектральные составляющие равномерно распределены по всему диапазону задействованных частот и относительные энергии практически равномерны на всех уровнях

разрешения. Относительный же энергетический вклад искомого паттерна концентрируется вокруг некоторого диапазона частот.

Спектральные составляющие распределяются при этом по частотам неравномерно и некоторые из них, в зависимости от свойств паттерна, вносят максимальный вклад в общую мощность спектра электрограммы. Следовательно, в тех временных интервалах, где присутствует паттерн, должен наблюдаться всплеск некоторых спектральных составляющих СПМ. Поэтому энтропия распределения по временным интервалам любой отдельной спектральной составляющей из расширенного частотного диапазона будет тем выше, чем равномернее это распределение. Если же в составе некоторого временного интервала наблюдается всплеск какой-либо спектральной составляющей, что может свидетельствовать о "вкладе" паттерна, то энтропия распределения по временным интервалам этой отдельной спектральной составляющей будет низкой.

Исходя из приведенных рассуждений сформулирована критерий оптимального выбора частотного диапазона

$$h_j^{FFT}(f_i) = -\sum_{l=1}^L \tilde{p}_{j,l}(f_i) \log(\tilde{p}_{j,l}(f_i)), \quad (18)$$

где $h_j^{FFT}(f_i)$ – энтропия распределения по временным интервалам каждой отдельной спектральной составляющей частоты f_i из расширенного частотного диапазона $f_i \in [f^{\min}; f^{\max}]$ для j -го сенсора.

Функция (18) будет иметь минимальное значение для тех i -х спектральных составляющих, которые максимально неравномерно распределены по временным интервалам, что будет свидетельствовать о наличии характерных локальных особенностей в составе ЭГ на частоте f_i .

Далее критерий для определения оценок \hat{f}^{\max} , \hat{f}^{\min} узкого частотного диапазона, соответствующего максимальному вкладу в общую мощность спектра именно спектральных составляющих искомым паттернов ответной биоэлектрической активности, зададим следующим образом:

$$\min_{f_i} \{h_j^{FFT}(f_i)\},$$

$$\tilde{p}_{j,l}(f_i) = \frac{\hat{P}_{j,l}(f_i)}{\sum_{l=1}^L \hat{P}_{j,l}(f_i)} - \text{вероятность, энергетический вклад на частоте } f_i \text{ в СПМ } l\text{-й}$$

выборки j -й компоненты ЭЭГ. Схема вычисления критериев оптимального выбора локального диапазона частот представлена на рисунке 9. В отличие от (15), энтропия (18) отражает распределение вейвлет-энергии по частотам. То есть, в пределах диапазона частот, соответствующих спектру частот искомого паттерна, если он присутствует в любой момент времени наблюдений в составе сигнала x_k , энтропия $h_j^{FFT}(f_i)$ (18) будет принимать сравнительно низкое значение.

Исходя из приведенных выше рассуждений и разработанного критерия оптимальности, формула (15) примет вид

$$H_j^{FFT}(l) = \sum_{f_i=f_{\min}}^{\hat{f}_{\max}} p_{j,l}(f_i) \log(p_{j,l}(f_i)),$$

где $p_{j,l}(f_i) = \frac{\hat{P}_{j,l}(f_i)}{\sum_{f_i=f_{\min}}^{\hat{f}_{\max}} \hat{P}_{j,l}(f_i)}$, $\sum_{f_i=f_{\min}}^{\hat{f}_{\max}} \hat{P}_{j,l}(f_i)$ - суммарная энергия во временном диапазоне

$[f^{\min}; f^{\max}]$ для l -го временного окна. Схема вычисления алгоритма функции $h_S^{CWT}(a_{i_a})$ представлена на рисунке 5.

Завершающим этапом разработки метода частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса является реализация всех используемых критериальных функций для многомерного случая. Такая необходимость обусловлена тем, что экспериментальные записи ЭЭГ в составе нейрокомпьютерного интерфейса проводятся посредством многоканальной записи от нескольких сенсоров J . Также реализация многомерного случая потенциально может повысить точность локализации паттернов за счет избыточности источников информации.




Рисунок 5 – Схема вычисления критерия оптимального выбора локального частотного диапазона

2.4 Критерии оптимальности для многомерного случая

При решении ряда задач, в которых требуется произвести, поиск локальных структурных особенностей одномерных ЭЭГ зачастую используется более одного сенсора. Использование нескольких сенсоров (отведений) позволяет получать несколько синхронизированных по времени одномерных ЭЭГ, отражающих текущее состояние системы. При этом предполагается, что искомые паттерны могут находить отражение в более чем одном сенсоре. Принято проводить исследование для одного конкретного сенсора, в котором вклад паттернов в суммарную интенсивность спектра будет максимален. Однако в случаях, когда интенсивность паттернов близка к интенсивности фоновой активности системы, а паттерны отражены в более чем одном сенсоре, предполагается повышение точности при использовании всех сенсоров.

Однако, например, усреднение по J сенсорам одноименных k -х значений многомерной ЭГ $\{\bar{X}\}_{k=1}^K = \left(\{x_{1,k}\}_{k=1}^K, \{x_{2,k}\}_{k=1}^K, \dots, \{x_{j,k}\}_{k=1}^K, \dots, \{x_{J,k}\}_{k=1}^K \right)^T$

$$\tilde{x}_k = \frac{1}{J} \sum_{j=1}^J x_k(j)$$

с последующим расчетом функции (15) для усредненной ЭГ было бы неверным, вследствие наличия относительных смещений ответных паттернов по сенсорам. Подобные временные смещения могут приводить к эффекту, в радиосвязи называемому федингом (замиранием) радиосигнала, обусловленному флуктуациями амплитуд, фаз и углов прибытия паттернов в каждом сенсоре. Соответственно, в некоторых случаях паттерны в разных сенсоре могут наблюдаться, например, в противофазе и, таким образом, усреднение по компонентам ЭЭГ, не приведет к ожидаемому эффекту от регистрации ЭГ на множестве сенсоре.

Для повышения точности вычисления вейвлет-энтропии на основе НВП предлагается использовать многомерный синхронизированный ЭЭГ

$\{\bar{X}\}_{k=1}^K = \left(\{x_{1,k}\}_{k=1}^K, \{x_{2,k}\}_{k=1}^K, \dots, \{x_{j,k}\}_{k=1}^K, \dots, \{x_{J,k}\}_{k=1}^K \right)^T$. Таким образом на для каждого одномерного ЭЭГ $\{x_{j,k}\}_{k=1}^K \in \{\bar{X}\}_{k=1}^K$, который входит в состав $\{\bar{X}\}_{k=1}^K$ необходим производить расчет функций $H_j^{CWT}(l)$ и $h_j^{CWT}(a_{i_a})$.

Полученные функции $H_j^{CWT}(l)$ и $h_j^{CWT}(a_{i_a})$ усредняются согласно формулам

$$\tilde{H}^{CWT}(l) = \frac{1}{J} \sum_{j=1}^J \hat{H}_j^{CWT}(l), \quad \hat{H}(l) = \frac{\hat{H}_j^{CWT}(l)}{\max(\hat{H}_j^{CWT}(l))}, \quad \hat{H}(l) = H_j^{CWT}(l) - \min(H_j^{CWT}(l)),$$

$$\tilde{h}^{CWT}(a_{i_a}) = \frac{1}{J} \sum_{j=1}^J \hat{h}_j^{CWT}(a_{i_a}), \quad \hat{h}_j^{CWT}(a_{i_a}) = \frac{\hat{h}_j^{CWT}(a_{i_a})}{\max(\hat{h}_j^{CWT}(a_{i_a}))}, \quad \hat{h}_j^{CWT}(a_{i_a}) = h_j^{CWT}(a_{i_a}) - \min(h_j^{CWT}(a_{i_a})),$$

где $j=1, \dots, J$ номер сенсора.

Стоит отметить, что для более качественного и робастного анализа разработанные критерии в первую очередь нормируются так, чтобы диапазон значений каждого критерия варьировался в диапазоне от 0 до 1.

Вышеперечисленное математическое описание подробно отражает концепцию разработанного метода частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса, основными отличительными особенностями которого является: применимость в условии отсутствия априорной информации об искомым паттернов, например, точного локального диапазона частот; применимость в условиях маскирования паттернов шумами различной природы; реализация с использованием множества сенсоров.

2.5. Выводы ко второй главе

В главе 2 продолжен новый метод на основе НВП, а также новые критерии оптимальности вейвлет-энтропии, позволяющие произвести локализацию ЭЭГ-паттернов в узком диапазоне масштабов (частотная локализация), а также в

качестве ядра вейвлет-энтропии предложено использование непрерывного вейвлет-преобразования. В результате проведенных исследований, представленных в данной главе, можно сделать следующие выводы:

1. предложенный метод частотно-временной локализации паттернов за счет избыточности НВП позволяет произвести качественную частотную и временную локализацию;
2. предложены критерии оптимальности позволяющие проводить частотную локализацию паттернов нейро в условиях, когда характеристики искомого паттерна – частота и интенсивность соответствующих осцилляторов, близки к характеристикам шумовых составляющих сигнала, а его локализация во времени априорно неизвестна;
3. предложена модификация критериев с использованием трансформант Фурье, позволяющая проводить вычисления с использованием портативных низкопроизводительных процессорных систем, т.к. обладают меньшей вычислительной нагрузкой;
4. предложены критерии оптимальности для использования разработанного метода в многомерном случае.

Далее в рамках поставленных требуется разработать и дать четкое описание алгоритмов, реализующих разработанный метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса. Также необходимо проверить работоспособность метода с посредством моделирования, а именно провести частотно-временную локализацию смоделированных сложных паттернов разной интенсивности.

Глава 3. Разработка алгоритмов частотно-временной локализации паттернов в составе зашумленных сигналов электроэнцефалограммы и моделирование

3.1. Алгоритм и программная реализация частотно-временной локализации на основе непрерывного вейвлет-преобразования

Для реализации нейроинтерфейсов с использованием разработанного метода и критериев оптимальности необходимо строгое описание структуры алгоритмов, реализующих предложенный метод.

В общем случае алгоритм реализующий предложенный метод частотно-временной локализации паттернов в зашумленных сигналах ЭЭГ в составе нейроинтерфейсов, отличается от традиционных тем, что содержит критерии оптимального поиска частотных границ искомого паттерна. Функциональная схема алгоритма частотно-временной локализации паттернов представлена на рисунке 6.

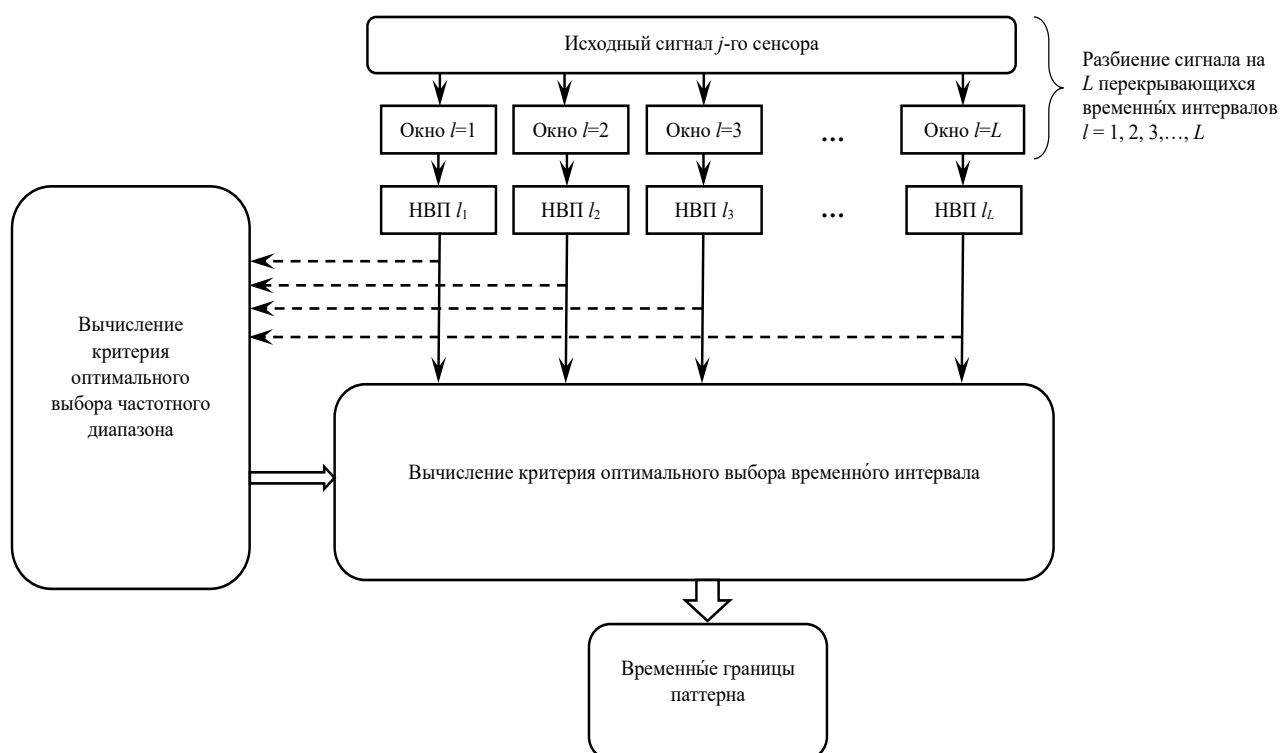


Рисунок 6 – Функциональная схема алгоритма частотно-временной локализации паттернов на основе НВП.

Реализация разработанного алгоритма и специального программного обеспечения (рисунок 7) проводилась с использованием среды графического программирования LabVIEW фирмы National Instruments, которая позволяет проводить различного рода моделирование и вычисления с использованием технологии создания виртуальных приборов.

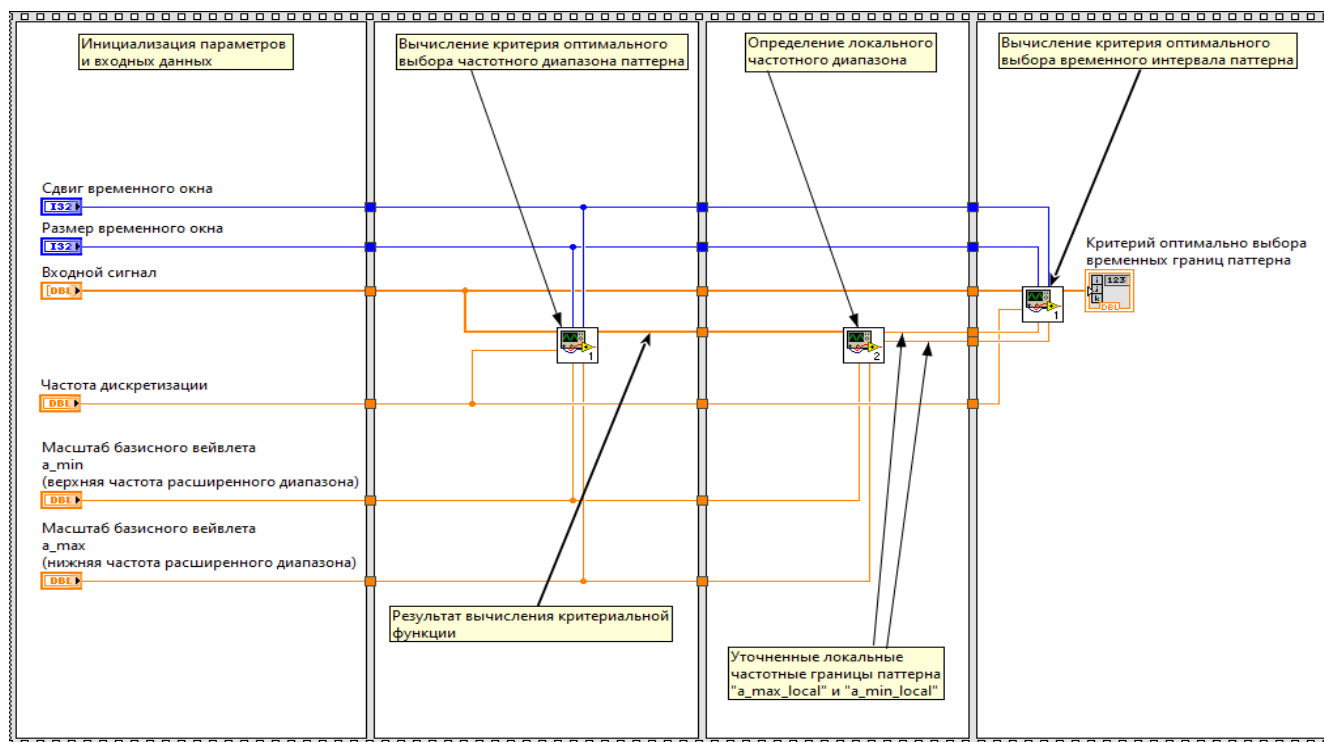


Рисунок 7 – Блок-диаграмма виртуального прибора частотно-временной локализации паттернов на основе НВП

В общем случае алгоритм, реализующий разработанный метод, в своем составе содержит ряд последовательных процедур, таких, как «Инициализация параметров и входных данных», «Вычисление критерия оптимального выбора частотного диапазона паттерна», «Определение локального частотного диапазона» и «Вычисление критерия оптимального выбора временного интервала паттерна».

Процедура «Инициализация параметров и входных данных» применяется для установки пользователем таких параметров, как:

- размер временного окна – временной интервал l в отсчетах сигнала устанавливаемый пользователем;

- сдвиг временного окна – сдвиг временного интервала в отсчетах сигнала устанавливаемый пользователем (в случае если сдвиг временного окна и размер временного окна равны – вычисление производится для непересекающихся временных интервалов);
- частота дискретизации исходного сигнала;
- a_{max} – масштаб базисной вейвлет функции НВП, соответствующий максимальной частоте расширенного частотного диапазона паттерна;
- a_{min} – масштаб базисной вейвлет функции НВП, соответствующий минимальной частоте расширенного частотного диапазона паттерна.

В качестве входного сигнала возможно использование как ранее записанного файла экспериментальных данных, так и непосредственно выходной сигнал измерительного оборудования, например, от многоканального АЦП Multichannel Acquisition processor фирмы National Instruments.

Процедура «Вычисление критерия оптимального выбора частотного диапазона паттерна» (Рисунок 8) реализует критериальную функцию $h^{CWT}(a_\alpha)$, вычисляемую в расширенном диапазоне масштабов $a_{max}(a_\alpha^{max})$ и $a_{min}(a_\alpha^{min})$.

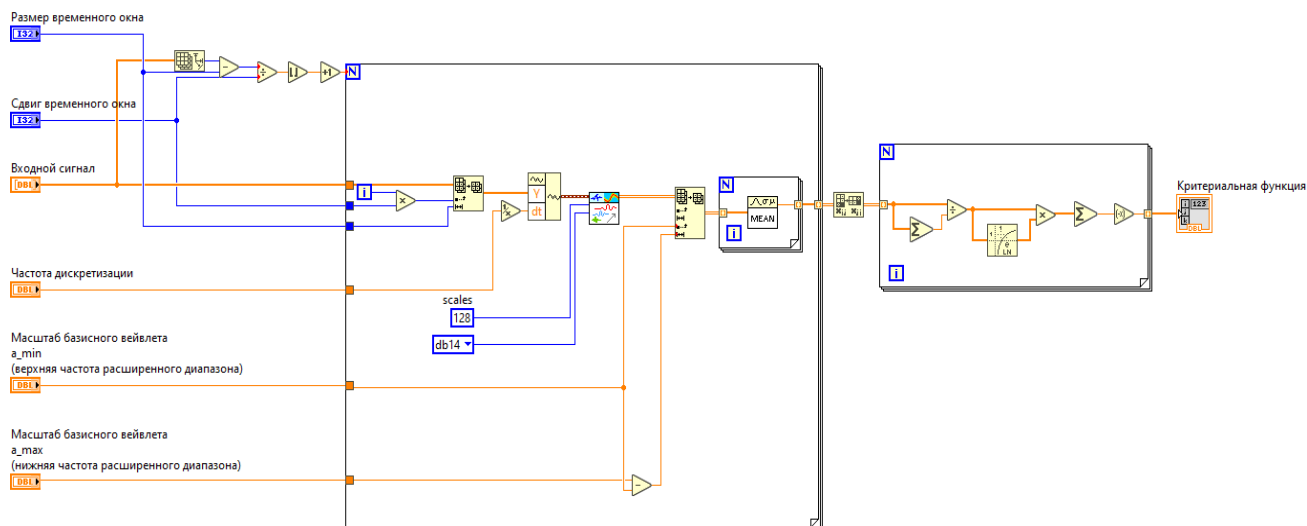


Рисунок 8 – Блок-диаграмма виртуального субприбора «Вычисление критерия оптимального выбора частотного диапазона паттерна»

В качестве входных параметров виртуальный прибор «Вычисление критерия оптимального выбора частотного диапазона паттерна» принимает входной сигнал, частоту дискретизации и границы расширенного диапазона масштабов базисной вейвлет функции. После получения входных данных вычисляется средняя вейвлет энергия каждого временного окна с заданным базисным вейвлетом (Добеши 14). Далее на основе средней вейвлет энергии на каждом базисном масштабе вейвлет-функции вычисляется критериальная функция выбора оптимально частотного диапазона искомого паттерна.

Следующим шагом работе алгоритма частотно-временной локализации паттернов в зашумленных сигналах ЭЭГ является определение границ частотного диапазона. По умолчанию определение границ локального частотного диапазона производится экспертом при визуальном анализе графика полученной критериальной функции. Однако для реализации автоматического режима работы виртуального прибора была реализована процедура «Определение локального частотного диапазона» (рисунок 9).

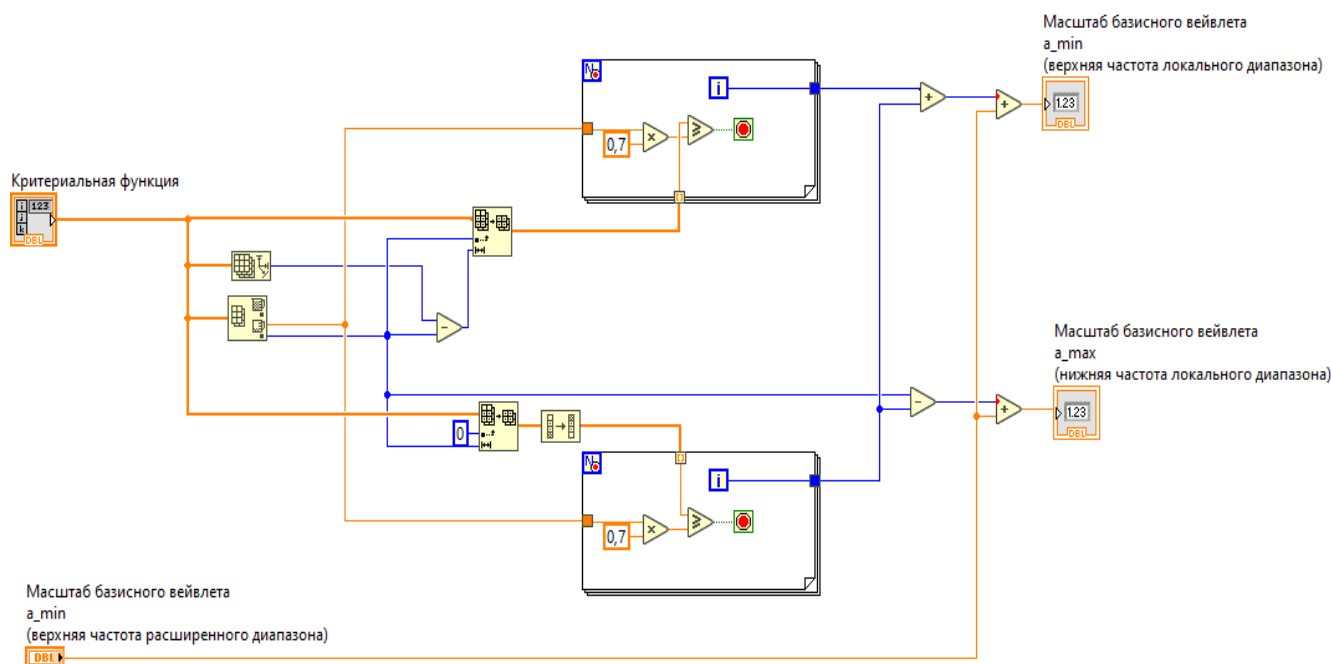


Рисунок 9 – Блок-диаграмма виртуального прибора «Определение локального частотного диапазона»

В первую очередь, определяется глобальный минимум критериальной функции. Далее в окрестностях минимума критериальной функции проводится поиск ближайших значений равных 0.7 от минимума. Полученные значения определяются как локальные границы частотного диапазона паттерна a_{max_local} и a_{min_local} .

Конечным шагом алгоритма является вычисление процедуры «Вычисление критерия оптимального выбора временного интервала паттерна», реализованной в субприборе на рисунке 10.

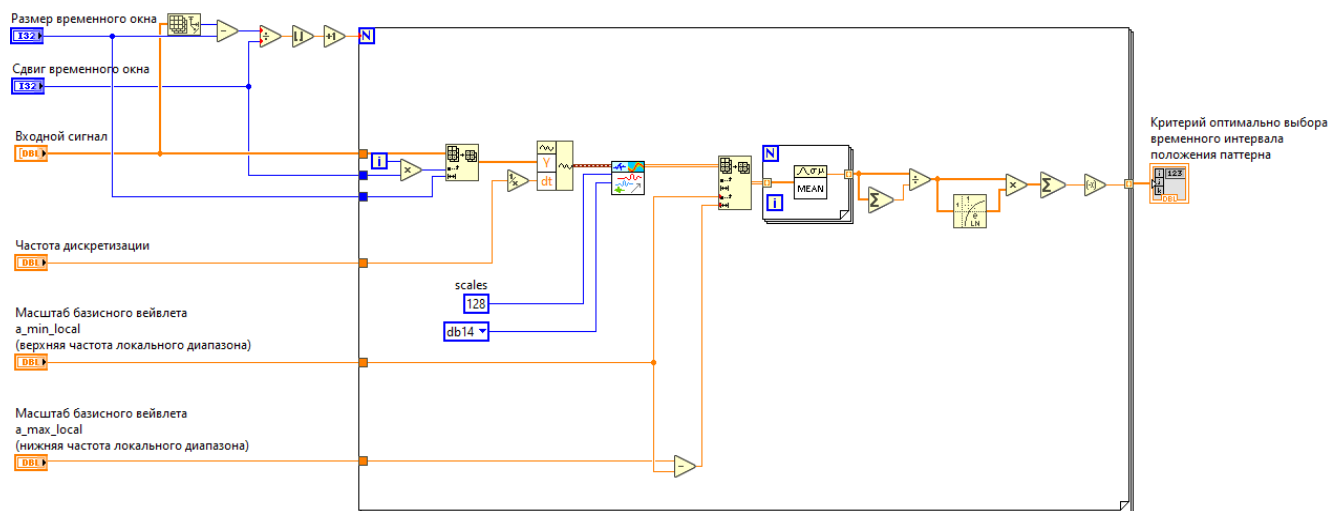


Рисунок 10 – Блок-диаграмма виртуального субприбора «Вычисление критерия оптимального выбора временного интервала паттерна»

В качестве входных данных субприбор принимает входной сигнал, частоту дискретизации и границы полученного локального диапазона масштабов базисной вейвлет функции. После получения входных данных вычисляется в каждом временном интервале средняя вейвлет энергия с заданным базисным вейвлетом (Добеши 14) и вейвлет энтропия НВП.

3.2. Апробация алгоритма частотно-временной локализации паттернов на основе непрерывного вейвлет преобразования с использованием модельных данных

Пусть существует электрограмма $Z(t) = (z_1(t) \ z_2(t) \ \dots z_j(t) \ \dots \ z_J(t))^T$ представленная многомерной ЭЭГ $\{\bar{Z}\}_{k=1}^K$ (Рисунок 11), в каждую одномерную ЭЭГ для j -го сенсора аддитивный модельный паттерн, задаваемый следующими уравнениями:

$$y_{k+1} = \begin{cases} k \in [520; 720]: A(-0,4\sin(5\pi u_k) - 0,4\sin(6\pi u_k)), \\ 0; \end{cases}$$

где $y_0 = 0$; $u_k = \sin(2\pi k/700)$; $u_k = \sin(2\pi k/1000)$, A – амплитуда паттерна. На временной оси паттерн локализован в пределах $k \in [520; 720]$ отсчетов, и максимальная интенсивность паттерна сосредоточена во временном окне №1, при этом номера окон $l=0,1,\dots,6$.

Для анализа точности временной локализации паттернов с помощью разработанного метода, произведено моделирование аддитивных паттернов y_1, y_2, y_3 с несколькими вариантами амплитуды $A_l=0, A_2=13, A_3=25$ и соответственно получены одномерные ЭЭГ $\{z_k^{(1)}\}_{k=1}^K, \{z_k^{(2)}\}_{k=1}^K, \{z_k^{(3)}\}_{k=1}^K$ (Рисунок 11), где $\{z_k^{(1)}\}_{k=1}^K = \{x_{j,k}\}_{k=1}^K$ исходный сигнал без паттерна.

Амплитудный спектр паттерна сосредоточен в диапазоне от 70 до 180 Гц (Рисунок 12), и согласно традиционному подходу применения спектральной энтропии, расширенный диапазон будет соответствовать частотному диапазону паттерна.

Так, для ЭЭГ $\{z_k^{(1)}\}_{k=1}^K, \{z_k^{(2)}\}_{k=1}^K, \{z_k^{(3)}\}_{k=1}^K$ были построены критерии оптимальности $H^{DWT}(l)$ на основе ДВП и $\tilde{H}^{CWT}(l)$ на основе НВП соответственно.

При этом критерий $\tilde{H}^{CWT}(l)$ была вычислен в локальном диапазоне масштабов, полученным с помощью функции $h^{CWT}(a_{i_u})$ (рисунок 13).

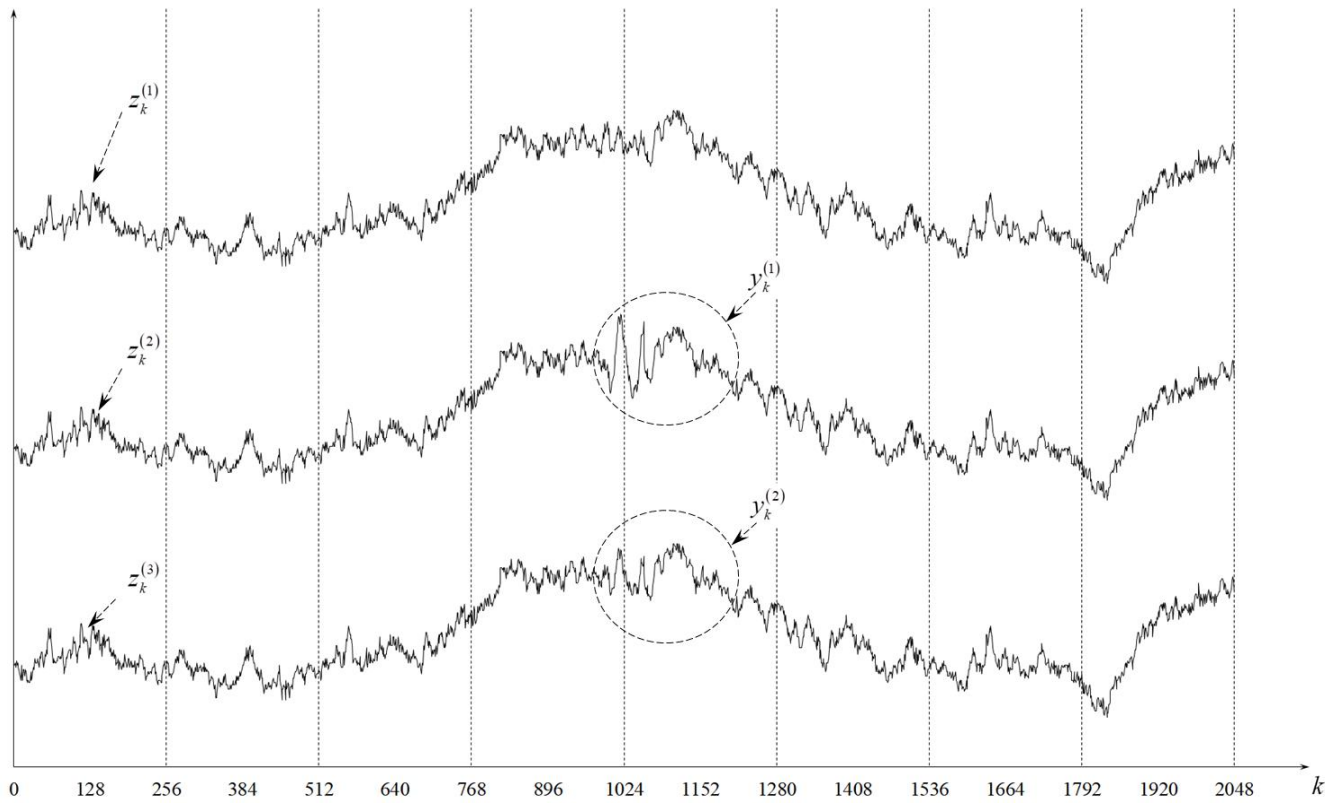


Рисунок 11 – Одномерные ЭЭГ $\{z_k^{(1)}\}_{k=1}^K, \{z_k^{(2)}\}_{k=1}^K, \{z_k^{(3)}\}_{k=1}^K$ с аддитивными паттернами

y_1, y_2






Рисунок 12 – Спектр искомого паттерна



a)



b)

Рисунок 13 – Результат вычисления функции $h_S^{CWT}(a_{i_a})$ во всем диапазоне масштабов НВП, $h_S^{CWT(1)}(a_{i_a})$ - для ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$, $h_S^{CWT(2)}(a_{i_a})$ - для ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$

Рисунок 13 показывает, что функция $h_S^{CWT(2)}(a_{i_a})$ принимает минимальное значение в пределах $[\hat{a}_{\alpha_{\min}} = 16; \hat{a}_{\alpha_{\max}} = 40]$ масштабов. Соответственно, согласно предложенному алгоритму вычисления, функция $\tilde{H}^{CWT}(l)$ вычислялась в пределах

$[\hat{a}_{\alpha_{\min}} = 16; \hat{a}_{\alpha_{\max}} = 40]$, а функция $H_S^{DWT}(l)$ вычислялась в соответствии с традиционным методом вычисления спектральной энтропии (Рисунок 14).

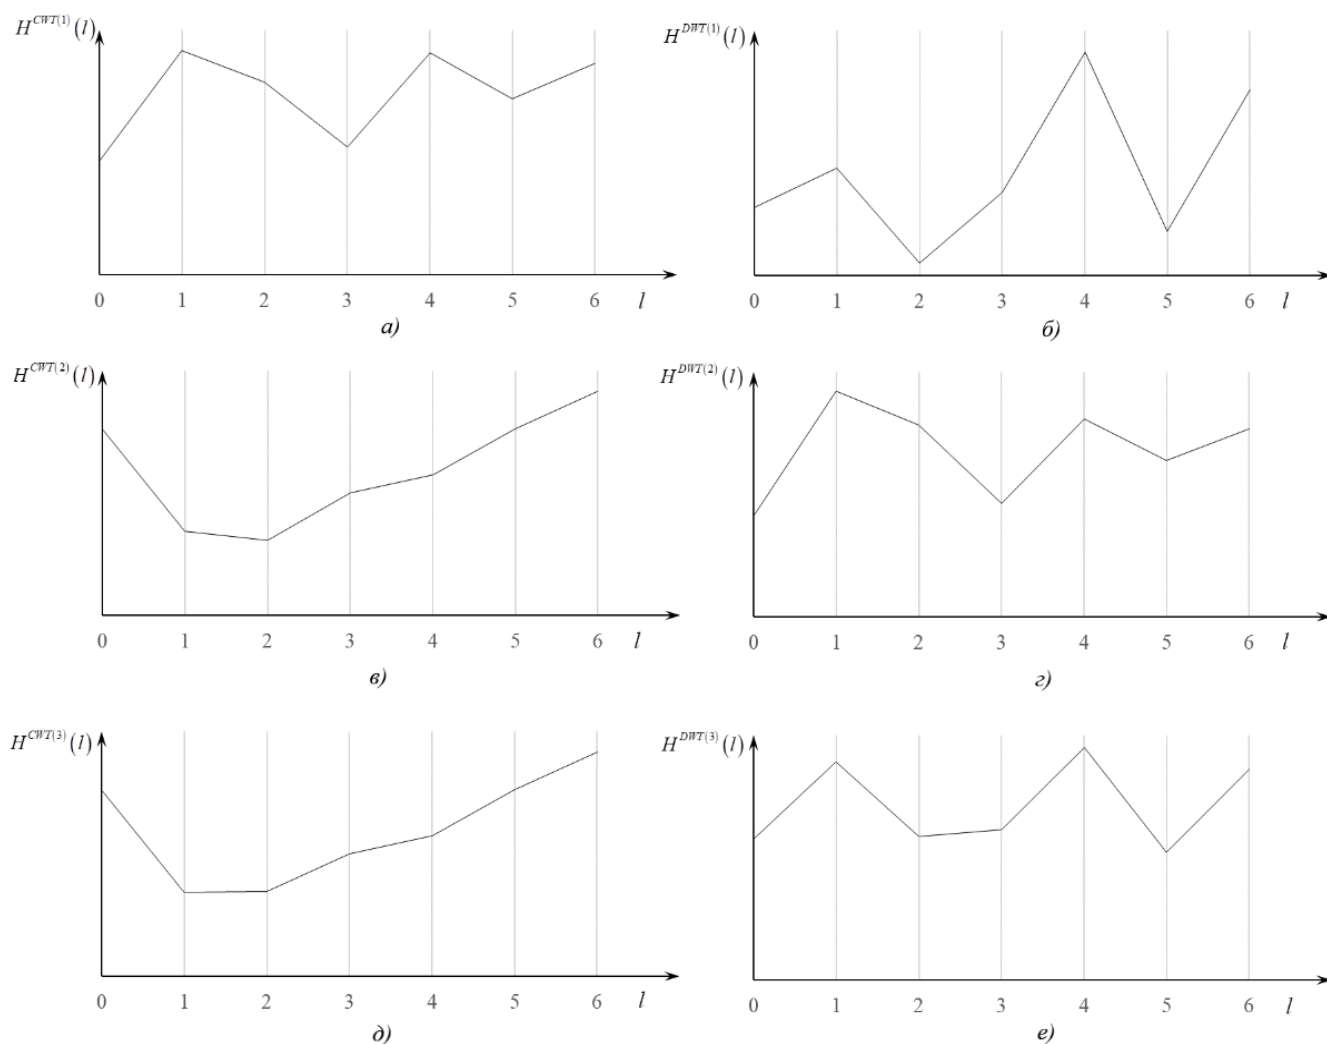


Рисунок 14 – Результаты вычисления вейвлет-энтропии (а - $H_S^{CWT(1)}(l)$ для $\{z_k^{(1)}\}_{k=1}^K$, б - $H^{DWT(1)}(l)$ для $\{z_k^{(1)}\}_{k=1}^K$, в - $H^{CWT(2)}(l)$ для $\{z_k^{(2)}\}_{k=1}^K$, г - $H^{DWT(2)}(l)$ для $\{z_k^{(2)}\}_{k=1}^K$, д - $H^{CWT(3)}(l)$ для $\{z_k^{(3)}\}_{k=1}^K$, е - $H^{DWT(3)}(l)$ для $\{z_k^{(3)}\}_{k=1}^K$)

Результаты представленные на рисунке 14 показывают, что для ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$ без паттерна функция $H^{CWT(1)}(l)$ принимает минимальное значение во 3-м временном окне (Рисунок 14, а), а функция $H^{DWT(1)}(l)$ (Рисунок 14, б) принимает минимальное значение во 2-м временном окне. Данный результат указывает на то,

что используемый тип вейвлет-преобразование отражает неравномерность энергии в найденных временных окнах. Также данный результат необходим для сравнения между критериями оптимальности, полученными для ЭЭГ без паттерна $\{z_k^{(1)}\}_{k=1}^K$ и для ЭЭГ с паттернами $\{z_k^{(2)}\}_{k=1}^K$ и $\{z_k^{(3)}\}_{k=1}^K$. Также согласно рисунку 14, функция $H^{CWT(2)}(l)$ вычисляемого в локальном диапазоне масштабов $[\hat{a}_{\alpha_{\min}} = 16; \hat{a}_{\alpha_{\max}} = 40]$ принимает минимальные значения во временных окнах 1 и 2 (Рисунок 12, в), что соответствует положению паттерна y_2 в ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$. Функция $H^{DWT(2)}(l)$ в свою очередь принимает минимальное значение во временном интервале 0 (Рисунок 14, з), что не соответствует положению паттерна в ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$. И наконец, принимает минимальные значения во временных окнах 1 и 2 (Рисунок 12, д) для ЭЭГ $\{z_k^{(3)}\}_{k=1}^K$ с паттерном y_3 , который имеет существенно меньшую интенсивность. Для ЭЭГ $\{z_k^{(3)}\}_{k=1}^K$ функция $H^{DWT(3)}(l)$ на основе ДВП принимает минимальное значение в 5-м временном окне.

Таким образом, результаты показывают, что для частотно-временной локализации паттернов, вейвлет-энтропия на основе ДВП $H^{DWT}(l)$, имеет низкую чувствительность и не позволяет определить положение паттерна на временной оси, в случаях, когда спектральный состав паттерна близок к спектральному составу исследуемого сигнала ЭЭГ, в отличии от разработанного метода, который доказал свою точность на модельных данных.

Следующим шагом является оценка точности частотно-временной локализации смоделированных паттернов для вариации метода с использованием трансформант Фурье.

3.3. Алгоритм и программная реализация частотно-временной локализации на основе трансформант Фурье

В ряде случаев, например, при разработке портативных устройств в составе которых используются нейроинтерфейсы, используются низкопроизводительные процессоры и вычислители. Важным аспектом такого рода устройств является низкая вычислительная нагрузка используемых алгоритмов, в том числе частотно-временной локализации паттернов в составе зашумленных. Для решения проблем высокой вычислительной нагрузки программного обеспечения был разработан алгоритм с использованием критериальных функций на основе трансформант Фурье, а именно БПФ. На рисунке 15 изображена Функциональная схема алгоритма частотно-временной локализации паттернов на основе БПФ.

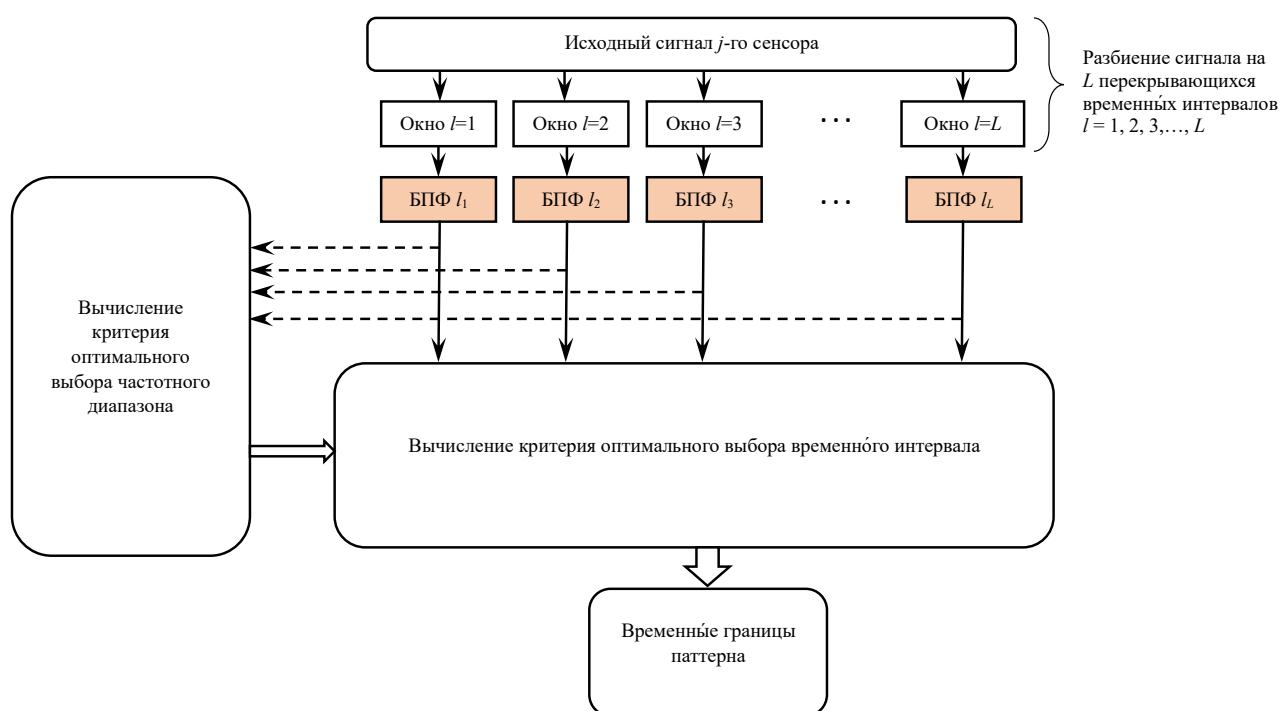


Рисунок 15 – Функциональная схема алгоритма частотно-временной локализации паттернов на основе БПФ

Алгоритм частотно-временной локализации паттернов на основе БПФ, отличается от соответствующего алгоритма на основе НВП тем что в качестве ядра

функции используются трансформанты преобразования Фурье. Таким образом, основные отличия в блок-диаграмме виртуального прибора, реализующего алгоритм заключаются в субприборах «Вычисление критерия оптимального выбора частотного диапазона паттерна на основе БПФ» (рисунок 16) и «Вычисление критерия оптимального выбора временного интервала паттерна на основе БПФ» (рисунок 17).

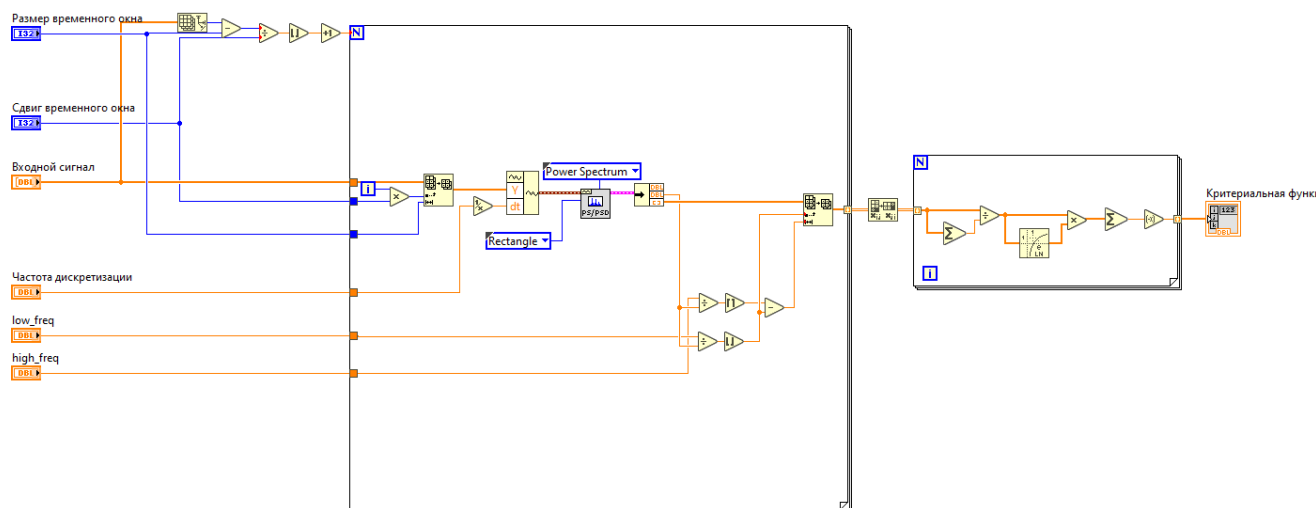


Рисунок 16 – Блок-диаграмма виртуального субприбора «Вычисление критерия оптимального выбора частотного диапазона паттерна на основе БПФ»

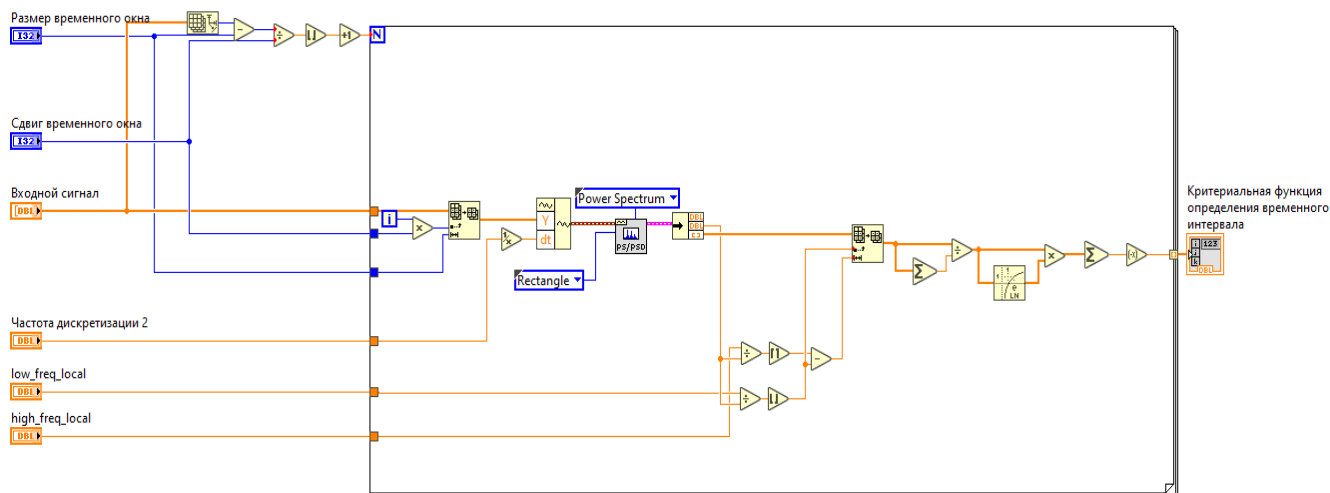


Рисунок 17 – Блок-диаграмма виртуального субприбора «Вычисление критерия оптимального выбора временного интервала паттерна на основе БПФ»

Согласно рисункам 16 и 17 также помимо способа декомпозиции сигнала используются не масштабы базисной вейвлет функции, а коэффициенты спектральной плотности мощности, соответствующие определенным частотным составляющим во входном сигнале:

- *low_freq* и *high_freq* – нижняя и верхняя частота расширенного диапазона частот искомого паттерна;
- *low_freq_local* и *high_local* – нижняя и верхняя частота полученного локального диапазона частот искомого паттерна.

3.4. Апробация алгоритма частотно-временной локализации паттернов на основе трансформант Фурье с использованием модельных данных

Для подтверждения повышения точности спектральной энтропии за счет разработанных критериев оптимальности, были произведены исследования на смоделированных данных.

Используя алгоритм спектральной энтропии, были получены зависимости точности определения паттерна от амплитуды (Рисунок 18).

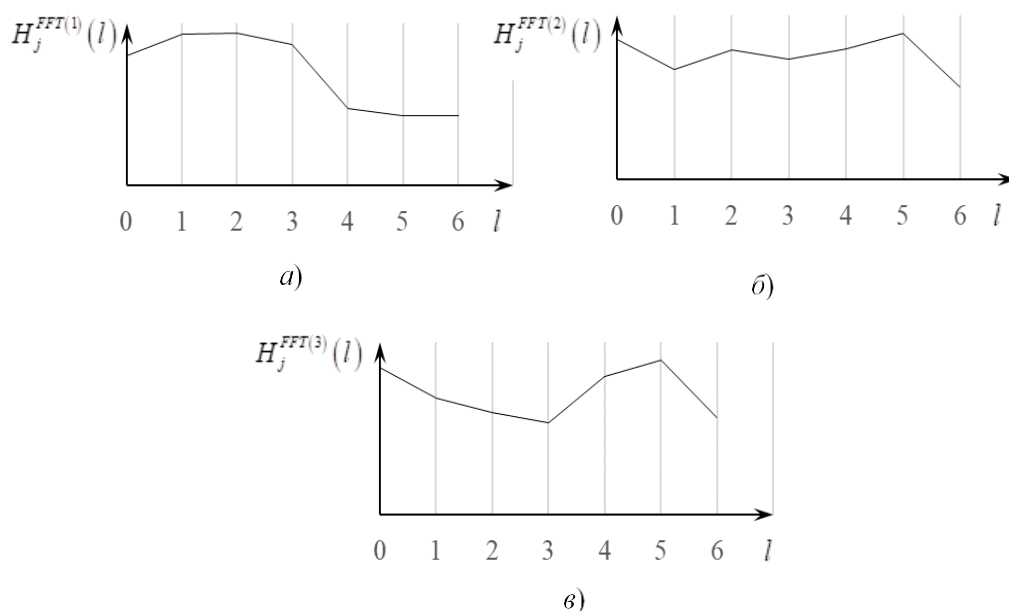


Рисунок 18 – Графики спектральной энтропии для одномерных ЭЭГ

$$\left\{z_k^{(1)}\right\}_{k=1}^K (a), \left\{z_k^{(2)}\right\}_{k=1}^K (б), \left\{z_k^{(3)}\right\}_{k=1}^K (в)$$

На рисунке 18 представлены графики спектральной энтропии $H_j^{(1)}(l)$ (Рисунок 18, а), $H_j^{FFT(2)}(l)$ (Рисунок 18, б), $H_j^{FFT(3)}(l)$ (Рисунок 18, в) для одномерных ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$, $\{z_k^{(2)}\}_{k=1}^K$, $\{z_k^{(3)}\}_{k=1}^K$ соответственно, которые показывают, что минимальное значение спектральной энтропии в расширенном (исходном) диапазоне частот для одномерных ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$ и $\{z_k^{(3)}\}_{k=1}^K$ принимает в первом временном интервале. Этот результат свидетельствует о том, что в случае, когда интенсивность паттернов близка к интенсивности фоновой активности исследуемой системы, функция $H_j^{FFT}(l)$ имеет низкую чувствительность. В то же время, функция $H_j^{FFT(2)}(l)$, принимает минимальное значение в третьем временном интервале для одномерной ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$, что соответствует местоположению паттерна на оси времени.

На рисунке 19 продемонстрированы результаты вычисления критериев оптимального выбора $h_j^{FFT}(f_i)$ локального диапазона для одномерных ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$, $\{z_k^{(2)}\}_{k=1}^K$, $\{z_k^{(3)}\}_{k=1}^K$, соответственно $h_j^{FFT(1)}(f_i)$, $h_j^{FFT(2)}(f_i)$, $h_j^{FFT(3)}(f_i)$. Согласно критерию, выбор диапазона частот заключается в поиске минимума и его окрестностей. Таким образом для одномерной ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$, для которого амплитуда аддитивного паттерна $A=0$, и который по сути является исходной одномерной ЭЭГ, локальный частотный диапазон будет соответствовать 150–170 Гц (Рисунок 19, а). Для одномерной ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$, аддитивный паттерн которого имеет низкую амплитуду $A=13$, локальный частотный диапазон будет соответствовать 100–120 Гц (Рисунок 19, б).




Рисунок 19 – Результаты вычисления критерия оптимального выбора локального

диапазона $h_j^{FFT}(f_i)$ для одномерных ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$ (а), $\{z_k^{(2)}\}_{k=1}^K$ (б), $\{z_k^{(3)}\}_{k=1}^K$ (в)

И для одномерной ЭЭГ $\{z_k^{(3)}\}_{k=1}^K$, паттерн которого имеет высокую амплитуду $A=25$, локальный частотный диапазон также соответствует 100–120 Гц (Рисунок 19, в). Данный факт говорит о том, что, во-первых, аддитивный паттерн вносит изменение в спектральные характеристики исследуемой одномерной ЭЭГ, так как результаты вычислений показывают очевидные различия в полученных критериях оптимального выбора.

Другим важным фактором свидетельствующим о чувствительности предложенного критерия оптимального выбора заключается в том, что полученные в соответствии с критерием (24) частотные диапазоны для одномерных ЭЭГ с аддитивным паттерном высокой интенсивности $\{z_k^{(3)}\}_{k=1}^K$ и с низкой интенсивностью

$\{z_k^{(2)}\}_{k=1}^K$ имеют одинаковые границы.

Для подтверждения применимости данного критерия оптимальности к поиску локального диапазона частот были повторно вычислены функции СЭ для каждого из модельных одномерных ЭЭГ (Рисунок 20).

Согласно результатам вычисления спектральной энтропии с использованием локального диапазона частот, выбранного на основе разработанного критерия оптимальности (21), минимальное значение функция $\tilde{H}_j^{FFT(1)}(l)$ (Рисунок 20, а) также принимает во втором временном окне и указывает на наличие некоторой неравномерности структуры одномерной ЭЭГ в данном временном окне. Важным фактом свидетельствующим о применимости критерия оптимальности $h_j(f_i)$ является положение максимумов для $\tilde{H}_j^{FFT(2)}(l)$ (Рисунок 20, б) и $\tilde{H}_j^{(2)}(l)$ (Рисунок 20, в) в первом временном окне для одномерной ЭЭГ.

Необходимо отметить, что минимальное значение достигается даже для паттерна, имеющего низкую интенсивность близкую к интенсивности фоновых осцилляций исследуемой системы, что в свою очередь говорит о повышении чувствительности функции спектральной энтропии.

Однако в случае применения спектральной энтропии $\tilde{H}_j^{FFT}(l)$ в локальном диапазоне частот, полученном для одномерной ЭЭГ $\{z_k^{(2)}\}_{k=1}^K$ с паттерном имеющим низкую амплитуду $A=13$, функция максимальное значение функции $\tilde{H}_j^{FFT(3)}(l)$ имеет менее явный вид, и в ряде случаев может быть лишь локальным экстремумом для функции спектральной энтропии. Следовательно, необходимо разработать критерии оптимальности, которые позволят увеличить чувствительность функции спектральной энтропии.

На первом этапе предложенной методики частотно-временной локализации паттернов в составе многомерных временных рядов производится выбор локального диапазона частот.

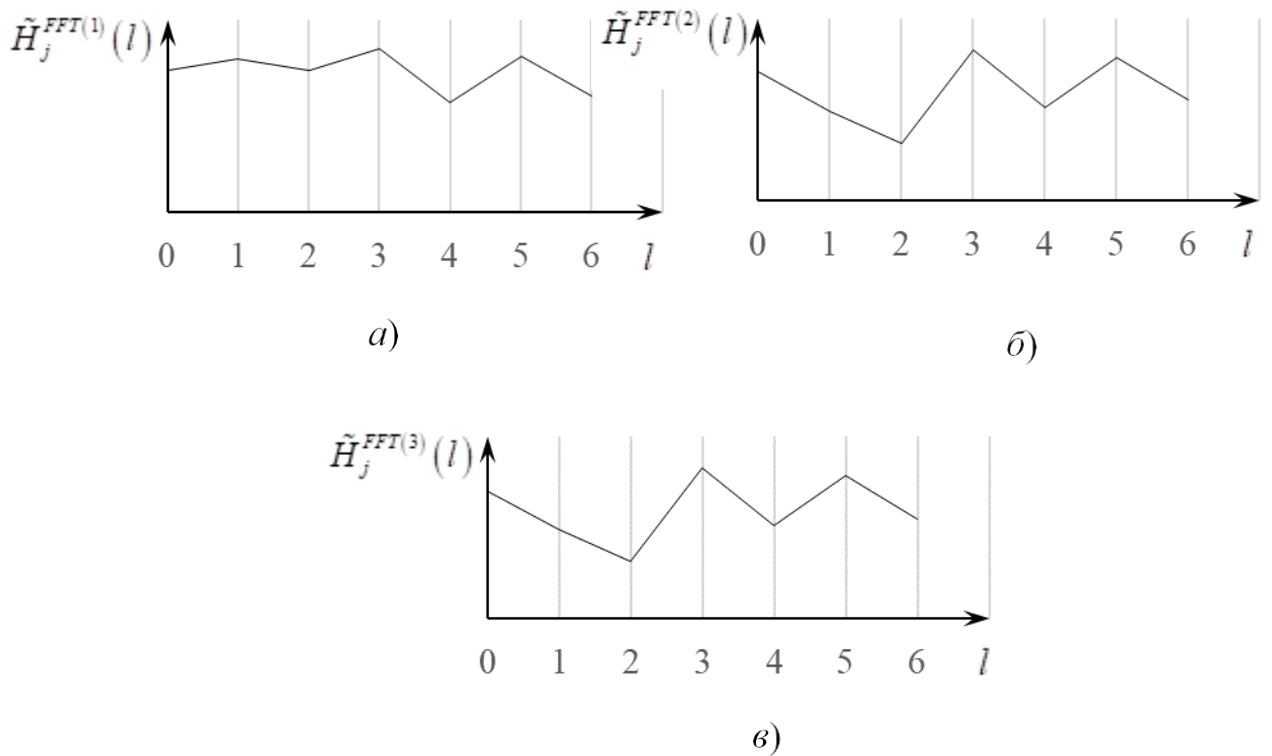


Рисунок 20 – Результаты вычисления функции спектральной энтропии $\tilde{H}_j^{FFT}(l)$ для одномерных ЭЭГ $\{z_k^{(1)}\}_{k=1}^K$ (а), $\{z_k^{(2)}\}_{k=1}^K$ (б), $\{z_k^{(3)}\}_{k=1}^K$ (в) после применения функции выбора локального диапазона частот $h_j(f_i)$

Согласно результатам вычисления критерия оптимальности $\tilde{h}^{FFT}(f_i)$ локальным частотным диапазоном для $\{\bar{z}_k^{(2)}\}_{k=1}^K$ (Рисунок 21, б) и $\{\bar{z}_k^{(3)}\}_{k=1}^K$ (Рисунок 21, в) выступает отрезок в 100-120 Гц, в отличие от локального частотного диапазона для многомерного временного ряда $\{\bar{z}_k^{(1)}\}_{k=1}^K$ (Рисунок 21, а), который составляет 120-130 Гц. Данный факт говорит о том, что критериальная функция частотной локализации структурных особенностей для многомерных временных рядов имеет ту же чувствительность, что и в одномерном случае, но при этом позволяет учитывать избыточность информации, связанной с получением данных из нескольких источников.




Рисунок 21 – Результаты вычисления критерия выбора локального диапазона

$\tilde{h}^{FFT}(f_i)$ для многомерных ЭЭГ $\{\bar{Z}_k^{(1)}\}_{k=1}^K$ (а), $\{\bar{Z}_k^{(2)}\}_{k=1}^K$ (б), $\{\bar{Z}_k^{(3)}\}_{k=1}^K$ (в)

Вторым и заключительным этапом частотно-временной локализации паттернов является поиск положения искомого паттерна на временной оси с помощью функции $\hat{H}^{FFT}(l)$ (Рисунок 22).

Анализ результатов вычисления функции спектральной энтропии $\hat{H}^{FFT}(l)$ для многомерных временных рядов после применения функции выбора локального диапазона частот $\tilde{h}^{FFT}(f_i)$, показывает, что минимальное значение спектральная энтропия принимает в первом и втором временных окнах для временных рядов $\{\bar{Z}_k^{(2)}\}_{k=1}^K$ (Рисунок 22, б) и $\{\bar{Z}_k^{(3)}\}_{k=1}^K$ (Рисунок 22, в), что соответствует положению паттерна на оси времени. Для временного ряда $\{\bar{Z}_k^{(1)}\}_{k=1}^K$ минимальное значение функции спектральной энтропии достигается в шестом временном окне. Важным

фактом, свидетельствующим о повышении чувствительности в многомерном случае, является более явное положение максимума функции $\hat{H}^{FFT(2)}(l)$.

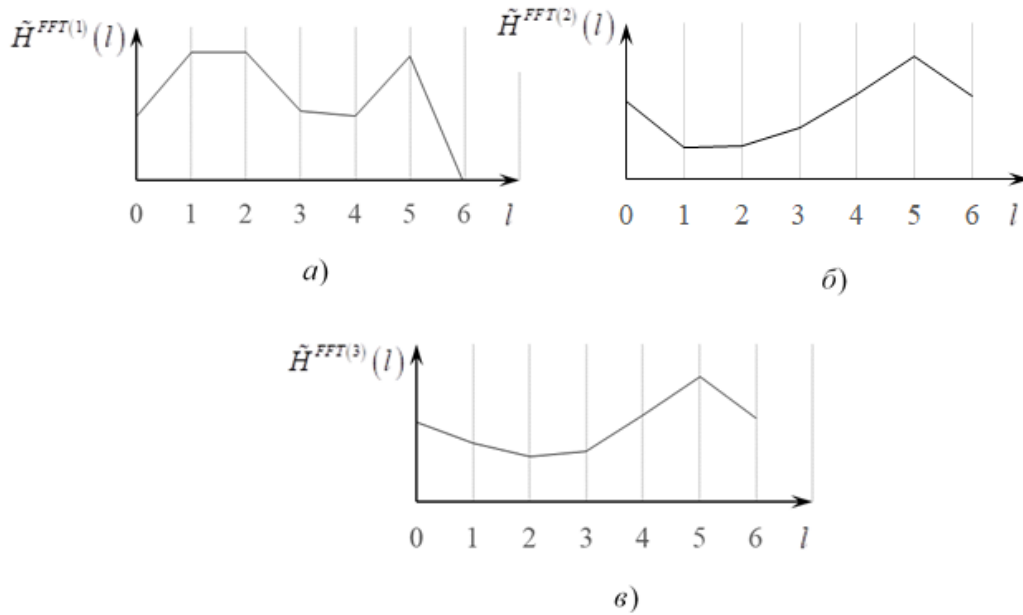


Рисунок 22 – Результаты вычисления функции спектральной энтропии $\hat{H}^{FFT}(l)$ для временных рядов $\{\bar{Z}_k^{(1)}\}_{k=1}^K$ (а), $\{\bar{Z}_k^{(2)}\}_{k=1}^K$ (б), $\{\bar{Z}_k^{(3)}\}_{k=1}^K$ (в) после применения функции выбора локального диапазона частот $\tilde{h}^{FFT}(f_i)$

Преимуществами использования многомерной реализации методики частотно-временной локализации паттернов в составе зашумленных многомерных временных рядов является повышение чувствительности критериальных функций за счет избыточности информации.

Однако основным недостатком является использования быстрого преобразования Фурье в качестве ядра для вычисления функции спектральной энтропии. Это обусловлено тем, что, во-первых, преобразование Фурье не имеет временного представления исследуемого ряда, во-вторых, базисная функции преобразования Фурье не имеет компактного носителя. И в-третьих, эффект, «размытия» спектра и граничные эффекты, не позволяющие качественно производить анализ нестационарных временных рядов.

Таким образом, алгоритм реализующий разработанный метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса показал высокую точность по сравнению с традиционными методами на модельных данных.

3.5. Выводы к третьей главе

В рамках третьей главы диссертационной работы дано описание алгоритмам, реализующим метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса. Также проведено исследование точности разработанного метода и сравнения с традиционными методами с использованием смоделированных сложных паттернов раной интенсивности, аддитивно добавленных в зашумленный сигнал.

Результаты моделирования показали высокую точность разработанного метода даже в условиях, когда интенсивность модельного паттерна близка к интенсивности шумов и фоновой активности системы.

Разработанный метод, критериальные функции и алгоритмы требуют дальнейшей экспериментальной апробации в задаче реализации нейрокомпьютерного интерфейса.

Глава 4. Экспериментальная апробация

4.1. Апробация к задаче поиска двигательных паттернов электроэнцефалограммы человека

Для подтверждения работоспособности разработанных критериев оптимальности, в первую очередь выполнены экспериментальные исследования по поиску двигательных паттернов в составе ЭЭГ человека. В качестве исходных данных были использованы нативные записи ЭЭГ добровольцев.

В обследованиях приняли участие 24 здоровых добровольца (16 мужчин и 8 женщин), средний возраст которых составил 21.5 года. В соответствии с этическими нормами, утвержденными комитетом по этике Южного федерального университета, все они подписывали протокол о добровольном согласии на участие в исследовании. В рамках экспериментальной сессии испытуемые в произвольном темпе выполняли реальные движения правой и левой рукой. Движения рукой чередовались с состоянием покоя, когда испытуемый находился некоторое время с открытыми глазами без движений. Движения рукой выполнялись с интервалом 5..10 с, по 70 циклов для каждого испытуемого. На рисунке 23 показан фрагмент временной диаграммы экспериментальной сессии для одного добровольца. Таким образом всего подлежали исследованию $24 \times 70 = 1680$ временных выборок мысленной подготовки к движению правой рукой.



Рисунок 23 – Временная диаграмма экспериментальной сессии одного добровольца при предъявлении двигательной активности

Регистрацию ЭЭГ $\bar{X}(t)$ осуществляли относительно ушных референтных электродов (референт объединенный) с использованием электроэнцефалографа “Энцефалан-131–03” (“Медиком МТД”, г. Таганрог) от $J=17$ стандартных сенсоров (отведений) (F7, F8, F3, Fz, F4, C3, Cz, C4, P3, Pz, P4, O1, O2, T3, T4, T5, T6) в соответствии с международной системой “10–20”. Частота дискретизации ЭЭГ составляла 250 Гц по каждому из каналов. За счет режекторного фильтра были удалены первая и вторая гармоники питающей сети 50 и 100 Гц.

Параллельно в области поверхностных мышц, сгибающих предплечье в локтевом суставе (*m. brachioradialis*) и поверхностных сгибателей пальцев (*m. flexor digitorum superficialis*) записывалась электромиограмма (ЭМГ). Таким образом, начальный момент времени реального движения рукой t_k достаточно точно регистрировали по ЭМГ.

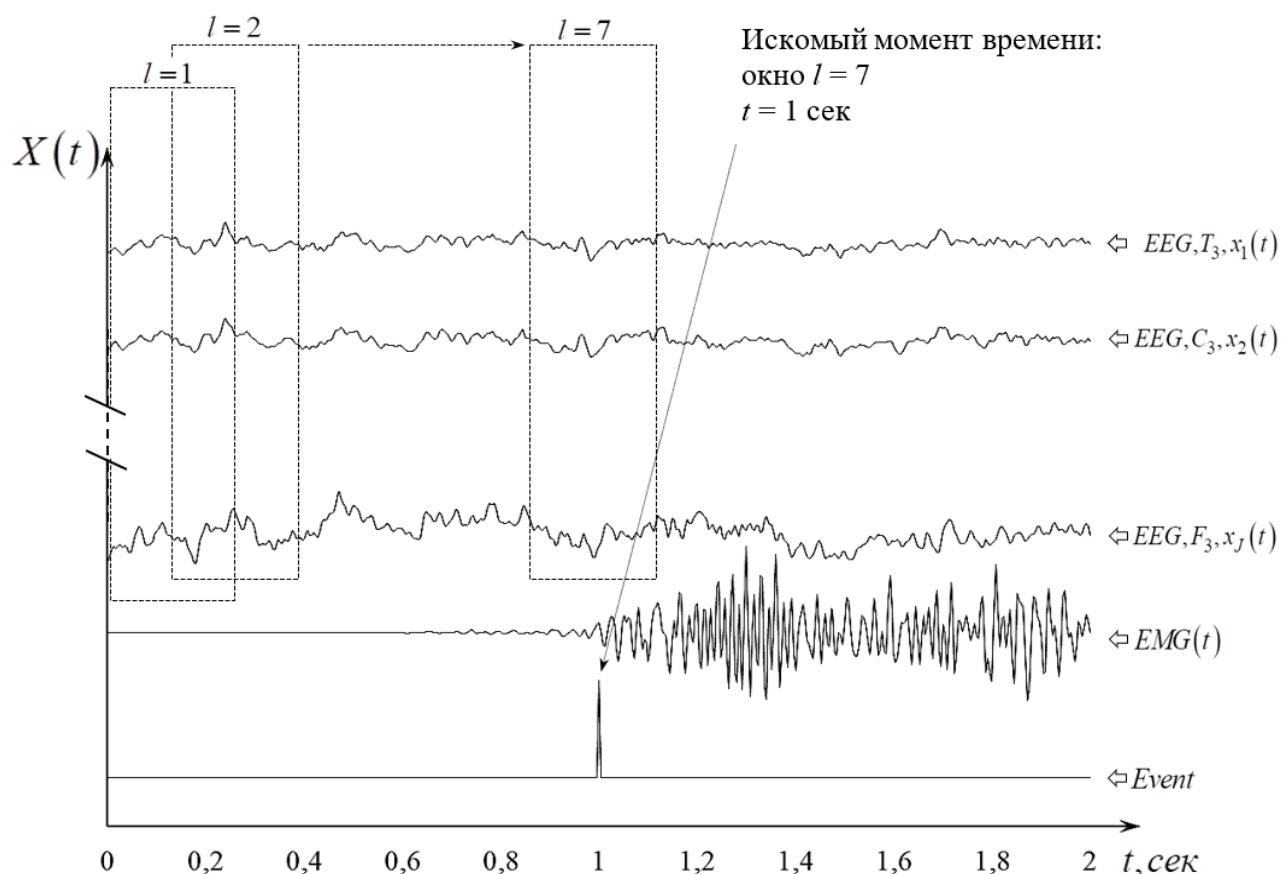


Рисунок 24 – Пример записанной исходной ЭЭГ и канал ЭМГ для поиска двигательных паттернов

Для обнаружения и последующей автоматической фильтрации артефактов, связанных с движением глаз и морганием, регистрировалась электроокулограмма (горизонтальная и вертикальная). На рисунке 24 представлен пример записанной исходной ЭЭГ и канал ЭМГ для поиска двигательных паттернов.

Требовалось произвести поиск двигательных паттернов в составе ЭЭГ с использованием разработанных критериев оптимальности, методов и алгоритмов. Перед применением разработанных методов производилась проверка каждой экспериментальной сессии на стационарность. А именно, каждый одномерный ряд ЭЭГ $\{x_{k,j}\}_{k=1}^N \in \{X_k\}_{k=1}^N$ прошел проверку тестом Дики-Фуллера на стационарность с вероятностью 0,95.

Важным замечанием является то, что данными, подаваемыми на входные узлы алгоритма, выступают только нативные записи ЭЭГ. ЭМГ же в свою очередь использовалась для проверки правильности обнаружения двигательной активности на оси времени.

Для апробации на реальных экспериментальных данных, в первую очередь вычислялся критерий оптимального выбора диапазона частот $h^{FFT}(f)$ (Рисунок 25, а) и критерий оптимального выбора диапазона масштабов $h^{CWT}(a_i)$ (Рисунок 25, б).

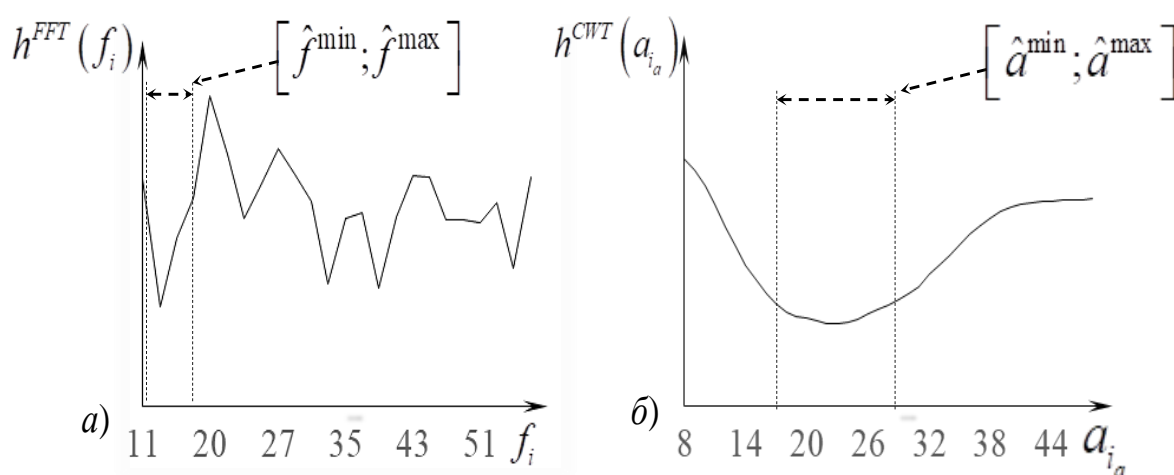


Рисунок 25 – Критерии оптимальности выбора частотного диапазона $h^{FFT}(f)$ - а, выбора диапазона масштабов $h^{CWT}(a_i)$ - б

Стоит отметить, что критерии оптимальности $h^{FFT}(f)$ (Рисунок 25, а) и $h^{CWT}(a_i)$ (Рисунок 25, б). вычисляются в скользящем временном окне размером 64 отсчетов без перекрытия.

Согласно результатам вычисления критериев оптимальности $h^{FFT}(f)$ и $h^{CWT}(a_i)$, были выбраны следующие диапазоны:

- локальный диапазон частот $f \in [11, 18]$ Гц, для вычисления функции $\tilde{H}^{FFT}(l)$;
- локальный диапазон масштабов $a_i \in [16, 28]$ для вычисления функции $\tilde{H}^{CWT}(l)$.

Функции $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$, в свою очередь, вычисляются традиционно в расширенном диапазоне частот, покрывающем основную интенсивность спектра полезного сигнала. Таким образом, для функций $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$ выбраны следующие диапазоны:

- расширенный диапазон частот $f \in [10, 50]$ Гц, для вычисления функции $H^{FFT}(l)$;
- все уровни декомпозиции, для вычисления функции $H^{DWT}(l)$;
- расширенный диапазон масштабов $a_i \in [8, 44]$ для вычисления функции $H^{CWT}(l)$.

Следующим этапом экспериментальной апробации является непосредственное вычисление функций $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$, $\tilde{H}^{FFT}(l)$, $\tilde{H}^{CWT}(l)$. Помимо этого, необходимо сопоставить положение минимумов критериев оптимальности с данными, отражающими наличие двигательной активности. Двигательная активность отображается на ЭМГ в виде осцилляций высокой интенсивности (по сравнению с фоновой активностью). Результаты вычисления критериев оптимальности, а также временной ряд ЭМГ представлены на рисунке 26.

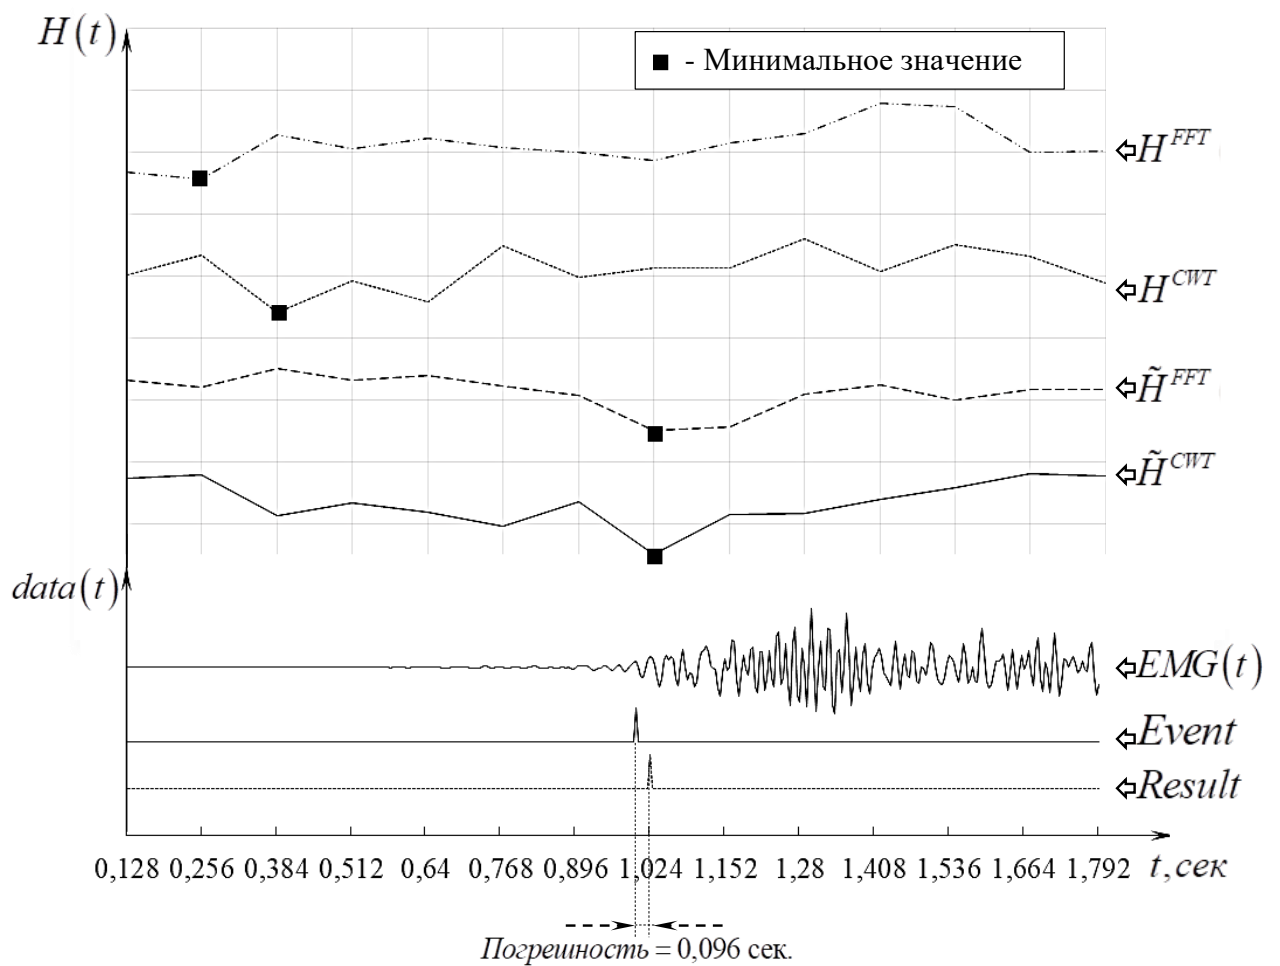


Рисунок 26 – Пример определения временной границы окончания префронтального ЭЭГ-паттерна в одной сессии

Временные диапазоны окон и номера временных окон представлены в таблице 2.

Таблица 2. Соответствие номеров временных окон и границ окон для поиска паттернов двигательной активности

Номер временного окна	Начальная граница окна	Конечная граница окна
0	0	256
1	128	384

2	256	512
3	384	640
4	512	768
5	640	896
6	768	1024
7	896	1152
8	1024	1280
9	1152	1408
10	1280	1536
11	1408	1664
12	1536	1792
13	1664	1920
14	1792	2048
15	1920	2176
16	2048	2304
17	2176	2432

Согласно таблице 2 и графику ЭМГ $EMG(k)$ (Рисунок 26, а) искомый двигательный ЭЭГ-паттерн перехода из состояния «Покой» к состоянию «Двигательная активность» имеет наибольшую интенсивность в $l=7$ временном окне.

Из графиков видно, что характер критериальных функций позволяет найти локальные диапазоны частот (Рисунок 26, а) или масштабов базисной вейвлет-функции (Рисунок 26, б), максимально соответствующие спектральным характеристикам искомого паттерна.

На рисунке 31 показан пример сравнения эффективности определения временной границы окончания премоторного паттерна биоэлектрической активности (событие *Event* на Рисунке 26) в одной сессии одного добровольца для традиционных подходов и для разработанного метода. Традиционный метод на основе расчета спектральной энтропии $H^{FFT}(l)$ без определения локального диапазона частот $[\hat{f}_i^{\min}; \hat{f}_i^{\max}]$, максимально соответствующего спектральным

характеристикам искомого паттерна, не позволяет корректно найти границу окончания премоторного ЭЭГ-паттерна (см. рисунок 26). Подобная ошибка характерна и при применении традиционного метода на основе расчета вейвлет-энтропии НВП $H^{CWT}(l)$. При этом по характеру функций $\tilde{H}^{FFT}(l)$ и $\tilde{H}^{CWT}(l)$ видно, что использование разработанного метода в обоих случаях – и для НВП, и для преобразования Фурье, позволяет корректно определить временную границу окончания премоторного паттерна. Так, при использовании НВП с высоким разрешением перехода в частотно-временное представление погрешность определения границы (событие *Result* на рисунке 26) в сравнении с меткой ЭМГ ($EMG(t)$ на рисунке 26), отражающей действительную временную границу окончания премоторного паттерна, составляла 96 мс. При использовании преобразования Фурье эта погрешность была равна 128 мс.

Статистический анализ результатов определения этой временной границы премоторного ЭЭГ-паттерна для всех сессий всех добровольцев для более, чем 1500 движений обеими руками показал, что наименьшей дисперсией и наибольшей точностью $100(+90/-56)$ мс с выбросами до +250 мс обладает разработанный метод на основе вейвлет-энтропии НВП («Мод. НВП Энтр.» на рисунке 27).

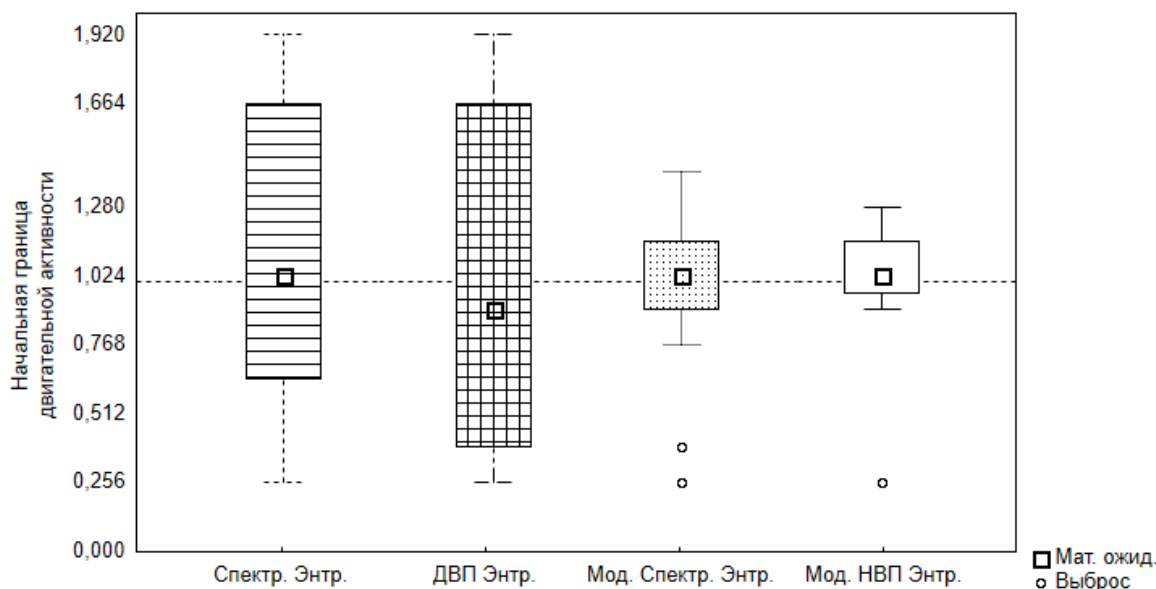


Рисунок 27 – Результаты статистического анализа определения временной границы премоторного ЭЭГ-паттерна для более, чем 1500 реализаций

На заключительном этапе экспериментальных исследований была выполнена оценка точности определения границ премоторных паттернов, посредством разработанного метода в задаче классификации типов премоторных паттернов, решение которой позволит повысить точность работы нейроинтерфейса.

Классифицировались два целевых состояния, а именно, «Покой» и «Подготовка к выполнению движения» (премоторный паттерн). Класс «Покой» во всех случаях представлял собой фрагменты экспериментальных записей ЭЭГ фоновой активности головного мозга человека в состоянии покоя. Класс «Подготовка к выполнению движения» представлял собой экспериментальные записи ЭЭГ, содержащие отрезки специфических премоторных ЭЭГ-паттернов, границы которых найдены посредством традиционного метода и разработанного метода. Всего было сформировано четыре набора данных для алгоритмов машинного обучения, которые отличались только методом определения границ премоторных паттернов, соответствующих классу «Подготовка к выполнению движения».

Для решения задачи классификации ЭЭГ-паттернов были применены стандартные модели на основе опорных векторов (SVM), градиентного бустинга деревьев принятия решений (GBDT), случайного леса (Random forest) и регуляризованных линейных моделей с обучением стохастическим градиентным спуском (SGD) библиотеки Python.Scikit-learn.

Точность бинарной классификации классов «Покой» и «Подготовка к выполнению движения» для традиционного метода на основе традиционного метода на основе НВП и спектральной энтропии составила 72,3% и 68,6%, соответственно. Для разработанного метода на основе НВП и его вариации с использованием трансформант Фурье точность составила 98,6% и 96,6%, соответственно.

4.2. Апробация к задаче поиска вербальных речевых паттернов электроэнцефалограммы человека

Для подтверждения работоспособности и универсальности разработанных критериев оптимальности и методик была проведена экспериментальная апробация для поиска паттернов речевой активности человека в составе временных рядов ЭЭГ. В качестве исходных данных были использованы нативные записи ЭЭГ добровольцев.

В исследовании приняли участие 10 здоровых мужчин-добровольцев, средний возраст которых составил $24,8 \pm 0,4$ года). Участники исследований не имели опыта участия в психофизиологический обследований, преобладающая рука - правая. Все испытуемые предоставили письменное согласие на участие в данном эксперименте. Эксперимент проводился в соответствии с рекомендациями комиссии по биоэтики Южного федерального университета, разработанной на основе Хельсинской декларации.

Для проведения эксперимента обследуемому было предложено расположиться в специальной камере, которая изолирована от света и звука и занять удобную позу. Напротив испытуемого на расстоянии 1 м располагался экран монитора и в условиях сниженной освещенности на экране монитора демонстрировалось стилизованное изображение циферблата часов с бегущей стрелкой. Минимальное смещение «стрелки» по циферблату, соответствующее одному делению, было эквивалентно одной секунде. Изображение имело размер 7 угловых градусов и предьявлялось на фоне серого экрана монитора. По центру циферблата появлялось слово, которое испытуемый должен был произнести вслух в моменты совмещения секундой стрелки с меткой. Время покоя перед произнесением слова составляло 1 секунду, на произнесение слова также давалась 1 секунда, после произнесения слова испытуемый находился в состоянии покоя 1.8 секунд. В соответствии с инструкцией участия в эксперименте произносить слова

необходимо было в обычном для него темпе и обычным голосом. Испытуемый не должен был отвлекаться или пропускать метки. Всего использовалось шесть слов, соответствующих названиям направлений в пространстве: вверх, вниз, вправо, влево, вперед, назад. Каждое слово предъявлялось 3 раза в случайном порядке. Временная диаграмма одной экспериментальной сессии представлена на рисунке 28.



Рисунок 28 – Временная диаграмма экспериментальной сессии одного добровольца при предъявлении речевой активности

Параллельно в ходе эксперимента использовался анализатор речи «Speech Analyzer» (version 3.0.1. 1996-2007 SIL International / All Rights Reserved) в моно режиме (частота дискретизации 22500 Гц, квантование 16 bit) для регистрации монограммы при помощи динамического микрофона с полосой АЧХ в пределах диапазона речевых частот (80–12000 Гц) и чувствительностью 2,24 мВ/Па. Микрофон был размещен на расстоянии 10 см от лица испытуемого. В дальнейшем фонограммы фрагментировались на синтаксически значимые участки, соответствующие произнесению слов, с использованием звукового редактора Sound Forge 7.0 и функции Insert Region.

Перед началом эксперимента проводился обучающий сеанс без регистрации ЭЭГ. Это позволяло подготовить обследуемых к условиям эксперимента и установить уровень записи их голосов.

Регистрация ЭЭГ $\bar{X}(k)$ (Рисунок 29) в течении основной проводилась непрерывно как в состоянии произношения так и в состоянии покоя, монополярно

от 14 сенсоров (отведений) ((F7, F8, F3, Fz, F4, C3, Cz, C4, P3, Pz, P4, O1, O2, T3, T4, T5, T6), в соответствии с международной системой 10x20, с использованием электроэнцефалографа “ЭНЦЕФАЛАН 131” производства “МЕДИКОМ-МТД” (Россия, г. Таганрог). Регистрировалась активность практически всех неокортикальных структур, которые, согласно имеющимся сведениям, участвуют в реализации различных аспектов речи. Референтные электроды (референт объединенный) располагались на мочках ушей. Частота дискретизации ЭЭГ составляла 250 Гц по каждому каналу регистрации. Перед применением разработанных методов производилась проверка каждой экспериментальной сессии на стационарность. А именно, каждый одномерный ряд ЭЭГ $\{x_{k,j}\}_{k=1}^N \in \{X_k\}_{k=1}^N$ прошел проверку тестом Дики-Фуллера на стационарность с 5% значимостью.




Рисунок 29 – Пример записанной исходной ЭЭГ и канал ЭМГ для поиска паттернов речевой активности

Для обнаружения мышечных артефактов в ЭЭГ проводилась регистрация миограммы мышц гортани. Для чего были использованы одноразовые

миографические электроды на клеевой основе, которые фиксировались на гортани справа и слева от средней линии в области голосовых связок. Регистрация велась с использованием биполярного электрода (сенсора, отведения) на полиграфическом блоке электроэнцефалографа.

В ходе экспериментальной апробации разработанных критериев и методик, по аналогии с поиском двигательных паттернов, необходимо было произвести поиск паттернов речевой активности. Стоит отметить, что также входными данными выступала только ЭЭГ человека. А ЭМГ использовалась для оценки положения паттерна на оси времени и оценки правильности обнаружения критериями.

В первую очередь необходимо вычислить критерии оптимальности $h^{FFT}(f)$ и $h^{CWT}(a_i)$ в скользящем окне размером 250 отсчетов (1 секунда) без перекрытия, результаты вычисления критериев представлены рисунке 30.

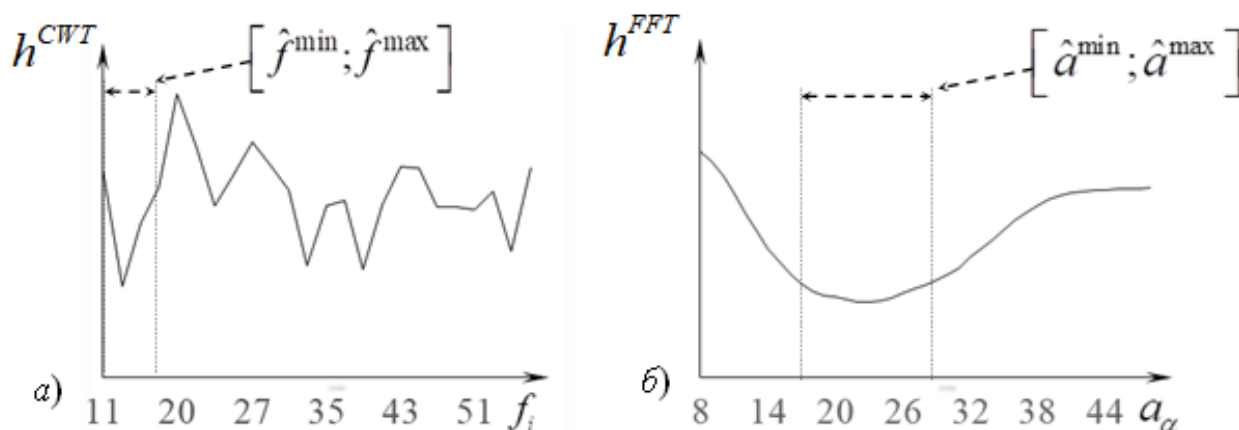


Рисунок 30 – Примеры критериальных функций $h^{FFT}(f_i)$ (а) и $h^{CWT}(a_\alpha)$ (б) разработанных критериев оптимальности

Согласно результатам вычисления критериев оптимальности $h^{FFT}(f)$ (Рисунок 30, а) и $h^{CWT}(a_i)$ (Рисунок 30, б), были выбраны следующие диапазоны:

- локальный диапазон частот $f \in [38, 52]$ Гц, для вычисления функции $\tilde{H}^{FFT}(l)$;
- локальный диапазон масштабов $a_i \in [16, 30]$ для вычисления функции $\tilde{H}^{CWT}(l)$.

Функции $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$, в свою очередь, вычисляются традиционно в расширенном диапазоне частот, покрывающем основную интенсивность спектра полезного сигнала. Таким образом, для функций $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$ выбраны следующие диапазоны:

- расширенный диапазон частот $f \in [10, 50]$ Гц, для вычисления функции $H^{FFT}(l)$;
- все уровни декомпозиции, для вычисления функции $H^{DWT}(l)$;
- расширенный диапазон масштабов $a_i \in [8, 44]$ для вычисления функции $H^{CWT}(l)$.

Следующим этапом экспериментальной апробации является непосредственное вычисление функций $H^{FFT}(l)$, $H^{DWT}(l)$, $H^{CWT}(l)$, $\tilde{H}^{FFT}(l)$, $\tilde{H}^{CWT}(l)$. Помимо этого, необходимо сопоставить положение минимумов критериев с ЭМГ, которая отражает наличие речевой деятельности.

По причине того, что речевая активность была записана с использованием миографических электродов в области гортани, паттерны активности отображаются на ЭМГ в виде осцилляций высокой интенсивности (по сравнению с фоновой активностью).

Результаты вычисления критериев оптимальности, а также временной ряд ЭМГ представлены на рисунке 31.




Рисунок 31 – Пример определения временной границы окончания речевого ЭЭГ-паттерна в одной сессии

Временные диапазоны временных окон и номера временных окон представлены в таблице 3.

Таблица 3. Соответствие номеров временных окон и границ окон для поиска паттернов речевой активности

Номер временного окна	Начальная граница окна	Конечная граница окна
0	0	256
1	128	384
2	256	512
3	384	640

4	512	768
5	640	896
6	768	1024
7	896	1152
8	1024	1280
9	1152	1408
10	1280	1536
11	1408	1664

Согласно таблице 3 и графику ЭМГ $EMG(k)$ (Рисунок 31) искомый паттерн располагается в пределах 5-го и 6-го временных окон. Таким образом, показателем успешности найденных паттернов будет являться минимальное значение критериев оптимальности во временных окнах 5 и 6.

Результат вычисления функции $H^{FFT}(l)$ (Рисунок 31) при сопоставлении с моментом начала речевой активности по $EMG(k)$ (Рисунок 31), говорит о том, что функция принимает минимальное значение во временном окне 0, которое не соответствует положению паттерна на временной оси. Аналогичные результаты также получены для критериев $H^{DWT}(l)$ (Рисунок 31) и $H^{CWT}(l)$ (Рисунок 31). При этом данные функции имеют локальные минимумы в 5-м временном окне, однако глобальный минимум достигается во временных окнах 9 и 0, соответственно.

Критерий $\tilde{H}^{FFT}(l)$ (Рисунок 31), вычисляемый в диапазоне частот $f \in [38, 52]$, полученных с помощью функции $h^{FFT}(f)$ (Рисунок 30), принимает минимальное значение в 5-м временном окне, что соответствует положению паттерна на временной оси.

Аналогичный результат был получен для критерия $\tilde{H}^{CWT}(l)$ (Рисунок 31), вычисляемой в пределах масштабов $a_i \in [8, 44]$, полученных с помощью функции $h^{CWT}(a_i)$ (Рисунок 30). Однако в данном случае минимум функция принимает в 5 и

6-м временных окнах, что в свою очередь подтверждает факт повышения точности за счет избыточности НВП.

С целью проверки корректности разработанного метода частотно-временной локализации ЭЭГ-паттернов и детектированных временных границ ЭЭГ-паттернов, были применены стандартные средства машинного обучения, при помощи которых решалась задача бинарной дискретной классификации двух целевых состояний, а именно, «Покой» и «Речевая активность». На первом этапе вычислительных экспериментов набор исходных данных для класса «Речевая активность» содержал одинаковые по длительности эпохи анализа ЭЭГ на интервалах $T=t_k-t_0=500$ мс, соответствующих меткам фактической инициализации речевой активности t_k .

К классу «Покой» на обоих этапах вычислений относили выборки эпох ЭЭГ длительностью по 500 мс каждая, отбираемых произвольным образом в каждом цикле экспериментальной серии в интервалах, соответствовавших состоянию оперативного покоя. Таким образом, совокупная выборка экспериментальных данных для класса «Покой» также содержала 1680 единичных примеров.

Для решения задачи классификации специфических электрографических ЭЭГ-паттернов ЭЭГ речевой активности были применены модели на основе опорных векторов (SVM), градиентного бустинга деревьев принятия решений (GBDT), случайного леса деревьев (Random forest) и регуляризованных линейных моделей с обучением стохастическим градиентным спуском (SGD) стандартной библиотеки Python.Scikit-learn. Выбор наилучших параметров указанных моделей, а также наилучшей модели классификации был осуществлён на первом этапе вычислений. В совокупности было рассчитано и синтезировано около 300 опорных признаков разных типов – временных, частотных и частотно-временных, а также пространственных. Дополнительно выполнялась стандартизация каждого выделенного признака в наборе данных путем удаления среднего значения и масштабирования его до единичной дисперсии. Выбранные модели классификации

обладали достаточной обобщающей способностью, что исключало возможность их недообучения или переобучения. Наилучшей по эффективности среди обученных методов оказалась модель классификации градиентного бустинга деревьев (GBDT), а к наиболее важным опорным признакам относились попарные корреляции между фронтальными, центральными, теменно-затылочными отведениями ЭЭГ, рассчитанными для трансформант дискретного вейвлет-преобразования, а также коэффициенты моделей регрессии первого порядка. При этом различия по средней точности классификации целевых премоторных паттернов ЭЭГ в зависимости от вида модели не превышали 5%.

Максимальная точность бинарной классификации в ходе кросс-валидации на первом этапе, ожидаемо, была невысокой и составила всего 45%. Наблюдались также существенные вариации точности классификации – от 30% до 45% у разных обследуемых. Межиндивидуальные различия, как известно, вносят существенный вклад при оценке оптимальных для задачи классификации подмножеств ЭЭГ-каналов, которые, обычно, существенно различаются. Фактически, низкая средняя точность классификации в генеральной совокупности, наблюдаемая на первом этапе вычислений, объясняется, по всей видимости, тем, что в составе эпох анализа $T=500$ мс класса «Речевая активность», помимо искомым ЭЭГ-паттернов, присутствовали также и иные электрографические паттерны, не связанные с реализацией текущей задачи.

На втором этапе вычислительных экспериментов эпохи анализа для класса событий «Речевая активность» были пересчитаны в связи с изменением временных границ, которые соответствовали строго границам паттернов ЭЭГ $[t_{0,p}; t_{k,p}]$. При этом выборка экспериментальных данных класса «Покой» осталась прежней. В ходе валидационной проверки модель классификации GBDT с аналогичными параметрами, что и на первом этапе вычислительных исследований, была заново обучена, а в ходе кросс-валидации проверена её точность. На втором этапе точность бинарной классификации повысилась в рамках анализа электрограмм

всех без исключения 24 обследуемых, в среднем, на величину, равную 35%. При этом, максимальная наблюдаемая точность классификации, рассчитанная отдельно для каждого обследуемого, в ряде случаев, повысилась с 45 до 80%.

4.3. Выводы к четвертой главе

В четвертой главе диссертационной работы для разработанных методов и критериев оптимальности приведены экспериментальные исследования, направленные на решение задачи частотно-временной локализации специфических априорно неопределенных ЭЭГ-паттернов при формировании нейроинтерфейсов.

Полученные результаты окончательно подтвердили высокую точность и чувствительность разработанных критериев оптимальности и метода в целом.

Сформированные, при помощи разработанного метода, выборки бинарной дискретной классификации, являются репрезентативными и, соответственно, подтвердили корректность разработанного метода частотно-временной локализации ЭЭГ-паттернов и выполненного алгоритмического и программного обеспечения.

Подтверждена точность разработанного метода частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса и приведено сравнение с традиционными методами. Таким образом, получено подтверждение того, что разработанный метод позволяет повысить эффективность нейроинтерфейсов за счет повышения точности идентификации команд управления.

ЗАКЛЮЧЕНИЕ

В результате проведенных исследований разработан метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса, позволяющий повысить точность классификации команд нейроуправления для нейрокомпьютерного интерфейса на основе решения задачи определения частотных и временных границ. Согласно результатам проведенных экспериментальных исследований, применение разработанного метода, критериев и алгоритмов позволяет повысить точность классификации команд нейроуправления в составе многомерных сигналов ЭЭГ в ИМК. Отличительной особенностью разработанного метода, критериев и алгоритмов является их высокая точность в условиях отсутствия априорной информации о частотных характеристиках искомым паттернов, а также в условиях маскирования паттернов шумами различного происхождения.

В результате проведенных исследований, в диссертационной работе получены следующие основные результаты:

1) предложенный в работе новый метод частотно-временной локализации ЭЭГ-паттернов биоэлектрической активности мозга человека отличается от традиционных методов тем, что обладает свойством робастности к априорно неизвестной вариативности текущего функционального состояния человека и к типу подготавливаемого человеком движения – реальному или мысленному, произвольному или баллистическому (пункт 4 паспорта специальности 2.3.1. Системный анализ, управление и обработка информации, статистика);

2) предложенные новые критерии оптимального поиска границ локального частотного диапазона, максимально соответствующего частотному диапазону искомого паттерна биоэлектрической активности мозга человека, отличаются тем, что применимы в условиях его маскирования шумами с близкими или частично совпадающими энергетическими спектрами (пункт 3 паспорта

специальности 2.3.1. Системный анализ, управление и обработка информации, статистика);

3) разработанное алгоритмическое и программное обеспечение для нейрокомпьютерного интерфейса реализует синтезированный метод (пункт 5 паспорта специальности 2.3.1. Системный анализ, управление и обработка информации, статистика);

4) полученные результаты экспериментальной апробации разработанного метода частотно-временной локализации априорно неопределенных паттернов в составе сигналов ЭЭГ подтвердили возможность повышения точности классификации команд нейроуправления в ИМК;

5) результаты работы были использованы для разработки нейроинтерфейсов в рамках выполнения научно-исследовательских работ: по гранту Российского Научного Фонда N20-19-00627 на тему "Разработка стимул-независимой модели интерфейса "Мозг-компьютер" для реабилитации людей с ограниченными возможностями", 2020-2022 г.; по проекту в интересах развития кооперации российских высших учебных заведений и организаций, реализующих комплексные проекты по созданию высокотехнологичного производства, на тему "Создание программного комплекса для управления человеческим капиталом на основе нейротехнологий для предприятий высокотехнологического сектора Российской Федерации", Постановление Правительства РФ N218.

Наиболее значимым и ценным результатом проведённого исследования является применение разработанного метода и детальное определение временных границ паттернов ЭЭГ. Новый метод позволил повысить вычислительную способность и точность моделей классификации.

Наряду с этим, полученные результаты позволяют утверждать, что разработанный метод частотно-временной локализации ЭЭГ-паттернов способен эффективно и надёжно определять временные границы переходов функционального состояния мозговых структур из холостого хода («Idle activity»

или «Default mode») к реализации актуальной задачи. Указанные переходы между состояниями являются важными событиями для принятия решения о наличии целевого паттерна ЭЭГ, потенциально пригодного для управления в контуре системы «Мозг-компьютер» или «Мозг-Мозг».

Полученные результаты могут быть применены в задачах частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса.

В перспективе дальнейшей разработки темы исследования может предполагаться модификация метода посредством автоматизации выбора частотного диапазона, за счет введения дополнительных критериев. Синтезированные с помощью метода системы, могут стать более эффективными в части повышения точности работы нейрокомпьютерного интерфейса на основе решения задачи поиска границ по оси времени паттернов в составе многомерной ЭЭГ биоэлектрической активности мозга человека.

СПИСОК СОКРАЩЕНИЙ И УСЛОВНЫХ ОБОЗНАЧЕНИЙ

БПФ – Быстрое преобразование Фурье

ДВП – Дискретное вейвлет-преобразование

ИМК – Интерфейс «мозг-компьютер»

НВП – Непрерывное вейвлет-преобразование

ПФСВО – преобразование Фурье в скользящем (по оси времени) окне

СКО – среднее квадратическое отклонение

СПМ – функция спектральной плотности мощности

ЭЭГ – Электроэнцефалограмма

ЭМГ – Электромиограмма

EMD – Empirical mode decomposition (разложение на эмпирические моды)

ICA – Independent component analysis (метод независимых компонент)

SSA – Singular spectrum analysis (спектральный сингулярный анализ)

СПИСОК ЛИТЕРАТУРЫ

1. Cao L. et al. An Effective Fusing Approach by Combining Connectivity Network Pattern and Temporal-Spatial Analysis for EEG-Based BCI Rehabilitation //IEEE Transactions on Neural Systems and Rehabilitation Engineering. – 2022. – Vol. 30. – P. 2264–2274.
2. Huang Q. et al. NCyborg Project—A new stroke rehabilitation pattern based on brain computer interface //Brain Hemorrhages. – 2021. – Vol. 2. – №. 2. – P. 95–96.
3. Cheng N. et al. Brain-computer interface-based soft robotic glove rehabilitation for stroke //IEEE Transactions on Biomedical Engineering. – 2020. – Vol. 67. – №. 12. – P. 3339–3351.
4. Al-Qazzaz N. K. et al. EEG Signal Complexity Measurements to Enhance BCI-Based Stroke Patients' Rehabilitation //Sensors. – 2023. – Vol. 23. – №. 8. – P. 38–59.
5. Kirilenko N. E. Development of Algorithms to Detect EEG Patterns Specific for Arbitrary Motor Activity of a Human in the BCI Applications //Advances in Neural Computation, Machine Learning, and Cognitive Research V: Selected Papers from the XXIII International Conference on Neuroinformatics, October 18-22, 2021, Moscow, Russia. – Springer Nature, 2021. – Vol. 1008. – P. 7–15.
6. Бодин О. Н., Солодимова Г. А., Спиркин А. Н. Нейроинтерфейс для управления роботизированными устройствами //Измерение. Мониторинг. Управление. Контроль. – 2019. – №. 4 (30). – С. 70–76.
7. Purnamasari P. D., Junika T. W. Frequency-based EEG human concentration detection system methods with SVM classification //2019 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom). – IEEE, 2019. – P. 29–34.
8. Seco G. B. S. et al. EEG alpha rhythm detection on a portable device //Biomedical Signal Processing and Control. – 2019. – Vol. 52. – P. 97–102.

9. Altameem A. et al. Performance Analysis of Machine Learning Algorithms for Classifying Hand Motion-Based EEG Brain Signals //Comput. Syst. Sci. Eng. – 2022. – Vol. 42. – №. 3. – P. 1095–1107.
10. Malviya L., Mal S., Lalwani P. EEG data analysis for stress detection //2021 10th IEEE international conference on communication systems and network technologies (CSNT). – IEEE, 2021. – P. 148-152.
11. Shcherban I. V., Kirilenko N. E. et al. Development of Algorithms to Detect EEG Patterns Specific for Arbitrary Motor Activity of a Human in the BCI Applications //Advances in Neural Computation, Machine Learning, and Cognitive Research V: Selected Papers from the XXIII International Conference on Neuroinformatics, October 18-22, 2021, Moscow, Russia. – Springer International Publishing, 2022. – P. 75–80.
12. Nakanishi M. et al. Facilitating calibration in high-speed BCI spellers via leveraging cross-device shared latent responses //IEEE Transactions on Biomedical Engineering. – 2019. – Vol. 67. – №. 4. – P. 1105–1113.
13. Wang K. et al. Enhance decoding of pre-movement EEG patterns for brain–computer interfaces //Journal of neural engineering. – 2020. – Vol. 17. – №. 1. – P. 16–33.
14. Ruijter B. J. et al. Treating rhythmic and periodic EEG patterns in comatose survivors of cardiac arrest //New England Journal of Medicine. – 2022. – Vol. 386. – №. 8. – P. 724–734.
15. Pastor J., Vega-Zelaya L., Martin Abad E. Specific EEG encephalopathy pattern in SARS-CoV-2 patients //Journal of Clinical Medicine. – 2020. – Vol. 9. – №. 5. – P. 15–45.
16. Dehais F. et al. Monitoring pilot’s mental workload using ERPs and spectral power with a six-dry-electrode EEG system in real flight conditions //Sensors. – 2019. – Vol. 19. – №. 6. – P. 13–24.

17. Arzate-Mena J. D. et al. Stationary EEG pattern relates to large-scale resting state networks—An EEG-fMRI study connecting brain networks across timescales //NeuroImage. – 2022. – Vol. 246. – P. 118–163.
18. Xiong R. et al. Pattern recognition of cognitive load using EEG and ECG signals //Sensors. – 2020. – Vol. 20. – №. 18. – P. 5122.
19. Runnova A. et al. Spatial patterns in EEG activity during monotonous sound perception test //The European Physical Journal Plus. – 2021. – Vol. 136. – №. 7. – P. 7–35.
20. Camaioni M. et al. EEG patterns prior to motor activations of parasomnias: a systematic review //Nature and Science of Sleep. – 2021. – P. 713–728.
21. Лебедева Н. Н., Каримова Е. Д. Устойчивость паттернов ЭЭГ человека в различных задачах: проблема аутентификации личности //Журнал высшей нервной деятельности им. ИП Павлова. – 2020. – Т. 70. – №. 1. – С. 40–49.
22. Anam K., Nuh M., Al-Jumaily A. Comparison of EEG pattern recognition of motor imagery for finger movement classification //2019 6th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI). – IEEE, 2019. – P. 24–27.
23. Rahman M. et al. Multiclass EEG signal classification utilizing Rényi min-entropy-based feature selection from wavelet packet transformation //Brain informatics. – 2020. – Vol. 7. – №. 1. – P. 1–11.
24. Pastor J., Vega-Zelaya L., Martin Abad E. Specific EEG encephalopathy pattern in SARS-CoV-2 patients //Journal of Clinical Medicine. – 2020. – Vol. 9. – №. 5. – P. 15–45.
25. Кутепов И. Е. и др. Визуализация энтропии сигналов ЭЭГ при шизофрении //Научная визуализация. – 2020. – Т. 12. – №. 1. – С. 1–9.
26. Ra J. S., Li T., Li Y. A novel spectral entropy-based index for assessing the depth of anaesthesia //Brain Informatics. – 2021. – Vol. 8. – №. 1. – P. 1–12.

27. Puri D. et al. Detection of Alcoholism from EEG signals using Spectral and Tsallis Entropy with SVM //2021 International Conference on Communication information and Computing Technology (ICCICT). – IEEE, 2021. – P. 1–5.
28. Zhu C., Xiao F., Cao Z. A generalized Rényi divergence for multi-source information fusion with its application in EEG data analysis //Information Sciences. – 2022. – Vol. 605. – P. 225–243.
29. Щербань И. В., Кириленко Н. Е., Красников С. О. Программа поиска осцилляторных паттернов в составе электрических сигналов на основе энтропийного подхода / И. В. Щербань, Н. Е. Кириленко, С. О. Красников// Свидетельство о регистрации программы для ЭВМ. –14.04.2017. – № RU 2017614416.
30. Chiang H. S., Chen M. Y., Huang Y. J. Wavelet-based EEG processing for epilepsy detection using fuzzy entropy and associative petri net //IEEE Access. – 2019. – Vol. 7. – P. 103255–103262.
31. Ferracuti F. et al. Comparing between Different Sets of Preprocessing, Classifiers, and Channels Selection Techniques to Optimise Motor Imagery Pattern Classification System from EEG Pattern Recognition //Brain Sciences. – 2021. – Vol. 12. – №. 1. – P. 5–17.
32. Суворов А. В. и др. Применение ИНС для распознавания патологических паттернов на ЭЭГ при дефиците исходных данных //Системы компьютерной математики и их приложения. – 2021. – №. 22. – С. 74–79.
33. Li M., Chen W. FFT-based deep feature learning method for EEG classification //Biomedical Signal Processing and Control. – 2021. – Vol. 66. – P. 10–22.
34. Брагин А. Д., Спицын В. Г. Распознавание моторных образов на электроэнцефалограммах с применением свёрточных нейронных сетей //Компьютерная оптика. – 2020. – Т. 44. – №. 3. – С. 482–489.
35. Xu M. et al. Learning EEG topographical representation for classification via convolutional neural network //Pattern Recognition. – 2020. – Vol. 105. – P. 107390.

36. Oliva J. T., Rosa J. L. G. Classification for EEG report generation and epilepsy detection //Neurocomputing. – 2019. – Vol. 335. – P. 81–95.
37. Jing J. et al. Development of expert-level classification of seizures and rhythmic and periodic patterns during EEG interpretation //Neurology. – 2023. – Vol. 100. – №. 17. – P. 1750–1762.
38. Капралов Н. В., Нагорнова Ж. В., Шемякина Н. В. Методы классификации ЭЭГ-паттернов воображаемых движений //Информатика и автоматизация. – 2021. – Т. 20. – №. 1. – С. 94–132.
39. Barua P. D. et al. Novel automated PD detection system using aspirin pattern with EEG signals //Computers in Biology and Medicine. – 2021. – Vol. 137. – P. 104841.
40. Bhardwaj H. et al. Eeg-based personality prediction using fast fourier transform and deeplstm model //Computational Intelligence and Neuroscience. – 2021. – Vol. 2021. – P. 1–10.
41. Yudhana A. et al. Human emotion recognition based on EEG signal using fast fourier transform and K-Nearest neighbor //Adv. Sci. Technol. Eng. Syst. J. – 2020. – Vol. 5. – P. 1082–1088.
42. Novitasari D. C. R., Suwanto M., Asyhar A. H. Classification of EEG Signals using Fast Fourier Transform (FFT) and Adaptive Neuro-Fuzzy Inference System (ANFIS) //Jurnal Matematika MANTIK. – 2019. – Vol. 5. – №. 1. – P. 35–44.
43. Sanjeet S., Sahoo B. D., Parhi K. K. Low-energy real FFT architectures and their applications to seizure prediction from EEG //Analog Integrated Circuits and Signal Processing. – 2022. – P. 1–12.
44. Woo S. W. et al. Sleep stage classification using electroencephalography via Mel frequency cepstral coefficients //2022 13th Asian Control Conference (ASCC). – IEEE, 2022. – P. 42–47.
45. Щербань И. В., Кириленко Н. Е., Щербань О. Г. Программа идентификации специфических паттернов в составе электрических сигналов на основе выделения и анализа MEL-кепстральных частотных коэффициентов / И. В.

Щербань, Н. Е. Кириленко, О. Г. Щербань// Свидетельство о регистрации программы для ЭВМ. – 29.11.2016. – № RU 2016663167.

46. Tajadini B., Seydnejad S. R., Rezakhani S. Prediction of Epileptic Seizures in Patients with Temporal Lobe Epilepsy (TLE) based on Cepstrum analysis and AR model of EEG signal //Signal and Data Processing. – 2023. – Vol. 19. – №. 4. – P. 155–178.

47. Chen K. et al. EEG-based mental fatigue detection using linear prediction cepstral coefficients and Riemann spatial covariance matrix //Journal of Neural Engineering. – 2022. – Vol. 19. – №. 6. – P. 66–81.

48. Rashid N. et al. EEG based four class human limb movement detection by mel frequency cepstral coefficients and quadratic multi-class support vector machine //Journal of Engineering and Applied Sciences. – 2021. – Vol. 39. – №. 1. – P. 116–126.

49. Кириленко Н. Е., Щербань И. В., Красников С. О. Идентификация фокальной активности макросматика на основе использования аппарата MEL-кепстральных коэффициентов //Актуальные проблемы науки на современном этапе развития. – 2015. – P. 106–108.

50. Щербань О. Г., Щербань И. В., Кириленко Н. Е. Синтез адаптивного фильтра для автоматической детекции и локализации по оси времени премоторных ЭЭГ-паттернов мозга человека //Информационные технологии. – 2021. – Vol. 27. – №. 9. – С. 484–493.

51. Wei M. et al. EEG beta-band spectral entropy can predict the effect of drug treatment on pain in patients with herpes zoster //Journal of Clinical Neurophysiology. – 2022. – Vol. 39. – №. 2. – P. 166–173.

52. Кубах Е. В., Щербань И. В., Кириленко Н. Е. Алгоритмы частотного анализа биомедицинских электрограмм //Труды Северо-Кавказского филиала Московского технического университета связи и информатики. – 2019. – №. 1. – С. 228–231.

53. Delimayanti M. K. et al. Classification of brainwaves for sleep stages by high-dimensional FFT features from EEG signals //Applied Sciences. – 2020. – Vol. 10. – №. 5. – P. 17–37.
54. Zeng W. et al. Identification of epileptic seizures in EEG signals using time-scale decomposition (ITD), discrete wavelet transforms (DWT), phase space reconstruction (PSR) and neural networks //Artificial Intelligence Review. – 2020. – Vol. 53. – P. 3059–3088.
55. Gosala B. et al. Wavelet transforms for feature engineering in EEG data processing: An application on Schizophrenia //Biomedical Signal Processing and Control. – 2023. – Vol. 85. – P. 104–111.
56. Abbasi H. et al. Wavelet spectral time-frequency training of deep convolutional neural networks for accurate identification of micro-scale sharp wave biomarkers in the post-hypoxic-ischemic EEG of preterm sheep //2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). – IEEE, 2020. – P. 1039–1042.
57. Chen J., Jiang D., Zhang Y. A common spatial pattern and wavelet packet decomposition combined method for EEG-based emotion recognition //Journal of Advanced Computational Intelligence and Intelligent Informatics. – 2019. – Vol. 23. – №. 2. – P. 274–281.
58. You Y., Chen W., Zhang T. Motor imagery EEG classification based on flexible analytic wavelet transform //Biomedical Signal Processing and Control. – 2020. – Vol. 62. – P. 102–129.
59. Savadkoohi M., Oladunni T., Thompson L. A machine learning approach to epileptic seizure prediction using Electroencephalogram (EEG) Signal //Biocybernetics and Biomedical Engineering. – 2020. – Vol. 40. – №. 3. – P. 1328–1341.
60. Sharmila A., Geethanjali P. DWT Based Time Domain Features on Detection of Epilepsy Seizures from EEG Signal //Biomedical Signal Processing: Advances in Theory, Algorithms and Applications. – 2020. – P. 181–200.

61. Jadhav P. et al. Automatic sleep stage classification using time–frequency images of CWT and transfer learning using convolution neural network //Biocybernetics and Biomedical Engineering. – 2020. – Vol. 40. – №. 1. – P. 494–504.
62. Щербань И. В., Кириленко Н. Е., Красников С. О. Метод поиска неизвестных высокочастотных осцилляторов в составе зашумленных сигналов на основе непрерывного вейвлет-преобразования //Автоматика и телемеханика. – 2019. – №. 7. – С. 122–133.
63. Khan K. A. et al. A hybrid Local Binary Pattern and wavelets-based approach for EEG classification for diagnosing epilepsy //Expert Systems with Applications. – 2020. – Vol. 140. – P. 112–135.
64. Upadhyay P. K., Nagpal C. Wavelet based performance analysis of SVM and RBF kernel for classifying stress conditions of sleep EEG //Science and Technology. – 2020. – Vol. 23. – №. 3. – P. 292–310.
65. Yahya N. et al. Classification of motor functions from electroencephalogram (EEG) signals based on an integrated method comprised of common spatial pattern and wavelet transform framework //Sensors. – 2019. – Vol. 19. – №. 22. – P. 48–78.
66. Kant P. et al. CWT based transfer learning for motor imagery classification for brain computer interfaces //Journal of Neuroscience Methods. – 2020. – Vol. 345. – P. 108–136.
67. Islam M. N. et al. Diagnosis of hearing deficiency using EEG based AEP signals: CWT and improved-VGG16 pipeline //PeerJ Computer Science. – 2021. – Vol. 7. – P. 6–38.
68. Thangarajoo R. G. et al. Machine learning-based epileptic seizure detection methods using wavelet and EMD-based decomposition techniques: A review //Sensors. – 2021. – Vol. 21. – №. 24. – P. 84–85.
69. Zhang X., Huo Y., Wan D. Improved EMD based on piecewise cubic Hermite interpolation and mirror extension //Chinese journal of electronics. – 2020. – Vol. 29. – №. 5. – P. 899–905.

70. Krishnan P. T. et al. Schizophrenia detection using Multivariate Empirical Mode Decomposition and entropy measures from multichannel EEG signal //Biocybernetics and Biomedical Engineering. – 2020. – Vol. 40. – №. 3. – P. 1124–1139.
71. Thangarajoo R. G. et al. Machine learning-based epileptic seizure detection methods using wavelet and EMD-based decomposition techniques: A review //Sensors. – 2021. – Vol. 21. – №. 24. – P. 84–85.
72. Ji N. et al. EEG signals feature extraction based on DWT and EMD combined with approximate entropy //Brain sciences. – 2019. – Vol. 9. – №. 8. – P. 201.
73. Matei R. Analysis of EEG Signals Using Empirical Mode Decomposition and Relative Band Energy //2022 E-Health and Bioengineering Conference (EHB). – IEEE, 2022. – P. 1–4.
74. Xie Y., Oniga S. A review of processing methods and classification algorithm for EEG signal //Carpathian Journal of Electronic and Computer Engineering. – 2020. – Vol. 13. – №. 1. – P. 23–29.
75. Иваницкий Г. А. Индивидуальные устойчивые паттерны ритмов мозга человека как отражение психических процессов //Современные технологии в медицине. – 2019. – Е. 11. – №. 1. – С. 116–131.
76. Acharya D. et al. Comparative analysis of feature extraction technique on EEG-based dataset //Soft Computing for Problem Solving: Proceedings of SocProS 2020, Volume 1. – Springer Singapore, 2021. – P. 405–416.
77. Barborica A. et al. Extracting seizure onset from surface EEG with Independent Component Analysis: Insights from simultaneous scalp and intracerebral EEG //NeuroImage: Clinical. – 2021. – Vol. 32. – P. 102–138.
78. Dora C. et al. Adaptive SSA based muscle artifact removal from single channel EEG using neural network regressor //Irbm. – 2021. – Vol. 42. – №. 5. – P. 324–333.

79. Agarwal S., Zubair M. Classification of alcoholic and non-alcoholic EEG signals based on sliding-SSA and independent component analysis //IEEE Sensors Journal. – 2021. – Vol. 21. – №. 23. – P. 26198–26206.
80. Feng Y. et al. A Novel SSA-CCA Framework for Muscle Artifact Removal from Ambulatory EEG //Virtual Reality & Intelligent Hardware. – 2022. – Vol. 4. – №. 1. – P. 1–21.
81. Dora C. et al. Adaptive SSA based muscle artifact removal from single channel EEG using neural network regressor //Irbm. – 2021. – Vol. 42. – №. 5. – P. 324–333.
82. Кириленко Н. Е., Кубах Е. В. Обоснование выбора SSA в качестве метода декомпозиции сигнала в задачах поиска осцилляторных паттернов //Транспорт: наука, образование, производство. – 2019. – С. 156–161.
83. Shcherban I. V., Lazurenko D.M., Shaposhnikov D. G., Kirilenko N. E. et al. Adaptive Hausdorff Estimation of Movement-Related Eeg Patterns for Brain-Computer Interfaces //Cell Reports Methods. – 2021. – URL: <http://dx.doi.org/10.2139/ssrn.3915013>.
84. Shcherban I. V., Kirilenko N. E., Krasnikov S. O. A search method for unknown high-frequency oscillators in noisy signals based on the continuous wavelet transform //Automation and Remote Control. – 2019. – Vol. 80. – P. 1279-1287.
85. Kirilenko N. E. Development of Algorithms to Detect EEG Patterns Specific for Arbitrary Motor Activity of a Human in the BCI Applications //Advances in Neural Computation, Machine Learning, and Cognitive Research V: Selected Papers from the XXIII International Conference on Neuroinformatics, October 18-22, 2021, Moscow, Russia. – Springer Nature, 2021. – Vol. 1008. – P. 75.
86. Щербань И. В., Кириленко Н. Е., Щербань О. Г. Эффективные критериальные функции спектральной энтропии для поиска высокочастотных паттернов в составе зашумленных электрограмм //Информационно-управляющие системы. – 2018. – №. 2 (93). – P. 8–17.

87. Кириленко Н. Е., Щербань И. В., Щербань О. Г. Разработка алгоритма энтропийного анализа сигналов с неопределенными статистическими характеристиками //Вестник современных исследований. – 2018. – №. 12.5. – С. 155–158.
88. Al-Qazzaz N. K. et al. Electroencephalogram profiles for emotion identification over the brain regions using spectral, entropy and temporal biomarkers //Sensors. – 2019. – Vol. 20. – №. 1. – P. 5–9.
89. Кириленко Н. Е. Разработка критерия для энтропийного анализа зашумленных сигналов с неопределенными статистическими характеристиками //Фундаментальные исследования, методы и алгоритмы прикладной математики в технике, медицине и экономике. – 2018. – С. 25–31.
90. Сидоров К. В. и др. Анализ биомедицинских сигналов как способ оценки когнитивной активности при эмоциональной стимуляции //Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. – 2019. – Т. 9. – №. 1. – С. 74–85.
91. Durongbhan P. et al. A dementia classification framework using frequency and time-frequency features based on EEG signals //IEEE Transactions on Neural Systems and Rehabilitation Engineering. – 2019. – Vol. 27. – №. 5. – P. 826–835.
92. Saxena A. et al. Emotion detection through EEG signals using FFT and machine learning techniques //International Conference on Innovative Computing and Communications: Proceedings of ICICC 2019, Volume 1. – Springer Singapore, 2020. – P. 543–550.
93. Hasan M. M. et al. Effect of Smoking in EEG Pattern and Time-Frequency Domain Analysis for Smoker and Non-Smoker //2019 International Conference on Computer, Communication, Chemical, Materials and Electronic Engineering (IC4ME2). – IEEE, 2019. – P. 1–4.

94. Gupta V., Pachori R. B. Classification of focal EEG signals using FBSE based flexible time-frequency coverage wavelet transform //Biomedical Signal Processing and Control. – 2020. – Vol. 62. – P. 102–124.
95. Durongbhan P. et al. A dementia classification framework using frequency and time-frequency features based on EEG signals //IEEE Transactions on Neural Systems and Rehabilitation Engineering. – 2019. – Vol. 27. – №. 5. – P. 826–835.
96. George F. P. et al. Recognition of emotional states using EEG signals based on time-frequency analysis and SVM classifier //International Journal of Electrical & Computer Engineering (2088-8708). – 2019. – Vol. 9. – №. 2.
97. Sun J. et al. A hybrid deep neural network for classification of schizophrenia using EEG Data //Scientific Reports. – 2021. – Vol. 11. – №. 1. – P. 1–16.
98. Khare S. K., Bajaj V. Time–frequency representation and convolutional neural network-based emotion recognition //IEEE transactions on neural networks and learning systems. – 2020. – Vol. 32. – №. 7. – P. 2901–2909.
99. Кириленко Н. Е. и др. Решение задачи поиска осцилляторных паттернов в составе зашумленных сигналов //Труды Северо-Кавказского филиала Московского технического университета связи и информатики. – 2017. – №. 1. – С. 236–238.
100. Sairamya N. J. et al. Hybrid approach for classification of electroencephalographic signals using time–frequency images with wavelets and texture features //Intelligent Data Analysis for Biomedical Applications. – Academic Press, 2019. – P. 253–273.
101. Kirilenko N. E., Shcherban' I. V., Kostoglotov A. A. Feature Extraction of High-Frequency Patterns with the a Priori Unknown Parameters in Noised Electrograms Using Spectral Entropy //Proceedings of the Third International Scientific Conference “Intelligent Information Technologies for Industry” (IITI'18). –Vol. 2. – Springer. – 2018. – T. 875. – С. 138–147.

102. Щербань И. В., Кириленко Н. Е., Красников С. О. Программа поиска частотного диапазона паттерна на основе расчета амплитудной вейвлет-функции регистрируемого сигнала / И. В. Щербань, Н. Е. Кириленко, С. О. Красников // Свидетельство о регистрации программы для ЭВМ. – 19.06.2017. – № RU 2017616868.

103. Щербань И. В., Кириленко Н. Е., Лобзенко П. В. Программа аутентификации пользователя на основе вейвлет-анализа речевых сигналов, регистрируемых с использованием микрофона / И. В. Щербань, Н. Е. Кириленко, П.В. Лобзенко// Свидетельство о регистрации программы для ЭВМ. – 11.01.2017. – № RU 2017610478.

104. Shcherban I. V., Kirilenko N. E., Krasnikov S. O. A search method for unknown high-frequency oscillators in noisy signals based on the continuous wavelet transform //Automation and Remote Control. – 2019. – Vol. 80. – P. 1279–1287.

105. Кириленко Н. Е., Щербань И. В., Костоглотов А. А. Выбор оптимальной базисной вейвлет-функции для непрерывного вейвлет-преобразования //Труды Ростовского государственного университета путей сообщения. – 2016. – №. 5. – С. 45–48.

106. Saha S. et al. Wavelet entropy-based inter-subject associative cortical source localization for sensorimotor BCI //Frontiers in Neuroinformatics. – 2019. – Vol. 13. – P. 4–7.

107. Sharma N., Kolekar M. H., Jha K. Iterative filtering decomposition based early dementia diagnosis using EEG with cognitive tests //IEEE Transactions on Neural Systems and Rehabilitation Engineering. – 2020. – Vol. 28. – №. 9. – P. 1890–1898.

108. Li M. A., Han J. F., Duan L. J. A novel MI-EEG imaging with the location information of electrodes //IEEE Access. – 2019. – Vol. 8. – P. 3197–3211.

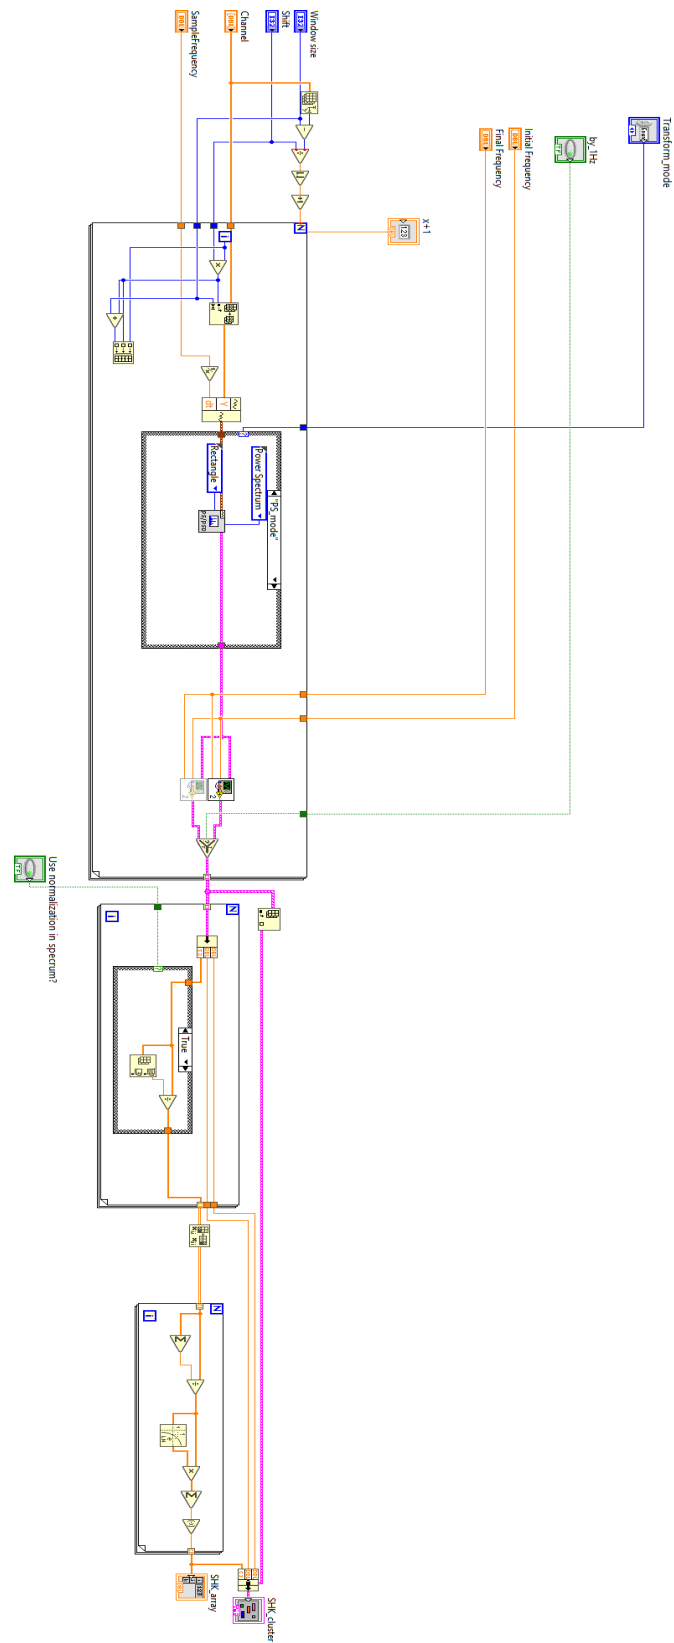
109. Li F. et al. A novel simplified convolutional neural network classification algorithm of motor imagery EEG signals based on deep learning //Applied Sciences. – 2020. – Vol. 10. – №. 5. – P. 16–25.

110. Zubair M. et al. Detection of epileptic seizures from EEG signals by combining dimensionality reduction algorithms with machine learning models //IEEE Sensors Journal. – 2021. – Vol. 21. – №. 15. – P. 16861–16869.
111. Ieracitano C. et al. A novel multi-modal machine learning based approach for automatic classification of EEG recordings in dementia //Neural Networks. – 2020. – Vol. 123. – P. 176–190.
112. Chacon-Murguia M. I., Rivas-Posada E. Feature extraction evaluation for two motor imagery recognition based on common spatial patterns, time-frequency transformations and SVM //2020 International Joint Conference on Neural Networks (IJCNN). – IEEE, 2020. – P. 1–7.
113. Haghayegh S. et al. Automated Sleep Stages Classification Using Convolutional Neural Network from Raw and Time-Frequency Electroencephalogram Signals: Systematic Evaluation Study //Journal of Medical Internet Research. – 2023. – Vol. 25. – P. 40–51.
114. Varlı M., Yılmaz H. Multiple classification of EEG signals and epileptic seizure diagnosis with combined deep learning //Journal of Computational Science. – 2023. – Vol. 67. – P. 101–123.
115. Luo T. et al. EMD-WOG-2DCNN based EEG signal processing for Rolandic seizure classification //Computer Methods in Biomechanics and Biomedical Engineering. – 2022. – Vol. 25. – №. 14. – P. 1565–1575.
116. Ömer T. Determination of emotional status from EEG time series by using EMD based local binary pattern method //European Journal of Technique (EJT). – 2020. – Vol. 10. – №. 2. – P. 313–321.
117. Бахтин О. М., Щербань И. В., Кириленко Н. Е. Метод детекции ЭЭГ-паттернов мозга человека в условиях мысленной вербализации //Приоритетные направления развития науки и технологий. – 2021. – С. 88–110.

118. Baradits M., Bitter I., Czobor P. Multivariate patterns of EEG microstate parameters and their role in the discrimination of patients with schizophrenia from healthy controls //Psychiatry research. – 2020. – Vol. 288. – P. 112–138.
119. Ji N. et al. EEG signals feature extraction based on DWT and EMD combined with approximate entropy //Brain sciences. – 2019. – Vol. 9. – №. 8. – P. 201.
120. Bairagi R. N. et al. Epileptic seizure identification in EEG signals using DWT, ANN and sequential window algorithm //Soft Computing Letters. – 2021. – Vol. 3. – P. 100–126.
121. Ma X. et al. DWT and CNN based multi-class motor imagery electroencephalographic signal recognition //Journal of neural engineering. – 2020. – Vol. 17. – №. 1. – P. 16–33.
122. Subasi A., Jukic S., Kevric J. Comparison of EMD, DWT and WPD for the localization of epileptogenic foci using random forest classifier //Measurement. – 2019. – Vol. 146. – P. 846–855.
123. Singh N., Dehuri S. Multiclass classification of EEG signal for epilepsy detection using DWT based SVD and fuzzy kNN classifier //Intelligent Decision Technologies. – 2020. – Vol. 14. – №. 2. – P. 239–252.
124. Zeng W. et al. Identification of epileptic seizures in EEG signals using time-scale decomposition (ITD), discrete wavelet transforms (DWT), phase space reconstruction (PSR) and neural networks //Artificial Intelligence Review. – 2020. – Vol. 53. – P. 3059–3088.
125. Saday A., Ozkan I. A. Classification of Epileptic EEG Signals Using DWT-Based Feature Extraction and Machine Learning Methods //International Journal of Applied Mathematics Electronics and Computers. – 2021. – Vol. 9. – №. 4. – P. 122–129.
126. Akbari H. et al. Recognizing seizure using Poincaré plot of EEG signals and graphical features in DWT domain //Bratislavske Lekarske Listy. – 2023. – Vol. 124. – №. 1. – P. 12–24.

Приложение А

Блок-диаграмма виртуального прибора в среде LABVIEW NI спектральной энтропии с использованием частотной-локализации



Приложение Б

Код программы вычисления спектральной энтропии и разработанных критериев оптимальности

```
import numpy as np

import math

from scipy.fftpack import fft

import wavelet_pack

def get_fft_subset(input_channel, Fd=250, low_freq=1, high_freq=100,
mode='PowerSpectrum'):
    """ Функция вычисления спектра
        Fd - sampling frequency
        input_data - 1d array
        mode =
            PowerSpectrum
            Magnitude"""
    df = Fd/input_channel.shape[0]
    freq_axis = np.arange(0, input_channel.shape[0]/2, df)
    Zxx = fft(input_channel)
    if mode=='Magnitude':
        Zxx = np.abs(Zxx)
    elif mode=='PowerSpectrum':
        Zxx = np.abs(Zxx)**2
    Zxx = Zxx[:int(Zxx.shape[0]/2)]
```

```

choosed_coef = np.where((freq_axis<=high_freq)&(freq_axis>=low_freq))
choosed_freq = freq_axis[choosed_coef]
choosed_Zxx = Zxx[choosed_coef]
return choosed_Zxx,choosed_freq

```

```

def spectral_entropy(channel, window_size,
window_shift,Fd=250,low_freq=1,high_freq=100, mode='PowerSpectrum'):
    """
    Функция вычисления спектральной энтропии
    на вход принимает:
    channel - исходный сигнал,
    window_size - размер окна в отсчетах,
    window_shift - сдвиг окна в отсчетах
    Fd - частота дискретизации,
    low_freq - минимальная частота расширенного диапазона,
    high_freq - мимаксимальная частота расширенного диапазона
    """
    num_of_windows = math.floor((channel.shape[0]-window_size)/window_shift)+1
    wind_entropy_array = []
    for w_it in range(num_of_windows):
        left_border = window_shift*w_it
        right_border = left_border+window_size
        window_signal = channel[left_border:right_border]
        Zxx,freq = get_fft_subset(window_signal,Fd,low_freq,high_freq,
mode='PowerSpectrum')
        p_Zxx = Zxx/sum(Zxx)
        wind_entropy = sum(p_Zxx*math.log1p(p_Zxx))*(0-1)
        wind_entropy_array.append(wind_entropy)

```

```

wind_entropy_array = np.asarray(wind_entropy_array)
return wind_entropy_array

def optimal_diapason_SE(channel, window_size,
window_shift,Fd=250,low_freq=1,high_freq=100, mode='PowerSpectrum'):
    """Функция вычисления критерия оптимального диапазона масштабов
на вход принимает:
channel - исходный сигнал,
window_size - размер окна в отсчетах,
window_shift - сдвиг окна в отсчетах
Fd - частота дискретизации,
low_freq - минимальная частота расширенного диапазона,
high_freq - максимальная частота расширенного диапазона"""
    num_of_windows = math.floor((channel.shape[0]-window_size)/window_shift)+1
    Zxx_array = []
    freq_entropy_arr = []
    for w_it in range(num_of_windows):
        left_border = window_shift*w_it
        right_border = left_border+window_size
        window_signal = channel[left_border:right_border]
        Zxx,freq = get_fft_subset(window_signal,Fd,low_freq,high_freq,
mode='PowerSpectrum')
        Zxx_array.append(Zxx)
    Zxx_array=np.vstack(Zxx_array).T
    for freq_it in range(Zxx_array.shape[0]):
        used_freq = Zxx_array[freq_it,:]
        p_uZxx = used_freq/sum(used_freq)
        freq_entropy = sum(p_uZxx*math.log1p(p_uZxx))*(0-1)

```

```

    freq_entropy_arr.append(freq_entropy)
freq_entropy_arr = np.asarray(freq_entropy_arr)
return freq_entropy_arr

```

```

def wavelet_entropy_CWT(channel, window_size,
window_shift,Fd,low_scale,high_scale, wavelet='db4'):

```

```

    """

```

Функция вычисления вейвлет энтропии НВП на вход принимает:

channel - исходный сигнал,

window_size - размер окна в отсчетах,

window_shift - сдвиг окна в отсчетах

Fd - частота дискретизации,

low_scale - минимальный масштаб б.в.ф. расширенного диапазона,

high_scale - мимаксимальный масштаб б.в.ф. расширенного диапазона

```

    """

```

```

num_of_windows = math.floor((channel.shape[0]-window_size)/window_shift)+1

```

```

wind_entropy_array = []

```

```

for w_it in range(num_of_windows):

```

```

    left_border = window_shift*w_it

```

```

    right_border = left_border+window_size

```

```

    window_signal = channel[left_border:right_border]

```

```

    wavelet_matrix = wavelet_pack.CWT(window_signal,Fd,low_scale,high_scale,
wavelet='db4')

```

```

    wavelet_scale_energy = [sum(math.pow(wavelet_matrix[scale,:])) for scale in
range(wavelet_matrix.shape[0])]

```

```

    p_WSE = wavelet_scale_energy/sum(wavelet_scale_energy)

```

```

    wind_entropy = sum(p_WSE*math.log1p(p_WSE))*(0-1)

```

```

    wind_entropy_array.append(wind_entropy)
wind_entropy_array = np.asarray(wind_entropy_array)
return wind_entropy_array

def optimal_diapason_WE(channel, window_size,
window_shift,Fd,low_scale,high_scale, wavelet='db4'):
    """Функция вычисления критерия оптимального диапазона масштабов
на вход принимает:
channel - исходный сигнал,
window_size - размер окна в отсчетах,
window_shift - сдвиг окна в отсчетах
Fd - частота дискретизации,
low_scale - минимальный масштаб б.в.ф. расширенного диапазона,
high_scale - мимаксимальный масштаб б.в.ф. расширенного диапазона
    """
    num_of_windows = math.floor((channel.shape[0]-window_size)/window_shift)+1
    WSE_array = []
    scale_entropy_arr = []
    for w_it in range(num_of_windows):
        left_border = window_shift*w_it
        right_border = left_border+window_size
        window_signal = channel[left_border:right_border]
        wavelet_matrix = wavelet_pack.CWT(window_signal,Fd,low_scale,high_scale,
wavelet='db4')
        wavelet_scale_energy = [sum(math.pow(wavelet_matrix[scale,:])) for scale in
range(wavelet_matrix.shape[0])]
        WSE_array=np.vstack(WSE_array).T
    for scale_it in range(WSE_array.shape[0]):

```

```

used_scale = WSE_array[freq_it,:]
p_uWSE = used_scale/sum(used_scale)
scale_entropy = sum(p_uWSE*math.log1p(p_uWSE))*(0-1)
scale_entropy_arr.append(scale_entropy)
scale_entropy_arr = np.asarray(scale_entropy_arr)
return scale_entropy_arr

```

```
file_path = r"G:\Dvijeniya
```

```
Dataset\subj_001\label_000\subj_001_label_000_example_001.CSV"
```

```
data_matrx = np.genfromtxt(file_path, delimiter=";")
```

```
channel = data_matrx[0]
```

```
window_size= 64
```

```
window_shift = 32
```

```
freq_entropy_arr = optimal_diapason_SE(channel, window_size, window_shift,
```

```
    Fd=250,low_freq=1,high_freq=100,
```

```
    mode='PowerSpectrum') #выбор оптимального диапазона
```

частот

```
spectral_entropy_arr = spectral_entropy(channel, window_size, window_shift,
```

```
    Fd=250,low_freq=1,high_freq=100,
```

```
    mode='PowerSpectrum') #спектральная энтропия
```

```
scale_entropy_arr = optimal_diapason_WE(channel, window_size, window_shift,
```

```
    Fd,low_scale,high_scale,
```

```
    wavelet='db4') #выбор оптимального диапазона масштабов
```

б.в.ф.

```
wavelet_entropy_arr = wavelet_entropy_CWT(channel, window_size, window_shift,
```

```
    Fd,low_scale,high_scale,
```

```
    wavelet='db4') #вейвлет энтропия
```

Приложение В

Акты о внедрении результатов работы

УТВЕРЖДАЮ

Руководитель научно-исследовательского
технологического центра нейротехнологий
ФГАОУ ВО ЮФУ

В.Н. Кирой

«17» февраля 2025 г.

АКТ

о внедрении (использовании) результатов диссертационной работы
Кириленко Николая Евгеньевича

Настоящим актом подтверждается, что результаты диссертационной работы Кириленко Н. Е. «Метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса», представленной на соискание ученой степени кандидата технических наук по специальности 2.3.1. «Системный анализ, управление и обработка информации, статистика», использованы в НИТЦ нейротехнологий ФГАОУ ВО ЮФУ в рамках работ по проекту в интересах развития кооперации российских высших учебных заведений и организаций, реализующих комплексные проекты по созданию высокотехнологичного производства, постановление Правительства РФ N218, на тему "Создание программного комплекса для управления человеческим капиталом на основе нейротехнологий для предприятий высокотехнологичного сектора Российской Федерации" (договор №19-2-051/2 от 16.09.2019), при разработке специализированного программного обеспечения детектирования пространственно-временных маркеров когнитивных состояний биоэлектрической активности головного мозга человека.

Ответственный исполнитель проекта №19-2-051/2,
ведущий научный сотрудник, к.т.н.



Д.Г. Шапошников

УТВЕРЖДАЮ

Руководитель научно-исследовательского
технологического центра нейротехнологий
ФГАОУ ВО ЮФУ

В.Н. Кирой

«20» марта 2025 г.

АКТ

о внедрении (использовании) результатов диссертационной работы
Кириленко Николая Евгеньевича

Настоящим актом подтверждается, что результаты диссертационной работы Кириленко Н. Е. «Метод частотно-временной локализации априорно неопределенных паттернов в составе зашумленных сигналов нейрокомпьютерного интерфейса», представленной на соискание ученой степени кандидата технических наук по специальности 2.3.1. «Системный анализ, управление и обработка информации, статистика», использованы в НИТЦ нейротехнологий ФГАОУ ВО ЮФУ в рамках работ по гранту Российского научного фонда N20-19-00627 на тему "Разработка стимул-независимой модели интерфейса "Мозг-компьютер" для реабилитации людей с ограниченными возможностями", 2020-2022 г. при разработке специального программно-алгоритмического обеспечения для формирования управляющих команд нейроинтерфейса на основе частотно-временной локализации специфических паттернов ЭЭГ, связанных с идеомоторной деятельностью.

Руководитель проекта РФФ N20-19-00627,
ведущий научный сотрудник, к.т.н.



Д.Г. Шапошников

Приложение Г

Свидетельства о регистрации программ для ЭВМ по теме исследования

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2016663167

Программа идентификации специфических паттернов в составе электрических сигналов на основе выделения и анализа MEL-кепстральных частотных коэффициентов

Правообладатель: *федеральное государственное автономное образовательное учреждение высшего образования «Южный федеральный университет» (Южный федеральный университет) (RU)*

Авторы: *Щербань Игорь Васильевич (RU), Кириленко Николай Евгеньевич (RU), Щербань Оксана Георгиевна (RU)*

Заявка № 2016661114

Дата поступления 18 октября 2016 г.

Дата государственной регистрации
в Реестре программ для ЭВМ 29 ноября 2016 г.

Руководитель Федеральной службы
по интеллектуальной собственности

 Г.П. Ильев



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2016663167

Программа идентификации специфических паттернов в составе электрических сигналов на основе выделения и анализа MEL-кепстральных частотных коэффициентов

Правообладатель: *федеральное государственное автономное образовательное учреждение высшего образования «Южный федеральный университет» (Южный федеральный университет) (RU)*

Авторы: *Щербань Игорь Васильевич (RU), Кириленко Николай Евгеньевич (RU), Щербань Оксана Георгиевна (RU)*

Заявка № **2016661114**

Дата поступления **18 октября 2016 г.**

Дата государственной регистрации

в Реестре программ для ЭВМ **29 ноября 2016 г.**

*Руководитель Федеральной службы
по интеллектуальной собственности*

Г.П. Ивлиев



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2017610478

**Программа аутентификации пользователя на основе
вейвлет-анализа речевых сигналов, регистрируемых с
использованием микрофона**

Правообладатель: *Ордена Трудового Красного Знамени федеральное
государственное бюджетное образовательное учреждение
высшего образования «Московский технический университет
связи и информатики» (МТУСИ) (RU)*

Авторы: *Щербань Игорь Васильевич (RU), Кириленко Николай
Евгеньевич (RU), Лобзенко Павел Владимирович (RU)*

Заявка № 2016662311

Дата поступления 15 ноября 2016 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 11 января 2017 г.

Руководитель Федеральной службы
по интеллектуальной собственности

Г.П. Ивлиев

