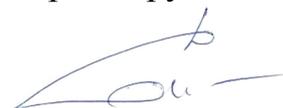


Федеральное государственное автономное образовательное учреждение
высшего образования
«Санкт-Петербургский политехнический университет Петра Великого»

На правах рукописи



СОНЬКИН Константин Михайлович

**СИСТЕМА КЛАССИФИКАЦИИ
ЭЛЕКТРОЭНЦЕФАЛОГРАФИЧЕСКИХ СИГНАЛОВ
ВООБРАЖАЕМЫХ ДВИЖЕНИЙ МЕЛКОЙ МОТОРИКИ
ДЛЯ ИНТЕРФЕЙСА МОЗГ-КОМПЬЮТЕР**

Специальность 05.11.16: «Информационно-измерительные и управляющие
системы (медицина)»

Диссертация на соискание ученой степени
кандидата технических наук

Научный руководитель:
к. т. н., проф. Станкевич Л.А.

Санкт-Петербург – 2016

СОДЕРЖАНИЕ

ВВЕДЕНИЕ.....	5
Глава 1. Обзор современного состояния проблемной области по анализу и классификации ЭЭГ сигналов в ИМК.....	13
1.1. Задача анализа и классификации сигналов ЭЭГ в ИМК	13
1.2. Современное состояние разработок ИМК.....	16
1.3. Современные разработки неинвазивных ИМК на основе сигналов ЭЭГ	19
1.4. Методы анализа сигналов ЭЭГ.....	29
1.5. Классификация методов распознавания ЭЭГ паттернов	31
1.6. Линейные классификаторы.....	32
1.7. Классификаторы на основе методов ближайших соседей.....	36
1.8. Байесовские классификаторы. Скрытые Марковские модели.....	37
1.9. Искусственные нейронные сети	40
1.10. Ансамбли классификаторов.....	42
1.11. Сопоставительный анализ методов классификации ЭЭГ паттернов моторных команд.....	43
Выводы к главе 1	46
Глава 2. Анализ ЭЭГ сигналов во временной области, выделение характерных признаков и классификация	48
2.1. Анализ ЭЭГ сигналов во временной области	48
2.1.1. Метод символьной регрессии	49
2.1.2. Вычисление характерных признаков сигнала	58
2.2. Преобразование ЭЭГ сигналов.....	60
2.2.1. Фильтрация ЭЭГ сигнала.....	61

2.2.2. Преобразование к взвешенному среднему монтажу	61
2.2.3. Разложение ЭЭГ сигнала на независимые компоненты	63
2.2.4. Преобразование к плотности источника тока	66
2.3. Классификация ЭЭГ паттернов	69
2.3.1. Комитет искусственных нейронных сетей	70
2.3.2. Комитет гетерогенных классификаторов	74
Выводы по Главе 2	80
Глава 3. Алгоритмы и программные средства системы анализа и классификации ЭЭГ паттернов моторных команд для ИМК	82
3.1. Модельные задания и регистрируемые сигналы	82
3.2. Алгоритмы извлечения признаков	88
3.3 Алгоритмы классификации ЭЭГ паттернов.....	96
3.4. Алгоритм выбора метода преобразования и информативных каналов ЭЭГ сигнала для индивидуальной настройки системы классификации	103
3.5. Структура программного пакета	105
3.6. Реализация и тестирование программного пакета	108
Выводы по главе 3.....	112
Глава 4. Применение разработанной системы анализа и классификации ЭЭГ паттернов в интерфейсе мозг-компьютер для управления искусственной кистью руки.....	114
4.1. Система анализа и классификации ЭЭГ паттернов моторных команд в ИМК с биологической обратной связью	114
4.2. Сопоставительный анализ результатов классификации ЭЭГ паттернов моторных команд, основанной на различных методах классификации	118

4.2.1. Сопоставительный анализ вероятности успешной классификации при использовании локальных классификаторов на основе ИНС и МОВ	118
4.2.2. Сопоставительный анализ вероятности успешной классификации при использовании комитета ИНС и классификатора на основе МОВ	121
4.2.3. Сопоставительный анализ вероятности успешной классификации при использовании гомогенного комитета ИНС и гетерогенного комитета классификаторов	123
4.3. Влияние индивидуальной настройки параметров системы классификации на вероятность успешного распознавания	125
4.3.1. Влияние методов преобразования ЭЭГ сигнала на вероятность успешной классификации	125
4.3.2. Влияние параметров генерации признаков на вероятность успешной классификации	128
4.3.3. Выбор наиболее информативных каналов методом картирования	136
4.4. Сравнение основных результатов разработанной системы анализа и классификации ЭЭГ паттернов с мировым уровнем	140
4.5. Применение разработанной системы в ИМК для управления искусственной кистью руки	145
4.6. Выводы к главе 4	147
ЗАКЛЮЧЕНИЕ	149
Литература	151

ВВЕДЕНИЕ

Актуальность темы исследования и степень ее разработанности.

Тематика диссертации связана с актуальным научным направлением - исследованием возможностей и путей совершенствования информационно-измерительных и управляющих систем (ИИУС) комплексов реабилитации, протезирования и мониторинга, использующих биоэлектрические сигналы центральной нервной системы человека. Такие ИИУС измеряют биоэлектрические сигналы, генерируемые мозгом или периферийными отделами центральной нервной системы, обрабатывают их для формирования информационных сигналов и используют эти сигналы для управления внешними устройствами или определения ментальных состояний человека. Фактически формируются искусственные выходы мозга и нервной системы, которые далее могут быть использованы для замены, восстановления, усиления, дополнения или улучшения естественных выходов центральной нервной системы.

Большинство таких ИИУС строится на базе интерфейсов «мозг-компьютер» (ИМК). ИМК, по существу, является средством коммуникации между мозгом и компьютерными устройствами без осуществления движений. Это - система, которая инвазивными (с хирургическим вмешательством) или неинвазивными способами измеряет сигналы биоэлектрической активности мозга, декодирует их и формирует сигналы, соответствующие определенным классам распознанных образов.

Неинвазивные ИМК наиболее часто строятся на основе электроэнцефалографии (ЭЭГ). Основу таких ИМК составляют системы анализа и классификации сигналов ЭЭГ. Проведение междисциплинарных исследований для совершенствования этих систем является главной целью диссертационной работы. Эта проблема в настоящее время является актуальной, поскольку ее решение позволяет увеличить эффективность ИМК и ИИУС в целом и обеспечить их практическое применение.

Разработки неинвазивных ИМК активно ведутся разными исследовательскими группами по всему миру. В России ряд научных коллективов и организаций проводит исследования, связанные с созданием ИМК, многие из которых известны на международном уровне. В их числе коллективы под руководством А. Я. Каплана (МГУ им. М.В. Ломоносова), К.В. Анохина (НИЦ «Курчатовский институт»), А. А. Фролова и Г.А. Иваницкого (ИВНД и НФ РАН), В. Н. Кироя (НИИ нейрокибернетики им. А.Б. Когана ЮФУ), В.Б. Казанцева (ННГУ им. Н.И. Лобачевского), А. Е. Осадчего (ИПМАШ РАН) и другие.

В настоящее время ИМК применяются для управления вспомогательными устройствами: протезами конечностей, экзоскелетом, инвалидными креслами, функциональными электростимуляторами мышц, а также для реабилитации, например, в постинсультном восстановительном периоде. В немедицинских целях ИМК применяются, в частности, для управления техническими устройствами в экстремальных условиях и оценки состояния человека в режиме реального времени.

Анализ этой предметной области показал существование тренда мировых исследований по созданию неинвазивных ИМК, основанных на воображаемых движениях. Такие исследования, в частности, активно ведутся ведущими зарубежными коллективами под руководством J.R.Wolpaw, G. Pfurtscheller, В. Blankertz, N. Birbaumer, С. Neuper и др. Ключевой проблемой при разработке таких ИМК, использующих сигналы ЭЭГ, является повышение эффективности системы анализа регистрируемых сигналов и классификации выделенных из них паттернов воображаемых моторных команд.

Основной целью совершенствования ИМК, основанных на распознавании ЭЭГ паттернов, является увеличение эффективности по таким показателям, как: (1) количество степеней свободы, т. е. количества распознаваемых моторных команд; (2) быстродействие ИМК, (3) вероятность успешной классификации ЭЭГ паттернов. Важными и нерешенными остаются вопросы повышения вероятности успешной классификации воображаемых движений мелкой моторики, например, пальцев одной руки. Решение этой трудной задачи требуется, прежде всего, для

увеличения степеней свободы ИМК и может быть достигнуто путем применения новых подходов к выделению информативных зон ЭЭГ сигналов, вычислению признаков и классификации ЭЭГ паттернов воображаемых моторных команд. Не менее важной и также трудно решаемой является задача уменьшения времени формирования на выходе ИМК сигналов управления внешними устройствами, что требует разработки новых методов обработки ЭЭГ сигналов с минимальным накоплением попыток воображения движений.

Цель и задачи диссертационной работы. Цель данной работы состоит в повышении эффективности ИМК путем разработки новых методов, алгоритмов и программ анализа ЭЭГ сигналов и классификации паттернов многоканальных ЭЭГ, соответствующих моторным командам.

Для достижения вышеуказанной цели в работе решаются следующие основные задачи:

1. Разработка математических методов анализа многоканальных сигналов ЭЭГ во временной области.
2. Разработка математических методов классификации многомерных ЭЭГ паттернов моторных команд.
3. Разработка алгоритмов выделения характерных признаков и классификации ЭЭГ паттернов моторных команд для масштабируемого комитета гетерогенных классификаторов.
4. Разработка программного пакета системы анализа и классификации, включающего программные модули регистрации, предобработки, анализа и классификации ЭЭГ паттернов в парадигме ИМК.

Решение и практическая реализация данных задач позволит создать комплексную систему анализа и классификации сигналов ЭЭГ, которая может применяться в неинвазивных ИМК, формирующих сигналы управления исполнительными устройствами в ИИУС комплексов реабилитации и протезирования.

Предмет исследования - методы, алгоритмы и программные средства, анализа и классификации сигналов ЭЭГ.

Методы исследования. В работе использовались методы искусственного интеллекта, эволюционное программирование, методы анализа временных рядов, методы вычислительной математики, теории вероятностей и математической статистики, теории информации, компьютерного моделирования, нейроинформатики.

При математическом моделировании и разработке программного обеспечения использовалась среда MATLAB и язык программирования C++.

Научные результаты и их новизна.

1. Предложен новый метод анализа многоканальных сигналов ЭЭГ. Новизна состоит в том, что определяются наиболее информативные участки сигналов и эффективные параметры для выделения классифицирующих признаков сигналов во временной области с использованием регрессионной модели в аналитической форме.

2. Предложен новый метод классификации выделенных ЭЭГ паттернов моторных команд. Новизна состоит в использовании комитета гетерогенных классификаторов, основанных на разных математических методах и демонстрирующих различную чувствительность к каждому из используемых пространств признаков.

3. Предложена новая методика регистрации, предварительной обработки сигналов ЭЭГ и выделения ЭЭГ паттернов моторных команд. Новизна состоит в том, что регистрируются сигналы, связанные с выполнением моторных команд в заданном ритме, и используются настраиваемые процедуры преобразования сигналов и выбора информативных каналов, обеспечивающие выделение ЭЭГ паттернов моторных команд.

Теоретическая значимость работы.

1. Предложенный метод анализа ЭЭГ сигналов путем построения регрессионной модели сигнала в аналитической форме с подбором базисных функций и их параметров с использованием генетического программирования позволил понять закономерности ЭЭГ сигналов и учесть такие временные характеристики ЭЭГ паттернов воображаемых моторных команд, как

локализацию признаков во времени, длительность информативных участков, а также повысить быстродействие при выделении признаков.

2. Предложенный метод классификации выделенных ЭЭГ паттернов моторных команд на основе комитета гетерогенных классификаторов, построенных на искусственных нейронных сетях и методе опорных векторов, позволил использовать разные признаковые пространства, учитывать временные особенности и многоканальность ЭЭГ сигналов и, в результате, повысить эффективность классификации многомерных ЭЭГ паттернов воображаемых моторных команд.

3. Предложенная методика регистрации и предобработки ЭЭГ сигналов, а также выделения ЭЭГ паттернов моторных команд позволила осуществлять эффективную классификацию воображаемых движений, обучение с биологической обратной связью и индивидуальную настройку системы классификации, что, в результате, обеспечило высокое быстродействие ИМК в системе управления внешними устройствами в реальном времени

Практическая значимость работы.

Разработанные методы, алгоритмы и программные средства позволили реализовать интегрированную систему классификации ЭЭГ паттернов моторных команд, которая может быть основой неинвазивных ИМК, используемых в составе ИИУС комплексов реабилитации, протезирования и мониторинга. Применение разработанной системы классификации на базе комитета гетерогенных локальных классификаторов обеспечивает возможность реализации ИМК реального времени. Разработанные программные средства могут быть использованы для прямого управления исполнительными устройствами в ИМК с биологической обратной связью, что особенно актуально для реабилитации пациентов с поражениями центральной нервной системы и управления роботизированными протезами кисти руки, а также другими исполнительными устройствами. В рамках данной работы была продемонстрирована возможность управления специально разработанной искусственной пятипалой кистью руки.

Положения, выносимые на защиту.

1. Методы анализа многоканальных сигналов ЭЭГ во временной области на основе символьной регрессии и методы классификации многомерных ЭЭГ паттернов воображаемых моторных команд на основе двухуровневого комитета гетерогенных классификаторов.

2. Алгоритмы классификации, основанные на выделении и использовании нескольких пространств признаков во временной области и использовании комитета классификаторов на базе нейронных сетей и метода опорных векторов, позволившие повысить вероятность успешных распознаваний и быстродействие классификатора ЭЭГ паттернов моторных команд и обеспечить возможность реализации ИМК.

3. Программный комплекс регистрации, предобработки сигналов ЭЭГ, выделения и классификации ЭЭГ паттернов воображаемых моторных команд, обеспечивающий индивидуальный подход к выбору временных параметров генерации различительных признаков и предназначенный, в том числе, и для использования при прямом управлении внешними устройствами в парадигме ИМК в реальном времени.

Степень достоверности и апробации. Обоснованность и достоверность полученных результатов обеспечивается корректностью применяемых методов исследования, а также соответствием теоретических положений и результатов экспериментальной проверки результатов разработанных методов, как на модельных данных, так и на экспериментальных данных, полученных при участии испытуемых.

На базе полученных научных результатов был разработан программный пакет системы регистрации, предобработки, анализа и классификации ЭЭГ паттернов моторных команд. Разработанный программный комплекс является основой программного обеспечения для систем ИМК реального времени.

Основные положения и результаты диссертационной работы были доложены и обсуждены на всероссийских и международных научных конференциях:

- XVIII Международная научно-техническая конференция "Нейроинформатика-2016" (Москва, 2016 г.)
- NEURONUS 2015 IBRO & IRUN Neuroscience Forum (Krakow, Poland, 2015)
- Society for Psychophysiological Research. 55th Annual Meeting (Seattle, USA, 2015)
- XVI Всероссийская научно-техническая конференция с международным участием "Нейроинформатика-2014" (Москва, 2014 г.)
- IV Съезд физиологов СНГ (Сочи – Дагомыс, 2014 г.)
- International Conference of Young Scientists "Automation & Control" (St. Petersburg, 2013)
- XV Всероссийская научно-техническая конференция "Нейроинформатика-2013" (Москва, 2013 г.)

Исследование было оценено экспертами Российского фонда фундаментальных исследований в рамках конкурса ориентированных фундаментальных исследований по актуальным междисциплинарным темам в 2013 году и поддержано грантом офи-м 13-01-12059.

Личный вклад автора

Все основные результаты получены лично автором или при его непосредственном участии.

Публикации.

Основные положения диссертации изложены в 12 печатных работах, в том числе в 4 работах в изданиях, рецензируемых ВАК РФ, и в 3, вошедших в международные системы цитирования Web of Science, Scopus.

Внедрение

На базе предложенных методов разработан комплекс программно-аппаратных средств в рамках интерфейса мозг-компьютер, который предполагается применить в управлении вспомогательными устройствами, такими как протезы конечностей, инвалидные кресла, роботы-помощники и др., а также может использоваться в процессе реабилитационных мероприятий, например, после инсульта.

Применение системы возможно и для немедицинских целей: для управления техническими устройствами в экстремальных условиях и для оценки состояния человека в режиме реального времени.

Структура и объем работы.

Диссертационная работа состоит из введения, 4 глав, заключения, списка литературы и приложений. Диссертация изложена на 163 страницах, содержит 36 рисунков, 4 таблицы и библиографический список из 126 наименований.

Глава 1. Обзор современного состояния проблемной области по анализу и классификации ЭЭГ сигналов в ИМК

1.1. Задача анализа и классификации сигналов ЭЭГ в ИМК

Цель диссертации состоит в разработке новых средств - методов, алгоритмов и программ - анализа и классификации паттернов многоканальных электроэнцефалограмм, соответствующих моторным командам.

Исходя из этой цели, можно выделить главную задачу для ее достижения – анализ и классификация сигналов ЭЭГ, соответствующих моторным командам. При этом анализ предполагает: очищение сигналов ЭЭГ от шумов и, так называемых, артефактов, затрудняющих классификацию; выделение участков ЭЭГ сигналов, соответствующих моторным командам; а также преобразование сигналов, направленное на вычисление признаков, позволяющих различать ЭЭГ паттерны разных моторных команд. Заметим, что фактически ЭЭГ паттерн соответствует образу моторной команды, отображаемому участком ЭЭГ, фиксированным во временном периоде воображения этой моторной команды. Классификация выделенных ЭЭГ паттернов направлена на распознавание скрытых в них образов моторных команд по набору предварительно вычисленных признаков.

Общая постановка задачи распознавания образов может быть следующей.

Дано M – множество образов w , которые могут быть разбиты на множество классов Ω . На этом множестве существует разбиение на конечное подмножество классов Ω_i ($i=1, \dots, m$), то есть $M = \bigcup_{i=1}^m \Omega_i$. Разбиение определено частично: задана лишь некоторая информация I_0 о классах Ω_i . Образы w задаются значениями признаков x_j ($j=1, \dots, N$). Набор этих признаков одинаков для всех образов множества M . Совокупность значений признаков определяет описание $I(w)$ образа. Описание образа $I(w)=(x_1(w), \dots, x_j(w), \dots, x_N(w))$ стандартное, если $x_j(w)$ принимает значения из допустимого множества значений. Стандартная эталонная

информация $I_0(\Omega_1, \dots, \Omega_m)$ является совокупностью множества описаний $\{I(w_1), \dots, I(w_m)\}$ и множества информационных векторов $\{\tilde{\alpha}(w_1), \dots, \tilde{\alpha}(w_m)\}$.

Тогда задача распознавания образов состоит в вычислении значений распознающих предикатов $P_i(w \in \Omega_i)$, $i=1, \dots, m$, для данного образа w , набора классов $\{\Omega_1, \dots, \Omega_m\}$, информации о классах $I_0(\Omega_1, \dots, \Omega_m)$ и описанию $I(w)$. Информация о вхождении образа w в класс Ω_i кодируется символами 1, если $w \in \Omega_i$, 0, если $w \notin \Omega_i$, Δ , если класс неизвестен. Это записывается в виде информационно вектора $\tilde{\alpha}(w) = (\alpha_1(w), \dots, \alpha_m(w))$, где $\alpha \in \{0, 1, \Delta\}$.

Образы моторных команд, содержащиеся в ЭЭГ паттернах, носят пространственно-временной характер, поскольку информация о них, как правило, содержится в ЭЭГ, регистрируемых в нескольких каналах, и сами сигналы представляют собой функции мозговой активности от времени. Признаки для распознавания образов моторных команд по ЭЭГ паттернам могут быть простыми (числа) и сложными (функции, распределения и пр.). Классы образов определяются шаблонами, в которых зафиксированы значения признаков данного класса, полученные при обучении.

Задача распознавания образов, содержащихся в паттернах многоканальной ЭЭГ, может быть сформулирована, используя принцип вложенности: так, анализ вектора признаков сегмента сигнала производится для каждого канала и обобщается нелинейной функцией второго уровня:

$$P_i = f' \left(\sum_{i=0}^K a_i^{(2)} f \left(\sum_{j=0}^N a_{ij}^{(1)} x_{ij} \right) \right),$$

где K – количество каналов, N – размерность вектора признаков, $a_{ij}^{(1)}$ – весовые значения для признаков первого уровня, $a_i^{(2)}$ – весовые значения для результатов анализа каждого из каналов, f и f' – функции преобразования каждого из уровней.

Параметры a определяются в процессе обучения на основе информации о классах $I_0(\Omega_1, \dots, \Omega_m)$ и описанию $I(w)$, вычисленных для обучающей выборки. Тогда задача классификации сводится к минимизации рассогласования между P_i и $\alpha_i(w)$ для всех $i=1, \dots, m$.

Следует отметить, что решение поставленной задачи классификации предполагает построение специальной системы распознавания паттернов ЭЭГ. Решение задачи классификации необходимо для того, чтобы система управления ИМК, основывающаяся на системе распознавания, могла принимать верные решения. Таким образом, система анализа и классификации ЭЭГ паттернов должна строиться так, чтобы обеспечивать системе управления возможность наиболее эффективно распоряжаться своими ресурсами и удовлетворять налагаемым на нее ограничениям по быстродействию, точности и числу распознаваемых классов.

Исследования показывают, что мозговая деятельность может быть описана как система динамического хаоса [120], таким образом генерируемые ей сигналы ЭЭГ в математическом плане являются функциями, подчиняющимися законам динамического хаоса. Это означает, что, несмотря на хаотический вид зависимости амплитуды от времени, она имеет динамические свойства, позволяющие решать задачи распознавания скрытых образов. Причем эффективность распознавания образов зависит от правильности выбора пространства признаков и процедур анализа сигналов ЭЭГ.

В следующих параграфах этой главы содержится обзор современного состояния в области разработки интерфейсов «мозг-компьютер» с выделением неинвазивных ИМК на основе сигналов ЭЭГ, а также описание методов анализа ЭЭГ сигналов и классификации ЭЭГ паттернов моторных команд с акцентом на наиболее трудно решаемую задачу классификации воображаемых команд на выполнение движения мелкой моторики, например, пальцами одной руки.

1.2. Современное состояние разработок ИМК

В 1973 г. было сформулировано новое научное направление, связанное с разработкой ИМК [113], после чего интерес к исследованиям в данной сфере стал неуклонно расти. Начиная с 2000-х годов, количество научных работ в этой области увеличилось до нескольких сотен в год. Это связано с разработкой новых методов регистрации и анализа данных об активности зон мозга, появлением новых программных и аппаратных средств реализации ИМК.

В последней декаде в базе данных Национальной медицинской библиотеки США (www.pubmed.com) проиндексировано более 2000 статей, посвященных разработке ИМК, причем пятая часть из них – около 500 работ – посвящены разработке ИМК на основе воображаемых движений (рис.1).

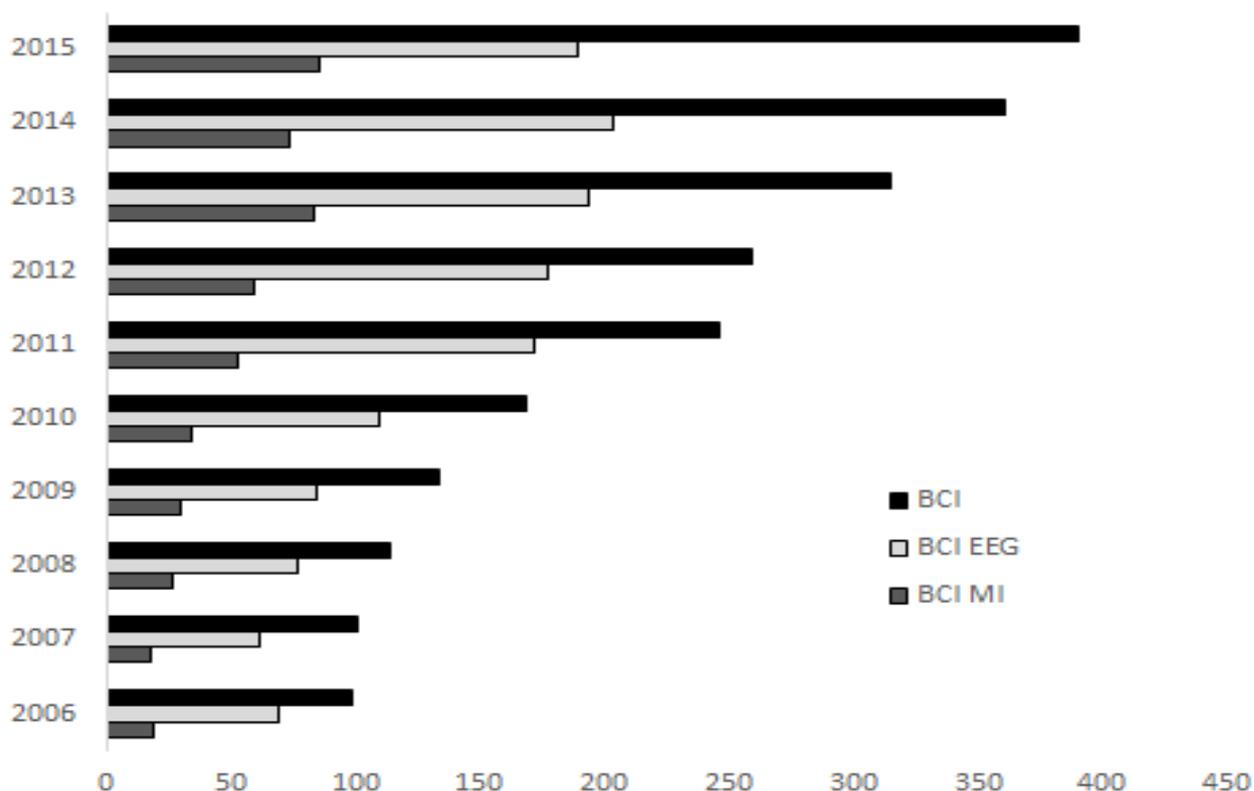


Рис. 1. Количество работ, индексированных в базе данных Национальной медицинской библиотеки США, посвященных: BCI (Brain Computer Interfaces) – ИМК, BCI-EEG – ИМК на основе сигналов ЭЭГ, BCI-MI (Motor Imagery) – ИМК на основе ЭЭГ паттернов воображаемых движений.

Для разработки ИМК может использоваться широкий спектр физиологических методов и сигналов, отражающих активность мозга – электрокортикограмма (ЭКоГ), электроэнцефалограмма (ЭЭГ), магнитоэнцефалограмма (МЭГ), функциональная магнитно-резонансная томография (фМРТ), оптической томография. Каждый из перечисленных методов регистрации физиологического сигнала обладает своими преимуществами и недостатками, являющимися ключевыми для дальнейших разработок ИМК на их основе.

Имплантированные электроды обеспечивают создание ИМК на основе анализа локальных нейрональных потенциалов. Такие ИМК характеризуются высокой вероятностью успешных распознаваний и относительно высокой скоростью. Однако они имеют существенные ограничения вследствие инвазивности, требующей хирургического вмешательства при имплантации электродов.

Функциональная магнитная резонансная томография [102, 71] регистрирует параметры мозгового кровотока и обладает хорошим пространственным разрешением, но недостаточным временным разрешением. Кроме того, для регистрации изменений мозгового кровотока используется массивное стационарное оборудование, которое затруднительно использовать ежедневно. Поэтому применение фМРТ, как правило, ограничивается исследовательскими целями. В некотором роде, перспективным может быть использование оптической томографии для анализа изменений мозгового кровотока в ограниченных областях коры.

Техники инфракрасной спектроскопии (NIRS – near infrared spectroscopy) [102, 71] также используются в ИМК, но имеют ограниченное применение в связи с низким временным разрешением.

ИМК на основе магнитоэнцефалографии [57], обладающей высоким пространственным и хорошим временным разрешением, применяются весьма ограничено. МЭГ достаточно громоздкая техника и в ежедневной практике ее использование затруднено: МЭГ регистрируется в изолированном помещении,

поскольку метод чувствителен к тонким изменениям магнитного поля и не является мобильным.

Результат сопоставительного анализа используемых методов регистрации биоэлектрических сигналов наглядно приведен на рис. 2.



Инвазивные	ЭКоГ	Измеряемая активность	прямое/непрямое измерение	временное разрешение	пространственное разрешение	портативность
	импл. электроды	электрическая	прямое	0.003 с	1 мм	+
	ЭЭГ	электрическая	прямое	0.003 с	0.05 - 0.5 мм	+
	фМРТ	электрическая	прямое	0.05 с	10 мм	+
Неинвазивные	NIRS	метаболическая	непрямое	1 с	1 мм	-
	МЭГ	метаболическая	непрямое	1 с	5 мм	+
		магнитная	прямое	0.05 с	5 мм	-

Рис. 2. Методы регистрации сигналов биоэлектрической активности.

Электроэнцефалографический метод, позволяющий регистрировать электрическую активность мозга с поверхности головы (скальпа) [103], по сравнению с перечисленными методами, характеризуется хорошим временным, но относительно низким пространственным разрешением, т. к. из-за прохождения мозговых оболочек сигнал уменьшается по амплитуде и «размазывается» по скальпу, вследствие чего распознавание паттернов ЭЭГ представляет собой весьма сложную задачу. Однако этот метод получил широкое распространение при создании ИМК, так как он неинвазивен, и ЭЭГ может регистрироваться легкими, мобильными, в том числе, беспроводными устройствами.

Анализ применимости ИМК показал, что их использование может существенно повысить качество жизни больных с тяжелыми поражениями центральной нервной системы, сопровождающихся частичным или полным параличом, больных с последствиями инсульта, тяжелых черепно-мозговых травм и других. Разработки ИМК для применения в клинике ведутся разными исследовательскими группами по всему миру [39, 115, 30, 1, 24]. ИМК могут применяться и для управления вспомогательными медицинскими устройствами: протезами конечностей, экзоскелетами, инвалидными креслами,

функциональными электростимуляторами мышц и др. [2], а также использоваться в процессе реабилитационных мероприятий, например, в постинсультном восстановительном периоде [24]. Кроме того, возможно применение ИМК для немедицинских целей: управление техническими устройствами в экстремальных условиях, оценка состояния человека в режиме реального времени и др. [36, 45].

1.3. Современные разработки неинвазивных ИМК на основе сигналов ЭЭГ

Специфика ЭЭГ сигналов. Электрическая активность, регистрируемая при помощи ЭЭГ, является результатом сложной суммации электрических градуальных потенциалов многих нейронов, работающих в значительной степени независимо. «Отклонения от случайного распределения в данном случае зависят от функционального состояния мозга (сон, уровни бодрствования) и от характера процессов, вызывающих элементарные потенциалы (спонтанная и вызванная активность). В случае временной синхронизации активности нейронов может наблюдаться повышение амплитуды суммарных потенциалов и увеличении когерентности между элементарными и суммарными процессами» (цитата по [9]). При исследовании биоэлектрических сигналов, связанных с событием, как экзогенных (реакции на внешние раздражители – звуковые, зрительные стимулы), так и эндогенных (принятие решений, планирование движений), в электрофизиологии используются методы когерентного накопления и когерентного усреднения сигнала, при которых увеличивается соотношение сигнал/шум. В этом случае спонтанная ритмическая активность, не связанная с событием (экзогенным или эндогенным), является «шумом», который, не будучи фазовосвязанным временной зависимостью с событием, в результате накопления значительно уменьшается по амплитуде.

Для улучшения соотношения сигнал/шум необходимо усреднение большого количества реакций на предъявляемые стимулы и четкая синхронизация по времени события и регистрируемого ответа. Это парадигма регистрации вызванных потенциалов (ВП) или связанных с событием потенциалов. Одной из особенностей ВП является их малая амплитуда по отношению к спонтанной

активности ЭЭГ, которая в данном случае выступает как шум. Например, зрительные ВП имеют амплитуду до 10 мкВ, а средний амплитудный уровень ЭЭГ составляет 50 мкВ.

Таким образом, одной из черт сигналов ЭЭГ, анализируемых в данной работе, является высокая доля «шума» в виде спонтанной (не связанной с событием) ритмической составляющей, отражающей общее функциональное состояние человека.

Следующей чертой спонтанной ЭЭГ является ее чувствительность к изменению общего состояния человека и условий проведения исследования: чувствительность к влиянию внешних раздражителей, не связанных с выполняемой задачей (таких как шум, освещение и др.), к «уровню бодрствования» и мобилизации человека, к «внутренним» состояниям: эмоциям, переживаниям. Достаточно много данных свидетельствует о том, что даже кратковременные флуктуации в ЭЭГ, особенно в альфа-полосе (8-14 Гц) ее частотного спектра, во многих случаях отражают колебания уровня функционального состояния мозга, определяющего, в частности, эффективность сенсомоторной деятельности [72, 53, 11, 61] человека. Существует представление о том, что «в спонтанных флуктуациях альфа-активности ЭЭГ человека может отражаться временная структура психической активности» (цитата по [26]). Вариативность и изменчивость паттернов ЭЭГ приводит к тому, что каждое регистрируемое событие происходит на разном «уровне» фоновой ритмики ЭЭГ, что может накладывать отпечаток на сигнал при малом количестве накоплений.

Особенностью ЭЭГ, регистрируемой с поверхности головы, является ее относительно низкое пространственное разрешение. Это, с одной стороны, препятствует четкой локализации сигнала, с другой стороны, может быть в некоторой мере преодолеваться при помощи пространственной фильтрации сигнала и выделения источников при помощи метода главных и независимых компонент.

Вышеперечисленные свойства ЭЭГ сигнала обуславливают особые требования к математическому аппарату анализа и классификации таких

сигналов, так как именно ЭЭГ наиболее широко используется для построения современных ИМК, благодаря следующим ключевым преимуществам: неинвазивность метода, высокое временное разрешение, мобильность (малый размер и вес оборудования) и невысокая стоимость.

Большинство разрабатываемых ИМК основаны на анализе многоканальной ЭЭГ. Для распознавания паттернов мысленных команд используются различные показатели ЭЭГ сигналов, такие как зрительные вызванные потенциалы, медленные корковые потенциалы, компонент Р300, паттерны ЭЭГ, соответствующие различным типам ментальной деятельности и сенсомоторные мю и бета ритмы.

ИМК на основе зрительных вызванных потенциалов.

ИМК, использующий зрительные вызванные потенциалы (ЗВП) для формирования управляющих команд исполнительному устройству, был предложен еще в начале 1970х годов [113]. В данном интерфейсе анализировались сигналы ЭЭГ от отведений, расположенных в затылочной области, соответствующие активности зрительной коры. Классифицирующая способность основывалась на эффекте зависимости ЭЭГ от направления взора. Таким образом, можно было сдвигать курсор монитора в ту точку, куда испытуемый произвольно направлял взор. Испытуемым предъявлялись мерцающие стимулы, измерялась амплитуда зрительно вызванных потенциалов через 100 мс после начала мерцаний каждой из групп стимулов. Амплитуда компоненты ЭЭГ была выше, если мерцала группа, в которую входил стимул, на который смотрел испытуемый.

Данный тип интерфейсов использует признаки, возникающие при формировании команды, управляющей направлением взора. Однако направление взора может быть определено и другим, более прямым способом, например, по зависимости амплитуды ЗВП от увеличения внимания на некоторый выделенный стимул [25].

ИМК на основе компонента P300.

Другим вариантом использования ЗВП в ИМК является применение потенциала P300. Данный потенциал отражается в записи ЭЭГ около 300 мс после предъявления значимого стимула и имеет длительность около 300 мс и положительную амплитуду до 15мкВ [48]. Таким образом, P300, вероятно связанный с процессом концентрации внимания, формируется при предъявлении именно того целевого стимула, который ожидает пользователь. Данный подход не требует длительного обучения перед использованием в ИМК. Ограничением использования P300 состоит в необходимости редкого предъявления целевого стимула среди незначимых, иначе происходит существенное снижение выраженности ответа в ЭЭГ.

Впервые ИМК на основе P300 был предложен в [48]. Интерфейс представлял собой матрицу размерностью 6x6, состоящую из букв, цифр и других символов или команд. Каждые 125 мс в случайном порядке высвечивался один ряд или одна колонка матрицы. В соответствии с природой P300, компонент появлялся только тогда, когда предъявляемый испытуемому ряд или колонка содержали этот символ. После предъявления всех 12 рядов и колонок можно вычислить вызванные ответы на предъявление каждой колонки и каждого ряда. Общее количество таких сумм равно 36 по числу различных парных комбинаций рядов и колонок. Наибольшая сумма должна соответствовать комбинации того ряда и той колонки, которые на пересечении содержали задуманный символ.

Дальнейшему развитию интерфейсов на основе P300 с помощью внедрения новых алгоритмов извлечения признаков и новых средств классификации посвящено значительное число исследований [58, 62]. В России изучение и совершенствование данной парадигмы также является актуальной темой исследований. Так, в работе [2] было предложено использование, одновременно с волной P300, других компонент ЭЭГ и мозговых потенциалов, связанных с событиями, с целью уменьшения времени распознавания вводимой оператором команды. Ранее было показано, что реакции оператора на целевые стимулы в ИМК сопровождаются не только волной P300, но и более ранним негативным

компонентом (N1), максимально выраженным в латеральных затылочных областях. В работе Шишкина С.Л. и коллег [27] показано, что характеристики работы ИМК при совместном использовании компонентов P300 и N1 достигается наилучшая эффективность интерфейса, по сравнению с вариантами использования компонентов по отдельности.

Несомненным достоинством этого ИМК является то, что его использование не требует предварительной тренировки. P300 – это естественный компонент вызванного ответа, возникающий в определенной экспериментальной ситуации. Вместе с тем, этот компонент изменяется как в сторону уменьшения, так и в сторону увеличения по мере повторения ситуации [25]. Поэтому, несмотря на то, что испытуемый может начинать пользоваться таким ИМК практически без предварительной тренировки, для обеспечения его длительного использования требуется наличие адаптивности алгоритма выделения компонента P300.

Однако внедрение ИМК P300 в реальную практику пока сдерживается ограниченной функциональностью и недостаточной эргономичностью пользовательского интерфейса ИМК P300. «В частности, отсутствие средств автоматического привлечения внимания к предъявляемым в контуре ИМК стимулам делает его незащищенным от внешнего фона неконтролируемых стимулов, а расположение символов в форме регулярной матрицы заранее определяет частичное смешение целевых и нецелевых стимулов в корковых ответах» [1].

ИМК на основе классификации типов ментальной деятельности. Отдельную группу интерфейсов образуют ИМК, основанные на распознавании паттернов ЭЭГ, соответствующих различным типам ментальной деятельности. При условии, что устойчивый паттерн ЭЭГ формируется при решении ментальной задачи определенного класса (например, вербального, логического, пространственного, моторного воображения), возможно связывание такого паттерна с командой управления внешним устройством. Для достижения этой цели необходимо решение нескольких проблем: 1) разработка наборов задач для

пользователя, формирующие устойчивые паттерны нескольких типов ментальной деятельности; 2) извлечение характерных признаков; 3) выбор оптимального классификатора. В большинстве работ в качестве пространственно-временного паттерна ЭЭГ исследуется пространственное распределение амплитуд различных ритмов ЭЭГ по поверхности головы, перестройка которых, как известно, отражает доминирование тех или иных когнитивных процессов [25].

Одним из вариантов такого ИМК является предложенный Z.A. Keirn и коллегами в 1990 г. [65] интерфейс на основе четырех типов задач: арифметическое умножение; воображаемое вращение геометрической фигуры; мысленное составление письма; визуальное представление последовательности чисел. Наборы задач были разработаны так, чтобы вызывать асимметрию в спектре основных частотных диапазонов.

Данный подход получил свое развитие в работах [29, 87], использующих для классификации искусственные нейронные сети, нечеткую логику и новые наборы задач.

В России изучению ритмов ЭЭГ при мышлении посвящен ряд исследований, начиная с 1990-х годов [17]. Было установлено, что при решении определенных мысленных задач спектры ЭЭГ закономерным образом изменяются, образуя специфичные для данного вида мышления паттерны (сочетание частоты, амплитуды и топографии). Выявленные паттерны являются устойчивыми и позволяют с высокой вероятностью (до 90% верных распознаваний) определять тип решаемой ментальной задачи [10].

Исследование динамики ЭЭГ при выполнении разнотипной ментальной деятельности является фундаментальной задачей. На практике выделение паттернов сопряжено со значительным временем решения задачи определенного типа, что ограничивает использование такого подхода для управления устройствами посредством ИМК. К тому же, такое управление является непрямым и требует значительного периода обучения. В ИМК наиболее широко используется один класс ментальных задач - воображение движений.

ИМК на основе компонента воображаемых движений.

Для классификации паттернов ЭЭГ в неинвазивных ИМК, основанных на распознавании воображаемых движений, используются показатели вызванной синхронизации/десинхронизации ЭЭГ в частотных диапазонах мю ритма и бета ритма ЭЭГ (в моторных и сенсомоторных областях), а также параметры вызванных потенциалов [81]. При создании ИМК на основе ЭЭГ сигналов, зарегистрированных при совершении воображаемых движений, одной из задач исследований является выделение сигнала для классификации, позволяющего с высокой вероятностью верного решения разделить паттерны моторных команд [63].

В частности, на анализе показателей сенсомоторного ритма основан ИМК «Wadsworth» [117, 67], в котором испытуемые используют воображаемые движения руки и всего тела для управления курсором на экране компьютера (в процессе обучения сознательной модуляции амплитуды своих сенсомоторных потенциалов).

«Graz» ИМК [91, 83] основан на различении воображаемых движений крупных частей тела – рук и ног – для управления курсором, виртуальной клавиатурой и ортопедическим устройством для парализованной руки.

«Berlin» ИМК [36] использует различение воображаемых движений правых и левых конечностей для управления компьютерными приложениями. В работе [45] использовались воображаемые движения рук, ног и языка для управления трехмерной моделью вертолета. Подобные системы ИМК также используются рядом исследователей для управления роботизированными протезами конечностей, инвалидными креслами и пр. [118].

В России на сегодняшний день отсутствуют применяемые в клинике коммерческие разработки подобные описанным выше. Вместе с тем, существуют российские научные коллективы международного уровня, исследующие нейрофизиологические аспекты, позволяющие разрабатывать современные нейроинтерфейсы на базе воображаемых движений. Так, актуальные работы по классификации воображаемых движений по паттернам ЭЭГ, в основном,

направлены на распознавание воображаемых движений крупных частей тела: рук, ног, кисти руки и стопы [12, 8, 16, 19, 14] с использованием различных методов классификации: Байесовского классификатора, линейного дискриминантного анализа, метода опорных векторов, ансамбля искусственных нейронных сетей. В 2016 г. сообщено о первом применении ИМК на основе моторного воображения в клинике для реабилитации пациентов, перенесших инсульт [80].

ИМК на основе компонента воображаемых движений мелкой моторики.

Многие исследования последних лет были посвящены различению воображаемых движений относительно крупных частей тела: рук, ног, движений в локтевых и плечевых суставах [124], запястье [56], и др. Вместе с тем, использование воображаемых движений «мелкой» моторики может обеспечить большее количество степеней свободы для системы ИМК и позволит приблизить ее использование на практике.

Количество работ, анализирующих ЭЭГ паттерны реальных и воображаемых движений пальцами руки, невелико. Некоторые из них приведены в таблице 1. Решение задачи классификации паттернов ЭЭГ сигналов, соответствующих воображению движений мелкой моторики руки для неинвазивного ИМК, важно для разработки методов восстановления подвижности пальцев рук после инсульта, травм мозга и для управления роботизированными протезами кисти руки. Сложность классификации ЭЭГ сигналов связана с низким пространственным разрешением метода.

Таблица 1. Современные исследования по классификации ЭЭГ паттернов мелкой моторики

Ссылка на работу	(а) Анализируемый сигнал (б) Тип движений (в) Длительность анализируемого сигнала (г) Количество испытуемых	Анализируемые параметры сигнала	Тип классификатора	Количество классов: Вероятность успешной классификации
[121]	(а) ЭЭГ (б) Сгибание 5 пальцев руки по отдельности (в) 2 с (г) 10	Проекционные веса 3-х Гл.К.	МОВ (РБФ)	1) 2 класса (движения от фона): 91% 2) 5 классов: 39,7%
[123]	(а1) ЭЭГ (а2) ИК-спектроскопия (б) Воображаемые сжатия кисти руки (скорость - 3 градации, сила - 3 градации) (в) 10 сек (г) 6	(п1) мгновенные амплитуда, фаза, частота и мощность в скользящем окне 0,5 с для а1 (п2). оксигемоглобин и деоксигемоглобин для а2	ИНС с 1 скрытым слоем и прямым распростр-м ошибки	2 класса: 89 ±2% (по п1 и п2 совместно)
[122]	(а) ЭЭГ (б) Сгибание 5 пальцев руки по отдельности (в) 2 с (г) 6	(п1) Коэффициенты 3-х Гл.К. (п2) Сигнал ЭЭГ во временной области	МОВ (РБФ)	5 классов: п.1. - 45.2%; п.2. - 39%;
[97]	(а) ЭЭГ, МЭГ (б) Нажатия большим, указательным, средним пальцами и мизинцем (в) 500 мс (г) 13	(п.1) Изменение амплитуды ЭЭГ и МЭГ в полосе 0.15-16Гц, с частотой дискрет-и 32Гц; (п.2) Мощность МЭГ в частотной полосе 1-120 Гц с шагом 2.5 Гц.	Ансамбль МОВ	4 класса: ЭЭГ - 43% МЭГ - 57%. По параметрам п.1. выше, чем по п.2.
[75]	(а) ЭЭГ, ЭКоГ (б) Реальные движения пальцами руки (в) 2 с (г) 10	Проекционные веса 3-х Гл.К.	МОВ (РБФ)	2 класса: -по ЭЭГ 77,1% -по ЭКоГ 91,3%
[107]	(а) ЭЭГ (б) Реальные и воображаемые движения большим и указательным пальцами (в) 2,3с, (г) 8	Площадь сегмента в скользящем временном окне	МОВ (РБФ) ИНС	4 класса: 45%

Примечание. ЭКоГ – электрокортикограмма, МОВ – метод опорных векторов, МОВ (РБФ) – метод опорных векторов на основе радиальной базисной функции; ИНС - искусственная нейронная сеть, ЛДА- линейный дискриминантный анализ, Гл.К. - главные компоненты, ГА – генетический алгоритм. Теоретический порог случайной классификации для 2-х движений - 50%, для 4-х - 25%, для 5 – 20%.

Следует отметить несколько научных коллективов, которые продемонстрировали принципиальную возможность мультиклассового

распознавания ЭЭГ паттернов, соответствующим реальным и воображаемым движениям пальцев руки. R. Xiao и L. Ding [122] предприняли попытку различения реальных движений пяти пальцев одной руки, используя для этого спектральные и временные характеристики ЭЭГ, при этом средняя вероятность успешного распознавания составила 45% (при выборе 1 из 5 возможных классов). Следует отметить, что приведенные в работе результаты показали неэффективность использования математического аппарата и характерных признаков, стандартно применяемых для различения движений больших частей тела (спектральная мощность в различных частотных диапазонах). Наилучший результат был получен при анализе сигнала во временной области (сравнение временного ряда амплитуд) и при использовании метода главных компонент в частотной области, который показал значимость учета высокочастотных составляющих.

В работе F. Quandt и коллег [97] проводится оценка возможности распознавания реальных движений (нажатие на кнопку) пальцев одной руки (четырёх пальцев из пяти – большого, указательного, среднего и мизинца) при помощи анализа временных рядов данных МЭГ и ЭЭГ. Средняя вероятность успешной классификации для сигналов МЭГ составила 57% (максимально - 70%), для сигналов ЭЭГ – 43% (максимально 54 %).

Существующие методы классификации сигналов ЭЭГ, соответствующих определенным моторным командам, достаточно эффективны для систем управления движениями крупных частей тела (рук или ног в целом). Для эффективного решения задачи классификации воображаемых моторных команд, управляющих движениями мелких частей тела, например, пальцев одной руки, требуется исследование и разработка новых методов классификации. Эффективное решение задачи распознавания паттернов крупной и мелкой моторики в совокупности позволит разработать более универсальные ИМК, использующие сигналы ЭЭГ для управления внешними устройствами с большим числом степеней свободы.

1.4. Методы анализа сигналов ЭЭГ

Специфика обработки и анализа многомерных временных рядов, которыми являются сигналы ЭЭГ, определяется задачами, необходимость решения которых привела к появлению энцефалографии. В общем понимании, прямой задачей энцефалографии является определение биоэлектрического потенциала в точках измерения по заданным источникам [5, 85]; обратной задачей является локализация источников электрической активности головного мозга на основании анализа распределения потенциалов на поверхности головы человека [4]. Одним из этапов решения обратной задачи ЭЭГ является выделение информативного биоэлектрического сигнала.

Количество методов анализа ЭЭГ сигнала, для выделения информативных признаков постепенно расширяется. Можно определить несколько направлений анализа биоэлектрических сигналов на основе решаемых задач и используемых методов.

Первое направление связано с оценкой функционального состояния человека и его изменений в относительно продолжительный период времени (порядка минут). Эти методы отличаются тем, что сигнал ЭЭГ накапливается относительно долгое время, в течение которого обеспечивается стационарность общего состояния человека и, несмотря на некоторые флуктуации ритмической активности, происходит усреднение по всему временному отрезку, и такая запись рассматривается как относительно стабильная. В данном случае для анализа биоэлектрической активности не используется синхронизация по времени биоэлектрических «ответов» и используются методы, не учитывающие временные особенности ЭЭГ сигнала. При этом могут применяться как линейные, так и нелинейные методы анализа ЭЭГ, такие как быстрое преобразование Фурье, анализ пространственной сложности и пространственной неупорядоченности сигнала, когерентный анализ на основе быстрого преобразования Фурье. Для выделения источников спонтанной (не связанной с событием) ЭЭГ могут применяться методы анализа *главных* и *независимых компонент*, повышающие пространственное разрешение ЭЭГ при многоканальной записи.

Второе направление анализа ЭЭГ связано с использованием временной синхронизации регистрируемой активности и исследуемого события. При этом происходит анализ ЭЭГ, в том числе, и во временной области. В данную группу методов, прежде всего, входит *анализ вызванных потенциалов и связанных с событием потенциалов* при помощи *когерентного накопления и когерентного усреднения сигнала*, синхронизованного с исследуемым событием. Анализ ВП направлен на подавление не связанной с событием спонтанной ритмики ЭЭГ и выделение низкоамплитудного сигнала. Для уменьшения количества необходимых повторений проб и выделения потенциала даже при единичных реализациях может использоваться *метод пространственного усреднения*, при котором происходит суммация сигнала не во временной области, а в пространственной, при этом выделяются ответы при подаче единичного стимула за счет усреднения по пространству электродов, так как «ответ» из-за смазывания сигнала скальпом не происходит локально [3].

Для анализа ЭЭГ сигнала в частотной и временной области используются методы анализа вызванной синхронизации/десинхронизации ЭЭГ и вейвлет-преобразования ЭЭГ. Сущность *метода анализа вызванной синхронизации/десинхронизации ЭЭГ* заключается в том, что фрагменты ЭЭГ, после предъявления стимула, подвергаются полосовой фильтрации в заданных частотных диапазонах, затем вычисляется величина изменения мгновенной мощности ЭЭГ (квадрата амплитуды сигнала) в тестовом интервале по сравнению с референтным интервалом (спокойного бодрствования до начала предъявления стимула) [92].

При *вейвлет-преобразовании* происходит свертка ЭЭГ сигнала в пространственной и временной области, что обеспечивает возможность оценки изменения мощности ЭЭГ в различных частотных диапазонах во времени, синхронизованном с предъявлением стимула (или другим событием, таким как фиксирующийся моторный ответ).

При анализе синхронизованного с событием сигнала ЭЭГ используется метод накопления ответов, при котором нивелируется влияние спонтанной

активности ЭЭГ на исследуемый сигнал. В данном направлении исследований также возможно применение методов пространственной фильтрации сигналов ЭЭГ для выделения источников активности, таких как анализ независимых компонент ВП, дипольный анализ.

Для выделения источников биоэлектрической активности по сигналам, регистрируемым со скальпа, используются методы анализа главных компонент, анализа независимых компонент, дипольный анализ, метод реконструкции источников биоэлектрической активности [4] и др.

1.5. Классификация методов распознавания ЭЭГ паттернов

Управление в системах ИМК основывается на распознавании паттернов ЭЭГ различных мысленных команд с помощью математических методов классификации. Необходимо отметить, что для обеспечения высокой эффективности распознавания необходим такой метод классификации, который наилучшим образом классифицирует используемый в конкретной работе набор признаков, учитывая его природу, размерность и вариативность. При выборе методов классификации для ЭЭГ сигналов важно учитывать особенности векторов характерных признаков и специфику ЭЭГ, а именно:

- 1) низкое соотношение сигнал/шум,
- 2) наличие выбросов в выборках,
- 3) высокая размерность векторов признаков, связанная с вариативностью и многоканальностью ЭЭГ, а также необходимость учета динамики изменений во времени,
- 4) малое число проб в обучающих выборках, т. к. эксперименты связаны с привлечением испытуемых и затратны по времени и ресурсам.

На рис. 3 приведены типы классификаторов и лежащие в их основе методы, применяющиеся для классификации ЭЭГ в ИМК [76, 82]



Рис. 3. Иерархический список классификаторов, использующихся для различения ЭЭГ паттернов в ИМК.

Обзор существующих методов классификации и анализ их свойств приводится ниже.

1.6. Линейные классификаторы

Классификаторы, использующие линейные функции для разделения классов, широко применяются в ИМК. Они основаны на простых моделях, устойчивы – в плане низкой зависимости от малых вариации входных данных – и продемонстрировали свою эффективность при классификации паттернов ЭЭГ крупной моторики [82]. Вместе с тем, наличие выбросов, зашумленность и

нестационарность ЭЭГ накладывают ограничения на использование данного класса методов для классификации сложных многомерных паттернов.

Линейный дискриминантный анализ (ЛДА).

ЛДА основан на нахождении гиперплоскости, разделяющей классы данных. При классификации ЭЭГ в ИМК вычисляются значения векторов характерных признаков $x_k \in X$, $k = 1:K$, из X - множества векторов признаков в n мерном пространстве. В обучающем наборе для каждого вектора x_k имеется значение y_k , равное метке принадлежности соответствующему классу. В случае наличия только двух классов $y_k \in \{-1, +1\}$. Дискриминирующая функция является линейной комбинацией компонентов вектора x и имеет вид:

$$y(x) = w^T x + b,$$

где w – вектор весов, b - пороговое значение (или смещение) [46].

Уравнение $y(x) = 0$ определяет разделяющую поверхность для двух классов, в случае, когда $y(x)$ линейна, такая поверхность является гиперплоскостью. Такая гиперплоскость H делит признаковое пространство на два подпространства, и если $y(x) > 0$, то x находится с положительной стороны от H , если $y(x) < 0$ – с отрицательной. Дискриминирующая функция позволяет вычислить алгебраическое расстояние от x до гиперплоскости. Для этого согласно [46] выразим x как: $x = x_p + r \frac{w}{\|w\|}$, где x_p - нормальная проекция x на гиперплоскость H , r - искомое расстояние.

Тогда, поскольку $y(x_p) = 0$,

$$y(x) = w^T x + b = r \|w\| \text{ или } r = \frac{y(x)}{\|w\|}$$

Таким образом, линейная дискриминирующая функция разделяет пространство признаков гиперплоскостью, ориентация которой определяется вектором-нормалью w , а расположение – смещением b . Функция $y(x)$ связана пропорцией с расстоянием от x до гиперплоскости.

Следует отметить, что ЛДА основан на допущении о нормальном распределении данных и равенстве ковариационных матриц обоих классов. Тогда разделяющая гиперплоскость находится путем поиска проекций, которые максимизируют расстояние между средними двух классов и минимизируют дисперсию внутри классов [51].

Для решения мультиклассовой задачи при количестве классов больше 2 используются несколько гиперплоскостей. Наиболее широко в ИМК используется стратегия «один против всех», состоящая в разделении одного класса и всех остальных.

ЛДА имеет высокое быстродействие и способен классифицировать ЭЭГ паттерны с удовлетворительной вероятностью верных решений, что сделало его одним из наиболее широко применяющихся методов в практических реализациях ИМК [92, 76]. Из преимуществ вытекает и основной недостаток ЛДА, состоящий в его линейности, что может стать причиной низкой эффективности метода при анализе сложных нелинейных данных ЭЭГ [52].

Метод опорных векторов (МОВ).

МОВ, также как и ЛДА, использует гиперплоскость для разделения классов. Отличие состоит в методе ее нахождения. МОВ стремится максимизировать отступы от ближайших паттернов, соответствующих векторам признаков из обучающей выборки. Метод предполагает преобразование данных для представления паттернов в пространстве высокой размерности, обычно значительно превосходящей размерность исходного пространства признаков.

МОВ относится к методам линейной классификации и заключается в разделении выборки на классы с помощью оптимальной разделяющей гиперплоскости, уравнение которой в общем случае имеет вид: $f(x) = w \cdot \phi(x) + b$.

Классификация на основе МОВ принимает решение о принадлежности данного вектора признаков x одному из двух классов в зависимости от того, с какой стороны от гиперплоскости он находится. Тогда вектор признаков x будет

классифицирован МОВ в соответствии с тем, положительное или отрицательное значение примет следующее выражение

$$\begin{aligned} w \cdot \phi(x) + b &= \sum_{i=1}^n \lambda_i y_i (\phi(x_i) \cdot \phi(x)) + b \\ &= \sum_{i=1}^n \lambda_i y_i K(x_i, x) + b, \end{aligned}$$

где коэффициенты λ_i зависят от y_i - вектора меток класса принадлежности, и от значения скалярных произведений $K(x_i, x) = (\phi(x_i), \phi(x))$.

Таким образом, для нахождения решающей функции необходимо знать значения скалярных произведений. Преобразования данных определяются функцией-ядром: $K(x_i, x_j) = (\phi(x_i), \phi(x_j))$. В случае линейной классификации МОВ ядро имеет вид: $K(x_i, x_j) = x_i^T x_j$. При переходе к нелинейной классификации методом МОВ применяется нелинейная функция ядра. Данный подход делает возможным поиск оптимальной разделяющей гиперплоскости в преобразованном пространстве признаков.

Наиболее распространенными функциями ядра являются [82]:

- Полиномиальное: $K(x, x') = (x^T \cdot x' + \theta)^d$, $d \in \mathbb{N}, \theta \in \mathfrak{R}$
- Сигмоид: $K(x, x') = \tanh(k(x^T \cdot x') + \theta)$, $k, \theta \in \mathfrak{R}$
- Радиальная базисная функция Гаусса: $K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right)$

МОВ на основе радиальной базисной функции (МОВ РБФ) продемонстрировал высокую вероятность успешной классификации паттернов ЭЭГ в ИМК [76].

МОВ обладает несколькими ключевыми преимуществами: подход по максимизации зазора между опорными векторами обеспечивает высокие обобщающие способности; отсутствует чувствительность к переобучению [40]. Также метод позволяет настраивать некоторые параметры в соответствии с особенностями классифицируемых данных, а именно: параметр регуляризации C и ширина РБФ (при использовании МОВ РБФ). Основным недостатком является

относительно низкое быстродействие и малая чувствительность к высоковариативным особенностям паттернов.

1.7. Классификаторы на основе методов ближайших соседей

Методы ближайших соседей используют подход, при котором вектору признаков присваивается принадлежность тому классу, который является наиболее распространённым среди ближайших соседей. Такими соседями могут быть вектора признаков из обучающего набора (метод k ближайших соседей) или класс-прототип (метод на основе расстояния Махаланобиса).

k ближайших соседей. Целью данного метода состоит в присвоении ранее не наблюдавшейся точке того класса, который доминирует среди k ее ближайших соседей из обучающего набора. Ближайшие соседи обычно определяются с помощью метрики расстояния в Евклидовом пространстве. Данный подход является распространённым при использовании в ИМК [35]. При достаточно высоком k и достаточно большом обучающем наборе, метод может эффективным при разделении трудно разделимых классов.

Вместе с тем, классификаторы на базе k ближайших соседей не часто демонстрируют высокую вероятность успешной классификации больших массивов многомерных данных в современных ИМК, так как соотношение сигнал/шум в ЭЭГ данных мало, а вектора признаков имеют большую размерность [82].

Расстояние Махаланобиса. Метод классификации на основе расстояния Махаланобиса определяет сходство неизвестной и известной выборок, по результатам оценки выносится решение о принадлежности классу. Вектор признаков x будет соотнесен к тому классу c , прототип которого является ближайшим (с минимальной дистанцией $d_c(x)$) [77], $d_c(x) = \sqrt{(x - \mu_c)M_c^{-1}(x - \mu_c)^T}$ где μ_c - среднее значение класса-прототипа, M_c - матрица ковариаций.

Данный метод предполагает, что распределение $N(\mu_c, M_c)$ каждого из прототипов класса Гауссово. Таким образом, расстояние Махаланобиса с

помощью матрицы ковариаций связана с корреляциями переменных. Когда корреляция между переменными равна нулю, расстояние Махаланобиса эквивалентно квадратичному Евклидову расстоянию.

Данный метод является относительно простым и устойчивым, продемонстрировавшим свою применимость в асинхронных ИМК [76, 42].

1.8. Байесовские классификаторы. Скрытые Марковские модели

Классификаторы на основе Байесова подхода направлены на вычисление вероятности принадлежности данного вектора признаков к возможным классам и отнесение его к классу с наибольшей вероятностью. Для классифицируемого объекта вычисляются функции правдоподобия каждого из классов, по ним определяют апостериорные вероятности принадлежности данного вектора признаков к возможным классам.

Среди большого числа байесовских методов классификации для распознавания паттернов ЭЭГ чаще используются скрытые модели Маркова. Они продемонстрировали свою способность к классификации многомерных временных рядов с приемлемым уровнем вероятности успешной классификации ЭЭГ паттернов моторных команд [76].

Скрытые Марковские модели (СММ).

В задачах анализа процесса, который развертывается во времени, имеются состояния в момент времени t , на которые непосредственно влияют состояния в предшествующий момент $t - 1$. Метод СММ представляет собой основанный на подходе Байеса по максимизации апостериорной вероятности метод классификации таких временных рядов. Паттерн из тестовой выборки классифицируется той моделью, которая имеет самую высокую апостериорную вероятность, то есть, лучше всего "объясняет" паттерн. Данный метод продемонстрировал свою эффективность для решения задачи распознавания речи и широко применяется для анализа сигналов, классификации, моделирования и управления [98].

Введем обозначение последовательности состояний длины T в каждый момент времени t : $\omega^T = \{\omega(1), \omega(2), \dots, \omega(T)\}$. Тогда модель любой последовательности переходов описывается вероятностями перехода:

$$P(\omega_j(t+1) | \omega_i(t)) = a_{ij},$$

не зависящая от времени вероятность иметь состояние ω_j на шаге $t+1$ в зависимости от состояния ω_i на предыдущем шаге t .

На практике последовательность скрытых состояний системы не известна, наблюдаются лишь видимые состояния $v(t)$. Определим последовательность таких видимых состояний как $V^T = \{v(1), v(2), \dots, v(T)\}$. Тогда в каждом скрытом от нас состоянии $\omega(t)$ имеется вероятность наблюдать одно из видимых состояний $v_k(t)$. Вероятность этого равна:

$$P(v_k(t) | \omega_j(t)) = b_{jk}.$$

Такая модель со скрытыми состояниями системы называется скрытой Марковской моделью. Пример СММ приведен на рис. 4.

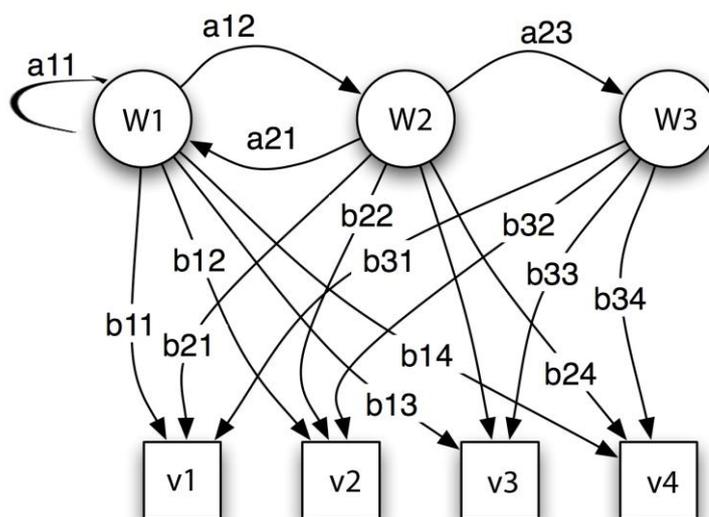


Рис. 4. Вариант СММ системы с тремя скрытыми состояниями, с неполным набором разрешенных переходов.

В целом такие сети (аналогичные изображенной на рис. 4) являются машинами с конечным числом состояний, и когда они связаны вероятностями

перехода, они называются сетями Маркова [46]. Вероятности перехода зависят только от предыдущих состояний. Конечным состоянием модели является то, для которого вероятность перехода в себя равна 1 ($a_{00} = 1$).

Требуется, чтобы переход осуществлялся на каждом шаге $t \rightarrow t+1$, даже если это переход в то же состояние, и, чтобы видимое состояние наступало после каждого перехода. Таким образом, нормализация происходит согласно:

$\sum_j a_{ij} = 1$ для всех i , и $\sum_k b_{jk} = 1$ для всех j при суммировании по всем скрытым и видимым состояниям.

Для построения СММ при имеющейся последовательности наблюдаемых состояний необходимо решение трех фундаментальных задач:

1. Проблема оценки. Предположим, что мы имеем СММ и вероятности перехода a_{ij} и b_{jk} . Определить вероятность того, что конкретная последовательность видимых состояний V^T была сгенерирована этой моделью.

2. Проблема декодирования. Предположим, что мы имеем СММ, а также множество наблюдений V^T . Определить наиболее вероятную последовательность скрытых состояний ω^T , которые послужили причиной к этим наблюдениям.

3. Проблема обучения. Пусть дана укрупненная структура модели (число состояний и число видимых состояний), но *не* вероятности переходов a_{ij} и b_{jk} . Имея обучающую выборку видимых состояний, необходимо определить эти параметры модели (найти наиболее правдоподобную модель).

Проблемы 1 и 2 решаются на этапе декодирования с использованием форвардной процедуры или алгоритмов Витерби [98]. Проблема 3 решается в процессе обучения с помощью итеративной процедуры поиска локального максимума (алгоритм Баума-Велха) [98] либо с помощью алгоритма глобальной оптимизации – имитации отжига [41].

При использовании в ИМК скрытые Марковские модели могут рассматриваться как вероятностный автомат, который вычисляет вероятность наблюдения заданной последовательности векторов признаков. Каждое состояние

автомата может моделировать вероятность наблюдения данного вектора признаков. В ИМК эти вероятности, как правило, являются Гауссовыми моделями [76].

СММ, благодаря своей природе, эффективны при классификации временных рядов. Поскольку ЭЭГ содержат характерные признаки, выделяемые во временной области, метод СММ применялся для классификации ЭЭГ в ИМК [86, 42]. Вместе с тем, СММ не нашли широкого применения при разработке ИМК, несмотря на относительно высокую вероятность верных решений, полученную в указанных исследованиях. Одним из основных ограничивающих факторов является необходимость выявления набора наблюдаемых состояний, связанных с событием, и не изменяющихся во времени. При анализе ЭЭГ выявление таких состояний возможно, например, при изучении вызванной десинхронизации (как в работе [86]), регистрируемой в разных каналах ЭЭГ. В случае же, если исследуются связанные с событием сигналы с близкой локализацией и сходной динамикой, то выделение устойчивых наблюдаемых состояний затруднительно. Требуется выявление аттракторов процесса, причем тех и только тех, которые связаны с классифицируемым событием, а не с фоновой активностью нервной системы. Более глубокое изучение ЭЭГ сигналов и нейрофизиологических принципов функционирования мозга может обеспечить такую возможность. В этом случае актуальность применения СММ может значительно возрасти.

1.9. Искусственные нейронные сети

Искусственные нейронные сети (ИНС) являются распространенным методом классификации ЭЭГ паттернов, продемонстрировавшим свою эффективность для распознавания сложных многомерных образов [76]. Среди различных архитектур ИНС, многослойный персептрон (МП) используется для классификации в ИМК наиболее часто.

МП состоит из нескольких слоев искусственных нейронов: входного слоя, на который подается вектор признаков, одного или нескольких скрытых слоев, и

выходного слоя. На вход каждого нейрона скрытого слоя подаются выходные значения нейронов предыдущего ряда. Итоговое решение о принадлежности данного вектора признаков одному из классов принимается нейронами выходного слоя.

ИНС формируют ответ вида: $y(x, w) = f\left(\sum_{j=1}^N w_j \phi_j(x)\right)$, где f - нелинейная функция активации, w - вектор весов, ϕ - нелинейные базисные функции. Обучение нейронных сетей состоит в настройке весов, а также базисных функций.

ИНС являются универсальными аппроксиматорами, так, с помощью линейных операций и одной нелинейной функции активации, можно приблизить любую непрерывную функцию с любой желаемой точностью. К тому же число распознаваемых классов не ограничено, что позволяет использовать ИНС для решения большого многообразия задач. МП применялся для классификации ЭЭГ паттернов как в ИМК реального времени, так и в офф-лайн исследованиях [76]. Сложность и универсальность классификатора являются причиной его подверженности переобучению и чувствительности к вариативности обучающей выборки. В связи с этим, для эффективной классификации необходим тщательный подбор архитектуры ИНС и выбор оптимальных параметров.

Нерешенной на данный момент проблемой является автоматический выбор оптимальных нелинейных функций активации нейронов скрытых слоев. Перебор функций из ограниченного набора может быть эффективным лишь в случае одинаковых функций для всех нейронов в слое, однако он не эффективен в случае гибкой настройки.

Другой важной задачей, требующей решения при применении ИНС, является задача регуляризации, подбора сложности модели (выбора топологии ИНС). В то время, как количество входов и выходов задается соответственно размерностью пространства признаков и количеством итоговых классов, общее количество весов или параметров сети остается неопределенным. Если будет использоваться слишком много параметров, вероятность успешной

классификации будет низкой; и наоборот, если слишком мало параметров, то обучение будет затруднено.

Для решения задачи выбора оптимальных функций активации и топологии ИНС необходимо предварительное изучение природы классифицируемых данных и учет их особенностей.

1.10. Ансамбли классификаторов

Построение ансамбля из набора несовершенных классификаторов рассматривается в качестве способа нивелирования известных ограничений локальных классификаторов, которые комбинируются таким образом, который минимизирует ошибку итоговой классификации. Целесообразно использование методов системного анализа данных при проектировании коллективных классификаторов [6]. Существует несколько стратегий по объединению классификаторов в ансамбли.

1. Усреднение и взвешенное усреднение. Ответы локальных классификаторов образуют пул решений и формируют линейную комбинацию, в которой в качестве веса может учитываться относительная вероятность верного решения локального классификатора [106].

2. Голосование. Используются несколько классификаторов, каждый из которых классифицирует один и тот же входной вектор признаков. Окончательный класс выбирается большинством голосов локальных классификаторов. Голосование является наиболее популярным способом объединения классификаторов в ИМК исследованиях, вероятно, вследствие простоты и эффективности [76].

3. Бустинг (англ. boosting). Подход по объединению локальных классификаторов последовательность, в которой каждый следующий классификатор стремится компенсировать недостатки композиции предыдущих. Другими словами, бустинг состоит в том, что классификаторы следующего уровня фокусированы на анализ тех проб, которые были ошибочно распознаны на предыдущем уровне. Данный подход позволяет построить относительно

эффективный ансамбль (или каскад) из нескольких классификаторов, вероятность верных решений для которых лишь незначительно превышает уровень угадывания. К тому же, такой ансамбль практически не подвержен переобучению. Вместе с тем, использование слабых локальных классификаторов для распознавания многоканальных паттернов ЭЭГ может быть мало эффективным.

4. Обобщение стеком (Стеккинг - Stacking). Подход заключается в использовании двухуровневого стека классификаторов. На первом уровне каждый классификатор анализирует входной вектор признаков. Их ответы формируют вход мета-классификатора второго уровня, который выносит окончательное решение. Термин был предложен в [119] для организации ансамбля ИНС.

Основным преимуществом комбинирования гомогенных классификаторов состоит в повышении итоговой вероятности успешной классификации за счет снижения дисперсии. В настоящее время при разработке ИМК комбинирование классификаторов используется для распознавания паттернов ЭЭГ нечасто, большая часть исследований ограничивается одним классификатором. Вместе с тем, в последние годы, возникла тенденция по разработке ансамблей классификаторов для ИМК.

1.11. Сопоставительный анализ методов классификации ЭЭГ паттернов моторных команд

Специфика ЭЭГ сигнала оказывает существенное влияние на вероятность успешной классификации паттернов, соответствующих моторным командам. Наличие высокоамплитудных шумов и выбросов в анализируемых данных предполагает использование классификаторов с параметрами регуляризации, таких как МОВ.

Для учета информации о времени возникновения связанного с событием образа (особенно в синхронизированных парадигмах исполнения моторных команд со стимулом) целесообразно использование динамических классификаторов, таких как СММ, в случае, если возможно выделить устойчивые состояния из данных ЭЭГ. Другим подходом, учитывающим временные

особенности, является анализ в скользящем окне. Однако такой подход приводит к формированию векторов признаков высокой размерности. При анализе таких векторов использование метода ближайших соседей нецелесообразно, т.к. это семейство методов особенно чувствительно к «проклятию размерности». Вместе с тем, высокая размерность не является ограничением для ИНС и МОВ.

Исследования на основе ЭЭГ зачастую имеют ограниченные выборки обучающих и тестовых данных, т.к. регистрация ЭЭГ связана с привлечением испытуемых, наличием специального помещения и оборудования. При малых обучающих выборках целесообразно использование простых линейных классификаторов.

Вариативность и нестационарность ЭЭГ данных являются теми особенностями сигнала, преодоление которых наиболее затруднительно. Для этого необходимо применение индивидуального подхода при настройке, а возможно, и при выборе средств классификации, а также целесообразно использование ансамблей гетерогенных классификаторов, сокращающих дисперсию.

На рис.5 приводится вариант систематизации рассмотренных в данной главе методов классификации. В качестве основных критериев выступают относительная сложность классификаторов и вероятность успешной классификации в соответствии с данными результатов распознавания моторного воображения, приведенных в обзорах [76, 82, 28]. Каждый из критериев имеет 5 градаций: так, относительная сложность варьируется от низкой (линейные методы) до высокой (ансамбли классификаторов). Вероятность успешной классификации acc также имеет 5 градаций: $\{1| acc \in 0 : \frac{1}{n}; 2|$

$$acc \in \frac{1}{n} : \frac{1}{n} + (1 - \frac{1}{n})/4; \quad 3| acc \in \frac{1}{n} + (1 - \frac{1}{n})/4 : \frac{1}{n} + 2 * (1 - \frac{1}{n})/4; \quad 4|$$

$$acc \in \frac{1}{n} + 2 * (1 - \frac{1}{n})/4 : \frac{1}{n} + 3 * (1 - \frac{1}{n})/4; 5| acc \in \frac{1}{n} + 3 * (1 - \frac{1}{n})/4 : 1 \}$$

Если вероятность успешной классификации, указанная в литературе, не превышает порога случайных распознаваний, то реализованный классификатор

именуется неэффективным, если вероятность успешной классификации превышает порог незначительно, то именуется низкой и т.д. до высокой (с вероятностью верных распознаваний близкой к 1).

Вероятность успешной классификации	Высокая (5)			МОВ (РБФ)				Многослойные ИНС	Ансамбли классификаторов
	Выше среднего (4)	ЛДА	МОВ (лин.)		Расст. Махаланобиса	СММ			
	Средняя (3)				к ближ. соседней				
	Низкая (2)								
	Неэффективный (1)								
	0	Низкая		Ниже среднего		Средняя	Выше среднего		Высокая
	Сложность классификатора								

Рис. 5. Сравнение существующих методов классификации по критериям вероятность успешной классификации и сложность классификатора (по литературным данным).

Данная систематизация носит условный, оценочный характер, так как не учитывает различий в методах извлечения признаков, их информативности, локализации в отведениях ЭЭГ и прочее. Вместе с тем, данные, приведенные на рис. 5 позволяют выбрать наиболее эффективные, по литературным данным, методы классификации с целью дальнейшей реализации для распознавания паттернов ЭЭГ, соответствующих моторным командам, в особенности для трудно классифицируемых воображаемых движений мелкой моторики.

С целью совершенствования ИМК посредством увеличения способности различения ЭЭГ паттернов при классификации воображаемых моторных команд, а также увеличения количества формируемых команд на внешние устройства, необходимо перейти от достаточно эффективно решаемой задачи классификации

движений крупной моторики к трудно решаемой задаче распознавания воображаемых движений отдельных пальцев руки и классификации их движений.

На основании проведенного анализа методов классификации ЭЭГ паттернов можно сформулировать подходы к совершенствованию существующих средств распознавания в неинвазивных ИМК. Целесообразно использование двух методов классификации - метод опорных векторов и многослойные искусственные нейронные сети. Данные методы основаны на различных принципах, поэтому демонстрируют различную устойчивость, быстрдействие, а главное, чувствительность к разным типам признаков. В связи с этим комбинирование таких разнотипных классификаторов путем объединения их в комитет гетерогенных классификаторов представляется эффективным решением поставленной задачи совершенствования информационно-измерительных и управляющих систем комплексов реабилитации, протезирования и мониторинга, использующих ЭЭГ сигналы.

Выводы к главе 1

1. Анализ разработок в области ИМК показал, что в настоящее время реализовано значительное число интерфейсов с разными способами регистрации сигналов активности мозга и методами их классификации. Наибольшую вероятность успешной классификации обеспечивают ИМК с инвазивными средствами регистрации сигналов биоэлектрической активности коры мозга, однако они требуют хирургического вмешательства и, поэтому имеют ограниченное применение на практике. Неинвазивные ИМК имеют меньшую точность, но чаще используются на практике, вследствие своей доступности и мобильности. Именно в области неинвазивных ИМК отмечается быстрый рост числа работ, направленных на повышение скорости и вероятности успешного распознавания ментальных состояний.

2. Анализ исследований в области неинвазивных ИМК показал, что наиболее перспективным для применения ИМК на практике, является использование электрофизиологических сигналов для управления внешними

устройствами и определения ментальных состояний человека. Существует множество методов решения прямой и обратной задачи в электрофизиологии. Обоснована рациональность построения ИМК с использованием неинвазивной технологии, основанной на электроэнцефалографии.

3. Сигналы ЭЭГ в математическом плане являются функциями, подчиняющимися законам динамического хаоса, что дает возможность решать задачу распознавания скрытых в них образов реальных и воображаемых моторных команд. Причем эффективность распознавания этих образов зависит от правильности выбора пространства признаков и процедур анализа сигналов ЭЭГ, максимально учитывающих их особенности.

4. Существующие методы классификации сигналов ЭЭГ, соответствующих определенным моторным командам, достаточно эффективны для распознавания движений крупными частями тела. Для эффективной классификации моторных команд, управляющих движениями мелкой моторики, например, пальцами одной руки, требуется исследование и разработка новых методов классификации. Эффективное распознавание ЭЭГ паттернов крупной и мелкой моторики в совокупности позволит разработать более универсальные ИМК, использующие сигналы ЭЭГ для управления внешними устройствами с большим числом степеней свободы.

5. На основании проведенного анализа разработок в области неинвазивных ИМК сформулированы следующие подходы: (1) в плане увеличения количества возможных команд, формируемых по распознанным ЭЭГ паттернам, предлагается перейти от достаточно эффективно решаемой задачи классификации движений крупной моторики к трудно решаемой задаче анализа нейрофизиологических коррелят движений мелкой моторики (отдельных пальцев руки) и классификации их движений; (2) для увеличения способности различения ЭЭГ паттернов предлагается использовать признаковые пространства, учитывающие временные характеристики сигналов ЭЭГ, и комбинирование разнотипных классификаторов путем объединения их в комитет гетерогенных классификаторов.

Глава 2. Анализ ЭЭГ сигналов во временной области, выделение характерных признаков и классификация

2.1. Анализ ЭЭГ сигналов во временной области

Электрическая активность, регистрируемая при помощи электроэнцефалографии, является результатом сложной суммации электрических градуальных потенциалов многих нейронов, работающих в значительной степени независимо [9]. При исследовании сигналов ЭЭГ, связанных с событием, одной из основных особенностей является их малая амплитуда по отношению к спонтанной активности ЭЭГ, которая, в данном случае, выступает как шум. Другой чертой спонтанной ЭЭГ является ее чувствительность к изменению общего состояния человека и условий проведения исследования так, что каждое регистрируемое событие происходит на разном «уровне» фоновой ритмики ЭЭГ. Таким образом, при разработке методов анализа ЭЭГ сигнала и извлечения признаков необходимо учитывать следующие особенности, выделенные в главе 1: 1) нестационарность ЭЭГ, 2) низкое соотношение сигнал/шум, 3) многоканальность, 4) наличие выбросов в выборках.

Большинство систем анализа сигналов ЭЭГ и распознавания их паттернов основаны на разных подходах, но имеют схожие шаги выделения признаков для различения образов [76, 25]:

- поиск сегментов регистрируемой многоканальной ЭЭГ, где ожидается связанный с событием сигнал;
- предварительная обработка;
- расчет характерных признаков при помощи методов спектрального анализа.

Анализ показывает, что традиционное использование спектрального анализа приводит к потере информации о временной локализации характерных признаков. При данном подходе сокращение длительности регистрируемого сигнала является затруднительным. Остается неизвестной последовательность возникновения и длительность участков сигнала, связанных с искомым событием.

Также необходимо отметить, что, в связи с нестационарностью ЭЭГ сигнала, для извлечения признаков с помощью спектрального анализа может требоваться накопление значительного числа образцов сигналов, соответствующих определенному событию. Данные ограничения существенно снижают возможность применения спектральных систем анализа ЭЭГ сигналов для практической реализации в ИМК реального времени.

С целью преодоления данного ограничения и более глубокого понимания параметров временного окна, в котором выделяются различающие особенности сигналов, в данной работе применяются методы анализа ЭЭГ сигналов во временной области, основанные на регрессии сигнала (числовой и символьной) и методы генерации признаков в скользящем временной окне.

2.1.1. Метод символьной регрессии

Задача отыскания оптимальной параметрической регрессионной модели является крайне актуальной в области распознавания образов, несмотря на большую историю исследований. Известен метод группового учета аргументов, согласно которому модель, доставляющая наилучшее приближение, отыскивается во множестве последовательно порождаемых моделей [79].

В диссертации реализуется метод символьной регрессии, основанный на построении регрессионных моделей путем перебора произвольных суперпозиций функций из некоторого заданного набора. Для построения суперпозиции функций и поиска оптимальной регрессионной модели используется генетическое программирование. При этом реализуется поиск моделей по итерационной схеме «порождение-выбор» в соответствии с определенными правилами порождения моделей и критерием их выбора. Последовательно порождаются наборы конкурирующих моделей, при этом каждая модель является суперпозицией элементов заданного множества гладких параметрических функций. Из набора выбираются лучшие модели для последующей модификации [23].

Поставим задачу нахождения символьной регрессионной модели нескольких свободных переменных следующим образом. Пусть имеется n

независимых переменных $X_i, i = \overline{1, n}$, и одна зависимая переменная Y . Также задана выборка $X \in R^{N \times n}$ значений независимых случайных величин $X_1 = x_{k,1}, X_2 = x_{k,2}, \dots, X_n = x_{k,n}, k = \overline{1, N}$:

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,n} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,n} \\ \vdots & \vdots & \vdots & \vdots \\ x_{N,1} & x_{N,2} & \cdots & x_{N,n} \end{bmatrix},$$

и вектор $Y \in R^N$ соответствующих значений зависимой случайной величины

$$Y(X_1 = x_{k,1}, \dots, X_n = x_{k,n}) = y_k, k = \overline{1, N}: Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}.$$

Обозначим за множество входных данных множество $D = \{X, Y\}$.

Также задано множество гладких функций $G = \{g(x, y, z, \dots) | g: R \times \dots \times R \rightarrow R\}$. Функции $g(x, y, z, \dots) \in G$ имеют конечное число аргументов, отличное от нуля. В качестве аргументов функций $g \in G$ могут выступать как значения независимых переменных из матрицы X , так и значения, являющиеся результатом вычисления другой функции $g' \in G$ (g' не обязательно должна быть отлична от g).

Рассмотрим множество всевозможных суперпозиций из не более, чем $r \in R$ функций $g \in G$:

$$\Omega_r = \{\omega(x) = (g_1 \circ g_2 \circ \dots \circ g_k)(x) | g_i \in G, i = \overline{1, k}, k \leq r\}.$$

Каждый элемент множества $\omega \in \Omega_r$ является гладкой функцией от вектора независимых переменных: $\omega = \omega(x), x = (x_1, \dots, x_n)^T$. В общем случае, произвольная функция ω может зависеть не от всех компонент вектора независимых переменных x .

Регрессионная модель $f^{r,d}(w, x)$ будет задаваться следующим образом:

$$f^{r,d}(w, x) = w^T \cdot \left[\frac{1}{\Omega_d^r} \right] = w_0 + w_1 \omega_1(x) + \dots + w_d \omega_d(x),$$

где $d \in R$; $w = (w_0, \dots, w_d)^T \in R^{d+1}$ - вектор параметров регрессионной модели;
 $x = (x_1, \dots, x_n)^T \in R^n$ - вектор независимых переменных;
 $\overline{\Omega}_d^r = [\omega_1(x), \dots, \omega_d(x)]^T, \omega_i(x) \in \Omega_r, i = \overline{1, d}$ - вектор, компонентами которого являются суперпозиции гладких функций из множества Ω_r .

Наконец, определим множество всех регрессионных моделей:
 $\Phi^{r,z} = \{f^{r,d}(w, x) \mid d \leq z\}$.

Зададим функционал невязки регрессионной модели $f^{r,d}(w, x)$ следующим образом:

$$p(f^{r,d}) = \sqrt{\frac{1}{N} \sum_{k=1}^N (f^{r,d}(\tilde{w}, X_k) - y_k)^2},$$

где X_k - строка матрицы X значений независимых переменных; y_k - компонента вектора Y - соответствующее значение зависимой переменной; \tilde{w} - вектор оптимальных параметров для линейной регрессионной модели $f^{r,d}(w, x)$, найденный с помощью метода наименьших квадратов:

$$\tilde{w} = \arg \min_{w \in R^{d+1}} \left(\frac{1}{2} \sum_{k=1}^N (f^{r,d}(w, X_k) - y_k)^2 \right).$$

Итак, требуется найти такую регрессионную модель $f^{r,d}(\tilde{w}, x) \in \Phi^{r,z}$, которая доставляет минимум функционалу $p(f^{r,d})$:

$$f^{r,d}(\tilde{w}, x) = \arg \min_{f^{r,d} \in \Phi^{r,z}} p(f^{r,d}).$$

Практическая реализация вышеописанного метода выполнена с использованием генетического программирования. Генетическое программирование – модификация классического генетического алгоритма, состоящая в нестационарности длины хромосом, необходимой для описания суперпозиции гладких функций регрессионной модели. Специфика задачи потребовала также модификации стандартных функций рекомбинации и мутации, используемых в генетическом алгоритме.

Поиск оптимальной модели происходит на множестве порождаемых моделей на каждой итерации алгоритма. Перед работой алгоритма задается

множество гладких функций G , суперпозиции которых будут образовывать хромосомы элементов популяций, и, соответственно, элементы регрессионных моделей. Данное множество крайне важно для сходимости алгоритма и должно включать в себя базисные функции, учитывающие природу сигнала.

На первом шаге алгоритма задается начальный набор конкурирующих моделей $F_0 = \{f_1, \dots, f_m \mid f \in \Phi\}$, в котором каждая модель f_i есть суперпозиция функций из G .

Хромосомы элементов популяций хранят представления суперпозиций гладких функций $\omega \in \Omega_r$ в виде дерева. В узлах дерева находятся функции $g_i \in G$, которые входят в данную суперпозицию ω , на каждом листе дерева может располагаться либо один из компонентов вектора независимых переменных $x = (x_1, \dots, x_n)^T$, либо числовая константа $c \in R$.

Далее выполняется последовательность шагов, приведенная ниже:

- вычисление оптимальных параметров каждой регрессионной модели методом наименьших квадратов;
- вычисление минимизируемого функционала невязки для каждой модели;
- сопоставление с условием останова и, в случае недостижения последнего, формирование следующей популяции (нового множества моделей).

Процесс вычислений останавливается, если выполнено заданное число итераций или достигнуто условие останова - нахождение регрессионной модели с заданным значением функционала невязки.

Генерация очередного множества моделей является ключевым этапом генетического программирования. Он состоит из действий, приведенных ниже.

1. Оператор выбора моделей

Выбор регрессионных моделей для дальнейшего изменения из множества U_k осуществляется с помощью метода турнирной селекции, состоящего из двух этапов:

- из множества моделей U_k с равной вероятностью выбираются TS моделей:
 $T = \{f_1, f_2, \dots, f_{TS}\}, f_i \in U_k, i = \overline{1, TS}$. Каждая модель может попасть в турнир только один раз.

- из полученного множества T выбирается одна модель с наименьшим значением функционала невязки.

При выборе двух моделей f_p и f_q из множества U_k , они исключаются из старого множества: $U_k = U_k \setminus \{f_p, f_q\}$.

2. Операторы порождения

После выбора двух моделей f_p и f_q из множества U_k , к ним применяются операторы порождения новых моделей. Осуществляется выбор типа оператора порождения из трех возможных: оператор мутации, оператор кроссовера, оператор прямого переноса. Этот выбор осуществляется с заранее заданным распределением вероятности $P_m, P_c, P_d : P_m + P_c + P_d = 1$, где P_m, P_c, P_d - вероятности операторов мутации, кроссовера и прямого переноса соответственно.

Оператор мутации применяется к случайно выбранному компоненту $\omega_k(x)$ вектора $\bar{\Omega}'_d$. Выбирается один из реализованных механизмов мутации: мутация поддеревьев, приравнивание выбранной константы к нулю, к единице, замена случайно выбранной в $\omega_k(x)$ константы на новое случайное значение.

Операторы кроссовера реализуют один из двух механизмов:

у моделей f_p и f_q из множества U_k выбираются поддеревья для обмена между моделями;

для моделей f_p и f_q случайным образом выбираются числовые интервалы, в рамках которых происходит обмен группами компонентов между моделями.

После завершения формирования части нового множества моделей U_{k+1} посредством применения стохастических операторов порождения моделей, необходимо выполнить копирование без изменений оставшегося числа моделей из множества U_k . Выбор моделей осуществляется на основе анализа двух показателей: функционала оценки качества модели и сложности модели (которая

характеризуется количеством узлов в деревьях, которые соответствуют данной модели). Приоритетным является первый показатель, дополнительным (при неопределенности в случае равенства функционалов) – второй.

В результате выполнения вышеописанного алгоритма определяется регрессионная модель, представленная в аналитическом виде, доставляющая минимум функционалу невязки.

Символьная регрессия ЭЭГ сигналов.

Символьная регрессия коротких участков сигналов ЭЭГ, соответствующих мысленным командам, рассматривается в качестве средства перехода от численных к аналитическим, функциональным методам анализа.

На данный момент среди ИМК, основанных на анализе ЭЭГ, наиболее перспективными представляются интерфейсы, классифицирующие ментальные состояния, соответствующие воображению движений различных частей тела. В таких интерфейсах производится анализ и распознавание сигналов ЭЭГ, соответствующих различным моторным командам.

В данной работе исследуются сигналы ЭЭГ, соответствующие воображаемым движениям пальцев одной руки. Такие сигналы имеют локализации источников в анатомически близких зонах коры головного мозга и близкие значения частотно-временных характеристик, вследствие чего задача по классификации таких сигналов является значительно более трудной по сравнению с классификацией ЭЭГ сигналов, соответствующих движениям крупными частями тела.

Проведены исследования по символьной регрессии сигналов ЭЭГ, зарегистрированных во время воображения движений пальцами одной руки (процедура регистрации, предобработки и удаления артефактов приведена в главе 3). Эволюционный алгоритм продемонстрировал свою применимость к регрессии таких сложных временных рядов, как сигналы ЭЭГ, в результате были получены регрессионные модели в аналитической форме. Примеры сигналов ЭЭГ, соответствующих моторным командам воображаемых движений большим

пальцем (рис. 6) и указательным пальцем (рис. 7), и построенные с целью их анализа регрессионные модели приведены на нижеследующих рисунках.

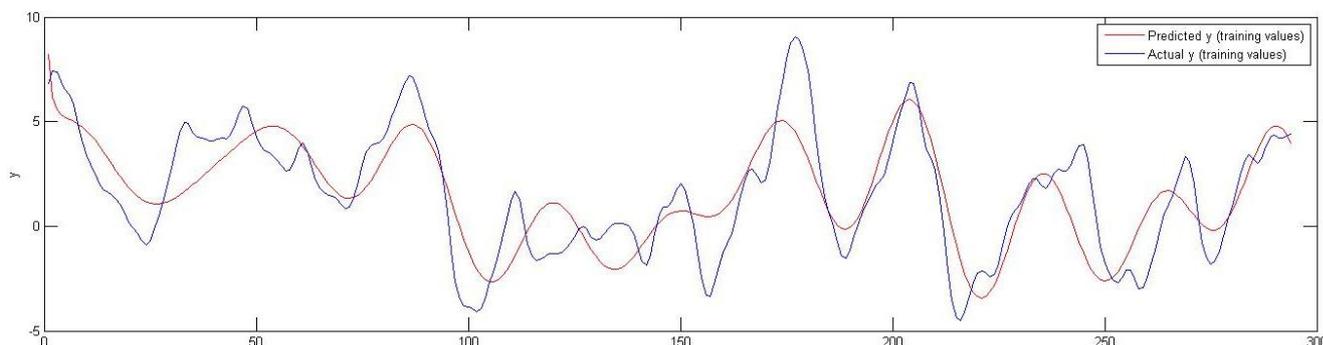


Рис. 6. ЭЭГ сигнал моторной команды воображаемого движения *большим* пальцем (синяя сплошная) и график найденной функции регрессионной модели (красная сплошная).

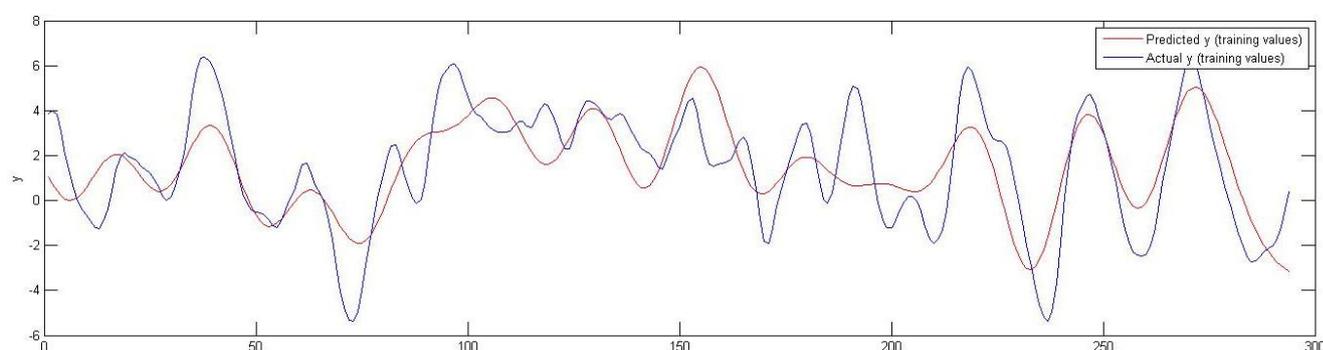


Рис. 7. ЭЭГ сигнал моторной команды воображаемого движения *указательным* пальцем (синяя сплошная) и график найденной функции регрессионной модели (красная сплошная).

Примечания: на оси абсцисс изображены временные отсчеты, один отсчет = 2 мс (длительность приведенного сигнала 600мс), на оси ординат изображена амплитуда в мкВ. Приведенный сигнал ЭЭГ зарегистрирован над сенсомоторной зоной коры, канал С3.

Функция построенной регрессионной модели ЭЭГ сигнала моторной команды воображаемого движения *большим* пальцем руки в аналитическом виде:

$$f_1(x) = 1,536 \sin(19,07x) - 2,02 \sin(0,055x + 1) - 1,362 \sin(19,06x) - 0,09x + 4,364/x + 1,536 \sin(0,162x) + 5,7 * 10^{-4} x^2 + 1,09 * 10^{-6} x^3 + 5,377$$

Функция аналогичной регрессионной модели ЭЭГ для воображаемого движения *указательным* пальцем руки имеет вид:

$$f_2(x) = 0,623 \sin(0,076x) - 0,784 \sin(18,81x) - 1,145 \sin(0,275x) - 1,145 \sin(0,111x) + 0,045x * \sin(18,81x) + 8,54 * 10^{-3} x * \sin(0,21x) - 1,75 * 10^{-4} x^2 * \sin(18,81x) + 1,421$$

В результате проведенных исследований установлено, что метод символьной регрессии применим для построения регрессионных моделей ЭЭГ сигналов и анализа их во временной области. В частности, были проведены эксперименты по анализу участков сигналов ЭЭГ, регистрируемых во время воображения движений мелкой моторики. Результатом применения вышеописанного метода для анализа сигналов стало нахождение регрессионной модели в аналитической форме, обеспечивающей возможность структурного и функционального анализа ЭЭГ сигналов, и позволяющей снизить размерность входных данных. Ключевыми преимуществами применения реализованного метода является автоматический подбор регрессионной модели в аналитическом виде и проведение анализа сигнала во временной области, что позволяет сохранить информацию о временной локализации характерных участков ЭЭГ сигнала.

Данный подход по построению моделей зарегистрированных ЭЭГ сигналов в аналитической форме открывает новые возможности для решения многих задач нейрофизиологии, таких как выявление паттернов аномальной активности, анализ связанной с событием синхронизации/десинхронизации и др.

Найденные модели указывают на ключевое значение гармонических функций в построении регрессионной модели сигналов биоэлектрической активности. Проведенные исследования показали низкую точность классических полиномиальных регрессионных моделей. Особенностью автоматически генерируемых регрессионных моделей является нестационарность их структуры, в то время как для использования их коэффициентов в качестве классифицирующих признаков необходимо выполнение условия о фиксированной структуре модели с постоянным числом членов. Конкретный вид модели в этом случае определяется лишь коэффициентами при постоянных членах. Другой особенностью метода символьной регрессии является значительное время эвристического поиска модели, что препятствует непосредственному применению данного подхода в ИМК реального времени.

Вариантом фиксированной структуры модели, найденным на основании результатов проведенной серии исследований по символьной регрессии ЭЭГ сигналов, является суперпозиция тригонометрических функций следующего вида: $a_1 \sin(b_1 x + c_1) + a_2 \sin(b_2 x + c_2) + \dots + a_n \sin(b_n x + c_n)$, где a_i, b_i, c_i – коэффициенты модели, $i=1:n$, n – число членов модели. Чем больше членов модели включено в реконструкцию, тем ближе реконструированный сигнал к форме исходного сигнала. Для практического использования необходимо соблюдение баланса необходимых вычислительных ресурсов, точности реконструкции модели и ее регрессионных свойств.

Пример ЭЭГ сигнала, соответствующего движению указательным пальцем, и регрессионная модель в виде суперпозиции функций синус, число членов $n=8$, приведены на рис. 8.

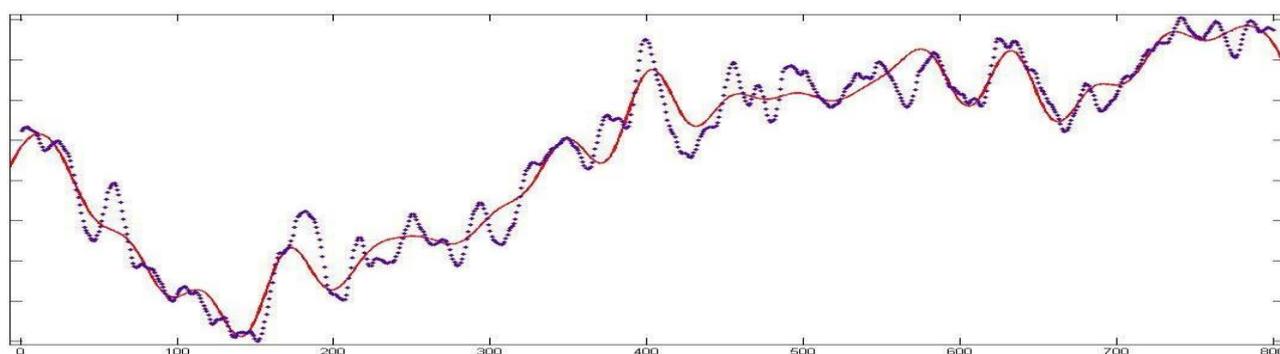


Рис. 8. ЭЭГ сигнал, соответствующий движению указательным пальцем – прерывистая линия, регрессионная модель – сплошная линия.

Примечание: на оси абсцисс изображены временные отсчеты, один отсчет = 2 мс, на оси ординат – амплитуда сигнала в мкВ.

Регрессионные модели в виде ряда гармонических функций позволяют реконструировать сложные временные ряды, которыми являются сигналы ЭЭГ. Коэффициенты таких моделей могут выступать в качестве признаков для классификации сами по себе (в случае распознавания коротких участков ЭЭГ, содержащих выраженные особенности) либо служить основой для выбора временных параметров генерации признаков, таких как величина скользящего окна анализа и значение сдвига.

В диссертации предлагается создание пространства признаков во временной области. Для этого необходимо использование скользящих временных окон, в каждом из которых происходит генерация вектора признаков. По результатам создания классификатора необходимо выделить те временные интервалы сигнала, признаки которых вносили наибольший вклад в распознающую способность классификатора. Таким образом, необходимо проанализировать возможность индивидуального подхода к генерации признаков для каждого испытуемого во временной области.

2.1.2. Вычисление характерных признаков сигнала

При анализе ЭЭГ сигналов с целью вычисления признаков, характерных для определенного типа мысленных команд или состояний, существенным является определение интервала времени в записи сигнала, в котором регистрируются отличительные признаки. Для учета временной локализации особенностей ЭЭГ сигналов целесообразно использование скользящих временных окон.

Важным для повышения вероятности успешной классификации является выбор значений ширины окна и сдвига окна анализа при вычислении характерных признаков. Проведенный ранее регрессионный анализ позволил получить модели сигналов в аналитическом виде, что делает возможным анализ каждой из функций, входящих в найденную суперпозицию.

Так, на рис. 9 приведен совместный график каждой из полученных функций вида $a \sin(bx + c)$, найденных в ограниченном базисном наборе. Суперпозиция приведенных функций соответствует модели сигнала ЭЭГ, зарегистрированного при совершении испытуемым воображаемого движения пальцем руки.

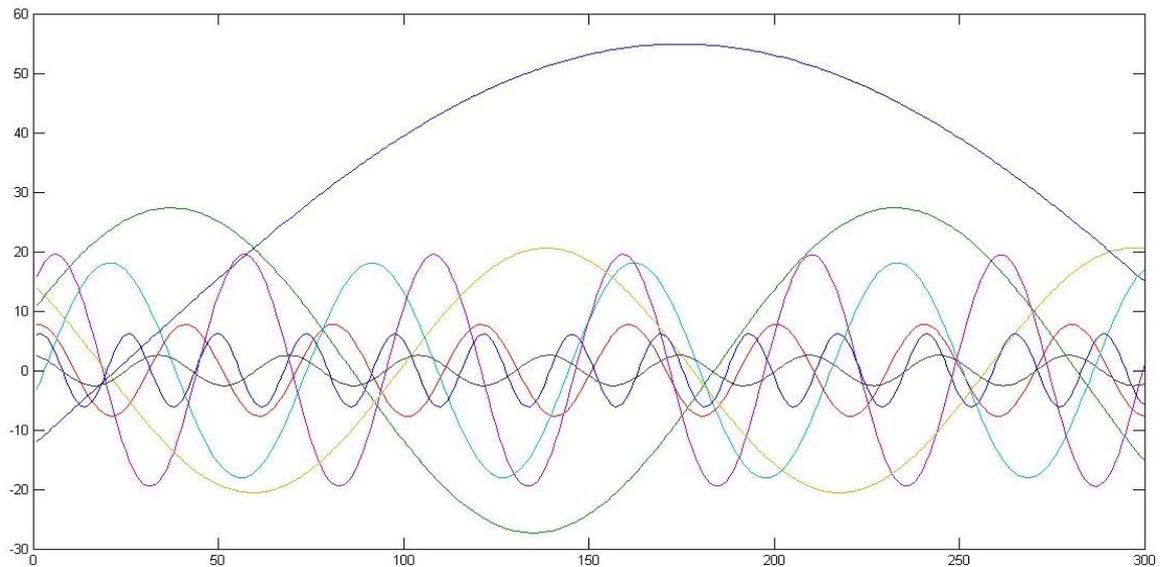


Рис. 9. Найденные функции вида $a \sin(bx + c)$, суперпозиция которых образует модель ЭЭГ сигнала.

Примечание: на оси абсцисс изображены временные отсчеты, один отсчет = 2, на оси ординат изображена амплитуда в мкВ.

Рисунок позволяет наглядно оценить временные интервалы, в которых целесообразно искать различимые образы, соответствующие различным моторным командам.

В данной работе реализован совместный учет двух типов признаков – площади сегмента под кривой сигнала в скользящем окне и длина кривой сегмента в скользящем окне. Данный класс признаков продемонстрировал свою эффективность при анализе ЭЭГ в клинике [7, 9], такие характерные признаки являются быстровычислимыми и не требуют специальных преобразований сигнала.

И низкочастотные и высокочастотные составляющие ЭЭГ сигнала могут вносить свой вклад в значение вероятности успешной классификации ЭЭГ паттернов, в связи с этим реализован совместный учет двух типов признаков – площади сегмента (низкочастотная составляющая) и длины кривой сегмента (высокочастотная составляющая) в скользящем окне. При этом важным параметром является значение величины окна анализа. Ранее было показано, что подбор индивидуальных окон анализа может существенно повысить вероятность

успешной классификации воображаемых движений [54]. Индивидуальная настройка параметров скользящего временного окна анализа является важным этапом конфигурирования разрабатываемой системы анализа и классификации ЭЭГ паттернов моторных команд и будет подробнее рассмотрена в соответствующем разделе главы 4.

Таким образом, в данном разделе предложен подход к извлечению характерных признаков паттернов ЭЭГ сигналов во временной области. В рамках данного подхода символьная регрессия коротких участков сигналов ЭЭГ, соответствующих мысленным командам, рассматривается в качестве средства перехода от численных к аналитическим, функциональным методам анализа. Для построения применимых на практике систем анализа и классификации ЭЭГ сигналов для ИМК реального времени целесообразно использование характерных признаков ЭЭГ сигнала, учитывающих временную локализацию информативных участков, обеспечивающих возможность индивидуальной настройки параметров их извлечения и вычисления которых не займет длительного времени.

2.2. Преобразование ЭЭГ сигналов

При разработке систем классификации ЭЭГ сигналов для неинвазивных ИМК одной из задач является поиск способа повышения соотношения сигнал/шум и выделения источников сигнала для повышения вероятности успешной распознавания воображаемых команд. Особенностью ЭЭГ, регистрируемой с поверхности головы, является ее относительно низкое пространственное разрешение (порядка квадратных сантиметров), по сравнению с данными электрокортикограммы (регистрации биоэлектрической активности с поверхности мозга) и магнитоэнцефалограммы, чье пространственное разрешение имеет порядок квадратных миллиметров. При прохождении мозговых оболочек, черепа и скальпа амплитуда биоэлектрических сигналов значительно уменьшается (особенно для высокочастотной составляющей). Наличие оболочек с сильно различающимся удельным сопротивлением приводит к "размазыванию" потенциала по скальпу, таким образом, с поверхности головы регистрируется не

только сигнал от ближнего к электроду поля, но и с «дальнего поля», когда генератор сигнала находится на значительном удалении от регистрирующего электрода, за счет объемного проведения токов мозгом и прохождения сигналом мозговых оболочек [4]. Данные ограничения могут быть в некоторой мере преодолены при помощи методов преобразования сигнала, такими как методы пространственной фильтрации и методы выделения источников.

В данной работе для снижения влияния объемного проведения и повышения пространственного разрешения сигналы ЭЭГ, зарегистрированные при выполнении воображаемых движений, проходили процедуру фильтрации, преобразования к взвешенному среднему монтажу (Weighted Average Reference - WAR) [73], разложения на независимые компоненты (Independent Component Analysis - ICA) [33, 114] и преобразования к плотности источника тока (Current Source Density – CSD) [90] для последующей классификации.

2.2.1. Фильтрация ЭЭГ сигнала

Применение фильтрации ЭЭГ сигнала направлено на выделение такой полосы частот, которая является наиболее информативной в плане наличия характерных признаков классифицируемых ЭЭГ сигналов, а также на подавление помех. Используются фильтры с бесконечной переходной характеристикой: фильтр высокой частоты первого порядка и фильтр низкой частоты второго порядка. Подавление сигнала за пределами полосы пропускания невелико - 12 дБ на октаву. Для подавления сетевой помехи используются режекторные 50 (60) Гц 12-го порядка, что обеспечивает подавление в полосе непропускания более чем 40 дБ в узкой полосе непропускания.

2.2.2. Преобразование к взвешенному среднему монтажу

Монтаж записи ЭЭГ – способ, в соответствии с которым измеряются потенциалы ЭЭГ [13].

Значения потенциалов электродов, расположенных на поверхности головы, измеряются по отношению к референтным электродам, установленным на

определенном удалении от мозга (в данном случае, на мочках ушей). В идеале, потенциал референтного электрода не должен изменяться с течением времени. Однако из-за проводимости покровов головы все отведения являются в той или иной степени электрически активными, что, в свою очередь, вносит искажения в регистрируемый сигнал ЭЭГ [20].

Не существует референтно-зависимого монтажа, который бы в полной мере решал проблему референтной записи. Вместе с тем, выбор такого монтажа оказывает существенное влияние на регистрируемые ЭЭГ сигналы и может быть одной из определяющих характеристик системы классификации ЭЭГ паттернов.

Для нивелирования искажений референтной записи на практике широко применяется перерасчет значений ЭЭГ сигнала относительно общего усредненного по всем электродам референта [13]. Метод может быть выражен следующим образом: пусть исходная запись ЭЭГ V содержит данные, полученные по N отведениям (каналам), при этом в каждом отведении сигнал представлен в виде совокупности дискретных отсчетов. Тогда преобразование к общему среднему монтажу можно выразить следующим образом:

$$V'_i = V_i - \frac{1}{N} \sum_{j=1}^N V_j, \text{ таким образом, потенциал усредняется по всем отведениям и}$$

вычитается из каждого отдельного потенциала [13].

Существенным ограничением общего среднего монтажа является лежащее в его основе допущение, что форма головы представляет собой сферу (тогда общим средним был бы ноль). Однако в действительности форма головы отлична от сферы, а электроды располагаются только на ее верхних и боковых поверхностях.

С целью преодоления указанного ограничения в работе реализован взвешенный средний референтный монтаж. Потенциал i -го отведения корректируется по взвешенной сумме потенциалов окружающих отведений

$$V'_i = V_i - \sum_{j=1}^N w_{ij} \times V_j. \text{ Веса референтных электродов вычислены с учетом}$$

измерения фактических межэлектродных расстояний в работе [73]

Взвешенный средний монтаж вычисляется на основе оценки оператора Лапласа для каждого отведения. Данный монтаж позволяет получить лучшее пространственное разрешение потенциала [13], что является крайне важным при классификации сигналов ЭЭГ, имеющих близкую локализацию источников.

2.2.3. Разложение ЭЭГ сигнала на независимые компоненты

Преобразование ЭЭГ сигнала с использованием метода независимых компонент, базируется на представлении об ЭЭГ, как о линейной суперпозиции статистически независимых и слабо коррелированных источников, которые можно разделить. Получающаяся модель непосредственно не описывает свойства электрической проводимости головы, но может быть эффективна для снижения влияния активности соседних мозговых областей, когда объемная проводимость оказывает значительное влияние на сигнал ЭЭГ [94]

Метод ICA [33] направлен на декомпозицию многокомпонентного сигнала на независимые негауссовы источники. Данная техника была разработана для выделения компонент таких классов сигналов, которые удовлетворяют следующим допущениям [78]:

- источники сигналов независимы,
- задержки распространения в среде смешивания незначительны,
- источники являются аналоговыми,
- количество независимых компонент сигнала равно количеству сенсоров.

Особенностью применения ICA для анализа ЭЭГ является тот факт, что электроды на поверхности головы регистрируют коррелированные сигналы, и целью метода является выделение независимых компонент «смешанных» при прохождении мозговых оболочек и черепа сигналов. Для применения ICA для решения задачи выделения компонент ЭЭГ необходимо ввести несколько допущений [125]: (1) ЭЭГ сигналы генерируются ограниченным числом статистически независимых процессов мозга; (2) отсутствует задержка в распространении сигнала от источников к электродам; (3) смешивание линейно

(уравнение Пуассона линейно); (4) число независимых компонент сигнала не превышает количество электродов (количество компонент, вносящих значимый вклад в результирующий сигнал, не превышает числа электродов).

В данной работе выполнен анализ независимых компонент на основе принципа Infomax.

Поставим задачу отыскания независимых компонент в соответствии с [108]. Имея набор смешанных компонент x и набор идентичных независимых модельных функций распределения g , необходимо отыскать разделяющую матрицу W , которая максимизирует совместную энтропию сигналов $Y = g(y)$, где $y = Wx$ - сигналы, вычисленные при помощи разделяющей матрицы. Нахождение оптимальной матрицы W обеспечит максимум совместной энтропии сигналов Y и их независимость, что означает также независимость извлеченных сигналов $y = g^{-1}(Y)$. g является обратимой функцией.

Необходимо отметить, что если функция плотности вероятности модели источника сигнала P_x соответствует функции плотности вероятности выделенного сигнала P_y , то максимизация совместной энтропии Y также максимизирует количество взаимной информации между x и Y . По этой причине подход к использованию энтропии для извлечения независимых сигналов известен как Infomax.

Рассмотрим энтропию вектора $Y = g(y)$. Для конечной выборки из распределения с функцией плотности вероятности P_y энтропия Y может быть

вычислена как

$$H(Y) = -\frac{1}{N} \sum_{t=1}^N \ln p_Y(Y^t)$$

Функция совместной плотности вероятности P_Y связана с функцией совместной плотности вероятности выделенных сигналов P_y следующим образом:

$$p_Y(Y) = \frac{p_y(y)}{\left| \frac{\partial Y}{\partial y} \right|},$$

$J = \frac{\partial Y}{\partial y}$ - матрица Якоби и $|J| = g'(y)$, а g' является функцией плотности

вероятности сигналов источников $g' = p_s$, следовательно,

$$p_Y(Y) = \frac{p_y(y)}{\left| \frac{\partial Y}{\partial y} \right|} = \frac{p_y(y)}{p_s(y)}$$

таким образом, $H(Y) = -\frac{1}{N} \sum_{t=1}^N \ln \frac{p_y(y)}{p_s(y)}$.

Когда $p_y = p_s$, p_y имеет равномерное распределение и $H(Y)$

максимизировано. Так как $p_y(y) = \frac{p_x(x)}{\left| \frac{\partial y}{\partial x} \right|} = \frac{p_x(x)}{|W|}$, где $|W|$ - абсолютное

значение определителя разделяющей матрицы, следовательно,

$$H(Y) = -\frac{1}{N} \sum_{t=1}^N \ln \frac{p_x(x^t)}{|W| p_s(y^t)} \quad \text{и} \quad H(Y) = \frac{1}{N} \sum_{t=1}^N \ln p_s(y^t) + \ln |W| + H(x)$$

Так как $H(x) = -\frac{1}{N} \sum_{t=1}^N \ln p_x(x^t)$ и максимизация W не влияет на H_x ,

мы можем максимизировать значение функции $h(Y) = \frac{1}{N} \sum_{t=1}^N \ln p_s(y^t) + \ln |W|$ с

тем, чтобы обеспечить независимость выделенным сигналам.

В качестве функции плотности вероятности модели источника сигнала p_s используется супер Гауссово распределение $p_s = (1 - \tanh(s)^2)$ и функция, значение которой подлежит максимизации, имеет вид

$$h(Y) = \frac{1}{N} \sum_{i=1}^M \sum_{t=1}^N \ln(1 - \tanh(w_i^T x^t)^2) + \ln|W|$$

В итоге, имея набор смешанных компонент x , соответствующий ему набор выделенных сигналов y и модель сигнала источника $p_s = g'$, возможно найти оптимальную разделяющую матрицу W методом градиентного спуска, и обеспечить независимость и негауссовость выделенных сигналов.

Необходимо отметить, что, необходимое для применения ИСА, допущение о том, что ЭЭГ является линейной композицией ровно такого числа источников, каково число электродов, остается существенным ограничением метода, так как реальное число статистически независимых сигналов головного мозга, регистрируемых ЭЭГ, неизвестно. При интерпретации результатов ИСА встает проблема определения физиологической значимости выделенных компонентов, исходя из количества регистрируемых каналов.

2.2.4. Преобразование к плотности источника тока

Преобразование ЭЭГ сигнала к плотности источников тока имеет своей целью локализацию источников ЭЭГ и направлено на уменьшение воздействия эффекта объемного проведения на сигнал, регистрируемый со скальпа [64].

Плотность источников тока является независимой от выбора референта мерой силы тока внеклеточных генераторов, лежащих в основе зарегистрированной ЭЭГ, вычисленной на базе линейной модели объемной проводимости [84]. Объемная проводимость рассматривается как пассивная передача электрических полей через биологическую ткань от базового генератора электрического тока.

Сила тока может быть вычислена при помощи закона Ома в векторной форме [84]:

$$J = \sigma E \quad (1)$$

где J является плотностью тока, E - электрическое поле, а σ - тензор проводимости для среды. Данное уравнение кратко описывает свойства протекания тока через среду, независимо от выбора референта, использованного при записи ЭЭГ.

Электрическое поле (E) выражено векторной величиной, которая может быть определена как отрицательный градиент (т.е. пространственный наклон) потенциала поля ($-\nabla\Phi$). Использование градиента, представляющего собой непрерывный разностный потенциал, указывающего в направлении наибольшего потенциального снижения, позволяет уйти от зависимости от выбора референта при записи ЭЭГ [109].

Для перехода к скалярному виду выражения (1) используется операция дивергенции ($\nabla \cdot$) – пространственная дифференциация для количественного определения дивергенции протекания тока в каждой точке, которая преобразует векторное поле J в скалярную плотность источников тока (CSD) или I_m [84], и выражение приобретает вид:

$$I_m = \nabla \cdot (\sigma(-\nabla\Phi)) \quad (2)$$

где индекс m обозначает, что ток проходит во внеклеточную среду через клеточные мембраны (m) нейронов внутри ткани.

Таким образом, на данном этапе I_m является скалярной величиной, вычисляемой от отрицательного градиента измеряемого потенциала поля.

Если импеданс ткани может дополнительно считаться пространственно инвариантным (с учетом допустимых отклонений), тензор σ может быть заменен скалярной константой σ_s , тогда выражение (2) становится скалярным соотношением:

$$I_m = -\sigma_s \nabla^2 \Phi \quad (3)$$

Это определение CSD свелось к уравнению Пуассона, которое связывает измеренное напряжение и амплитуду нижележащих генераторов тока [109]. Следовательно, плотность источников тока пропорциональна второй пространственной производной (т.е. Лапласиану) измеряемого потенциала поля.

Физический смысл взятия второй пространственной производной потенциала поля может быть проиллюстрирован по аналогии: так, ускорение является второй производной пути по времени, а закон $\vec{F} = m\vec{a}$ отражает взаимосвязь между направлением и величиной ускорения и приложенной движущей силой.

Для ЭЭГ, зарегистрированного со скальпа, значения CSD на основе Лапласиана поверхности соответствуют оценкам радиального тока в череп из (или в) нижележащей нервной ткани [110]. Таким образом, Лапласиан поверхности определяет месторасположения, в которых ток поступает в пространство измерений (т.е. монтаж записи ЭЭГ на скальпе) из нижележащих проводящих сред, после прохождения множественных оболочек. Лапласиан поверхности является применением оператора Лапласа, ограниченного топографией двумерной поверхности [109].

Для аппроксимации CSD в данной работе применен метод картирования с использованием сферических сплайнов (по [90]). Для построения пространственных карт плотностей тока скальпа надо точно определить на какой поверхности вычисляются CSD и каковы проекции между поверхностью черепа и поверхностью вычислений и между поверхностью вычислений и плоскостью, на которой конечная карта составляется. В качестве поверхности вычислений выбрана сфера, для нахождения проекции череп-сфера применен метод интерполяции на основе сферических сплайнов, а для нахождения проекции сфера-плоскость использован метод радиальной проекции [90].

Ключевыми особенностями преобразования к плотности источников тока являются независимость от референта при записи ЭЭГ и соотнесение топографии ЭЭГ с выделенными генераторами тока. В результате значимо повышается

амплитуда связанного с событием сигнала в отдельных зонах и улучшается соотношение сигнал/шум.

Преобразование CSD является эффективным средством предобработки сигнала ЭЭГ с целью выделения локальных различий и нивелирования влияния активности соседних зон для последующего извлечения характерных признаков в системах ИМК. Сопоставительный анализ реализованных подходов к преобразованию ЭЭГ сигналов, зарегистрированных при выполнении воображаемых движений (моторных команд) приведен в Главе 4.

2.3. Классификация ЭЭГ паттернов

Задача построения эффективных средств классификации часто недооценивается исследователями, которые направляют основные усилия на разработку методов извлечения признаков. Между тем, ввиду нестационарной природы ЭЭГ, классы характерных признаков (например, при классификации моторных команд мелкой моторики) зачастую являются линейно неразделимыми и требуется применение специально разработанных для решения конкретной задачи средств классификации, основанных на ассоциативном выводе.

Обзор литературы выявил эффективные средства классификации в плане повышения вероятности успешного распознавания моторных команд. Для классификации ЭЭГ паттернов в мире наиболее часто используются методы: линейной дискриминации, опорных векторов, Байесовские классификаторы, искусственные нейронные сети [48, 115]. Эти методы позволяют принимать решение о классе текущего ЭЭГ-паттерна в результате прямого сопоставления соответствующего ему набора признаков (классифицируемого вектора) с шаблонными наборами (векторами классов в разделенном на классы пространстве признаков) или ассоциативного вывода, основанного на соотнесении наиболее соответствующего образа-шаблона класса (введенного при обучении) и классифицируемого вектора (входного образа). Наибольшую вероятность успешной классификации ЭЭГ паттернов, по сравнению с другими классическими подходами, демонстрируют МОВ и ИНС [76]. Однако

достигаемые ими значения вероятности успешных распознаваний на данный момент недостаточны для применения в ИМК с большим числом степеней свободы, т.е. с большим числом надежно распознаваемых моторных команд. Данный раздел направлен на разработку подходов, способствующих преодолению данного ограничения.

2.3.1. Комитет искусственных нейронных сетей

Искусственные нейронные сети (ИНС) широко применяются для практического анализа в статистике и обработке сигналов. ИНС основаны на принципах нелинейной, распределенной и локальной обработки и адаптации. Данный метод продемонстрировал принципиальную возможность по классификации сложных ЭЭГ паттернов, соответствующих моторным командам, однако вероятность успешного распознавания таких паттернов остается невысокой. Кроме того, в данном исследовании предложен подход по одновременному учету нескольких массивов характерных признаков разных типов. Для решения задачи классификации на основе анализа входного массива данных, составленного из разнотипных признаков, целесообразно применение комитета локальных классификаторов, каждый из которых анализирует свое пространство признаков. Такой подход аналогичен кооперации экспертов.

Определение комитета искусственных нейронных сетей. Термин комитет искусственных нейронных сетей обозначает комбинацию избыточного количества сетей. Избыточность заключается в том, что каждый член комитета вырабатывает свое решение общей задачи.

Мотивация по использованию комитета локальных классификаторов базируется на трех положениях:

1. комитет может достичь уровня вероятности успешной классификации тестовой выборки, недостижимого любым из членов комитета в отдельности;
2. комитет имеет модульную структуру, которая разделяет комплексную задачу классификации на подзадачи, которые решаются отдельными членами комитета;

3. использование комитета классификаторов уменьшает вычислительную сложность решения задачи [111].

В подходе по построению комитета комбинирование набора несовершенных классификаторов рассматривается в качестве способа нивелирования известных ограничений локальных классификаторов, которые комбинируются так, чтобы минимизировать ошибку итоговой классификации.

Для формализации цели комбинирования локальных классификаторов представим ошибку комитета ИНС в терминах смещения и дисперсии согласно [55]. В процессе обучения ИНС на обучающей выборке $\{(x_1, y_1), \dots, (x_n, y_n)\}$ формируется функция ответа классификатора $f(x)$, которая ставит в соответствие предъявляемой переменной x значение ответа сети $f(x)$, аппроксимирующего y . Значение функции f зависит не только от x , но и от обучающей выборки D , таким образом, следует записать $f(x; D)$. Тогда среднеквадратическая ошибка функции f относительно наблюдаемого значения y может быть записана как $E_D[(f(x; D) - E[y | x])^2]$, где E_D -оператор математического ожидания при использовании обучающего набора D , а $E[y | x]$ - целевая функция. Тогда разложение в виде суммы квадрата смещения и дисперсии примет вид

$$E_D[(f(x; D) - E[y | x])^2] = \underbrace{(E_D[f(x; D)] - E[y | x])^2}_{\text{Смещение}^2} + \underbrace{E_D[(f(x; D) - E_D[f(x; D)])^2]}_{\text{Дисперсия}}$$

Произвести оценку смещения и дисперсии комитета ИНС можно путем обучения на различных обучающих выборках, сформированных случайным образом из единого набора. Смещение, будучи систематической ошибкой, может быть интерпретировано как оценка способности к обобщению. Дисперсия классификатора может соответствовать оценке степени чувствительности к обучающему набору, т.е. степени вариативности ответа классификатора, обученного на разных обучающих выборках [105].

Наилучшая обобщающая способность достигается при нахождении оптимального баланса между задачами минимизации смещения и минимизации дисперсии. Таким образом, необходимо нахождение именно компромиссного соотношения двух величин, т. к. стремление минимизировать смещение, а значит увеличить размерность обучающей выборки, приводит к росту дисперсии, и наоборот.

В терминах комитета ИНС смещение представляет собой величину, на которую усредненный ответ всех членов комитета отличается от значения целевой функции. Дисперсия же отражает меру несогласованности членов комитета. При построении комитета классификаторов повышение общей эффективности достигается, в основном, за счет снижения дисперсии [105].

При построении комитета классификаторов определяющим являются этапы выбора типа классификатора, генерации обучающих выборок для каждого из членов комитета и обобщения ответов локальных классификаторов. Рассмотрим реализацию этих этапов для построения комитета ИНС для классификации паттернов ЭЭГ моторных команд.

Для классификации сложных образов необходимо выбирать многослойную топологию нейронной сети [34]. Вариантом такой сети является многослойный персептрон, для которого ответ сети для каждого выхода k вычисляется согласно следующему выражению:

$$y_k = \tilde{g} \left(\sum_{j=0}^M w_{kj}^{(2)} g \left(\sum_{i=0}^d w_{ji}^{(1)} x_i \right) \right),$$

$w_{ji}^{(1)}$ - веса первого скрытого слоя, $w_{kj}^{(2)}$ - веса второго скрытого слоя, g и \tilde{g} - функции активации соответствующих слоев.

В данной работе локальные классификаторы реализованы в виде многослойного персептрона, состоящего из двух скрытых слоев и одного выходного. В качестве функции активации в скрытых слоях используется

определенная в диапазоне $(0,1)$ сигмоидная функция $g(a) = \frac{1}{1 + \exp(-a)}$, а в выходном слое – линейная функция активации.

Формирование обучающих выборок для каждой из локальных ИНС происходит из массивов признаков разных типов. Таким образом, комитет ИНС используется для совместного учета нескольких типов признаков.

Обобщение решений ИНС первого уровня происходит с использованием принципа вложенной генерализации. Нелинейная ИНС обучается для объединения результатов классификаторов первого уровня, которые формируют выходные значения в виде вектора, в котором содержатся рассчитанные вероятности принадлежности текущей пробы к каждому из классов. Схема комитета ИНС приведена на рис. 10.

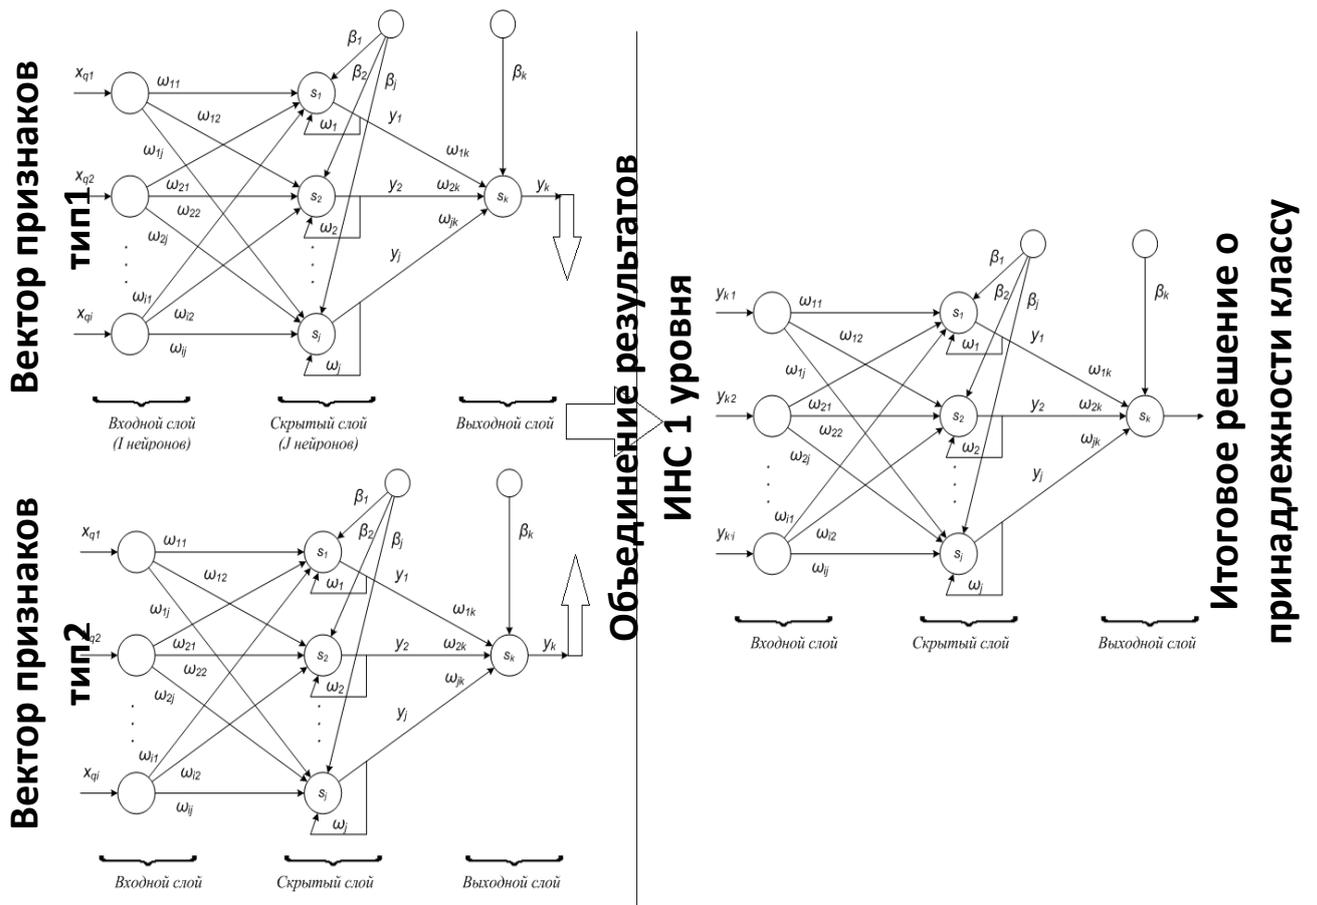


Рис. 10. Схема комитета искусственных нейронных сетей, построенного по принципу вложенности.

Преимуществом этого подхода является обобщение результатов ИНС первого уровня сетью второго уровня на основе обучения. Кроме того, такой комитет нейронных сетей является масштабируемым, то есть при добавлении новых пространств признаков возможно расширение комитета ИНС с помощью добавления новых нейронных сетей нижнего уровня, основанных на новых пространствах признаков.

2.3.2. Комитет гетерогенных классификаторов

ЭЭГ сигнал имеет ряд особенностей, которые налагают особые требования на методы его анализа и классификации. Так, ЭЭГ является результатом сложной суммации электрических градуальных потенциалов многих нейронов, работающих в значительной степени независимо. А связанный с событием (моторной командой) сигнал маскирован «шумом» в виде спонтанной ритмической составляющей, отражающей общее функциональное состояние человека.

В связи с этим ни один из методов классификации не продемонстрировал способности учета такого числа характерных особенностей ЭЭГ сигналов с близкой пространственной локализацией (например, моторные команды мелкой моторики), чтобы обеспечить достаточно высокую для практического применения вероятность успешного распознавания.

Наиболее эффективные средства классификации ЭЭГ паттернов, в том числе, и воображаемых движений [76] были подвергнуты сопоставительному анализу (глава 1), который показал, что для построения эффективных средств классификации ЭЭГ паттернов моторных команд целесообразно комбинирование классификаторов, построенных на искусственных нейронных сетях и методе опорных векторов.

Метод опорных векторов. МОВ состоит в преобразовании данных для представления паттернов в пространстве высокой размерности, значительно превосходящей размерность исходного пространства признаков, и разделении классов с помощью гиперплоскости. Построение оптимальной гиперплоскости

происходит путем максимизации отступов от ближайших паттернов, соответствующих векторам признаков из обучающей выборки. МОВ предполагает, что с использованием подходящего нелинейного преобразования $\phi()$ в пространство достаточно высокой размерности, данные из двух классов всегда могут быть разделены с помощью гиперплоскости [46].

Пусть каждый паттерн x_k был преобразован в $y_k = \phi(x_k)$. Для каждого из n паттернов $k = 1, 2, \dots, n$, определим метку принадлежности классу $z_k = \pm 1$, в зависимости от того, принадлежит ли паттерн k классу ω_1 или классу ω_2 . Линейный дискриминант в пространстве с увеличенной размерностью y равен $g(y) = w^T y$. Таким образом, разделяющая гиперплоскость должна удовлетворять

$$z_k g(y_k) \geq 1, k = 1, \dots, n. \quad (4)$$

В методе ЛДА расстояние от гиперплоскости до ближайшего паттерна должно быть больше нуля. МОВ направлен на нахождение оптимальной гиперплоскости с наибольшим зазором, что является существенным при классификации паттернов из тестовой выборки. Как показано ранее расстояние от гиперплоскости до преобразованного паттерна y может быть выражено как $r = \frac{|g(y)|}{\|w\|}$. В случае, если искомым неотрицательный зазор b существует, то для $k = 1, \dots, n$.

$$\frac{z_k g(y_k)}{\|w\|} \geq b \quad (5)$$

Цель состоит в отыскании вектора весов w , который максимизирует b и минимизирует $\|w\|^2$ [46].

Опорными векторами являются преобразованные паттерны из обучающей выборки, для которых выражение (4) превращается в равенство: расстояние от векторов до гиперплоскости одинаково минимально. Таким образом, опорные вектора определяют положение разделяющей гиперплоскости, находятся близко друг к другу и их классификация наиболее затруднительна. Другими словами, эти паттерны являются наиболее информативными для классификатора. Следует

отметить, что выбор преобразования $\phi()$ должен быть направлен на сокращение количества опорных векторов для повышения вероятности успешной классификации. На рис. 11 приведена оптимальная разделяющая гиперплоскость и найденные опорные вектора.

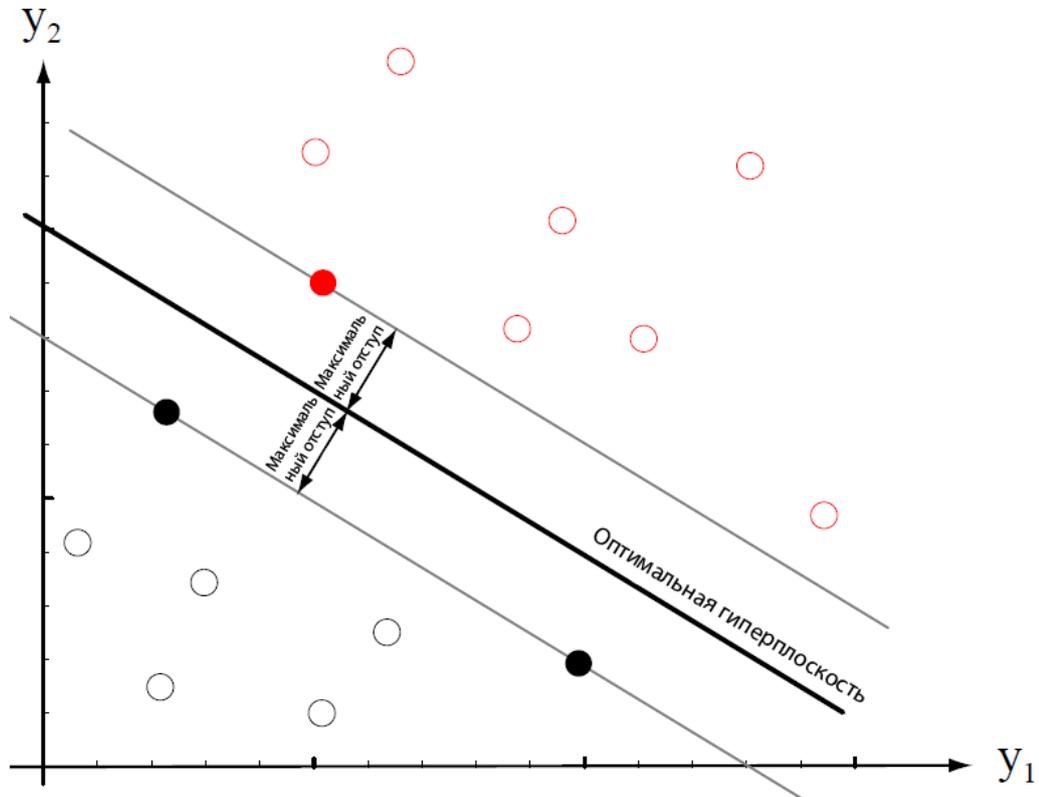


Рис. 11. Оптимальная разделяющая гиперплоскость с наибольшим расстоянием от ближайших обучающих паттернов, которые являются опорными векторами (выделены сплошной заливкой) [46].

В общем случае данные могут быть линейно неразделимыми. Тем не менее, возможно отыскать гиперплоскость, наилучшим образом разделяющую данные, а также максимизировать зазор. Позволим методу допускать ошибки на обучающей выборке и введем набор дополнительных переменных $\xi_i \geq 0$, характеризующих величину ошибки для паттернов x_i , $i = 1, \dots, n$. Тогда должны выполняться неравенства

$$\phi(x_i) \cdot w + b \geq +1 - \xi_i \text{ для } y_i = +1$$

$$\phi(x_i) \cdot w + b \leq -1 + \xi_i \text{ для } y_i = -1$$

Поскольку опорные вектора должны находиться на одинаковом расстоянии от разделяющей гиперплоскости, итоговый зазор между ними равен $b_+ + b_- = \frac{2}{\|w\|}$

Для максимизации зазора следует минимизировать $\|w\|$ или $\|w\|^2$.

Для управления допустимой суммарной ошибкой вводится термин штрафа $C \sum_i \xi_i$, где C — параметр настройки метода (регуляризации), который позволяет регулировать отношение между максимизацией ширины зазора и минимизацией суммарной ошибки.

В итоге задача отыскания разделяющей гиперплоскости сводится к задаче оптимизации [112]:

$$\left\{ \begin{array}{l} \|w\|^2 + C \sum_i \xi_i \rightarrow \min \quad (6) \\ y_i(\phi(x_i) \cdot w + b) - 1 + \xi_i \geq 0 \text{ при } i = 1, \dots, n \quad (7) \\ \xi_i \geq 0, i = 1, \dots, n \quad (8) \end{array} \right.$$

По теореме Куна - Таккера эта задача эквивалентна двойственной задаче поиска седловой точки функции Лагранжа. Эта проблема имеет известное решение, которое находится с помощью квадратичного программирования [69]:

$$\left\{ \begin{array}{l} w = \sum_{i=1}^n \lambda_i y_i \phi(x_i) \quad (9) \\ \lambda_i (y_i (w \cdot \phi(x_i) + b) - 1) = 0 \text{ при } i = 1, \dots, n \quad (10) \\ y_i (\phi(x_i) \cdot w + b) - 1 \geq 0 \text{ при } i = 1, \dots, n \quad (11) \end{array} \right.$$

где $\lambda = (\lambda_1, \dots, \lambda_n)$ - вектор двойственных переменных.

Решение оптимизационной проблемы позволяет найти значения λ_i и ξ_i . Зная их, w вычисляется по формуле (9), b – по формуле (10). Решение проблемы оптимизации и определение параметров гиперплоскости составляет этап обучения. Для отнесения паттерна к одному из классов необходимо лишь определить, с какой стороны от гиперплоскости он находится.

Для практической реализации МОВ важно выбрать метод преобразования $\phi()$. Поскольку вектор признаков имеет высокую размерность сам по себе (особенно при классификации многомерных ЭЭГ), то пространство, в которое производится преобразование, должно иметь еще большую размерность. Таким образом, вычисление $\phi()$ может быть весьма затруднительно. Для преодоления данного ограничения был предложен переход от скалярных произведений $\phi(x_i) \cdot \phi(x)$ к функции-ядру $K(x_i, x)$, с целью значительного упрощения вычислений [112].

В итоге, вектор признаков x будет классифицирован МОВ в соответствии с тем, положительное или отрицательное значение примет следующее выражение:

$$\begin{aligned} w \cdot \phi(x) + b &= \sum_{i=1}^n \lambda_i y_i (\phi(x_i) \cdot \phi(x)) + b \\ &= \sum_{i=1}^n \lambda_i y_i K(x_i, x) + b \end{aligned}$$

где коэффициенты λ_i зависят от y_i - вектора меток класса принадлежности, и от значения скалярных произведений $K(x_i, x) = (\phi(x_i), \phi(x))$.

Таким образом, для нахождения решающей функции необходимо знать значения скалярных произведений. Преобразования данных определяются функцией-ядром: $K(x_i, x_j) = (\phi(x_i), \phi(x_j))$. В случае линейной классификации МОВ ядро имеет вид: $K(x_i, x_j) = x_i^T x_j$. При переходе к нелинейной классификации методом МОВ применяется нелинейная функция ядра. Данный подход делает возможным поиск оптимальной разделяющей гиперплоскости в преобразованном пространстве признаков. В настоящей работе в качестве функции-ядра применена радиальная базисная функция Гаусса:

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \text{ для } \gamma > 0.$$

В рамках данного исследования был проведен сопоставительный анализ эффективности двух типов классификации на основе МОВ: линейной классификации и нелинейного подхода с использованием радиальной базисной функции, который показал преимущество нелинейного подхода при

классификации ЭЭГ паттернов. Результаты данного этапа исследования опубликованы в [18]

Гетерогенный классификатор ЭЭГ паттернов моторных команд.

Для построения эффективных средств классификации ЭЭГ паттернов моторных команд целесообразно комбинирование классификаторов, построенных на искусственных нейронных сетях и методе опорных векторов. Был предложен новый подход по объединению разнородных классификаторов в масштабируемый комитет гетерогенных классификаторов, обобщенных нейробиологическим обучаемым классификатором второго уровня.

Для совместного учета двух типов признаков был разработан двухуровневый комитет классификаторов, первый уровень которого состоит из двух ИНС и двух классификаторов на основе МОВ, а второй уровень - из нейронной сети, объединяющей результаты классификаторов первого уровня (рис. 12).



Рис. 12. Схема двухуровневого комитета гетерогенных классификаторов.

Классификаторы первого уровня анализируют отдельные векторы признаков одного из типов признаков и генерируют ответы об отнесении пробы к тому или иному классу, на основе которых формируется вектор признаков для ИНС второго уровня, которая принимает окончательное решение о принадлежности данного ЭЭГ сигнала определенному классу. В качестве локальных

классификаторов используются МОВ на основе радиальной базисной функции и ИНС с 2 скрытыми и 1 выходным слоем, описанные выше.

Данный подход может быть масштабирован путем включения новых типов классификаторов и новых пространств признаков. Ограничением служит требование о разнотипности классификаторов и/или использование различных обучающих выборок из общего набора проб для обучения.

Другим подходом для повышения эффективности разработанных средств классификации является выбор для каждого испытуемого индивидуальных параметров генерации признаков, таких как информативные для данного испытуемого каналы.

Выводы по Главе 2

1. Спектральный анализ сигналов ЭЭГ приводит к потере информации о временной локализации характерных признаков, что затрудняет решение задачи сокращения длительности регистрируемого сигнала и определения последовательности возникновения и длительности участка сигнала, связанного с событием. Кроме того, в связи с нестационарностью ЭЭГ сигнала, для извлечения признаков требуется накопление значительного числа образцов сигналов, соответствующих определенному событию. Для устранения этих ограничений и повышения эффективности классификации ЭЭГ сигналов предлагается проводить анализ многоканальных ЭЭГ во временной области.

2. Символьная регрессия сигналов ЭЭГ, соответствующих моторным командам, предлагается как средство перехода от числовых к аналитическим, функциональным методам анализа. Главным преимуществом этого метода является автоматическая генерация регрессионной модели в аналитической форме, что позволяет раскрыть структуру паттернов мозговой активности и извлекать признаки ЭЭГ сигнала в скользящем временном окне анализа с учетом их временной локализации.

3. Реализованные методы преобразования ЭЭГ сигналов (преобразование к взвешенному среднему монтажу, разложение на независимые компоненты,

преобразование к плотности источников тока) направлены на повышение соотношения сигнал/шум и выделение источников сигнала для более точного распознавания моторных команд.

4. Продемонстрирована целесообразность одновременного использования разнотипных средств классификации, чувствительных к различным особенностям сигнала, для распознавания ЭЭГ паттернов, соответствующих моторным командам. Предложен метод построения гетерогенного комитета классификаторов на основе ИНС и МОВ, объединяющий разнородные способности к классификации двух подходов. Показано, что объединение разнотипных классификаторов в двухуровневый масштабируемый комитет гетерогенных классификаторов целесообразно производить с помощью нейрологического классификатора второго уровня.

5. Совокупность приведенных методов предобработки, преобразования, извлечения признаков и классификации сложных многомерных сигналов ЭЭГ подлежит реализации в разрабатываемой системе классификации для применимого на практике ИМК реального времени.

Глава 3. Алгоритмы и программные средства системы анализа и классификации ЭЭГ паттернов моторных команд для ИМК

Разработка алгоритмов и программных средств направлена на создание специализированной системы классификации ЭЭГ паттернов. Использование системы предполагается как для исследований ЭЭГ сигналов и оценки их различимости, так и для управления внешними устройствами в парадигме ИМК.

Система предназначена для предобработки, анализа и классификации паттернов биоэлектрической активности моторных команд. Результат классификации может быть использован для управления внешними устройствами, такими как искусственная кисть руки.

3.1. Модельные задания и регистрируемые сигналы

ЭЭГ сигналы моторных команд для обучения системы анализа и классификации ЭЭГ паттернов регистрировались в процессе физиологических исследований с испытуемыми, которые выполняли задания на воображение движений пальцами и кистью руки в заданном ритме.

Испытуемые. В исследованиях участвовали праворукие испытуемые (3 мужчин, 6 женщин, средний возраст 29 ± 5 [SD] лет). Испытуемые были здоровы на момент исследования и сообщали, что не имеют никаких медицинских и нейрофизиологических нарушений, имеют нормальное зрение. Все процедуры исследования выполнялись в соответствии с Хельсинской декларацией (1974) о проведении исследований с участием добровольцев. После детального объяснения процедуры исследования, участники давали письменное согласие на участие в нем.

Модельные задания на выполнение воображаемых движений мелкой моторики. В рамках настоящего исследования была разработана новая парадигма исполнения заданий пользователем с использованием подстройки воображаемых движений мелкой моторики под заданный ритм - «*ритмическая парадигма*».

Необходимый ритм воображения движений для испытуемых задавался с помощью аудио стимулов.

В отдельных блоках заданий испытуемым предлагалось выполнить поочередно несколько типов воображаемых движений (одно движение в одном блоке проб) - мизинцем, большим, указательным, средним пальцами правой руки и сжатие кисти руки. Так же исследование содержало блок фоновых или контрольных проб, в которых перед испытуемыми не ставилось задачи воображать, звуки не предъявлялись.

Испытуемые должны были сначала в заданном звуками ритме нажимать на кнопку компьютерной мыши обозначенным согласно инструкции исследователя пальцем или сжимать кисть, а затем продолжать воображать нажатие этим же пальцем или сжатие кисти в заданном ритме, когда звук пропадал. Инструкция на воображение нажатий и воображение сжатия была ориентирована на инициацию кинестетических ощущений у испытуемого [83]. Показано, что при возникновении кинестетических ощущений при воображении движений зоной интереса являются сенсомоторные зоны коры, как и при выполнении реальных моторных команд.

На рис.13 представлена схема последовательности синхронизирующих проб - (со звуком) и проб без звука, требующих инициации кинестетического воображения в заданном ритме.

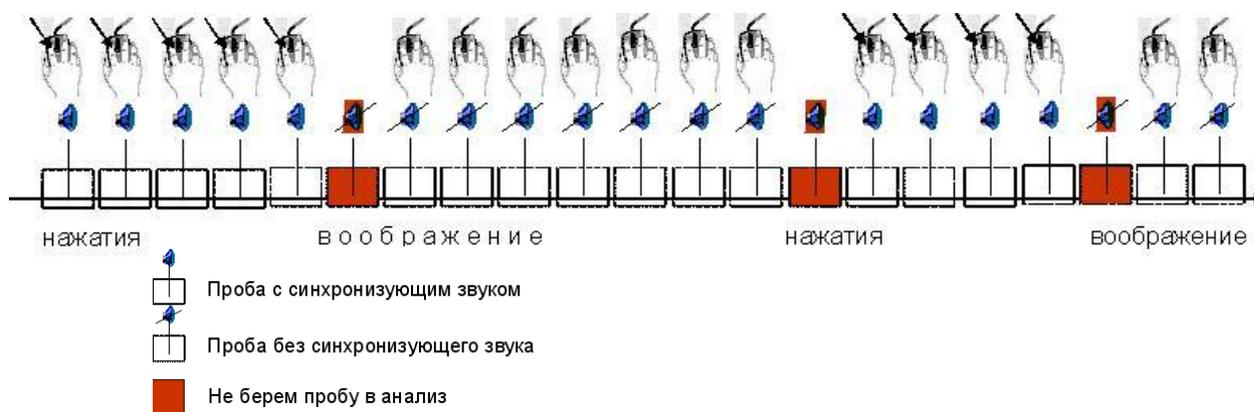


Рис. 13. Схема предъявления последовательности проб в исследовании с использованием «аудио-ритмической модели».

Задания имели блоковую схему. Внутри одного блока задания серии реальных и воображаемых движений повторялись многократно. В результате, испытуемый выполнял не менее 100 реальных и 100 воображаемых движений в заданном темпе внутри одного блока задания. Количество блоков задания соответствовало количеству классифицируемых моторных команд. Далее для анализа и классификации использовались только пробы с воображаемыми движениями.

Длительность отдельной пробы составляла 600 мс, межпробный интервал – 100 мс. На 300-той мс от начала «синхронизирующей» пробы испытуемому предъявлялся звуковой сигнал. Такие синхронизирующие пробы предъявлялись сериями так, что испытуемый какое-то время слышал задаваемый ему ритм и выполнял движения одновременно со звуком, настраиваясь на воображение в этом же ритме, когда звук пропадет. Начало и конец проб не были известны пользователю. Синхронизирующие звуковые пробы предъявлялись небольшой последовательностью от 5 до 10 штук, так чтобы пользователь а) запомнил или б) обновил необходимый ритм воображения движений, когда звук снова пропадет. Параметры предъявляемого звука в синхронизирующих пробах: 500 Гц на 50 мс, уровень громкости не более 60 дБ.

Дополнительно в целях контроля были проанализированы контрольные пробы без кинестетического воображения, когда после серии синхронизирующих проб со звуком, испытуемый не должен был воображать какие-либо движения в заданном темпе.

Процедура регистрации ЭЭГ сигналов. Испытуемые находились в звукоизолированном помещении в положении сидя на расстоянии одного метра от экрана компьютера. Нажатия на кнопку или сжатие кисти и выполнение задач на воображение производились с открытыми глазами в заданном звуками темпе (ритмическая парадигма). Длительность одного блока проб составляла не менее 8 минут. Порядок блоков заданий был рандомизирован между испытуемыми для того, чтобы избежать эффекта утомления при выполнении заданий в одной и той же последовательности.

Сигналы ЭЭГ регистрировались монополярно от 19-ти отведений (Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, O2 в соответствии со стандартной системой 10-20). Референтные электроды располагались на мочках обеих ушей, заземляющий электрод - во фронтальной части головы. Для записи использовали 32х канальный электроэнцефалограф «Мицар» (Санкт-Петербург, Россия). Регистрация ЭЭГ проводилась с применением сетевого фильтра 45-55 Гц, для записи ЭЭГ использовали программное обеспечение WinEEG (авторские права - Пономарев В.А., Кропотов Ю.Д. № LtD 2001610516 от 08.05.2001). Сопротивление электродов не превышало 5 кОМ. Частота дискретизации на канал соответствовала 2000 Гц. Для последующего анализа ЭЭГ данные подвергались децимации до 500 Гц на канал.

Фильтрация сигнала. Выполнена фильтрация ЭЭГ в разных частотных диапазонах (0.5-15Гц, 10-15 Гц, 0.5-30 Гц), проведен сравнительный анализ результатов классификации ЭЭГ в узких и широкой полосах. Было показано, что использование широкой полосы является предпочтительной при классификации паттернов ЭЭГ [107], в связи с этим, для использования в данной системе классификации ЭЭГ сигнал был отфильтрован в широкой полосе частот 0.5-30 Гц.

Удаление артефактов. Из анализируемых файлов ЭЭГ исключались фрагменты, содержащие высокочастотный и/или низкочастотный сигнал, превышающий определенный порог. Детектировался медленный сигнал мощностью 50 мкВ в полосе 0-2 Гц, и быстрый сигнал мощностью более 35 мкВ в полосе 20-35 Гц. Пробы, содержащие артефактные фрагменты, не рассматривались при анализе и классификации данных.

Временная область анализа составляла 600 мс от начала пробы. В это окно, предположительно, попадали последние этапы подготовки к воображаемому движению и само воображаемое движение, ранее задававшееся звуковыми стимулами или зрительными стимулами на 300 мс от начала пробы.

Алгоритм извлечения участков ЭЭГ сигналов из потоковой записи.

Данный алгоритм направлен на автоматическое извлечение участков записи ЭЭГ, соответствующих моторным командам, в соответствии с парадигмой исследования.

В алгоритме автоматического извлечения сигналов из потоковой записи ЭЭГ используются следующие входные данные:

- t – общее число отсчетов в потоковой ЭЭГ записи;
- $Data1C3Cz(t, 2)$ – двумерный массив записи, содержащий потоковую ЭЭГ запись для двух анализируемых каналов;
- sz – количество сигналов в потоковой записи;
- $DataInfo1(sz, 2)$ – двумерный массив, содержащий отсчет начала сигнала в потоковой записи с указанием типа движения для данного сигнала;
- l_probi – длина участка ЭЭГ сигнала, соответствующего одной пробе;
- $metki$ – массив меток классов принадлежности для анализируемых участков ЭЭГ, соответствующих различным моторным командам;
- RT_otstup – отступ от нажатия кнопки;
- RT_stimul – отступ от предъявления стимула.

Параметры l_probi , $metki$, RT_otstup , RT_stimul задаются исследователем. Массив $Data1C3Cz(t, 2)$, содержащий потоковую ЭЭГ запись для двух каналов, формируется из массива $Data1$, содержащего потоковые записи по всем отведениям, поступающие с энцефалографа.

На рис. 14 показана схема алгоритма извлечения участков ЭЭГ сигнала из потоковой записи для последующего анализа и классификации.

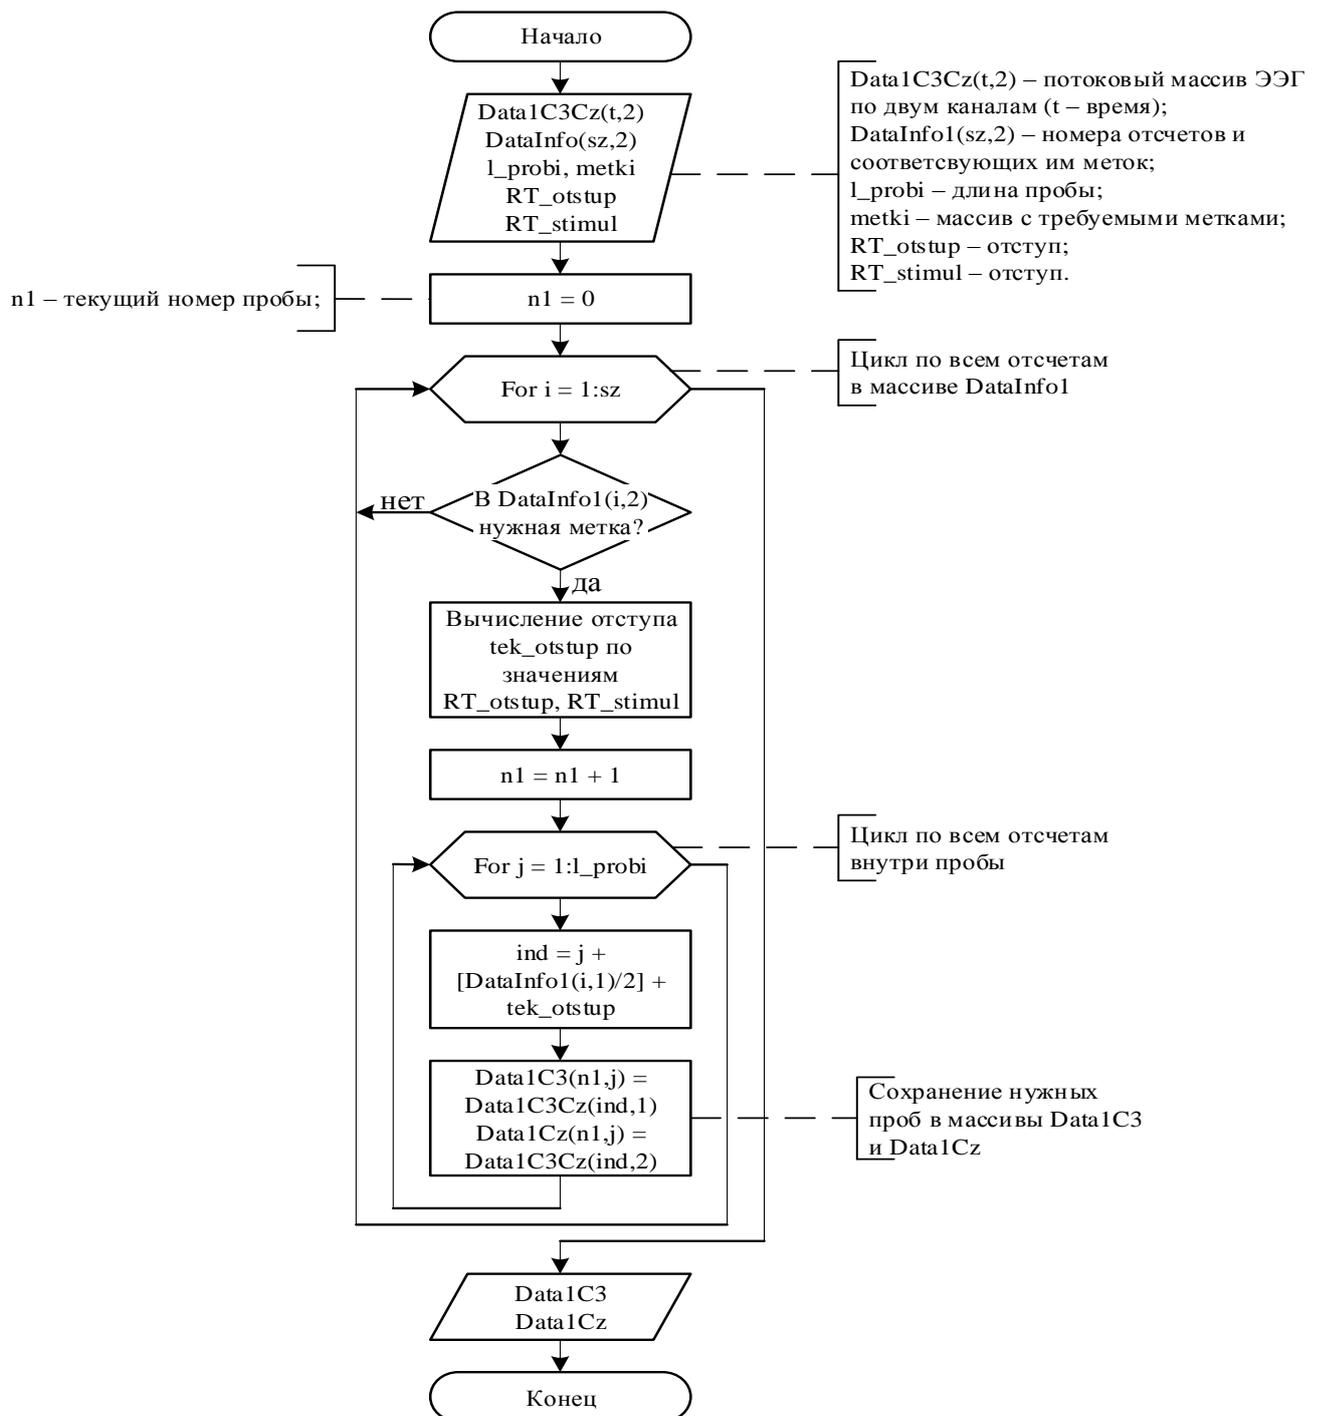


Рис. 14. Схема алгоритма формирования массива данных из потоковой записи ЭЭГ

Примечание: для записи выражений в схеме алгоритма использован синтаксис языка MatLab, для обозначения операции округления использованы квадратные скобки.

Алгоритм автоматического извлечения сигналов из потоковой записи ЭЭГ заключается в следующих действиях:

- 1) поиск в массиве DataInfo1 отсчетов начала исследуемых типов сигналов;

2) для каждого найденного отсчета начала исследуемых типов сигнала вычисление значения отступа tek_otstup от начала сигнала;

3) сохранение в переменную $Data1C3$ части массива $Data1C3Cz$, являющейся сигналом первого канала, начинающимся с отсчета начала сигнала со сдвигом tek_otstup , длительностью l_probi отсчетов;

4) аналогично происходит сохранение в переменную $Data1Cz$ сигнала второго канала.

Массивы $Data1C3$ и $Data1Cz$ являются результирующими данными алгоритма, содержащими совокупность выделенных участков ЭЭГ сигнала, соответствующих моторным командам, для последующего анализа и классификации.

3.2. Алгоритмы извлечения признаков

Алгоритм накопления сигналов. Накопление сигнала путем суммирования нескольких образцов сигналов одного типа воображаемых движений направлено на увеличение соотношения сигнал шум, т. е. на выделение слабого управляющего сигнала. Подход основан на том факте, что связанный с событием сигнал повторяется в серии проб в рамках одной сессии, а математическое ожидание сигнала фонового состояния стремится к нулю. В эксперименте реализовано несколько вариантов накопления проб – по 5, 10, 20 образцов, а также реализован single-trial подход. Необходимо отметить, что метод накопления проб имеет регрессионные свойства, что приводит к нивелированию индивидуальных особенностей сигналов, оставляя лишь их общий тренд. Для практического использования системы анализа и классификации в ИМК реального времени перспективным является single-trial подход без накопления, а также накопление малого количества образцов (распознавание с подкреплением). На рис. 15 показан результат накопления путем суммации 10 проб ЭЭГ сегментов одного типа.

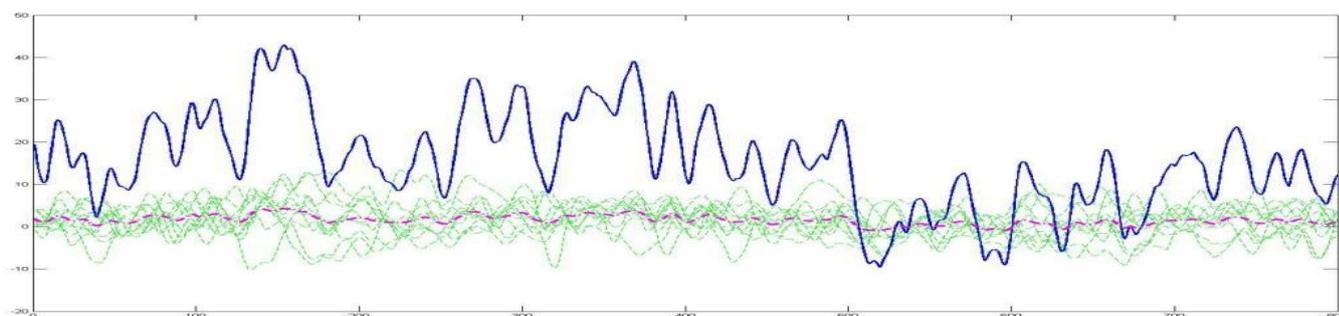


Рис. 15. Сигналы ЭЭГ, соответствующие воображаемому движению указательным пальцем (пунктирная линия); накопленный по 10 пробам сигнал (сплошная линия), среднее по 10 пробам (пунктирная линия с точкой). На оси абсцисс изображены временные отсчеты (1 отсчет = 2мс), на оси ординат амплитуда в мкВ.

Реализация вышеуказанного подхода выполняется алгоритмом формирования накопленных сигналов. С целью реализации и исследования влияния подхода накопления проб на успешность классификации воображаемых движений по данным ЭЭГ был разработан алгоритм формирования выборок сигналов, полученных путем накопления (суммации) исходных записей попыток (single-trial) из ограниченного пула таких ЭЭГ-записей. Для решения данной задачи был использован метод бутстрэп, предложенный Эфроном [47]. Цель метода состоит в том, чтобы из имеющейся выборки сформировать достаточно большое количество повторных выборок заданного размера, состоящих из случайных комбинаций исходного набора элементов, и для каждой полученной повторной выборки определить значения анализируемых статистических характеристик. Алгоритм формирования накопленных сигналов приведен на рис. 16.

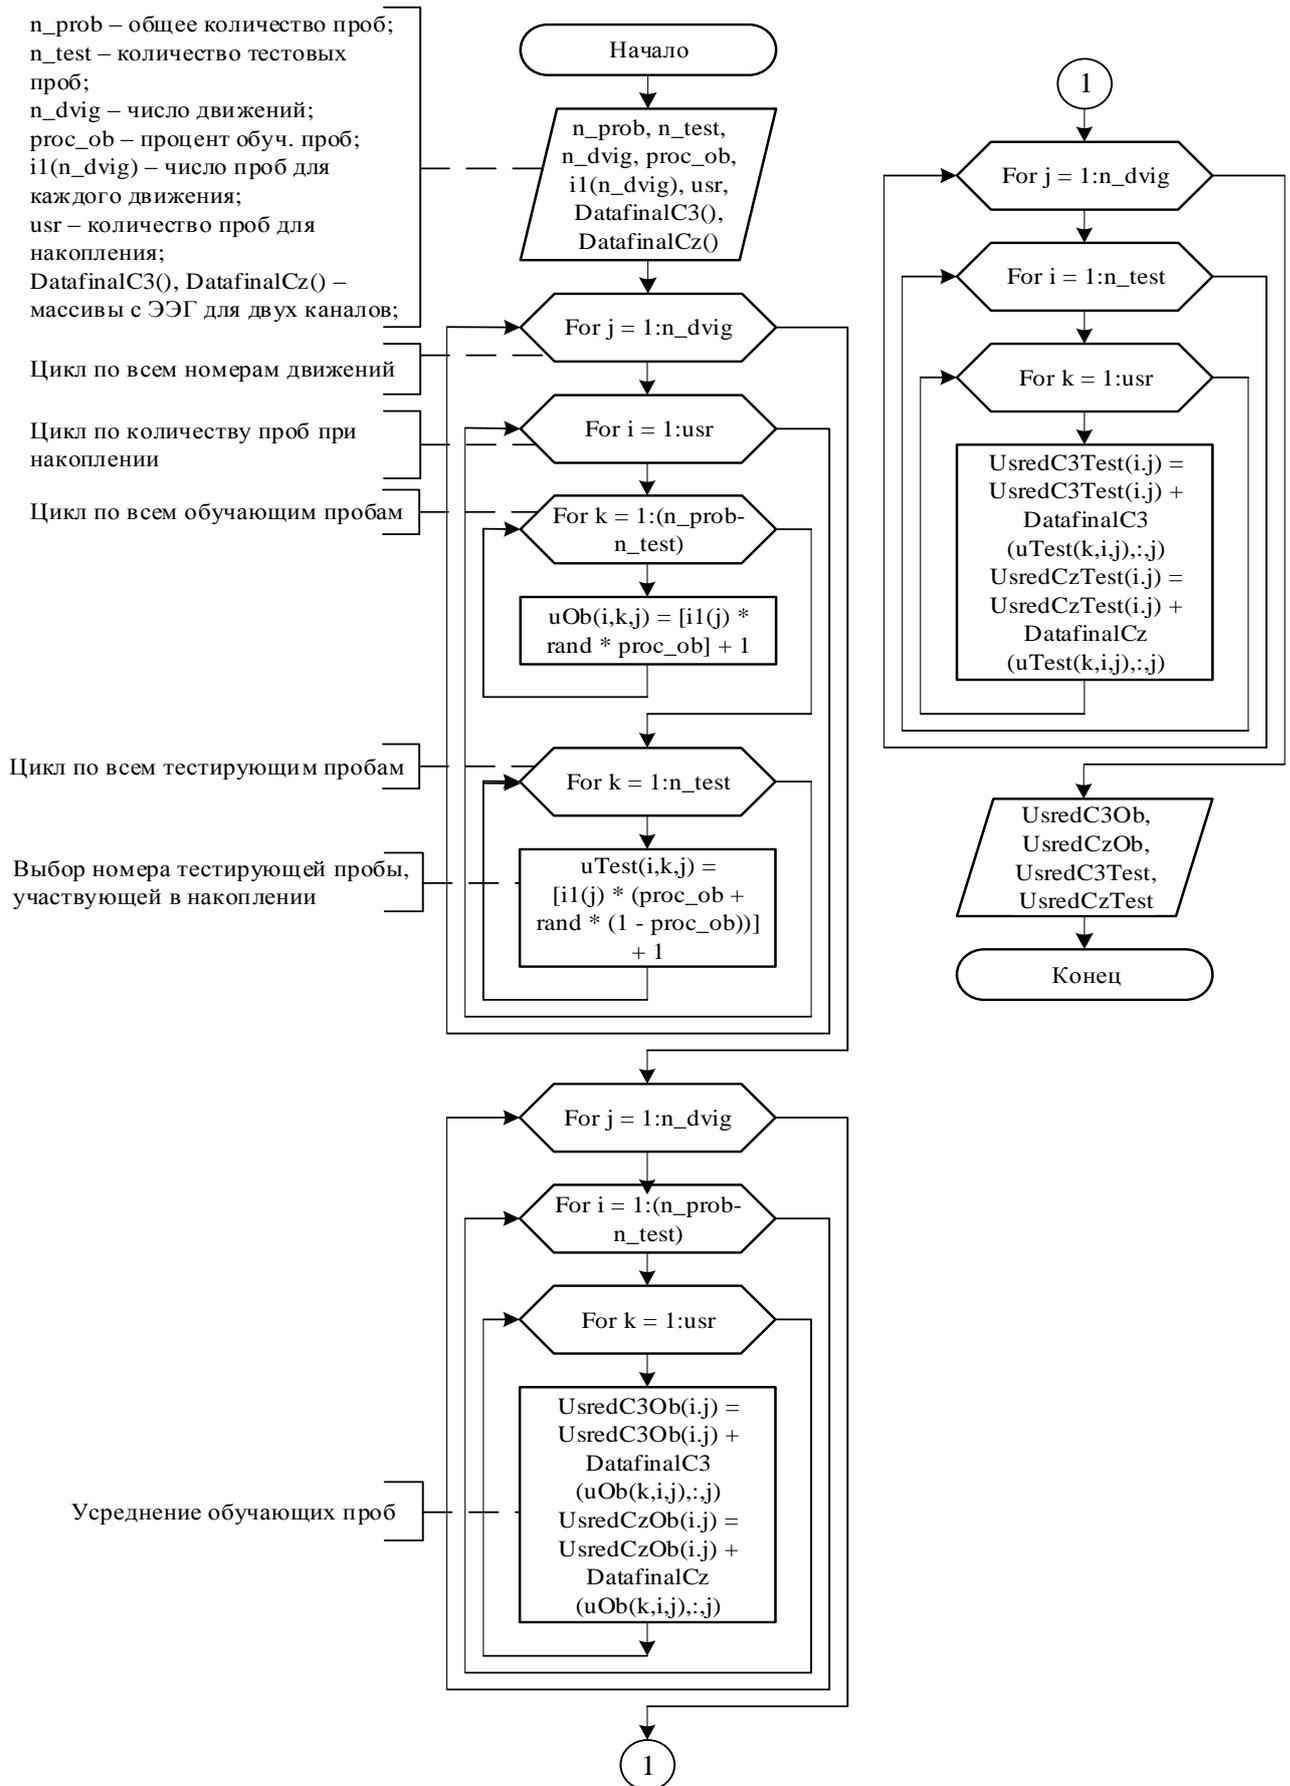


Рис. 16. Алгоритм формирования накопленных сигналов из ограниченного пула ЭЭГ-записей.

Для алгоритма формирования накопленных сигналов необходимы следующие входные данные:

- n_prob – общее число ЭЭГ-сигналов;
- n_test – число ЭЭГ-сигналов, используемых для тестирования классификатора и не участвующих в обучении;
- n_dvig – количество воображаемых движений / моторных команд, которые должен распознавать классификатор после обучения;
- $proc_ob$ – число, принимающее значения от нуля до единицы, определяющее границу между пулами ЭЭГ-записей, используемых для обучения и тестирования классификатора. Таким образом, наборы обучающих и тестирующих выборок не пересекаются;
- usr – число ЭЭГ-записей, которые суммируются для получения накопленного сигнала;
- $DatafinalC3$, $DatafinalCz$ – матрицы с ЭЭГ-записями для двух каналов, полученные с помощью алгоритма автоматического извлечения сигналов из потоковой записи ЭЭГ.

Параметры n_prob , n_test , n_dvig , $proc_ob$, usr задаются исследователем.

После ввода данных для формирования накопленных сигналов осуществляются следующие действия:

- 1) выбор случайным образом номеров сигналов из пула обучающих проб и их сохранение в массив uOb ;
- 2) выбор случайным образом номеров сигналов из пула тестирующих и их сохранение в массив $uTest$;
- 3) суммирование обучающих сигналов с номерами, хранящимися в массиве uOb , и сохранение накопленного обучающего сигнала в массивы $UsredC3Ob$ и $UsredCzOb$ для двух каналов;
- 4) суммирование тестирующих сигналов с номерами, хранящимися в массиве $uTest$, и сохранение накопленного обучающего сигнала в массивы $UsredC3Test$ и $UsredCzTest$ для двух каналов.

Результирующими данными алгоритма являются массивы, содержащие накопленные обучающие и тестирующие сигналы для двух каналов.

Алгоритм генерации характерных признаков во временной области. Предобработанные и накопленные сигналы служат исходными данными для алгоритма вычисления векторов характерных признаков. В данной работе реализован алгоритм совместного учета двух типов признаков – площади сегмента ЭЭГ сигнала в скользящем временном окне и длины кривой сегмента в скользящем окне.

Крайне важным для повышения вероятности успешной классификации является выбор исследователем длины окна и значения сдвига окна при запуске очередного эксперимента. Эти параметры являются глобальными и задаются при запуске программы. Проведенный ранее регрессионный анализ позволил получить модели сигналов в аналитическом виде, что делает возможным построение графика каждой из функций, входящих в найденную суперпозицию.

Схемы алгоритмов вычисления площади сегмента под кривой сигнала и сложности сегмента кривой в скользящем окне для выбранной длины окна и значения сдвига приведены на рис. 17 и 18 соответственно.

В алгоритме вычисления площади сегмента под кривой ЭЭГ сигнала используются следующие входные данные:

- n_okon – общее число окон в потоковой ЭЭГ записи в двух каналах;
- n_chan – число каналов;
- n_prob – общее число проб;
- n_test – число тестирующих проб;
- n_dvig – число движений;
- $sdvig$ – шаг сдвига скользящего окна;
- l_okna – длина скользящего окна в отсчетах;
- $Sgnl$ – массив с накопленными ЭЭГ сигналами.

Параметры $n_окон$, n_chan , n_prob , n_test , n_dvig , $sdvig$, $l_окна$ задаются исследователем. Массив $Sgnl$, содержащий накопленные ЭЭГ сигналы, формируется в результате выполнения алгоритма накопления ЭЭГ сигналов.

Алгоритм вычисления площади сегмента под кривой ЭЭГ сигнала заключается в следующих действиях:

- 1) вычисление и сохранение в переменную $n_окон_vканале$ числа окон в канале;
- 2) вычисление смещения от начала сигнала $nach_окна$;
- 3) вычисление площади под кривой ЭЭГ сигнала с помощью численного интегрирования по методу трапеций;
- 4) для каждого скользящего окна накопление в переменную $SSgnl$ площади сегмента под кривой ЭЭГ сигнала;
- 5) сохранение накопленной площади $SSgnl$ в массиве $FinSSign$.

Результатом алгоритма является массив $FinSSign$, являющийся вектором характерных признаков, представляющих собой площадь сегментов под кривой накопленного ЭЭГ сигнала.

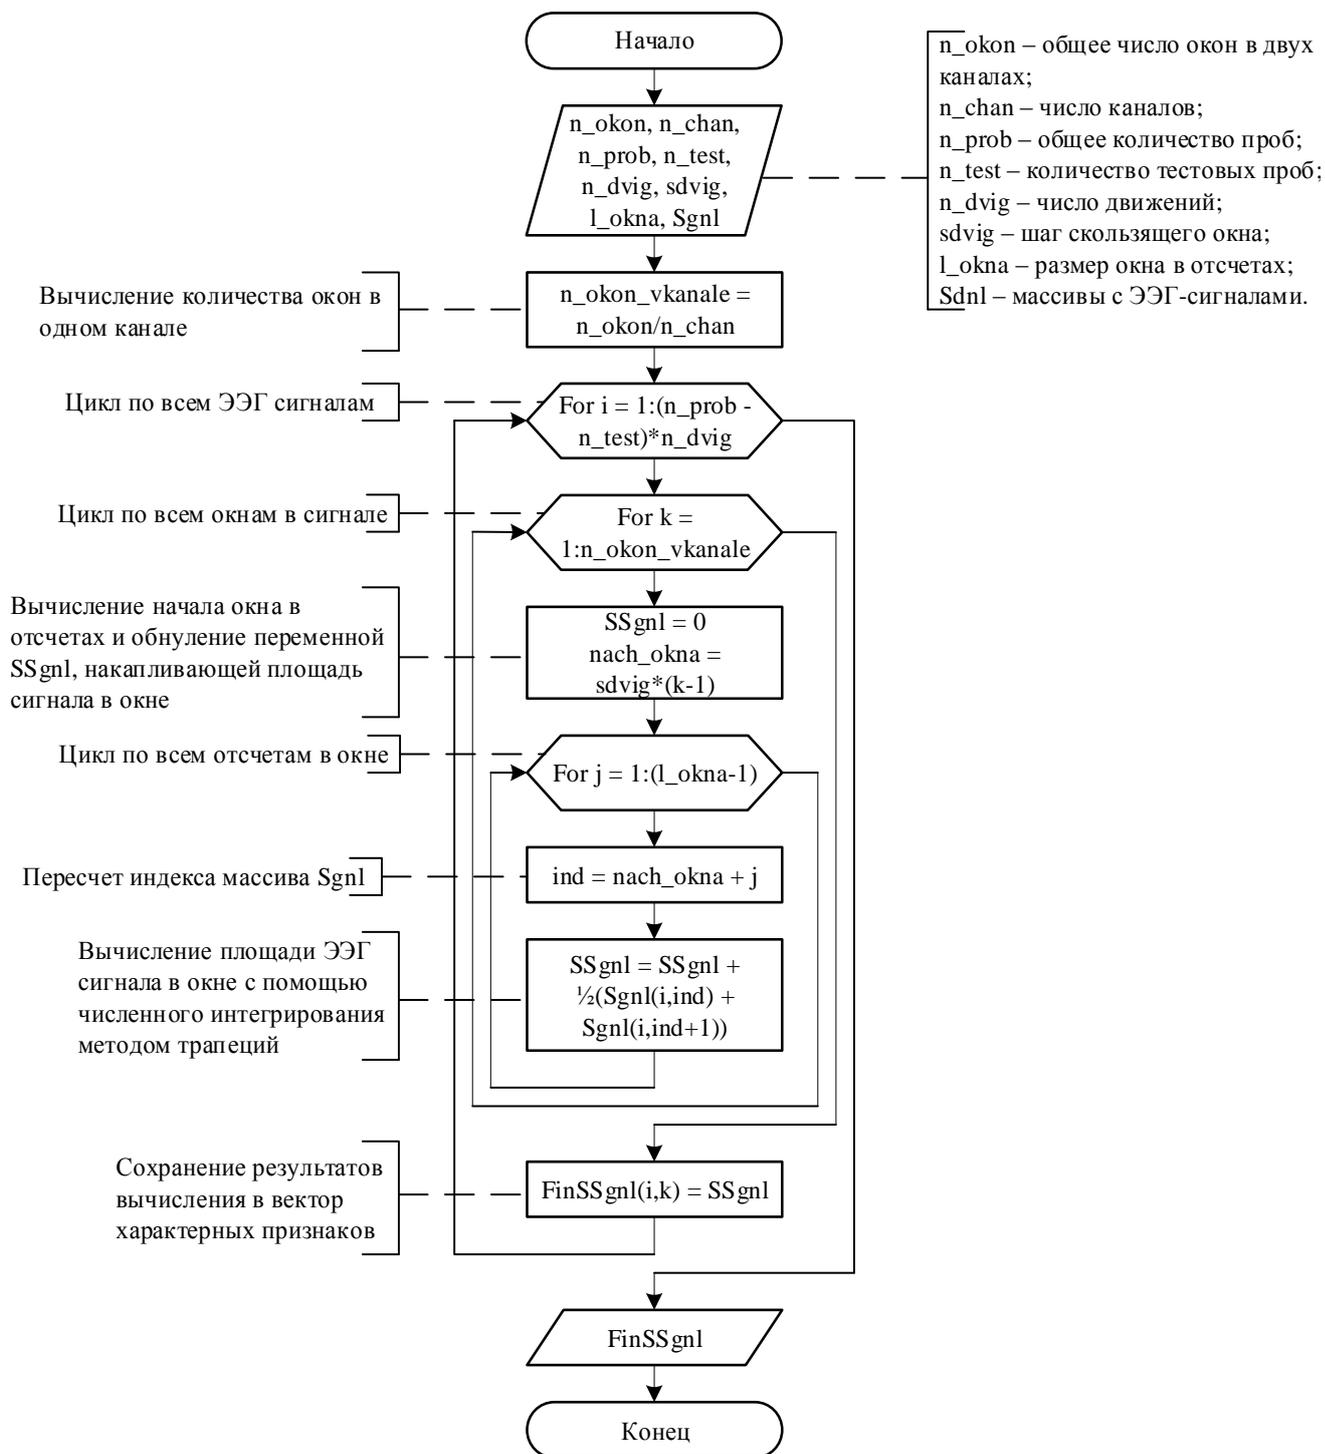


Рис. 17. Алгоритм вычисления площади сегмента под кривой ЭЭГ сигнала в скользящем окне.

В алгоритме вычисления длины кривой сегмента ЭЭГ сигнала используются те же входные данные, что и в алгоритме вычисления площади сегмента. Алгоритм вычисления длины кривой сегмента ЭЭГ сигнала заключается в следующих действиях:

- 1) вычисление и сохранение в переменную $n_окон_vканале$ числа окон в канале;
- 2) вычисление смещения от начала сигнала $nach_окна$;
- 3) вычисление длины кривой сегмента ЭЭГ сигнала;
- 4) для каждого скользящего окна накопление в переменную $LSgnl$ длины кривой сегмента ЭЭГ сигнала;
- 5) сохранение значения наколенной переменной $LSgnl$ в массиве $FinLSign$.

Результатом алгоритма является массив $FinLSign$, являющийся вектором характерных признаков.

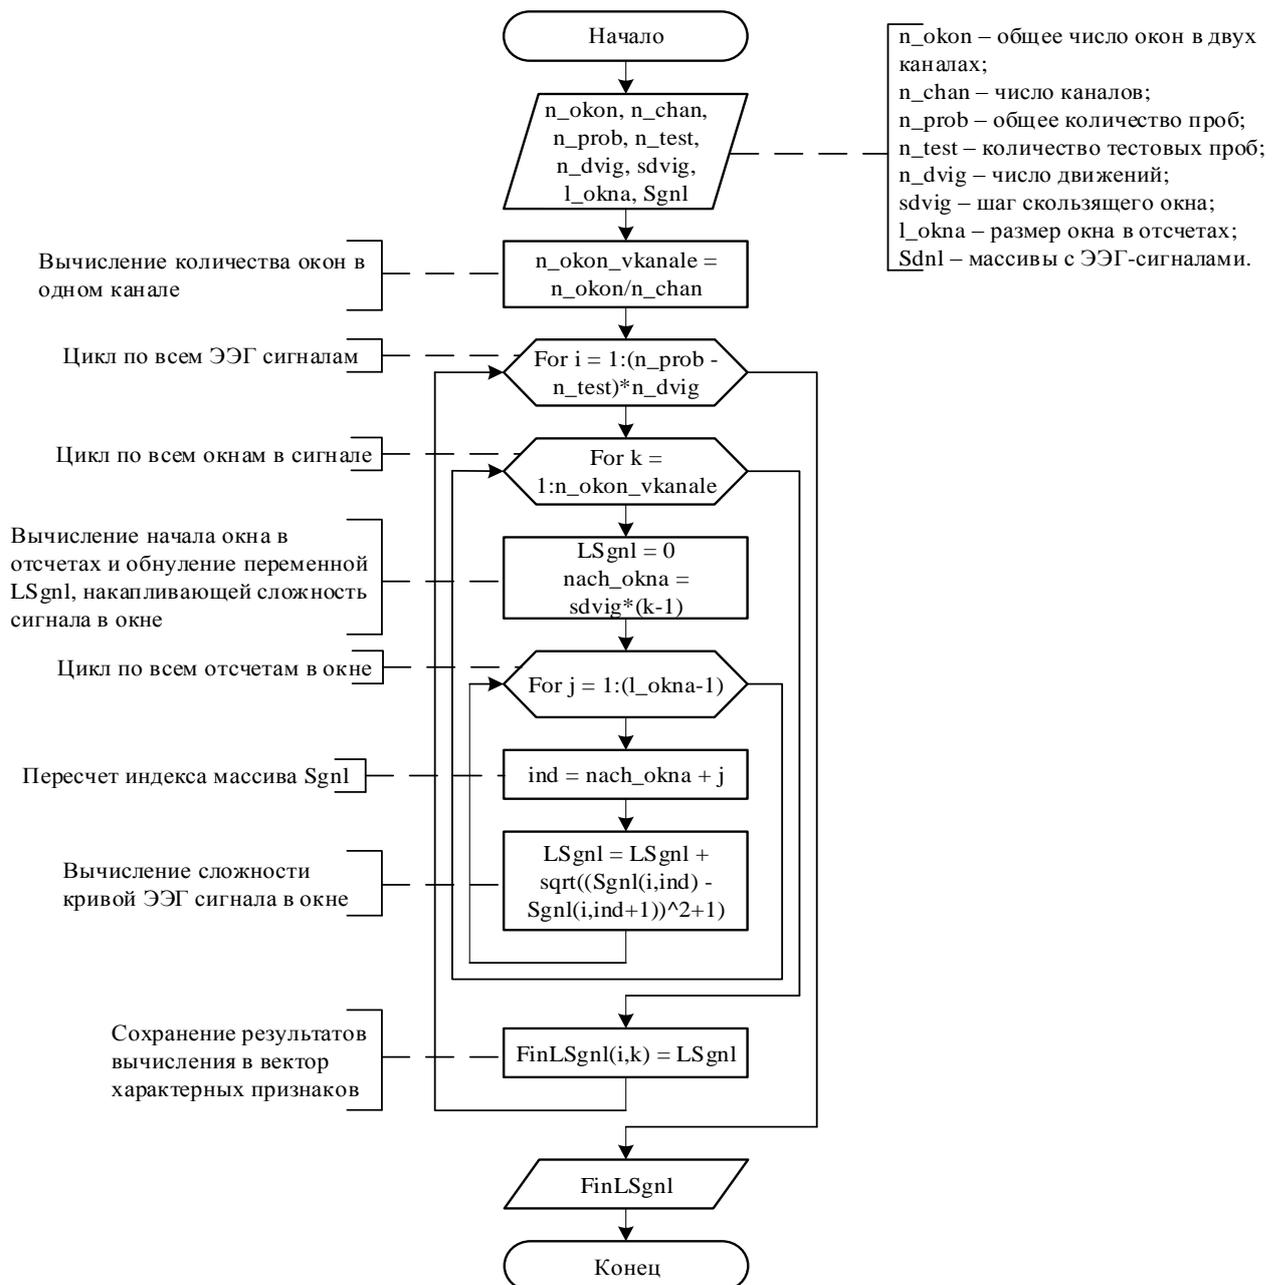


Рис. 18. Алгоритм вычисления длины кривой сегмента сигнала в скользящем окне.

Для всех испытуемых анализ проводился во временных окнах, равных -30, 50, 70, 100 отсчетам, при значении одного отсчета - 2 мс. Сдвиг окна анализа составлял последовательно - 10, 30, 50 процентов от рассматриваемой длины окна. Вариации окон и сдвигов при анализе данных были необходимы для реализации индивидуализированного подхода, выбора параметров, обеспечивающих наибольшую вероятность успешного распознавания воображаемых движений (результаты исследований приведены в главе 4). Было показано, что подбор индивидуальных окон анализа может существенно повысить вероятность успешной классификации воображаемых движений [21].

3.3 Алгоритмы классификации ЭЭГ паттернов

Разработанные алгоритмы классификации паттернов ЭЭГ, соответствующих моторным командам, основаны на методах классификации, приведенных в главе 2. В рамках проведенных исследований [107] было показано, что классификаторы на основе искусственных нейронных сетей демонстрируют более высокую вероятность успешной классификации сигналов без накопления, по сравнению с классификаторами на основе метода опорных векторов. Тем не менее, классификация методом опорных векторов на основе радиальной базисной функции предпочтительна при условии накопления сигналов, так как процент успешных распознаваний с использованием МОВ увеличивается по мере увеличения числа накоплений сигнала.

Таким образом, были разработаны классификаторы на основе комитета гомогенных ИНС и на основе комитета гетерогенных классификаторов, включающего ИНС и МОВ.

Алгоритм классификации с использованием комитета гомогенных ИНС. Для совместного учета двух типов признаков был разработан комитет ИНС, состоящий из двух нейронных сетей нижнего уровня и объединяющей ИНС верхнего уровня. Каждая их ИНС нижнего уровня анализирует вектор признаков «своего» пространства признаков. Результаты ИНС нижнего уровня

обрабатываются нейронной сетью верхнего уровня, которая на основе этих результатов классифицирует ЭЭГ паттерн. В работе применена ИНС типа многослойный персептрон с двумя скрытыми и одним выходным слоями и обучением по методу обратного распространения ошибки. В формальных нейронах скрытых слоев была использована сигмоидная функция активации (гиперболический тангенс), а для нейронов выходного слоя – линейная функция. Процесс обучения сети продолжался до тех пор, пока не было достигнуто заданное значение вероятности успешной классификации на всей обучающей выборке, или пока число итераций не достигло порогового значения. Обучающая выборка содержала 70% безартефактных проб, тестовая выборка состояла из оставшихся 30% проб. Выборки не пересекались.

Алгоритм обучения комитетов ИНС приведен на рис. 19.

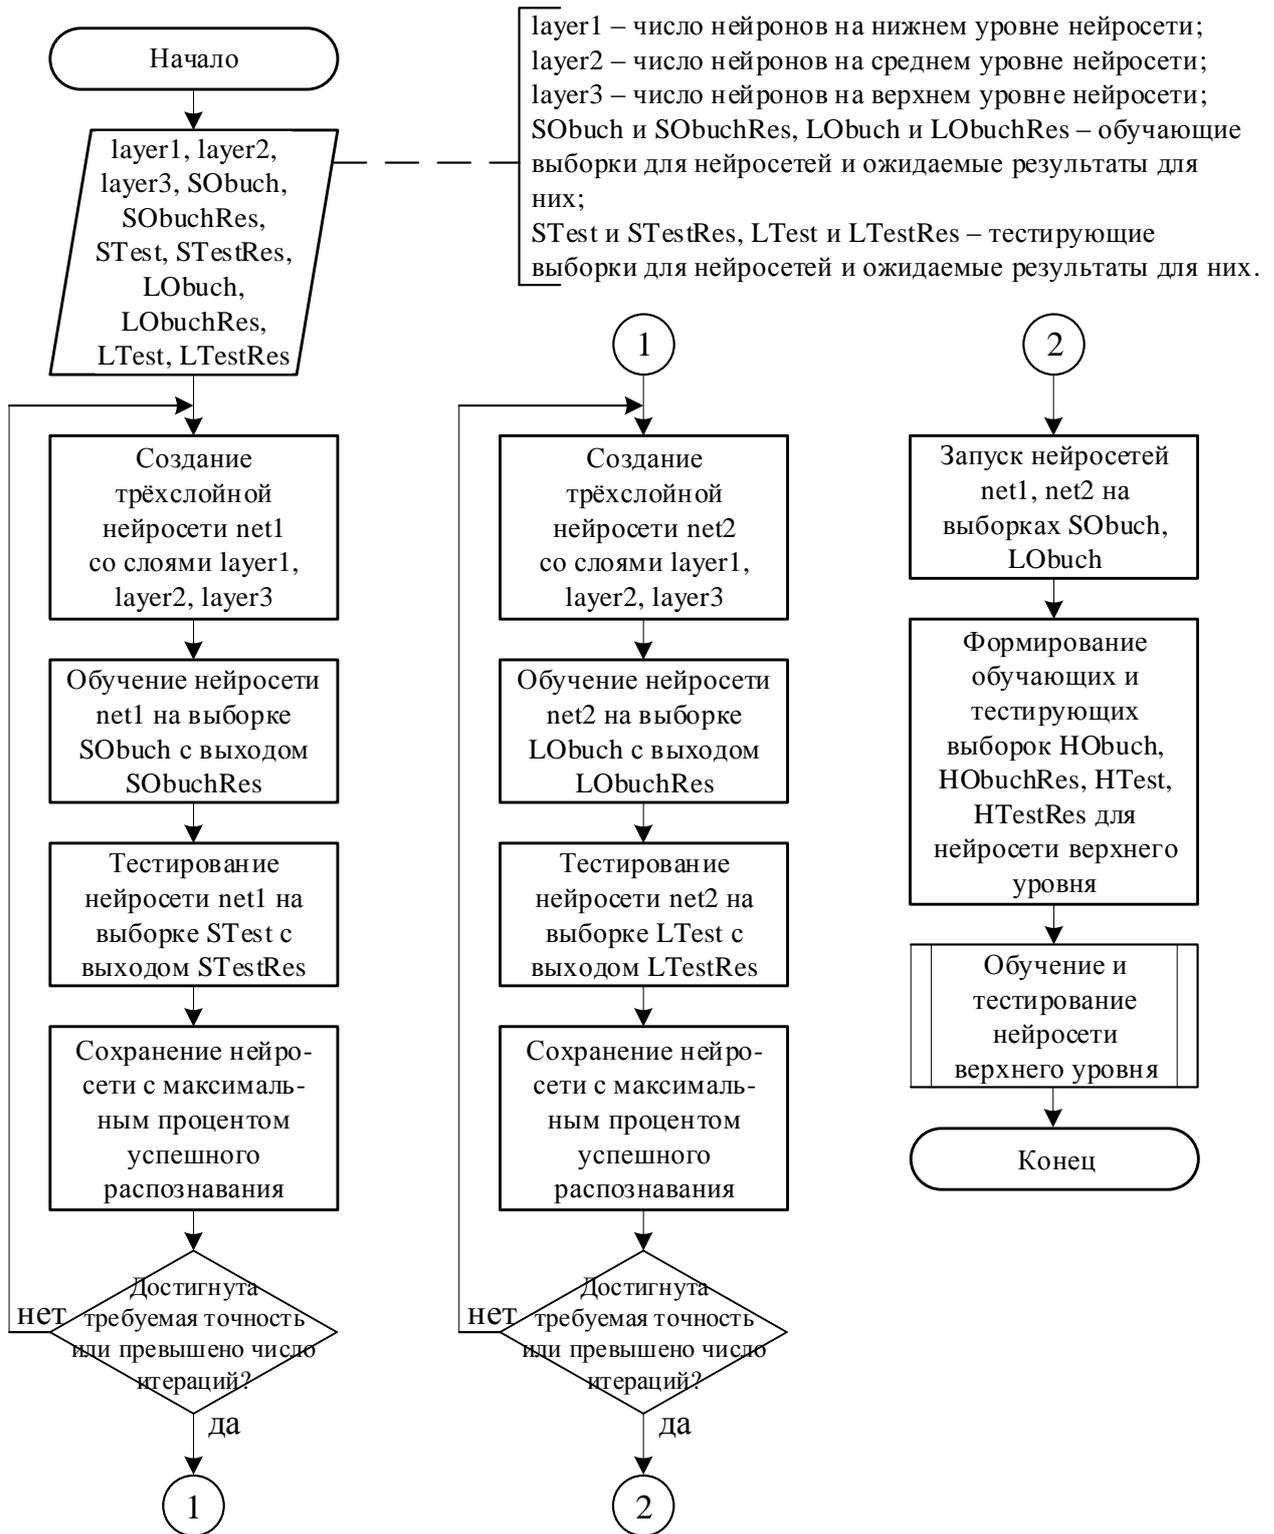


Рис. 19. Алгоритм обучения комитета ИНС.

В алгоритме обучения комитета используются следующие входные данные:

- layer1, layer2, layer3 – число нейронов на нижнем, среднем и верхнем уровне нейросетей нижнего уровня;

- SObuch и SObuchRes – обучающие векторы характерных признаков (площадь сегмента под кривой ЭЭГ сигнала в скользящем окне) для первой нейросети нижнего уровня net1 и ожидаемые результаты для этих векторов;
- STest и STestRes – тестирующие векторы характерных признаков для нейросети net1 и ожидаемые результаты для этих векторов;
- LObuch и LObuchRes – обучающие векторы характерных признаков (длина кривой сегмента ЭЭГ сигнала в скользящем окне) для второй нейросети нижнего уровня net2 и ожидаемые результаты для этих векторов;
- LTest и LTestRes – тестирующие векторы характерных признаков для нейросети net2 и ожидаемые результаты для этих векторов.

Алгоритм обучения комитета ИНС заключается в следующих действиях:

1) построение ИНС нижнего уровня net1, принимающей вектора, элементами которых являются площади сегментов под кривой сигналов в скользящем окне;

2) построение ИНС нижнего уровня net2, принимающей вектора длины кривой сегментов сигнала в скользящем окне;

3) обучение ИНС net1 и net2 на различных наборах данных для обучения;

4) тестирование обученных ИНС net1 и net2 на различных наборах данных;

5) сохранение текущей ИНС net1 или net2, если продемонстрированная ими вероятность успешной классификации на тестовом наборе выше ранее построенных ИНС;

6) повторение шагов 1-5 до тех пор, пока не будет достигнут заданный порог вероятности успешной классификации с использованием ИНС при обучении, или превышено число итераций

7) массивы выходов ИНС net1 или net2, которые представляют собой рассчитанную нейросетями вероятность принадлежности очередного паттерна ЭЭГ к каждому из классов, объединяются для формирования обучающих и тестирующих наборов векторов HObuch и HTest для ИНС верхнего уровня с ожидаемыми результатами HObuchRes и HTestRes;

8) построение ИНС верхнего уровня с использованием сформированных на шаге 7 наборов векторов.

Процесс создания и обучения ИНС верхнего уровня аналогичен алгоритму обучения сетей нижнего уровня. Обучающей выборкой для нее служат результаты классификации сетями нижнего уровня. Алгоритм обучения ИНС верхнего уровня приведен на схеме (рис. 20).



Рис. 20. Алгоритм обучения ИНС верхнего уровня.

Обучение комитета ИНС в целом происходит в несколько шагов:

- 1) формирование векторов характерных признаков двух пространств (площадь под кривой сегмента и длина кривой сегмента ЭЭГ сигнала в скользящем окне);
- 2) запуск ИНС нижнего уровня со сформированными векторами признаков;
- 3) результаты классификации ИНС нижнего уровня формируют вектора признаков для ИНС верхнего уровня;
- 4) запуск ИНС верхнего уровня для вынесения окончательного решения о принадлежности ЭЭГ паттерна определенному классу.

Разработанный алгоритм классификации ЭЭГ паттернов моторных команд на основе обучаемого комитета ИНС имеет ключевую особенность – он допускает масштабирование. Развитием предложенного алгоритма является комитет гетерогенных классификаторов, состоящий из классификаторов различных типов.

Алгоритм классификации с использованием комитета гетерогенных классификаторов.

Для совместного использования различных методов классификации ЭЭГ паттернов для анализа нескольких пространств признаков был разработан алгоритм комитета гетерогенных классификаторов. Предлагаемый комитет классификаторов является двухуровневым, первый уровень которого состоит из двух ИНС и двух классификаторов на основе МОВ, а второй уровень – из ИНС, объединяющей результаты классификаторов первого уровня (рис. 21).

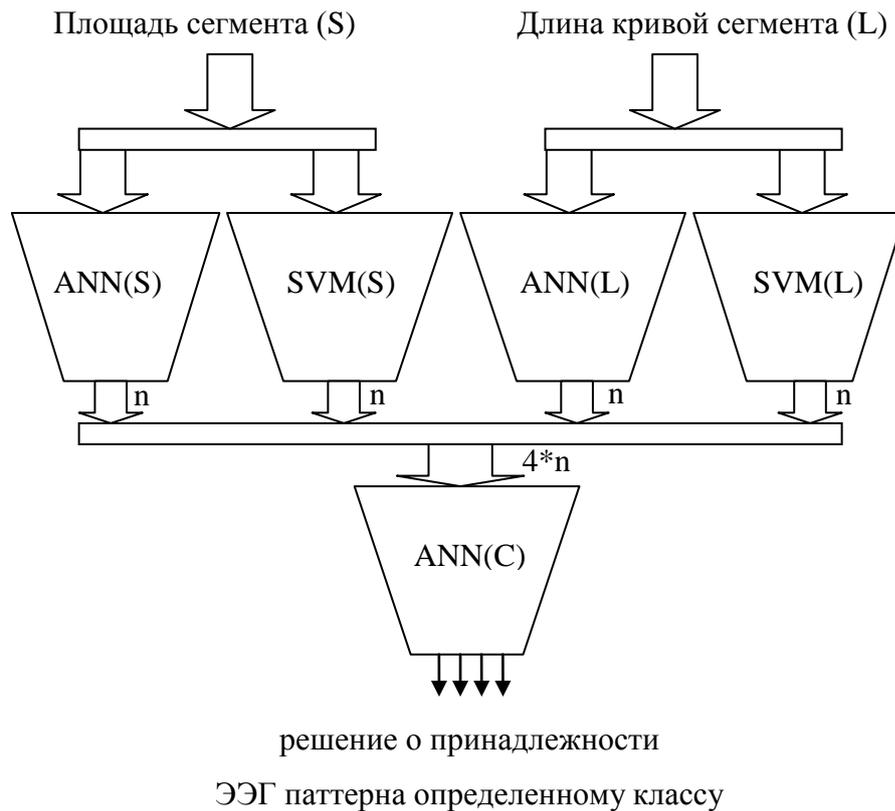


Рис. 21. Схема двухуровневого комитета гетерогенных классификаторов.

Примечание: n – число распознаваемых классов, $4*n$ – размерность входного вектора для объединяющей ИНС второго уровня.

Алгоритм обучения комитета гетерогенных классификаторов аналогичен алгоритму обучения комитета ИНС, приведенному выше. Отличия заключаются в том, что параллельно с обучением и тестированием ИНС первого уровня, происходит настройка и тестирование классификаторов на основе МОВ. Пары классификаторов первого уровня, состоящие из одной ИНС и одного МОВ, анализируют векторы разнотипных признаков. Результат опроса четырех классификаторов формирует вектор решений локальных классификаторов первого уровня, который подается на вход обобщающей ИНС второго уровня. Данная ИНС выносит окончательное решение о принадлежности ЭЭГ паттерна одному из классов.

Дальнейшее совершенствование системы классификации связано с выбором для каждого испытуемого индивидуальных параметров настройки системы

(временные параметры генерации признаков, информативные каналы для данного испытуемого и др.).

3.4. Алгоритм выбора метода преобразования и информативных каналов ЭЭГ сигнала для индивидуальной настройки системы классификации

Одна из задач исследования состояла в реализации индивидуального подхода при выборе наиболее информативных каналов и методов преобразования сигнала для повышения вероятности успешной классификации паттернов моторных команд с использованием разработанной системы классификации.

Преобразование ЭЭГ сигнала и выбор информативных каналов. При разработке неинвазивных ИМК, основанных на распознавании ЭЭГ паттернов одной из задач является реализация преобразования сигнала, повышающего соотношение сигнал/шум и выделяющего источники. В данной работе, в соответствии с приведенными в главе 2 методами, с целью снижения влияния объемного проведения и повышения пространственного разрешения, ЭЭГ сигналы, зарегистрированные при выполнении воображаемых движений, были преобразованы к взвешенному среднему монтажу, разложены на независимые компоненты, преобразованы к плотности источника тока.

С целью выделения информативных каналов, содержащих связанные с событием признаки, была разработана процедура картирования вероятности успешной классификации воображаемых движений для различных топографий ЭЭГ сигнала, после его предварительного преобразования для каждого испытуемого. Разработанная процедура картирования является необходимым элементом индивидуальной настройки системы классификации для выбора пары каналов, содержащих наибольшее количество признаков для классификации для данного испытуемого. Укрупненная схема алгоритма преобразования ЭЭГ сигналов и выбора информативных каналов из записи ЭЭГ приведена на рис. 22.



Рис. 22. Схема алгоритма преобразования и выбора информативных каналов.

Таким образом, в алгоритме предобработки ЭЭГ сигнала и индивидуальной настройки системы анализа и классификации в качестве основных шагов выступают: (1) преобразование сигналов в соответствии с выбранными методами, и (2) картирование вероятности успешной классификации по отдельным ЭЭГ отведениям для определения каналов, содержащих наибольшее количество информативных признаков. Преобразование массива входных данных происходит каждым из методов в отдельности, с сохранением результата в соответствующий раздел сводного массива предобработанных данных для картирования вероятности успешной классификации. Для применения вышеуказанных методов преобразования с заданными параметрами к записи ЭЭГ использовалось специализированное программное обеспечение регистрации ЭЭГ (WinEEG, Пономарев В.А., Кропотов Ю.Д., № государственной регистрации 2001610516 от 08.05.2001).

Картирование вероятности успешной классификации производится по отдельным каналам, тогда как для дальнейшей работы комитета гетерогенных классификаторов в системе ИМК используются данные с двух лучших каналов ЭЭГ. Процедура картирования по отдельным каналам не требует значительного времени для вычисления и может быть использована для индивидуальной настройки системы классификации.

Реализованный подход, в сочетании с выбором способа преобразования сигнала, направлен на предобработку входных данных с целью повышения эффективности системы классификации моторных команд. Метод картирования, реализованный в данной работе, позволяет получить значения вероятности успешной классификации для каждого из ЭЭГ каналов (топографий), что делает выбор информативных каналов численно обоснованным.

3.5. Структура программного пакета

Для реализации программного пакета предложенные алгоритмы были объединены в следующие программные модули:

- `ImportSelect(filename, fileinfo)` – модуль считывания входных данных. В качестве параметров модуль принимает переменные `filename` (имя файла с расширением `.mat`, содержащего потоковые ЭЭГ записи), `fileinfo` (имя файла с расширением `.txt`, содержащего номера отсчетов начала сигналов и соответствующие им типы движений). Модуль возвращает имя файла с расширением `.mat`, содержащего необходимые предобработанные входные переменные.
- `FeatureGen()` – модуль генерации векторов характерных признаков, основанных на вычислении площади под кривой ЭЭГ сигнала в скользящем окне. В качестве параметров модуль принимает имя файла, содержащего необходимые переменные. Модуль возвращает наборы обучающих и тестирующих векторов характерных признаков вместе с ожидаемыми результатами классификации для этих наборов.
- `FeatureGen2()` – модуль генерации векторов характерных признаков, основанных на вычислении сложности кривой ЭЭГ сигнала в скользящем окне. В качестве параметров модуль принимает имя файла, содержащего необходимые переменные. Модуль возвращает наборы обучающих и тестирующих векторов характерных признаков вместе с ожидаемыми результатами классификации для этих наборов.
- `NNTrainCycle()` – модуль обучения нейробиологического комитета классификаторов. В качестве параметров модуль принимает обучающие и тестирующие наборы векторов характерных признаков из двух пространств. Модуль возвращает программные модели обученных классификаторов (две ИНС нижнего уровня, два классификатора на основе МОВ нижнего уровня и одну ИНС верхнего уровня).
- `NNTrainCycle()` – модуль тестирования комитета классификаторов. В качестве параметров модуль принимает программные модели обученных классификаторов и тестирующие наборы векторов характерных признаков. Модуль возвращает процент успешных распознаваний ЭЭГ паттернов для данных индивидуальных настроек системы классификации.

Разработанные программные модули объединены в систему автоматического анализа и классификации ЭЭГ паттернов в соответствии со схемой системы, приведенной на рис. 23.

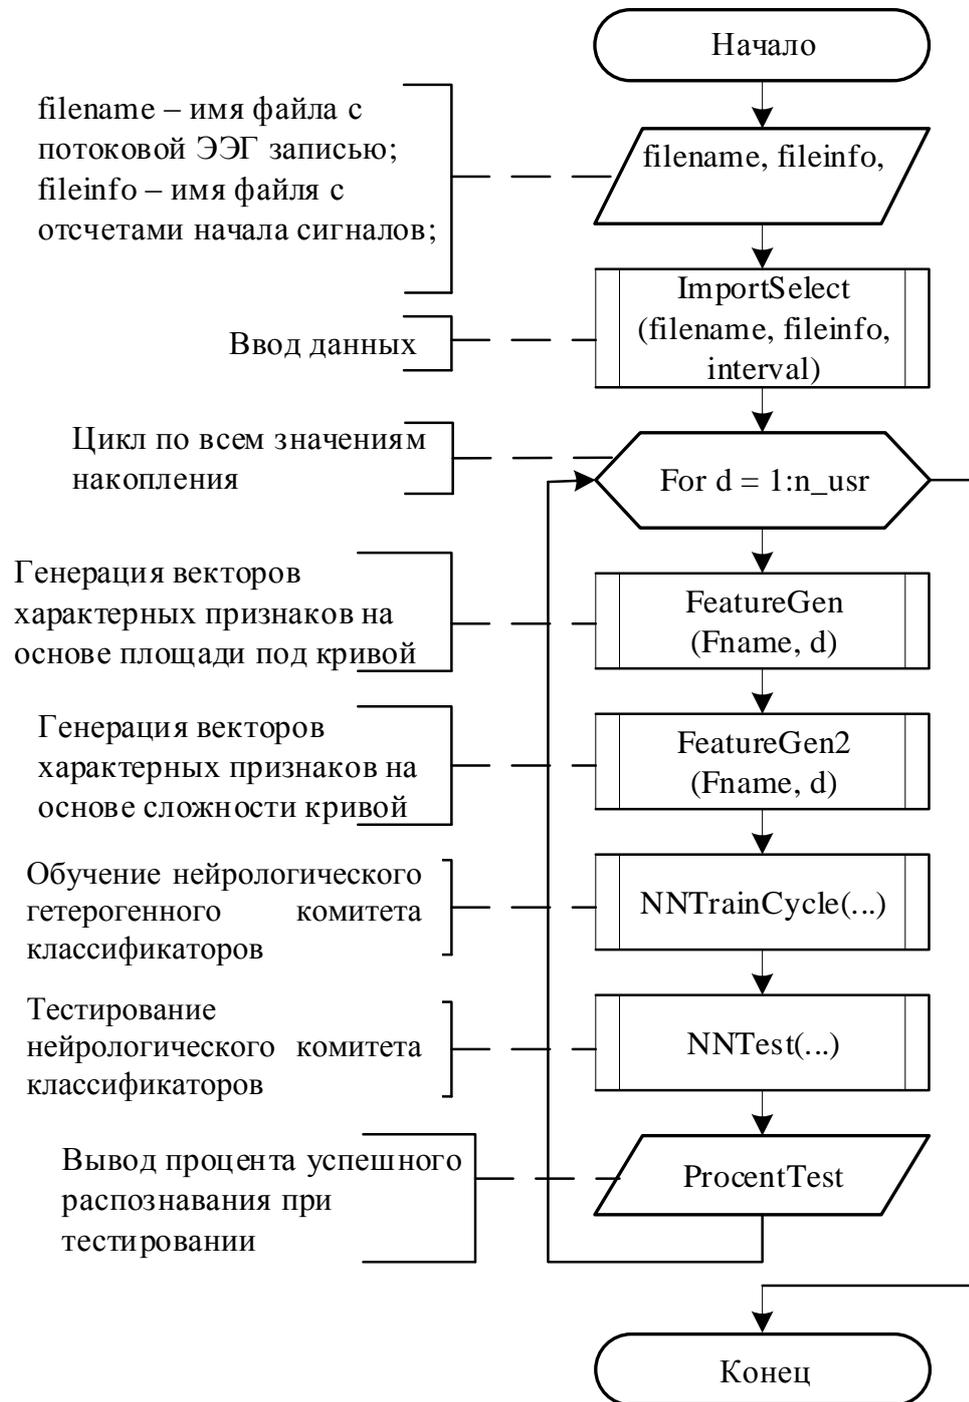


Рис. 23. Структура модулей программного пакета.

Следует отметить, что данная система основана на алгоритмах искусственного интеллекта, использует комитет гетерогенных обучаемых классификаторов, а также имеет значительное число специальных настроек,

позволяющих использовать его для классификации сигналов ЭЭГ, зарегистрированных в разнообразных парадигмах исследований.

3.6. Реализация и тестирование программного пакета

Система предназначена для предобработки, анализа и классификации ЭЭГ паттернов моторных команд. Результаты классификации предполагается использовать для управления внешними устройствами.

Требования к программному продукту.

1. Требования к функциональным характеристикам - система обеспечивает выполнение следующих функций:

- Индивидуальный подход к инициализации системы (ввод данных ЭЭГ испытуемых, выбор типов движений для классификации, настройка параметров анализа, таких как число накоплений сигнала, длина окна, сдвиг окна и др. согласно разработанному интерфейсу, приведённому на рис. 24).

The screenshot shows a software interface window titled "interface". It contains two columns of input fields for configuring EEG data processing. The left column is for data files and session parameters, and the right column is for EEG channel and analysis parameters. At the bottom right, there is an "OK" button.

Имя файла с данными		Имя файла с метками	
ubj1_RythmAUD_0.5-30Hz_19all.mat		subj1_RythmAUD_Lat_met.txt	
Метки	3; 4	левое полушарие	правое полушарие
Число сессий	1	Каналы EEG	9
Feature type	1		10
Общее число проб	100	В отсчетах:	
Число тестовых проб	30	Отступ от начала пробы	0
Процент выборки для обучения	0.7	Длина пробы	300
Число тестов	20	Ширина окна	50
Число накоплений	1;5;10;20	Сдвиг скользящего окна	30
		Отступ от нажатия кнопки	0
		Отступ от стимула	0

Рис. 24. Интерфейс программного пакета.

- Вычисление векторов характерных признаков в каждом из пространств признаков в соответствии с заданными параметрами.
- Обучение комитета классификаторов с выводом процента успешных классификаций при обучении.
- Построение тестовых выборок и тестирование на них обученного комитета классификаторов с регистрацией следующих выходных данных:
 - процент успешной классификации ЭЭГ-паттернов выбранных движений для каждого испытуемого на каждой тестовой выборке (глубина тестовой выборки задается пользователем);
 - матрица взаимных ошибок при мультиклассовой классификации (распределение процента ошибочных распознаваний по классам);

2. Исходные данные:

- данные потоковой записи ЭЭГ в специализированном формате .edf или .mat для каждого испытуемого для каждой сессии;
- дополнительный файл в формате.txt с информацией о начале каждой очередной пробы в мс, а также тип движения очередной пробы;

3. Требования к надежности:

- Автоматический контроль входных данных с исключением артефактных проб.
- Информирование пользователя в случае недостижения заданного порога вероятности успешного распознавания при обучении комитета классификаторов.
- Обеспечение полноты результатов.

4. Требования к составу и параметрам технических средств и программной совместимости.

Система должна работать на IBM совместимых персональных компьютерах. Минимальная конфигурация: тип процессора Intel Core i3 и выше; объем ОЗУ 2 Гб и более. Система должна работать в программной среде MATLAB 2010 и выше.

5. Требования к программной документации

Разрабатываемые программные модули самодокументированы, т.е. тексты программ содержат все необходимые комментарии. Программная система выводит текущие результаты по завершении каждого из этапов работы для обеспечения контроля процесса классификации пользователем. В состав сопровождающей документации входит: пояснительная записка, содержащая описание разработки, руководство пользователя.

Тестирование программного пакета.

Под тестированием в данном случае понимается проверка соответствия между реальным и ожидаемым поведением программы, осуществляемая на конечном наборе выбранных тестов.

Для всесторонней оценки работоспособности и функциональной полноты программного пакета проведено тестирование различных уровней – от модуля до системы в целом.

Модульное тестирование — протестирован минимально возможный для тестирования компонент – отдельная функция. Модульное тестирование осуществлялось на каждом этапе разработки. Все функции проверены на соответствие заявленным алгоритмам, не содержат скрытых ошибок в коде. По результатам модульного тестирования определено, что модули могут быть объединены в систему, а также выработаны рекомендации по увеличению быстродействия модулей путем устранения избыточности и применения более простых счетных операций.

Интеграционное тестирование — протестированы интерфейсы между компонентами и порядок обмена данными. Тестирование проводилось пошагово с отслеживанием входных и выходных данных для каждого модуля и порядка их передачи. Отслеживалась постепенное подключение последующих подсистем и отсутствие конфликтов по времени и данным. При обнаружении дублирующих участков кода в модулях, такие участки выносились в отдельную функцию.

Системное тестирование – протестирована интегрированная система на её соответствие требованиям спецификации. Данная процедура проходила в два этапа.

Альфа-тестирование – имитация реальной работы с системой потенциальными пользователями. Альфа-тестирование проводилось на различных стадиях разработки программной реализации системы, вплоть до законченного продукта, в качестве внутреннего приёмочного тестирования. Этот вид тестирования выполнялся исследователем с целью выявления функциональных ошибок. Обнаруженные ошибки исправлялись, а также выяснялось возможное влияние на работоспособность других модулей. Участки кода, зависимые от входных данных и настроек, задаваемых пользователем, защищались дополнительными проверками в коде.

Бета-тестирование – после завершения разработки программный продукт был передан специалистам по нейрофизиологии для работы с реальными ЭЭГ данными без наложения ограничений, с тем, чтобы убедиться, что продукт не содержит критических ошибок, а количество предложений о корректировке достаточно мало.

По результатам тестирования получена обратная связь о программной реализации системы от его будущих пользователей, произведена оценка быстродействия модулей программы и продукта в целом. Программный продукт не содержит функциональных ошибок и может быть применен для классификации ЭЭГ паттернов моторных команд. Программный пакет выполнен по модульному принципу, его архитектура позволяет производить дальнейшее расширение функционала, добавление модулей. Конечной целью реализации данного программного пакета является создание эффективной быстродействующей системы классификации ЭЭГ паттернов для интерфейса мозг-компьютер реального времени с возможностью выдачи управляющих команд на внешние устройства.

Выводы по главе 3

1. Разработанная методика регистрации ЭЭГ сигналов, основанная на новой парадигме исследования воображаемых движений, выполняемых в заданном ритме, обеспечивает получение коротких проб сигнала, не связанных с предъявлением внешнего стимула непосредственно в течение пробы. Это ускоряет процесс регистрации сигналов и способствуют синхронизации моментов воображения движений в разных пробах, что является существенным для построения системы классификации.

2. Разработанные алгоритмы предобработки и извлечения признаков для сигналов ЭЭГ позволяют получать и одновременно использовать два пространства признаков, по которым далее производится классификация ЭЭГ паттернов моторных команд.

3. Разработанный алгоритм и система классификации ЭЭГ паттернов, построенная на основе двухуровневого масштабируемого комитета гетерогенных классификаторов с использованием МОВ и ИНС дает возможность решать задачи классификации воображаемых движений не только крупной, но и мелкой моторики.

4. Реализован индивидуальный подход к выбору метода преобразования ЭЭГ сигнала (преобразование к взвешенному среднему монтажу, разложение на независимые компоненты, преобразование к плотности источников тока), а также к выбору временных (длины окна и величины сдвига окна анализа) и пространственных (ЭЭГ каналов, содержащих информативные признаки) параметров генерации признаков. Это позволяет повысить эффективность классификации ЭЭГ паттернов воображаемых движений мелкой моторики.

5. Выполнена программная реализация системы анализа и классификации ЭЭГ паттернов моторных команд в среде MatLab. Программный пакет состоит из программных модулей, соответствующих разработанным алгоритмам. Особенностью данного пакета является возможность применения индивидуального подхода к выбору параметров предобработки, генерации

признаков и др. Тестирование программного пакета показало его работоспособность и функциональную полноту.

6. Дальнейшее совершенствование программного пакета направлено на создание ИМК реального времени, состоящего из модулей автоматического получения входных данных в реальном времени, их обработки, обучения классификаторов, распознавания паттернов ЭЭГ воображаемых моторных команд, число которых может быть увеличено за счет возможности распознавания движений мелкой моторики. Предполагается использовать такой ИМК для управления исполнительными устройствами, такими как искусственная кисть руки.

Глава 4. Применение разработанной системы анализа и классификации ЭЭГ паттернов в интерфейсе мозг-компьютер для управления искусственной кистью руки

4.1. Система анализа и классификации ЭЭГ паттернов моторных команд в ИМК с биологической обратной связью

Практическое применение разработанных средств анализа и классификации ЭЭГ паттернов сопряжено с объединением их в систему управления исполнительными устройствами для ИМК реального времени. Такая система состоит из модулей автоматического получения входных данных в реальном времени, их обработки, обучения классификаторов, классификации паттернов ЭЭГ и супервизорного управления внешними исполнительными устройствами, такими как искусственная кисть руки. Супервизорное управление предполагает выдачу пользователем ИМК команды высокого уровня на выполнение некоторой составной задачи целиком вместо того, чтобы управлять отдельными функциями низкого уровня, которые требуются для выполнения этой задачи. Важным фактором для эффективной работы такой системы управления является обеспечение биологической обратной связи (БОС) для пользователя, что требует сведения к минимуму временных задержек, необходимых для выдачи ответов каждого из программных модулей и системы классификации в целом.

Управление искусственной кистью руки основано на декодировании команд мелкой моторики (воображаемых движений пальцев одной руки). Эта задача является трудно решаемой вследствие анатомической близости структур мозга, задействованных в реализации воображаемых движений, и незначительных различий в ЭЭГ сигналах при воображении движений мелкой моторики, что требует специальных методов анализа данных при сохранении высоких требований к быстродействию. Для реализации данного подхода необходимо эффективное взаимодействие систем регистрации, анализа, классификации

сигналов ЭЭГ, а также исполнения распознанной моторной команды искусственной кистью руки с задержкой, незаметной для пользователя.

Работа системы ИМК, как правило, функционирующей в реальном времени, предполагает постоянное считывание ЭЭГ данных. Для обеспечения непрерывности приема массива входных данных и параллельного их анализа был использован метод многопоточного программирования: поток 1 непрерывно записывает данные в буфер памяти, а поток 2 производит автоматическую разметку массива ЭЭГ данных в моменты времени, соответствующие завершению текущей пробы, активирует разработанную систему анализа и классификации паттернов ЭЭГ. Укрупненная схема функционирования разработанной системы анализа и классификации для интерпретации ЭЭГ паттернов моторных команд пользователя в инструкции исполнительным устройствам в ИМК приведена на рис. 25.

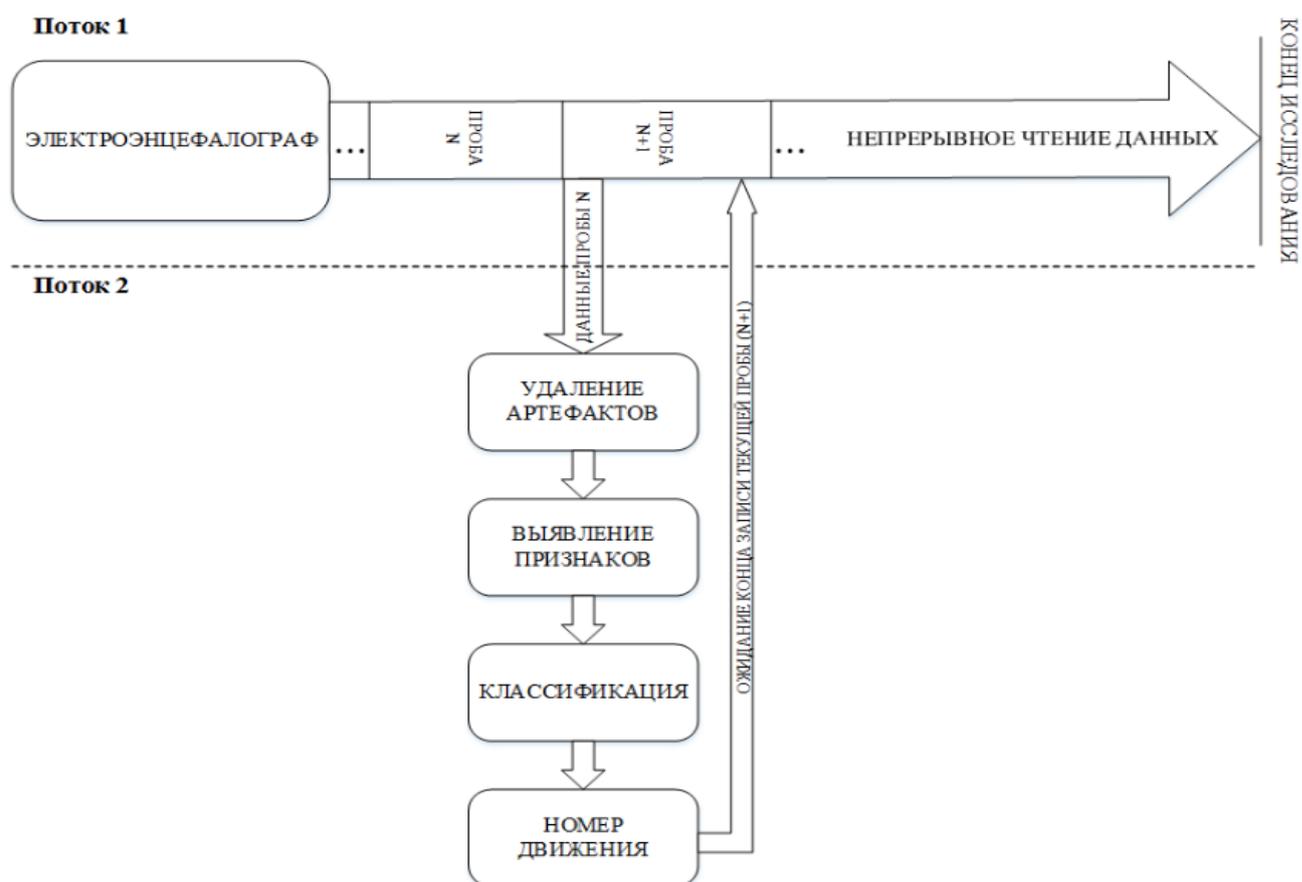


Рис. 25. Схема функционирования системы анализа и классификации ЭЭГ паттернов моторных команд в ИМК.

Система, представленная на рис. 25, предназначена для управления исполнительными устройствами путем выдачи супервизорных инструкций, соответствующих распознанным моторным командам. Работа системы организована следующим образом: как только закончилась очередная проба N и начинается следующая проба N+1, поток 2 выгружает данные, соответствующие пробе N, производит предобработку, извлечение признаков и классификацию с выдачей ответа в виде номера класса распознанной моторной команды. Таким образом, реализуется одновременная запись и анализ ЭЭГ данных, что важно для классификации всех проб без исключения и повышения быстродействия ИМК. Основным требованием, которое предъявляется к применимым на практике системам классификации с БОС, является сокращение времени, необходимого для выдачи ответа классификатора, до минимума так, чтобы оно в любом случае не превышало длительности одной пробы. В противном случае не происходит связывания моторной команды с полученным ответом системы.

Таким образом, эффективность системы анализа и классификации ЭЭГ паттернов моторных команд может быть оценена, по крайней мере, по *трем ключевым критериям*: вероятность успешной классификации, количество распознаваемых классов и быстродействие. Повышение эффективности применимой на практике системы связано, во-первых, с разработкой адекватных методов и алгоритмов анализа и классификации ЭЭГ паттернов, и, во-вторых, с индивидуальной настройкой системы на конкретного пользователя. В связи с этим итоговая реализация системы анализа и классификации ЭЭГ паттернов моторных команд объединяет нижеследующие основные модули, каждый из которых включает в себя несколько методов и алгоритмов для обеспечения возможности сопоставительного анализа их эффективности и реализации индивидуальной настройки системы.

1. Модуль регистрации ЭЭГ сигналов.

Реализует регистрацию ЭЭГ сигналов в соответствии с разработанной процедурой исследования воображаемых движений, выполняемых в заданном ритме. Результатом этапа регистрации является потоковая запись ЭЭГ коротких

эпизодов воображения движений (600 мс). Следующим этапами являются удаление артефактов и извлечение участков, соответствующих моторным командам, из потоковой записи ЭЭГ.

2. Модуль фильтрации и преобразования ЭЭГ сигналов.

Производит фильтрацию в задаваемом частотном диапазоне и преобразование ЭЭГ сигнала в соответствии с одним из трех реализованных методов: преобразование к взвешенному среднему монтажу, разложение на независимые компоненты, преобразование к плотности источников тока. Обеспечивает возможность сравнительного исследования результатов применения методов преобразования ЭЭГ паттернов моторных команд и фильтрации сигнала (в разных частотных полосах) для повышения вероятности успешной классификации.

3. Модуль извлечения признаков.

Реализует вычисление признаков во временной области для последующего обучения и тестирования комитета классификаторов. Для обеспечения необходимого быстродействия системы вычисление признаков осуществляется путем анализа каждой отдельной пробы (single-trial подход). Используется алгоритм совместного учета двух пространств признаков: площадь под кривой и длина кривой сегмента сигнала, вычисляемых в скользящем окне анализа. Обеспечивает возможность индивидуального выбора величины окна анализа и поиска наиболее информативных участков сигнала.

4. Модуль классификации ЭЭГ паттернов.

Классифицирует ЭЭГ паттерны моторных команд на основе двухуровневого масштабируемого комитета классификаторов с использованием метода опорных векторов и искусственных нейронных сетей. Обеспечена возможность конфигурирования комитета классификаторов путем комбинирования локальных классификаторов.

5. Модуль индивидуального выбора ЭЭГ каналов.

Реализует индивидуальный подход к выбору наиболее информативных ЭЭГ каналов для повышения вероятности успешной классификации разработанными средствами.

6. Модуль управления внешним исполнительным устройством.

На основе ответа классификатора формирует супервизорную инструкцию для исполнительного устройства, обеспечивает реализацию биологической обратной связи.

Разработанная система анализа и классификации применена для распознавания ЭЭГ паттернов воображаемых движений пальцев искусственной кисти руки. Управление искусственной кистью руки основано на декодировании команд мелкой моторики (воображаемых движений пальцев одной руки). Эта задача является трудно решаемой вследствие анатомической близости структур мозга, задействованных в реализации воображаемых движений, и незначительных различий в ЭЭГ сигналах при воображении движений мелкой моторики, что требует специальных методов анализа данных при сохранении высоких требований к быстродействию. Для реализации данного подхода необходимо эффективное взаимодействие систем регистрации, анализа, классификации сигналов ЭЭГ, а также исполнения распознанной моторной команды искусственной кистью руки с задержкой, незаметной для пользователя.

Далее приведены результаты сравнительных исследований влияния на вероятность успешной классификации ЭЭГ паттернов таких факторов, как методы классификации и преобразования ЭЭГ сигнала, параметры генерации признаков и выбор наиболее информативных каналов.

4.2. Сопоставительный анализ результатов классификации ЭЭГ паттернов моторных команд, основанной на различных методах классификации

4.2.1. Сопоставительный анализ вероятности успешной классификации при использовании локальных классификаторов на основе ИНС и МОВ

В ходе исследования по классификации 4-х моторных команд на основе анализа идентичных наборов характерных признаков было показано, что классификаторы на базе ИНС и МОВ демонстрируют различную чувствительность к характеристикам физиологического сигнала. На рис. 26 и рис. 27 приведена динамика изменения вероятности успешной классификации с использованием ИНС и МОВ соответственно, при различном числе накоплений образцов классифицируемого сигнала (по 3, 5, 10, 20 и по 1 образцу без накопления). Так, вероятность верной классификации с использованием метода опорных векторов увеличивается при накоплении ЭЭГ сигнала, а вероятность успешной классификации на основе искусственной нейронной сети была выше при классификации единичных реализаций.

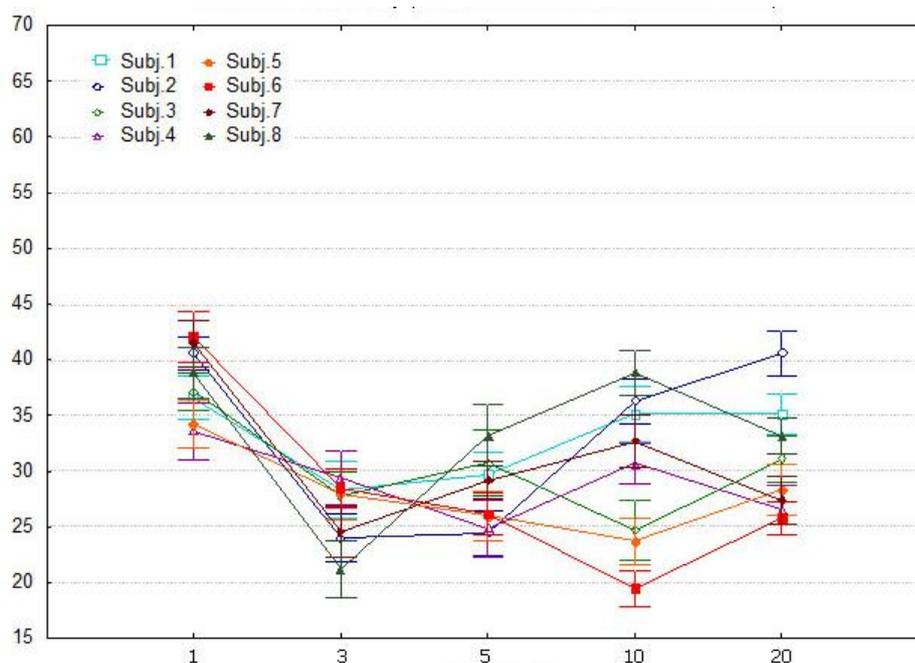


Рис. 26. Вероятность успешной классификации с использованием ИНС

(на оси абсцисс - число накопленных попыток; на оси ординат - вероятность верных классификаций, Subj1-8 - испытуемые).

Классификация на основе ИНС демонстрирует U-образную динамику, причем наибольшая вероятность успешной классификации достигается при использовании отдельных проб без накопления (single-trial подход) и уменьшается при накоплении проб.

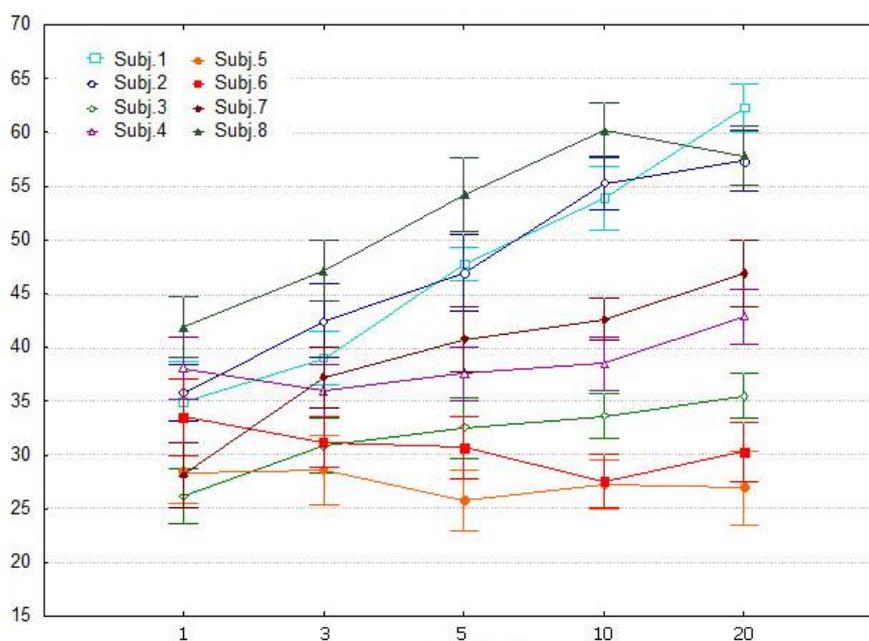


Рис. 27. Вероятность успешной классификации с использованием МОВ

(на оси абсцисс - число накопленных попыток; на оси ординат - вероятность верных классификаций, Subj1-8 - испытуемые).

Полученные результаты демонстрируют преимущества ИНС при использовании для классификации отдельных проб и лучшую чувствительность МОВ для различения ЭЭГ сигналов при их накоплении. Предположительно, вероятность успешного распознавания ИНС связана с высокочастотным компонентом сигнала ЭЭГ, влияние которого уменьшается с накоплением данных. В то же время классификатор МОВ, возможно, более чувствителен к низкочастотному компоненту ЭЭГ сигнала, влияние которого увеличивается с накоплением данных. Следует отметить, что при использовании ИНС наблюдается меньшая дисперсия вероятности успешного распознавания, особенно в случае использования отдельных проб.

На основании полученных результатов сопоставительного анализа локальных классификаторов на основе ИНС и МОВ при классификации ЭЭГ паттернов моторных команд была выявлена различная чувствительность классификаторов к особенностям ЭЭГ сигнала и преимущество ИНС при классификации проб без накопления, что является актуальным для реализации в ИМК реального времени. Для совместного учета особенностей ЭЭГ сигнала

необходимо построение гетерогенного комитета классификаторов на основе локальных классификаторов типа ИНС и МОВ.

4.2.2. Сопоставительный анализ вероятности успешной классификации при использовании комитета ИНС и классификатора на основе МОВ

В данном разделе исследования приводятся результаты классификации ЭЭГ паттернов воображаемых движений пальцев одной руки, которая проводилась с использованием двух подходов: метода опорных векторов и комитета искусственных нейронных сетей. Получены данные, позволяющие сопоставить эффективность данных методов в составе разработанной системы классификации и сделать вывод о преимуществе использования одного из них при распознавании ЭЭГ сигналов без накопления.

Анализировались ЭЭГ сигналы 5-и классов моторных команд, зарегистрированные в соответствии с описанной ранее ритмической парадигмой исследования, - воображаемые движения мизинцем, большим, указательным, средним пальцами и сжатие кисти руки. С целью исследования влияния накопления сигнала на вероятность успешной классификации в данном разделе работы использовалось накопление сигнала по 5, 10, 20 проб, а также подход без накопления (по одной пробе). Результаты попарной классификации всех типов движений в зависимости от количества накопленных проб приведены на рис. 28.

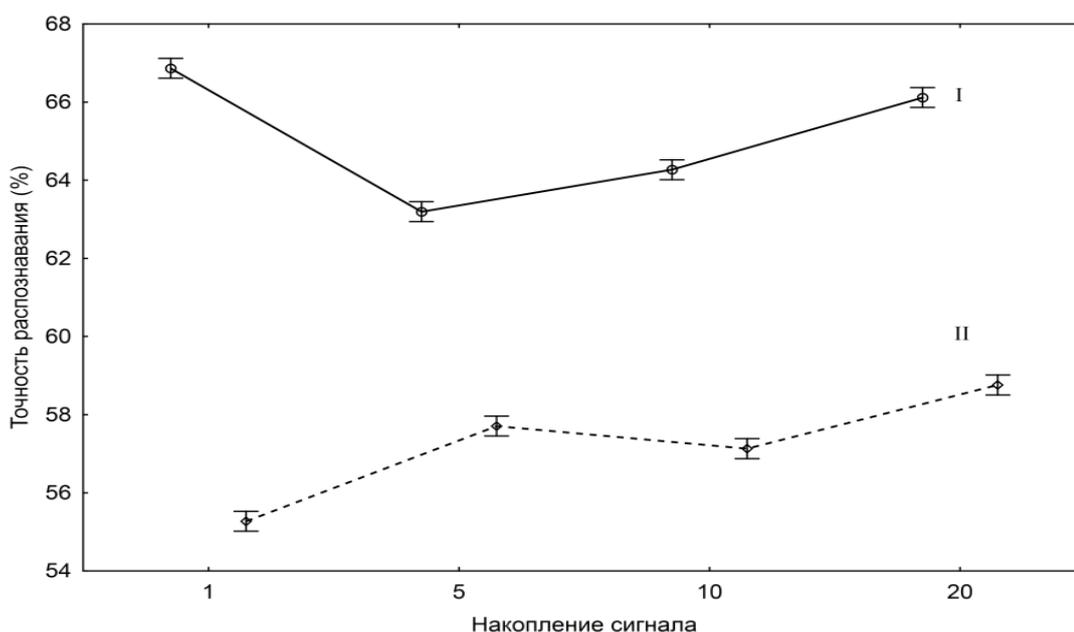


Рис. 28. Вероятность успешной классификации ЭЭГ паттернов воображаемых движений, выполняемых в заданном ритме, с использованием классификаторов на основе комитета ИНС и МОВ.

Примечания: 1, 5, 10, 20 по оси абсцисс – количество накопленных проб, по оси ординат – вероятность успешной классификации (в процентах), усредненная по всем парам движений и всем испытуемым. I – классификация при помощи комитета ИНС. II – классификация методом опорных векторов на основе радиальной базисной функции.

На рис. 28 видно, что вероятность успешного распознавания ЭЭГ паттернов воображаемых движений при помощи комитета ИНС была значимо выше, чем при помощи классификатора МОВ, в среднем по всем парам воображаемых движений: $F_{(1,22800)}=7434.1$, $p<0.05$. Оценка результатов работы разных типов классификаторов с учетом количества накопленных проб выполнена с использованием дисперсионного анализа (ANOVA), который показал достоверный эффект влияния фактора «число накоплений (проб)» (4 градации) на процент верного распознаваний для обоих алгоритмов классификации (комитета ИНС и МОВ): $F_{(3,22800)}=202.1$, $p<0.05$. Зависимость вероятности успешной классификации ЭЭГ паттернов различных классификаторов от количества накоплений проб, приведенная на рис. 28, демонстрирует различную динамику: так, вероятность верного распознавания методом опорных векторов возрастает

при увеличении количества накопленных проб, тогда как вероятность успешного распознавания при помощи комитета искусственных нейронных сетей носит U-образный характер. Процент успешных распознаваний комитетом ANN в среднем по всем парам движений достигает максимальных значений при классификации единичных проб и с использованием наибольшего числа накоплений.

Необходимо отметить, что эффективность работы ИМК определяют и скорость, и вероятность успешной классификации, а при накоплении 20, даже весьма коротких, проб длительностью 600 мс, задержка исполнения моторной команды составит не менее 12 секунд. В этих условиях для реализации интерфейса мозг-компьютер предпочтительным будет являться использование комитета ИНС.

Комитет ИНС может быть расширен за счет дополнительного использования классификаторов на основе МОВ. При этом для повышения вероятности успешной классификации могут использоваться преимущества обоих типов классификаторов.

4.2.3. Сопоставительный анализ вероятности успешной классификации при использовании гомогенного комитета ИНС и гетерогенного комитета классификаторов

Разработанные средства классификации были применены для решения задачи распознавания ЭЭГ паттернов воображаемых движений пальцев руки. Результаты, полученные при использовании гомогенного комитета ИНС и гетерогенного комитета классификаторов на базе ИНН и МОВ для классификации идентичных выборок ЭЭГ паттернов моторных команд, были сопоставлены для определения наиболее эффективного из разработанных средств классификации. При классификации в обоих случаях анализировались ЭЭГ сигналы без накопления (single-trial подход), зарегистрированные в описанной ранее ритмической парадигме исследования, соответствующие 4 моторным командам – воображаемым движениям мизинцем, большим, указательным и средним пальцами руки. Производился совместный учет двух типов признаков – площади

сегмента сигнала и длины сегмента кривой сигнала, вычисленных в скользящем окне анализа (100 мс).

Были выявлены значимые различия между вероятностью успешной классификации моторных команд комитетом гетерогенных классификаторов и комитетом гомогенных ИНС: $F(1,8)=19.9$, $p<0.003$. Вероятность успешной классификации с использованием комитета гетерогенных классификаторов составила в среднем по испытуемым $60\pm 10\%$, максимально - $77\pm 5\%$, а с использованием комитета ИНС – в среднем $52\pm 9\%$, максимально $65\pm 5\%$. Сводные результаты 4-х классового распознавания, полученные с использованием разработанных средств классификации приведена в таблице 2.

Можно отметить, что для большинства испытуемых вероятность успешной классификации 4-х воображаемых движений пальцев руки комитетом гетерогенных классификаторов на базе ИНС и МОВ была выше, чем вероятность верной классификации комитета ИНС при анализе идентичных ЭЭГ сигналов.

Таблица 2. Вероятность успешной классификации ЭЭГ паттернов 4 моторных команд

Испытуемые	Вероятность успешной классификации в % комитетом классификаторов	Вероятность успешной классификации в % комитетом ИНС
Исп.1	72±7	65±4
Исп.2	53±5	46±6
Исп.3	49±6	41±6
Исп.4	64±7	47±5
Исп.5	61±5	53±7
Исп.6	56±6	57±5
Исп.7	63±4	51±5
Исп.8	77±5	65±5
Исп.9	45±5	43±5
Среднее	60±10	52±9

При применении комитета гетерогенных классификаторов вероятность успешной 4-х классовой классификации составила $60\pm 10\%$, в среднем по испытуемым, при уровне случайного распознавания 25%. Данные результаты, полученные с использованием комбинированного комитета классификаторов, демонстрируют более высокую вероятность верных распознаваний у большинства испытуемых (Исп. 1-5,7,8) в сравнении с комитетом искусственных нейронных сетей. Таким образом, использование комитета гетерогенных классификаторов позволило повысить вероятность успешной классификации на 8% в среднем по группе, у ряда испытуемых – на 12-17%.

В ходе предыдущих исследований было показано, что разные локальные классификаторы демонстрируют чувствительность к разным характеристикам ЭЭГ сигнала. В связи с этим, использование двухуровневого комитета гетерогенных классификаторов с обобщающей искусственной нейронной сетью для совместного учета разных характеристик сигналов, может быть более перспективным, чем использование однотипных классификаторов.

4.3. Влияние индивидуальной настройки параметров системы классификации на вероятность успешного распознавания

4.3.1. Влияние методов преобразования ЭЭГ сигнала на вероятность успешной классификации

Были проведены сравнительные исследования влияния различных способов преобразования ЭЭГ сигнала на вероятность успешной классификации разработанной системы на основе гетерогенного комитета классификаторов при распознавании 4-х и 5-и классов воображаемых движений по одной пробе (single-trial подход).

На рис. 29 приведены полученные значения вероятности верной классификации ЭЭГ сигналов, преобразованных разными методами, для одних и тех же испытуемых.

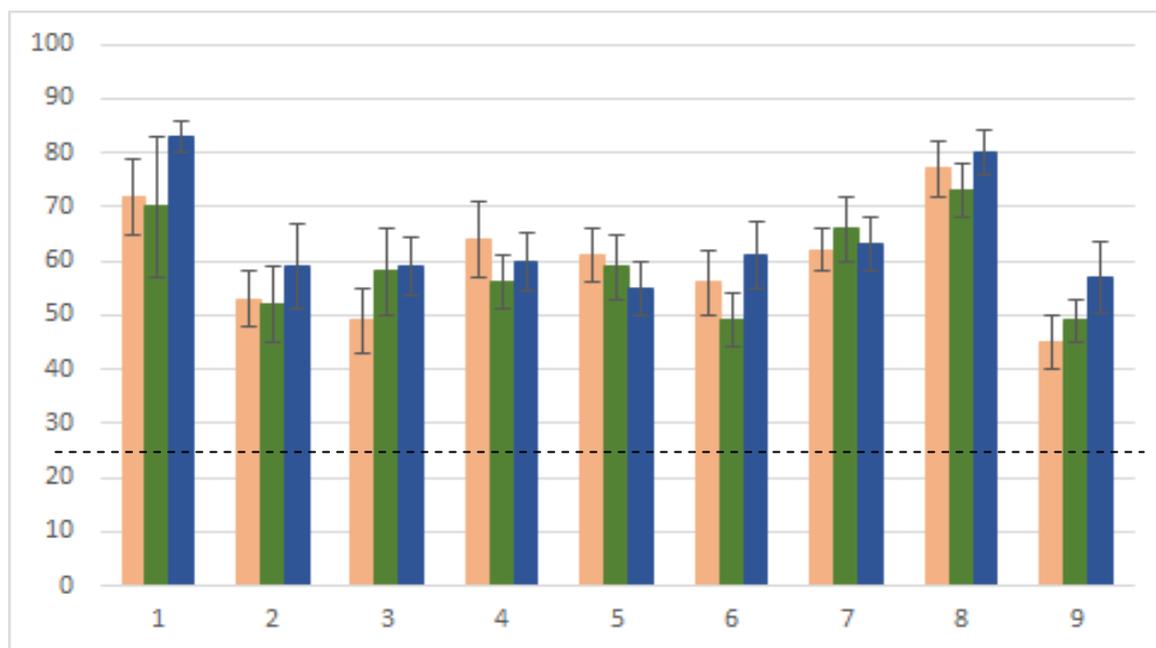


Рис. 29. Вероятность успешной классификации ЭЭГ паттернов при воображении 4-х классов движений в условиях различных преобразований ЭЭГ сигнала.

Примечания: По оси абсцисс – порядковые номера испытуемых, по оси ординат – вероятность успешной классификации (%) при различных преобразованиях ЭЭГ сигнала. **Левый столбец** для каждого испытуемого – вероятность успешной классификации сигнала, преобразованного к взвешенному среднему монтажу (WAR); **средний столбец** – сигнала после разложения на независимые компоненты (ICA); **правый столбец** – сигнала, преобразованного к плотности источника тока (CSD).

На рис. 29 приведены результаты классификации 4-х типов моторных команд (воображаемых движений мизинцем, большим, указательным и средним пальцами руки) для каждого испытуемого.

При анализе данных в общей группе испытуемых, принявших участие в данной части исследований, наблюдается достоверное влияние фактора «тип преобразования» на вероятность успешной классификации для лучших пар каналов $F=3.7$, $p<0.05$. По данным апостериорного анализа с использованием LSD критерия Фишера выявлена более высокая вероятность успешной классификации при применении преобразования к CSD по сравнению с ICA ($p<0.02$) и WAR ($p<0.05$). Вместе с тем для некоторых испытуемых были получены сопоставимые результаты вероятности верной классификации для всех реализованных типов

преобразования, а у двух из испытуемых преобразование к плотности источника тока уступало результатам классификации при использовании WAR преобразования.

Применение метода независимых компонент с выбором двух наиболее информативных компонент методом предварительного картирования не приводило к повышению вероятности успешной классификации по сравнению с двумя другими использованными преобразованиями ЭЭГ.

Следующим этапом сравнительного анализа двух наиболее эффективных методов преобразования стала реализация 5-и классового распознавания воображаемых движений в той же парадигме исследования. Классифицировались ЭЭГ паттерны, соответствующие следующим моторным командам: воображаемые движения большим, указательным, средним пальцами, мизинцем и воображение сжатия кисти руки. Полученные результаты классификации при использовании двух методов преобразования сигналов сопоставлены на рис. 30.

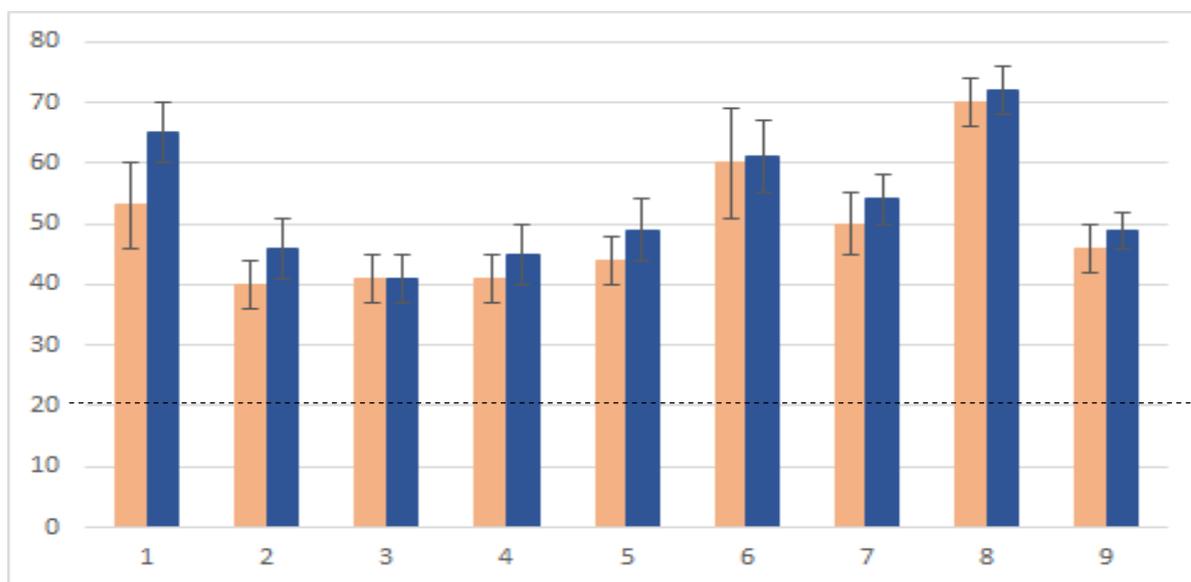


Рис. 30. Вероятность успешной классификации 5-и воображаемых движений пальцами и кистью одной руки при использовании преобразования к взвешенному среднему монтажу (WAR) и к плотности источника тока (CSD).

Примечание: По оси абсцисс – порядковые номера испытуемых, по оси ординат – вероятность успешной классификации (%) при различных преобразованиях ЭЭГ сигнала. Горизонтальная пунктирная линия - теоретический порог случайной классификации (20%). **Левый столбец** для

каждого испытуемого – вероятность успешной классификации сигнала, преобразованного к взвешенному среднему монтажу; **правый столбец** – сигнала, преобразованного к плотности источника тока.

При преобразовании ЭЭГ сигнала к плотности источника тока наблюдается значимо более высокие результаты распознавания 5-и типов воображаемых движений по сравнению с использованием взвешенного среднего монтажа ($F=11.7$, $p<0.01$). У всех испытуемых при использовании преобразования ЭЭГ сигнала к плотности источника тока вероятность успешного распознавания 5-и классов движений была равна или превышала таковую при использовании взвешенного среднего монтажа. Таким образом, при увеличении количества распознаваемых классов, целесообразно использование преобразование к CSD.

В результате сравнительного исследования методов преобразования ЭЭГ сигнала (преобразование к взвешенному среднему монтажу, разложение на независимые компоненты, преобразование к плотности источников тока) были определены предпочтительные, в плане повышения вероятности успешной классификации, параметры предобработки ЭЭГ сигнала. Наибольшая вероятность верной классификации ЭЭГ паттернов моторных команд достигается разработанной системой классификации при преобразовании ЭЭГ сигнала к плотности источника тока.

4.3.2. Влияние параметров генерации признаков на вероятность успешной классификации

Индивидуальный подход к выбору параметров генерации признаков на основе анализе ЭЭГ сигналов, соответствующих моторным командам, может оказывать существенное влияние на итоговую вероятность успешного распознавания с использованием разработанной системы классификации. Было проведено исследование с целью выделения тех параметров анализа ЭЭГ сигналов и вычисления характерных признаков, которые способствовали повышению вероятности успешной классификации.

При использовании двух типов признаков – площади сегмента сигнала (низкочастотная составляющая) и длины кривой сегмента (высокочастотная составляющая), вычисленных в скользящем окне, важным для повышения вероятности успешной классификации является выбор значения величины окна анализа.

Индивидуальная настройка параметров скользящего временного окна анализа направлена на решение задачи повышения вероятности успешной классификации с помощью варьирования временных параметров генерации признаков. Целесообразность индивидуальной настройки обуславливается индивидуальной вариативностью ЭЭГ сигнала. Настройка временных параметров генерации признаков целесообразна для определения такой величины окна анализа, которая максимально приближена к величине характерного ЭЭГ паттерна.

Влияние параметров генерации признаков на вероятность успешной классификации комитетом ИНС.

С целью реализации индивидуального подхода и выбора параметров, обеспечивающих наибольшую вероятность успешного распознавания воображаемых движений у отдельных испытуемых, анализ сигналов ЭЭГ для извлечения признаков проводился во временных окнах длиной от 60 до 140 мс. Сдвиг окна анализа составлял 50 % от длины окна анализа. Было выявлено влияние фактора «длина окна анализа» на вероятность успешного распознавания ЭЭГ паттернов воображаемых движений пальцев и кисти руки при попарной классификации ($F[24,22800]=11.9$; $p<0.05$). При этом влияние фактора было индивидуальным, т.е. для каждого испытуемого могут быть определены временные параметры генерации признаков, в среднем повышающие процент распознавания воображаемых движений.

На рис. 31 приведен пример индивидуального влияния длины окна анализа и количества накоплений проб на вероятность успешной классификации моторных команд комитетом ИНС. Графики отображают вероятность верной

классификации при различной длине окна анализа (60, 100, 140 мс) и при различном количестве накопления проб сигнала.

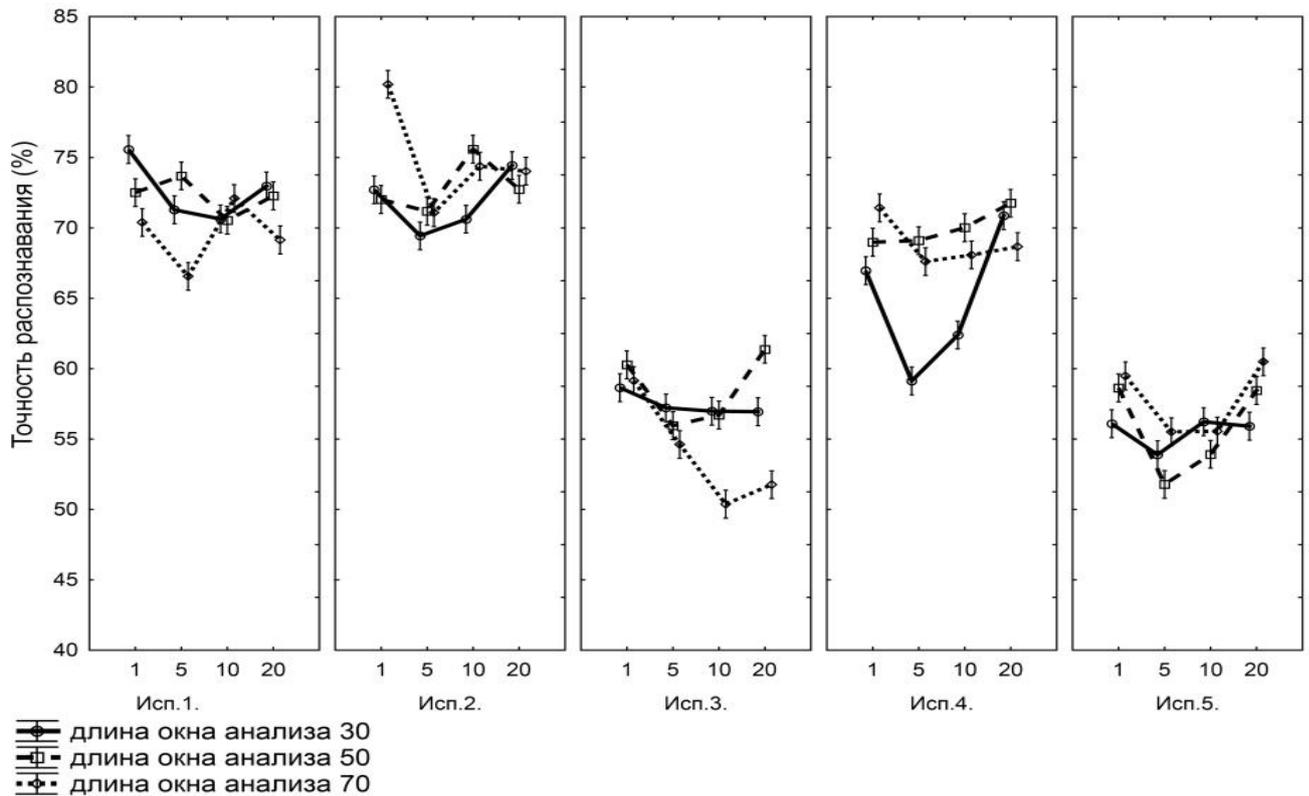


Рис. 31. Влияние параметров генерации признаков (длины окна анализа и количества накопленных проб сигнала) на вероятность успешной классификации комитетом ИНС индивидуально по испытуемым.

Примечания: приведены индивидуальные данные для испытуемых. 1, 5, 10, 20 по оси абсцисс – количество накопленных проб. По оси ординат – индивидуальная вероятность успешной классификации, усредненная по всем парам движений. Кривые отражают динамику вероятности верной классификации при различных длинах окна анализа (длина окна анализа в отсчетах: 1 отсчет = 2 мс.).

Как видно из приведенных данных у некоторых испытуемых вероятность успешного распознавания воображаемых движений при изменении длины окна анализа изменяется незначительно – в пределах 2-5% (испытуемый 5), в то время как у других вариативность выше, и вероятность успешного распознавания изменяется, в среднем, на 8-10% (испытуемые 2, 3, 4). Таким образом, при индивидуальной настройке длины окна анализа реализуется возможность

повышения вероятность успешной классификации с использованием разработанной системы.

Влияние параметров генерации признаков на вероятность успешной классификации методом опорных векторов.

Для оценки влияния длины окна анализа и величины сдвига окна анализа на вероятность успешной классификации воображаемых движений использовались следующие комбинации факторов:

- длина окна анализа составляла: 30, 50, 70, 100 отчетов (60, 100, 140, 200 мс соответственно),
- величина сдвига окна анализа составляла 10, 30 и 50% для каждого из окон.

Было выявлено влияние факторов «длина окна анализа» и «величина сдвига окна анализа» на вероятность успешного распознавания ЭЭГ паттернов воображаемых движений пальцев и кисти руки при попарном сравнении ($F[24,68400]=34,56$; $p<0,01$). Влияние данных факторов было индивидуальным: для каждого испытуемого параметры генерации признаков, в среднем повышающие вероятность успешного распознавания воображаемых движений, могут быть различными.

На рис. 32 приведен график зависимости вероятности верной классификации воображаемых движений от длины окна анализа и величины его сдвига индивидуально по испытуемым.

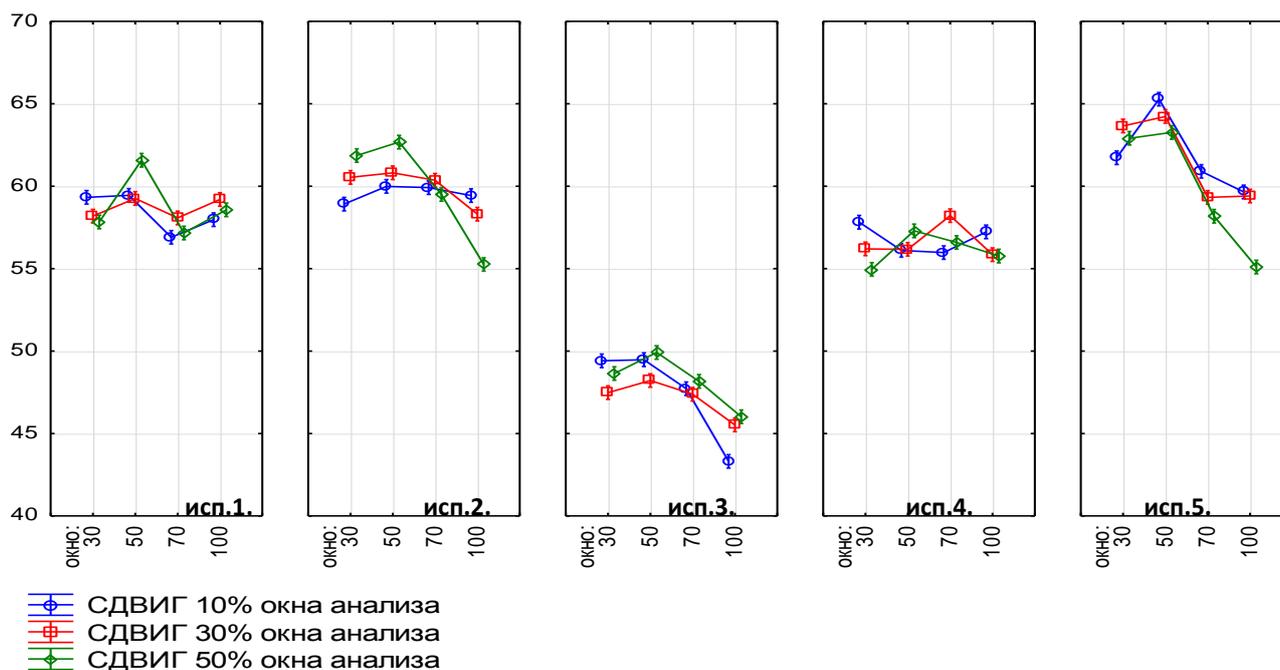


Рис. 32. Влияние временных параметров генерации признаков (длины окна анализа и величины сдвига окна анализа) на индивидуальную вероятность успешной классификации методом опорных векторов.

Примечания: приведены индивидуальные данные для участников исследования. По оси абсцисс – длина окна анализа в отчетах (1 отчет = 2 мс). По оси ординат – индивидуальная вероятность успешной классификации, усредненная по всем парам движений.

Приведенные зависимости показывают, что у некоторых испытуемых средняя вероятность успешного распознавания воображаемых движений при изменении параметров длины окна и величины сдвига окна анализа изменяется в среднем на 8% между показателями максимальной и минимальной средней вероятности (испытуемый 2 и испытуемый 5). У остальных испытуемых она изменяется незначительно – от 2 до 5%.

Вместе с тем, выбор оптимальных индивидуальных характеристик длины окна анализа и сдвига окна анализа позволяет повысить вероятность успешной классификации отдельных пар движений до 80-98%, что продемонстрировано в таблице 3.

Таблица 3. Результаты классификации попарно распознаваемых воображаемых движений при выборе оптимальной длины окна анализа.

Пары	Вероятность успешной классификации (%), окно (отсчеты)									
	Комитет ANN					RBF SVM				
	Исп. 1	Исп. 2	Исп. 3	Исп. 4	Исп. 5	Исп. 1	Исп. 2	Исп. 3	Исп. 4	Исп. 5
Б- У	65%, 50	98% , 50	65%, 30	93% , 30	75%, 70	77%, 50	78%, 30	47%, 50	80% , 30	91% , 70
Б- К	60%, 30	84% , 70	64%, 70	89% , 70	63%, 70	82% , 30	81% , 30	61%, 30	70%, 70	62%, 30
Б- С	94% , 30	96% , 70	69%, 30	93% , 70	71%, 70	65%, 30	81% , 50	62%, 30	67%, 50	78%, 30
Б- М	97% , 50	66%, 50	66%, 70	93% , 70	78%, 70	75%, 30	69%, 50	77%, 30	70%, 70	84% , 30
У- К	75%, 30	84% , 50	64%, 50	63%, 50	77%, 50	74%, 50	73%, 70	59%, 70	85% , 50	63%, 50
У- С	95% , 70	62%, 30	70%, 70	74%, 50	69%, 30	65%, 50	70%, 50	59%, 70	67%, 50	68%, 50
У- М	94% , 70	99% , 50	69%, 50	72%, 50	66%, 70	58%, 70	80% , 30	63%, 50	79% , 50	66%, 50
К- С	91% , 50	62%, 30	78%, 70	63%, 30	65%, 50	77%, 30	67%, 50	75%, 50	54%, 30	60%, 30
К- М	93% , 70	89% , 70	66%, 50	72%, 50	76%, 50	74%, 70	76%, 50	54%, 50	84% , 50	77%, 30
С- М	68%, 30	95% , 50	71%, 70	62%, 70	68%, 50	58%, 30	75%, 50	66%, 70	60%, 30	62%, 50

Примечания: в каждой ячейке таблицы указаны – вероятность успешной классификации в процентах и соответствующая длина окна анализа в отсчетах (1 отсчет = 2 мс) для попарных классификаций. Сдвиг окна анализа составлял 50% длины окна. Типы воображаемых движений: Б – воображаемое движение большим пальцем; У – воображаемое движение

указательным пальцем; К – воображаемое движение кистью правой руки; С – воображаемое движение средним пальцем; М – воображаемое движение мизинцем.

Результаты исследований показали, что для некоторых типов моторных команд изменение длины окна анализа является несущественным, для других - определение оптимальных параметров критично и является ограничивающим фактором для настройки классификатора. При индивидуальной настройке длины окна анализа обеспечивается выбор индивидуального набор команд с заданным минимальным порогом распознавания.

Выбор параметров генерации признаков в среднем по испытуемым для классификаторов на основе ИНС и МОВ.

На практике в случае использования системы классификации в составе ИМК большим количеством пользователей (вариант совместной эксплуатации) индивидуальная настройка параметров генерации признаков на каждого пользователя может быть затруднена, так как она сопряжена с необходимостью проведения предварительного исследования. Вместе с тем, по результатам изучения влияния временных параметров генерации признаков на вероятность успешной классификации с использованием ИНС и МОВ, можно определить унифицированные параметры, которые обеспечивают предпочтительную вероятность верной классификации в среднем по испытуемым.

При анализе влияния длины окна анализа на вероятность верных распознаваний воображаемых движений классификатором на основе комитета ИНС (рис. 33) было обнаружено, что вероятность успешной классификации повышается при увеличении длины окна анализа до 70 отчетов, а затем существенно не меняется. Предпочтительными являются окна анализа длиной в 50 и 70 отчетов (100 и 140 мс соответственно). Влияние фактора величина сдвиг окна анализа оказывается несущественным для вероятности успешной классификации с использованием комитета ИНС.

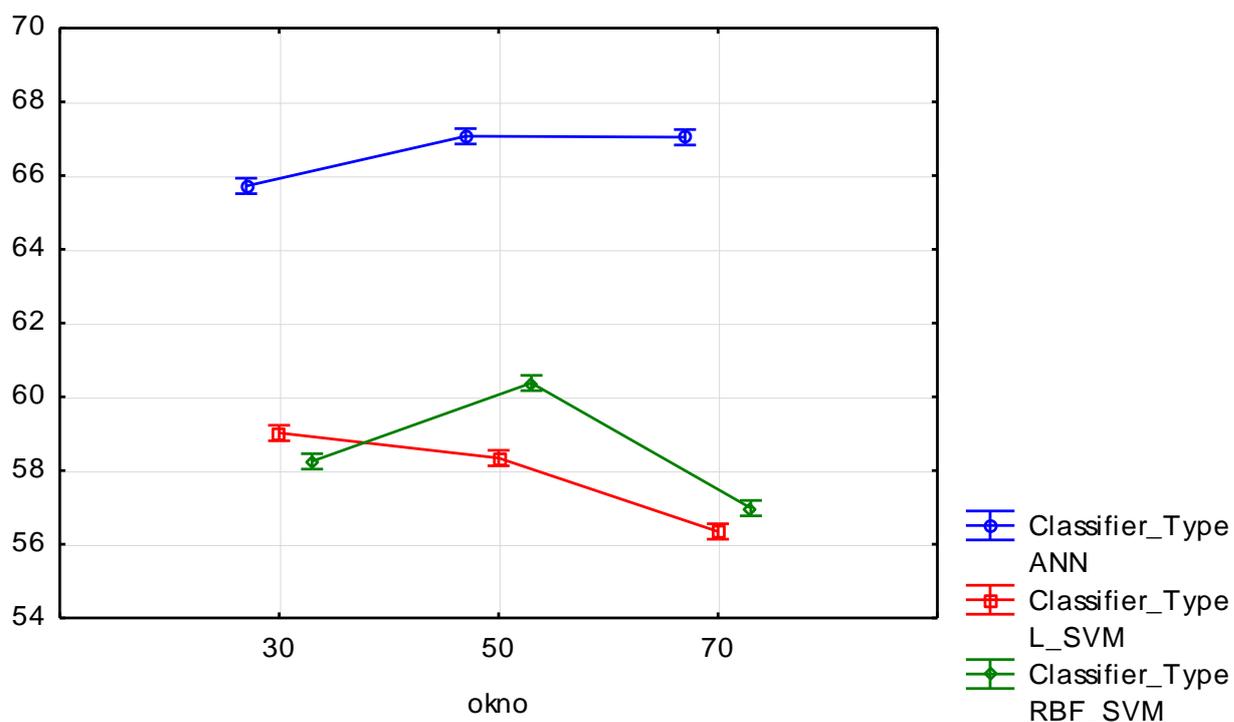


Рис. 33. Вероятность успешной классификации ЭЭГ паттернов моторных команд с использованием классификаторов на основе комитета искусственных нейронных сетей и метода опорных векторов в зависимости от длины окна анализа.

Примечание: по оси абсцисс – длина окна анализа в отчетах (1 отчет = 2мс), по оси ординат – вероятность успешной классификации, усредненная по всем парам движений и всем испытуемым.

L_SVM – классификация методом опорных векторов с линейной базисной функцией, RBF_SVM – классификация методом опорных векторов с радиальной базисной функцией.

ANN – классификация на основе комитета ИНС.

При использовании для классификации метода опорных векторов наблюдается другая закономерность (рис. 33) – вероятность верного распознавания пар движений выше при использовании малых и средних длин окон (30 и 50 отчетов) и величины сдвига окна – 50% длины окна анализа.

На основании выявленных закономерностей можно определить унифицированные временные параметры генерации признаков для классификаторов на основе ИНС и МОВ, которые обеспечивают более высокую вероятность успешной классификации в среднем по испытуемым – длина окна

анализа – 50 отсчетов (100 мс), величина сдвига окна анализа – 25 отсчетов (50 мс).

4.3.3. Выбор наиболее информативных каналов методом картирования

Реализован подход по выбору наиболее информативных, для разработанной системы классификации, каналов ЭЭГ посредством картирования вероятности успешной классификации ЭЭГ паттернов моторных команд для различных каналов/топографий ЭЭГ сигнала у каждого испытуемого.

Задача выбора наиболее информативных каналов по-разному решается научными коллективами: применяется метод общего пространственного паттерна [31], автоматического выбора наиболее информативных каналов по модифицированному регрессионному алгоритму [104], применяются процедуры кластеризации информации с каналов, ранжирование по значению коэффициентов детерминации (r^2) [121], выбор топографий для классификации сигнала на основе главных [122] и независимых компонент [37].

При выполнении картирования вероятности успешной классификации ЭЭГ сигналов воображаемых движений возможна реализация двух подходов: (1) информативный сигнал, связанный с моторной командой, возникает преимущественно в сенсомоторной зоне, поэтому можно ограничиться картированием отведений этой зоны; (2) необходимо картирование всех отведений, так как информативные признаки, связанные с воображением и моторной активностью, могут возникать в различных зонах.

Была сформулирована гипотеза о необходимости учета всех топографий постановки электродов по системе 10-20 при выборе каналов, содержащих наиболее информативные признаки для классификации моторных команд.

На рис. 34 приводится пример картирования вероятности успешной классификации ЭЭГ сигналов при воображении 4-х типов движений от девяти каналов, расположенных над сенсомоторными и прилегающими зонами коры.

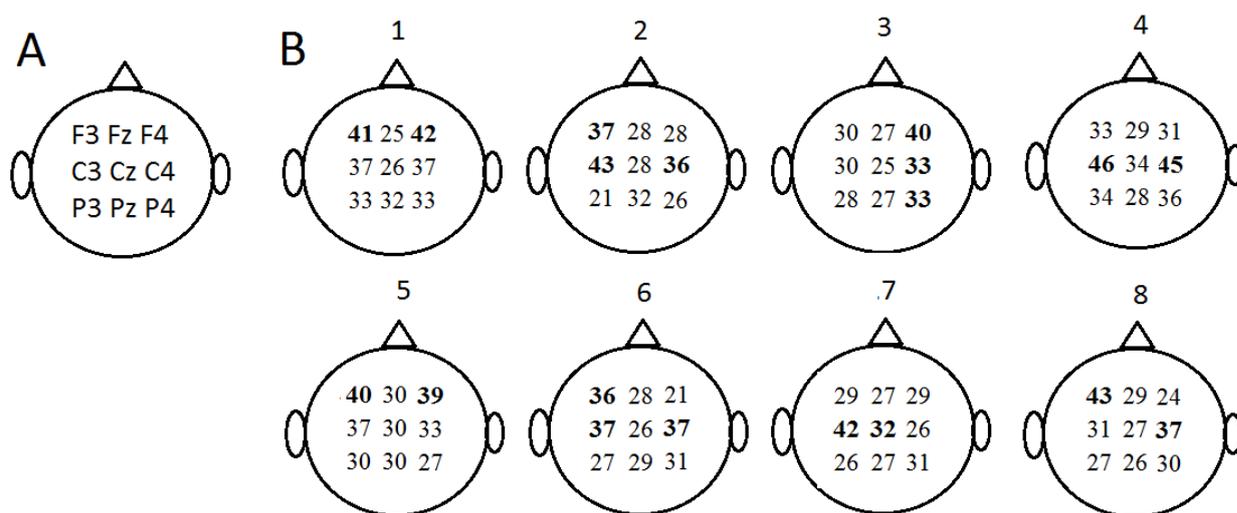


Рис. 34. Вероятность успешной классификации паттернов ЭЭГ для отдельных отведений при процедуре предварительного выбора информативных каналов, расположенных над сенсомоторной и прилегающими областями коры.

Примечание: А – схема расположения электродов. В – индивидуальные результаты картирования вероятности успешной классификации паттернов ЭЭГ с соответствующего канала

Как видно на рис. 34, часть испытуемых имела один доминантный канал со значительно более высокой вероятностью успешной классификации по сравнению с остальными каналами. Остальные испытуемые имели два доминантных канала. Предположительно именно доминантные каналы содержат наибольшее число характерных признаков для последующей классификации моторных команд. Следует отметить, что в случае наличия только одного доминантного канала целесообразно проведение дополнительного исследования с целью выбора второго канала для анализа, т.к. каналы с близкими результатами картирования могут вносить разный вклад в итоговый результат классификации.

Исследование показывает, что классификация на основе 2-3 каналов/топографий, выбранных по результатам картирования, является наиболее эффективной, и включение в анализ дополнительного числа каналов не приводит к значимому повышению вероятности успешной классификации, а может стать причиной ее снижения. Этот вывод совпадает с результатами научных коллективов, классифицировавших ЭЭГ сигналы, преобразованные по методу

независимых компонент и главных компонент, сообщавших о достижении максимальной вероятности успешной классификации при использовании от 2-х до 4-х главных/независимых компонент [50, 122].

При картировании всех 19 зон и выделении признаков в двух лучших каналах, средняя вероятность успешной классификации ЭЭГ сигнала была выше средней вероятности успешной классификации при выборе из девяти каналов. Результаты классификации воображаемых движений на основе картирования вероятности верной классификации ЭЭГ сигнала и выбора лучших каналов для зон, прилегающих к сенсомоторной коре (9 каналов) и для всех топографий (19 каналов) приведены на рис. 35.

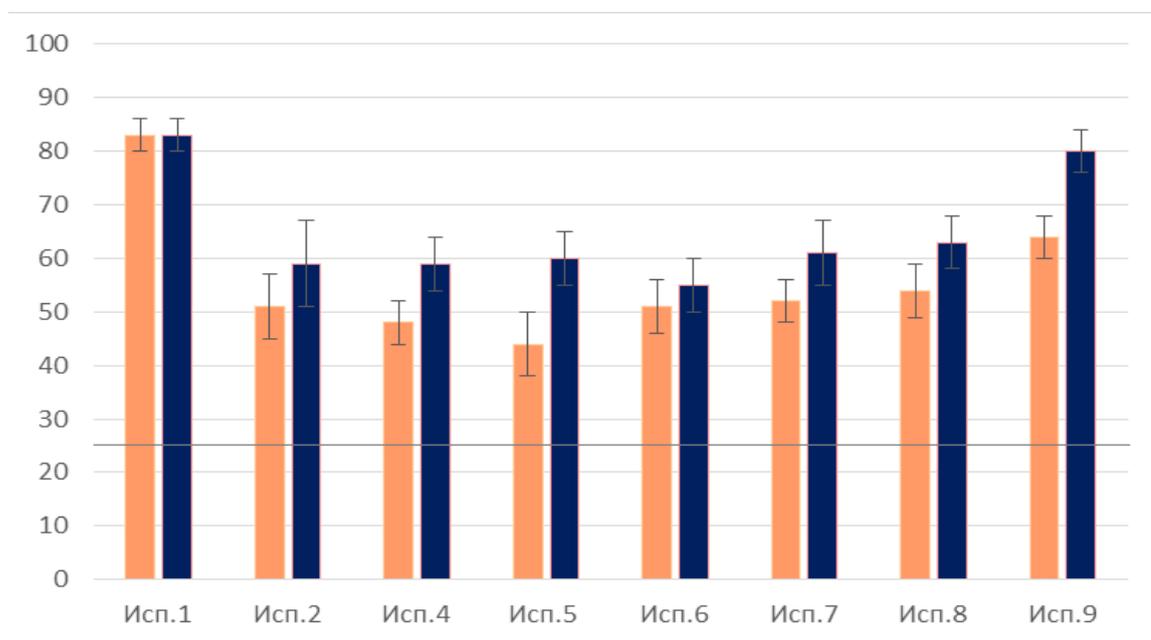


Рис. 35. Вероятность успешной классификации ЭЭГ паттернов воображаемых движений 4-х классов при выборе каналов, содержащих информативные признаки, на основе картирования: левый столбец для каждого испытуемого – выбор каналов в пределах сенсомоторной области, правый столбец – выбор каналов из всех топографий.

По оси абсцисс – порядковые номера испытуемых, по оси ординат – вероятность успешной классификации (%)

Использование сигналов со всей поверхности головы и выбор лучших каналов позволили повысить среднюю вероятность успешной классификации до

65±10% для исследованной группы испытуемых. Для всех испытуемых вероятность успешного распознавания с использованием разработанной системы классификации при выборе лучших каналов из всех топографий оказалась выше или равна вероятности успешной классификации при определении лучших каналов только из сенсомоторной области. Таким образом, индивидуальный выбор информативных каналов повышает вероятность верного распознавания ЭЭГ паттернов воображаемых движений и может быть использован при индивидуальной настройке классификатора в системе ИМК. Приведенные результаты подтверждают гипотезу о необходимости картирования всех топографий для выбора наиболее информативных каналов.

Вместе с тем, при ограничении количества рассматриваемых каналов определенными зонами, наряду с некоторым снижением вероятности успешной классификации, повышается физиологическая значимость тренировки выбранных зон, например при реабилитации. Таким образом, выбор зон для картирования и выделения наиболее информативного сигнала может зависеть от задач исследования и целей пользователя ИМК. Так, для управления внешними устройствами целесообразно использование лучших каналов из всех картированных, тогда как для целей реабилитации и тренировок двигательных функций предпочтительно использование наиболее информативных каналов ЭЭГ, зарегистрированных с сенсомоторных зон коры.

Метод картирования, примененный в данной работе, позволяет получить значения вероятности успешной классификации для каждого из ЭЭГ каналов (топографий), что делает выбор информативных каналов численно обоснованным. Несмотря на то, что данная процедура является вычислительно-затратной, индивидуальная настройка систем ИМК производится перед началом эксплуатации пользователем, поэтому разумные временные затраты являются целесообразными при значимом повышении эффективности классификации.

Выбор наиболее информативных каналов позволил увеличить скорость и вероятность успешной классификации за счет исключения из рассмотрения каналов, предположительно, содержащих значимо меньшее количество

признаков, характерных для определенного типа моторной команды. Для достижения наибольшего быстродействия, необходимого для ИМК реального времени, целесообразна минимизация анализируемых каналов при сохранении требуемой вероятности успешного распознавания.

Реализованный в данной работе метод картирования является необходимым элементом индивидуальной настройки ИМК для выбора каналов, содержащих информативные признаки для классификации паттернов моторных команд.

4.4. Сравнение основных результатов разработанной системы анализа и классификации ЭЭГ паттернов с мировым уровнем

Проведенный анализ результатов системы анализа и классификации, основанной на различных методах классификации, с использованием индивидуальной настройки параметров, позволил определить наиболее эффективную конфигурацию разработанной системы анализа и классификации ЭЭГ паттернов. Основными элементами такой конфигурации стали: преобразование ЭЭГ сигнала к плотности источника тока, проведение процедуры картирования вероятности успешной классификации по отдельным каналам, с последующей настройкой индивидуальных параметров окна анализа.

При данной конфигурации разработанной системы на основе гетерогенного комитета классификаторов, анализирующего два пространства признаков, были проведены исследования с целью определения вероятности успешной классификации 4-х и 5-и моторных команд. Классифицировались ЭЭГ паттерны, соответствующие следующим моторным командам: воображаемые движения 1) большим, 2) указательным, 3) средним пальцами, 4) мизинцем и 5) воображение сжатия кисти руки. Моторная команда сжатия кисти распознавалась только в варианте классификации 5-и типов воображаемых движений. Результаты исследования приведены в таблице 4.

Таблица 4. Вероятность успешной классификации ЭЭГ паттернов 4 и 5 моторных команд гетерогенным комитетом классификаторов

Испытуемые	Вероятность успешной классификации 4 моторных команд, %	Вероятность успешной классификации 5 моторных команд, %
Исп.1	83±3	65±5
Исп.2	55±5	46±5
Исп.3	59±9	41±4
Исп.4	60±5	45±5
Исп.5	62±6	49±5
Исп.6	64±5	61±6
Исп.7	63±5	54±4
Исп.8	80±3	72±4
Исп.9	59±5	49±3
Среднее	65±10	54±10

Достигнуто среднее значение вероятности успешных распознаваний для 4-х классов воображаемых движений пальцами одной руки – 65±10%, максимальное – 83±3%; для 5-и классов воображаемых движений (четырьмя пальцами руки и кистью)-54±10%, максимальное-72±3%. Вместе с тем, вероятность успешной классификации является не единственным параметром разработанной системы, требующим оценки.

Настоящая работа находится в тренде мировых разработок неинвазивных ИМК, основанных на классификации ЭЭГ паттернов воображаемых движений [39, 68]. При создании ИМК на основе ЭЭГ сигналов при совершении воображаемых движений основной задачей исследований является построение эффективной системы классификации, позволяющей с высокой вероятностью и быстродействием разделить паттерны моторных команд.

Анализ приведенных в литературе подходов и результатов зарубежных и российских научных коллективов к решению актуальных проблем при разработке

эффективных систем анализа и классификации ЭЭГ паттернов мелкой моторики обобщен в таблице 1 главы 1. Сопоставительный анализ основных полученных результатов решения общих задач, возникающих при разработке систем классификации для ИМК, с мировым уровнем приведен ниже.

1.Задача: повышение вероятности успешной классификации при увеличении степеней свободы ИМК – за счет увеличения количества распознаваемых движений.

В большинстве реализованных классификаторов паттернов ЭЭГ распознается не более 3 движений крупной моторики (наличие/отсутствие воображаемого движения, до 3 типов движений рук, ног, комбинации последовательных движений), при этом вероятность успешной классификации 2-х классов находится в диапазоне от 70 до 99 % [123, 104, 59, 60]. Переход к классификации паттернов ЭЭГ, соответствующих мелкой моторике, направлен на увеличение числа степеней свободы ИМК, является актуальной задачей, к решению которой приступили лишь несколько коллективов в мире. Так, Хiao и коллеги [121] достигли вероятности верного декодирования движений 5 пальцев руки в 39,7 % в среднем по испытуемым. Группа Quandt [97] сообщала о распознавании движений 4-я пальцами со средней вероятностью верного решения в 43%. Максимальные значения вероятности успешной классификации у некоторых испытуемых достигали 46% и 54% при классификации движений 5-ти и 4-х пальцев соответственно.

В настоящей работе была разработана система классификации воображаемых движений с числом распознаваемых моторных команд – до 5. Наибольшая вероятность успешной классификации паттернов четырех воображаемых движений составила - $83\pm 3\%$, пяти воображаемых движений - $72\pm 3\%$ у отдельных испытуемых. В среднем вероятность успешной классификации 4-х воображаемых движений составляла $65\pm 10\%$, 5-и – $54\pm 10\%$. Полученная в ходе выполнения данного проекта вероятность верной классификации для четырех и пяти классов находится на мировом уровне для

мультиклассового распознавания ЭЭГ паттернов мелкой моторики и даже несколько превышает опубликованные результаты других коллективов.

2. *Задача: разработка новых парадигм исполнения воображаемых и реальных движений (моторных команд).*

Описанные в литературе современные парадигмы исследований предусматривают выполнение движений/воображение движений в течение 2–10 с [121, 123, 31]. С целью увеличения быстродействия и эффективности классификации в работе предложена новая парадигма выполнения воображаемых движений, предполагающая короткие эпизоды воображения движений (600 мс) в заданном ритме без внешнего стимула внутри предъявляемых испытуемым проб. Преимуществом данной парадигмы является возможность локализации воображения движений в коротком интервале времени. При этом сам момент выполнения воображаемого движения не сопряжен с предъявлением внешнего стимула.

Разработанная система анализа зарегистрированного сигнала ЭЭГ и классификации паттерна моторной команды обеспечивает выдачу ответа о принадлежности паттерна одному из классов за время, не превышающее длительности одной пробы. В условиях практической реализации ИМК перспективными являются подходы с наименьшим временным интервалом, необходимым для исполнения управляющей команды, и минимальным временем, необходимым для классификации.

3. *Задача: разработка эффективных алгоритмов классификации ЭЭГ сигналов.* В большинстве лабораторий, занимающихся разработками ИМК, используются подходы к классификации ЭЭГ сигнала из ограниченного набора методов, продемонстрировавших свою пригодность к распознаванию сложных нестационарных образов, проанализированных в главе 1.

В данной работе были разработаны новые алгоритмы предобработки и анализа сигналов ЭЭГ. В результате сравнительного исследования методов преобразования ЭЭГ сигнала (преобразование к взвешенному среднему монтажу, разложение на независимые компоненты, преобразование к плотности источников

тока) были определены предпочтительные для использования в системе классификации ЭЭГ паттернов моторных команд. Для классификации характерных признаков был разработан двухуровневый комбинированный комитет гетерогенных классификаторов на базе метода опорных векторов и искусственных нейронных сетей.

4. *Задача: индивидуальная настройка параметров системы анализа и классификации паттернов ЭЭГ в ИМК.* В работах научных коллективов, занимающихся классификацией ЭЭГ паттернов, особое внимание уделено необходимости выбора индивидуальных состояний, заданий для классификации, а также задаче индивидуального выбора признаков и каналов для классификации [49, 43, 126, 75].

В диссертации также используется подход по индивидуальной настройке системы классификации. В рамках реализации индивидуализированного подхода был применен метод картирования вероятности успешной классификации для отдельных топографий ЭЭГ сигнала с целью индивидуального выбора каналов, обеспечивающих максимальную вероятность успешной классификации для данного испытуемого. Дополнительно обеспечена возможность настройки параметров генерации признаков и методов преобразования ЭЭГ сигнала для конкретного пользователя. Метод картирования, реализованный в данной работе, позволяет получить значения вероятности успешной классификации для каждого из каналов, что делает выбор информативных каналов численно обоснованным.

В целом, в диссертации исследованы различные признаки ЭЭГ сигнала и разработан комитет классификаторов для распознавания ЭЭГ паттернов моторных команд. Полученные результаты мультиклассового (4-х и 5-и воображаемых движений мелкой моторики) распознавания воображаемых движений по одной пробе (single-trial подход) с выбором индивидуальных параметров классификации продемонстрировали сопоставимую с описанной в литературе вероятность успешной классификации *реальных* движений. Частично данные представлены в работах [22, 107]. Внедрение разработанных средств

классификации в ИМК реального времени может существенно расширить возможности применяемых неинвазивных интерфейсов.

4.5 Применение разработанной системы в ИМК для управления искусственной кистью руки

Для проведения исследований по применению разработанной системы классификации паттернов моторных команд в неинвазивном ИМК была использована специально разработанная искусственная кисть руки. Пятипалая кисть руки (Low-cost Arm Prototype with Actuators) и открытый блок управления показаны на рис. 36.



Рис. 36. Блок управления и механическая кисть руки.

Искусственная кисть руки состоит из основания, в которое устанавливаются 6 сервоприводов. Четыре привода используются для пальцев с указательного по мизинец, а для большого пальца устанавливается 2 сервопривода, обеспечивающие его подвижность в двух плоскостях. Такая подвижность большого пальца дает возможность простыми средствами достичь соприкосновения кончиков большого и любого другого пальца, т. е. обеспечивает возможность аккуратного захвата небольших предметов.

От сервоприводов к кончикам пальцев проложены нити, которые действуют против пружин, установленных в каждом из гибких соединений. Жесткость

пружин подобрана таким образом, чтобы обеспечить плавный сгиб пальцев в каждом из его соединений при натяжении нити.

Каждый из сервоприводов работает в режиме широтно-импульсной модуляции и отслеживает заданный угол поворота рычага натяжения нити привода пальца, что соответствует заданному положению сгиба пальца. Распрямление пальца происходит за счет обратного хода пружин в сочленениях при ослаблении натяга нити.

От блока управления к кисти руки подсоединяется шлейф управления, по которому происходит управление сервоприводами. Внутри блока располагаются блок питания от сети AC 220В (со стандартным разъемом для шнура питания), одноплатный компьютер Raspberry и подключенная к нему через интерфейс I2C плата управления сервоприводами. Одноплатный компьютер управляется удаленно через Ethernet.

Формирование сигналов управления приводами всех 5-и пальцев искусственной кисти осуществлялось разработанной системой классификации ЭЭГ паттернов моторных команд движений пальцами в рамках ИМК. Для выполнения требований реального времени анализировались одиночные попытки воображения движений (режим single-trial).

В результате данного исследования была показана реальная возможность управления искусственной кистью руки с помощью разработанной системы классификации в ИМК реального времени. Основным результатом является тот факт, что характеристики разработанных программных средств отвечают требованиям, необходимым для построения ИМК. Временные задержки, необходимые для получения ответа классификатора, находятся в пределах длительности 1 пробы (600 мс), что является приемлемым для использования ИМК с биологически обратной связью. Согласно субъективному самоотчету испытуемого, у него происходит связывание воображаемого действия с получаемым ответом системы.

При практическом использовании системы для управления искусственной кистью руки важно обеспечение максимально возможной вероятности успешной

классификации для недопущения ошибочных действий исполнительного устройства. С целью совершенствования разработанной системы и для повышения вероятности успешной on-line классификации ЭЭГ паттернов воображаемых движений планируется реализация следующих подходов:

- тренировка испытуемых с использованием нейробиоуправления, направленного на обучение испытуемого управлению своим состоянием при воображении движений пальцев рук, что, предположительно, может привести к большей различимости ЭЭГ паттернов, соответствующих различным воображаемым движениям;
- использование алгоритма формирования решения о принадлежности к определенному классу по результатам классификации нескольких последовательных проб (с подкреплением);
- выбор для каждого испытуемого индивидуальных параметров настройки классификатора (временные окна, сдвиг, информативные каналы для данного испытуемого).

4.6 Выводы к главе 4

1. Разработка неинвазивного, мобильного ИМК с высокой вероятностью успешных распознаваний, работающего с незначительными временными задержками и большим числом выполняемых команд, является приоритетной задачей фундаментальной и прикладной науки с целью улучшения качества жизни и реабилитации пациентов с двигательными нарушениями. При разработке ИМК на основе воображаемых движений в режиме реального времени должны быть, в первую очередь, решены следующие задачи: (1) повышение скорости и вероятности успешной классификации до уровней, приемлемых для эффективного использования в ИМК; (2) увеличение степеней свободы ИМК за счет увеличения количества распознаваемых моторных команд.

2. Объединение разработанных средств анализа и классификации ЭЭГ паттернов позволило создать ИМК, состоящий из модулей автоматического

получения входных данных в реальном времени, их обработки, обучения классификаторов, классификации паттернов ЭЭГ, который обеспечил декодирование ЭЭГ сигналов и классификацию ЭЭГ паттернов воображаемых моторных команд в реальном времени и выдачу сигналов для управления внешними устройствами.

3. Проведенные сравнительные исследования продемонстрировали влияние различных параметров системы, таких как методы классификации и преобразования ЭЭГ сигнала, параметры генерации признаков и выбор наиболее информативных каналов, на вероятность успешной классификации паттернов воображаемых движений.

4. Проведенный анализ результатов реализованной системы классификации ЭЭГ паттернов позволил определить наиболее эффективную конфигурацию системы при распознавании моторных команд в режиме single-trial для удовлетворения требований по быстродействию ИМК реального времени.

5. Реализованные средства анализа и классификации позволили перейти к распознаванию воображаемых движений мелкой моторики, увеличить число распознаваемых моторных команд до 5-и и повысить вероятность успешной классификации для четырех и пяти классов. Эти показатели соответствуют мировому уровню для распознавания ЭЭГ паттернов мелкой моторики и даже несколько превышают опубликованные результаты других коллективов.

6. Реализованная система классификации паттернов моторных команд применена в неинвазивном ИМК с биологической обратной связью для управления разработанной искусственной пятипалой кистью руки. Показана реальная возможность управления с помощью предложенной системы классификации в составе информационно-измерительных и управляющих систем комплексов реабилитации, протезирования и мониторинга в режиме реального времени.

ЗАКЛЮЧЕНИЕ

1. Предложены новые методы анализа многоканальных ЭЭГ сигналов и классификации многомерных ЭЭГ паттернов моторных команд. Метод анализа ЭЭГ сигналов путем построения регрессионной модели сигнала в аналитической форме с подбором базисных функций и их параметров с использованием генетического программирования позволил понять закономерности ЭЭГ сигналов и учесть такие временные характеристики ЭЭГ паттернов воображаемых моторных команд, как локализацию признаков во времени, длительность информативных участков, что в результате дало возможность сократить длительность анализируемого сигнала, повысить вероятность успешных распознаваний и быстродействие классификатора. Метод классификации выделенных ЭЭГ паттернов моторных команд на основе комитета гетерогенных классификаторов, построенных на искусственных нейронных сетях и методе опорных векторов, позволил использовать разные признаковые пространства, учитывать временные особенности и многоканальность ЭЭГ сигналов и, в результате, повысить эффективность классификации многомерных ЭЭГ паттернов моторных команд.

2. Разработанные алгоритмы анализа и классификации, основанные на выделении нескольких пространств признаков во временной области и использовании комитета гетерогенных классификаторов на базе искусственных нейронных сетей и метода опорных векторов, позволили повысить вероятность успешных распознаваний и быстродействие классификатора ЭЭГ паттернов моторных команд и обеспечить возможность программной реализации ИМК.

3. На базе предложенной методики регистрации, преобразования, анализа ЭЭГ сигналов и классификации ЭЭГ паттернов моторных команд разработан программный комплекс, позволивший реализовать интегрированную систему классификации ЭЭГ паттернов моторных команд, которая может быть основой неинвазивных ИМК, используемых в составе ИИУС комплексов реабилитации, протезирования и мониторинга. Применение разработанной системы классификации на базе комитета гетерогенных локальных классификаторов

обеспечивает возможность реализации ИМК реального времени. Разработанные программные средства могут быть использованы для прямого управления исполнительными устройствами в ИМК с биологической обратной связью, в том числе, роботизированными протезами кисти руки.

Полученные результаты соответствуют п.6 «Исследование возможностей и путей совершенствования существующих и создания новых элементов, частей, образцов информационно-измерительных и управляющих систем, улучшения их технических, эксплуатационных, экономических и эргономических характеристик, разработка новых принципов построения и технических решений» паспорта специальности 05.11.16 – «Информационно-измерительные и управляющие системы (технические науки)»

Литература

1. Ганин И. П., Каплан А. Я. Интерфейс мозг компьютер на основе волны р300: предъявление комплексных стимулов “подсветка + движение” // Журнал высшей нервной деятельности. – 2014. – Т.64. – № 1. – С. 32-40.
2. Ганин И. П., Шишкин С. Л., Кочетова А. Г., Каплан А. Я. Интерфейс мозг-компьютер “на волне Р300”: исследование эффекта номера стимулов в последовательности их предъявления // Физиология человека. – 2012. – Т. 38. – № 2. – С.5-13.
3. Гнездицкий В.В. Вызванные потенциалы мозга в клинической практике. – М.:МЕДпресс-информ, 2003. – 264 с.
4. Гнездицкий В.В. Обратная задача ЭЭГ и клиническая электроэнцефалография. – М.:МЕДпресс-информ, 2004. – 624 с.
5. Гутман А.М. Биофизика внеклеточных полей мозга. – М.:Наука, 1980. – 184 с.
6. Дорогов А.Ю., Лесных В.Ю., Шестопалов М.Ю. Нейросетевая классификация в неоднородном признаковом пространстве // Нейрокомпьютеры: разработка, применение. – 2010. – № 4. – С. 20-33.
7. Егорова И.С. Электроэнцефалография. – М.: Медицина, 1973. – 294 с.
8. Захаров А.В., Антипов О.И., Пятин В.Ф. и др. Использование электроэнцефалографических фазовых образов планируемых движений в качестве управляющих сигналов для решения проблем двигательной реабилитации // Избранные вопросы нейрореабилитации: материалы VII международного конгресса «Нейрореабилитация - 2015». – 2015. – С. 140-142.
9. Зенков Л.Р. Клиническая электроэнцефалография (с элементами эпилептологии). – М: МЕДпресс-информ, 2002. – 268 с.
10. Иваницкий Г.А. Распознавание типа решаемой в уме задачи по нескольким секундам ЭЭГ с помощью обучаемого классификатора // ЖВНД им. И.П.Павлова. – 1997. – Т. 47. – С. 743-747.

11. Изнак А.Ф. Модуляция сенсо-моторной деятельности человека на фоне альфа-ритма ЭЭГ // Проблемы развития науч. иссл. в обл. псих. здоровья / МЗ СССР, АМН СССР. – 1989. – С. 3-24.
12. Котов С.В., Турбина Л.Г., Бобров П.Д., Фролов А.А., Павлова О.Г., Курганская М.Е., Бирюкова Е.В. Применение комплекса «интерфейс “мозг-компьютер” и экзоскелет» и техники воображения движения для реабилитации после инсульта // Альманах клинической медицины. – 2015. – № 39. – С. 15-21.
13. Кропотов Ю.Д. Количественная ЭЭГ, когнитивные вызванные потенциалы мозга человека и нейротерапия. – Донецк: Издатель Заславский А.Ю., 2010. – 512 с.
14. Лазуренко Д.М., Шепелев И.Е., Киров В.Н. и др. Идеомоторные ЭЭГ-паттерны в контуре интерфейса мозг-компьютер // Избранные вопросы нейрореабилитации: материалы VII международного конгресса «Нейрореабилитация - 2015». – 2015. – С. 246-249.
15. Маркин М.Е., Дыда А.А., Оськин Д.А. Управление подвижными объектами при помощи интерфейса мозг-компьютер на примере роботизированного манипулятора // Современные проблемы науки и образования. – 2014. – № 6
16. Пятин В.Ф., Колсанов А.В., Сергеева М.С. и др. Информационные возможности использования мю- и бета-ритмов ЭЭГ доминантного полушария в конструировании нейрокомпьютерного интерфейса // Фундаментальные исследования. – 2015. – № 2-5. – С. 975-978.
17. Роик А.О., Иваницкий Г.А., Иваницкий А.М. Когнитивное пространство человека: совпадение моделей, построенных на основе анализа ритмов мозга и на психометрических измерениях // Российский физиологический журнал им. И.М. Сеченова. – 2012. – Т. 98. – № 11. – С. 1314-1328.
18. Сонькин К.М., Станкевич Л.А., Хоменко Ю.Г., Нагорнова Ж.В., Шемякина Н.В. Классификация ЭЭГ-паттернов воображаемых и реальных движений пальцев одной руки методом опорных векторов // Тихоокеанский медицинский журнал. – 2014. – №. 2 – С. 30-35.

19. Сотников П.И. Выбор оптимальных частотных диапазонов сигнала электроэнцефалограммы в интерфейсе мозг-компьютер // Наука и Образование. МГТУ им. Н.Э. Баумана. Электрон. журн. – 2015. – № 06. – С. 217-234.
20. Сотников П.И. Обзор методов обработки сигнала электроэнцефалограммы в интерфейсах мозг-компьютер // Инженерный вестник. МГТУ им. Н.Э. Баумана. Электронный научно-технический журнал. – 2014. – № 10. – С. 621-632.
21. Станкевич Л.А., Сонькин К.М., Нагорнова Ж.В., Хоменко Ю.Г., Шемякина Н.В. Классификация электроэнцефалографических паттернов воображаемых движений пальцами руки для разработки интерфейса мозг-компьютер // Труды СПИИРАН. – 2015. – Т. 3. – №. 40. – С. 163-182.
22. Станкевич Л.А., Сонькин К.М., Шемякина Н.В. и др. Классификация ЭЭГ-паттернов воображаемых движений пальцами одной руки, выполняемых в заданном ритме // Физиология человека. – 2016. – Т. 42. – № 1. С. 40-52.
23. Стрижов В.В. Поиск параметрической регрессионной модели в индуктивно заданном множестве // Журнал вычислительных технологий. – 2007. – № 1. – С. 93-102.
24. Фролов А.А., Бирюкова Е.В., Бобров П.Д. и др. Принципы нейрореабилитации, основанные на использовании интерфейса «мозг-компьютер» и биологически адекватного управления экзоскелетом // Физиология человека. – 2013. – Т.39. – №2. – С. 99-113.
25. Фролов А.А., Роцин В.Ю. Интерфейс мозг-компьютер. Реальность и перспективы // Научная конференция по нейроинформатике МИФИ 2008г., Лекции по нейроинформатике, 2008г. [Электронный ресурс] <http://neurolectures.narod.ru/2008/Frolov-2008.pdf> (дата обращения 19.02.14).
26. Шишкин С.Л. Исследование синхронности резких изменений альфа-активности ЭЭГ человека // Дисс. канд. биол. наук: 03.00.13. – Москва, 1997.

27. Шишкин С.Л., Ганин И.П., Басюл И.А., Каплан А.Я. Интерфейс мозг-компьютер на основе волны P300: волна N1 и проблема дистракторов // Материалы XV Междунар. конф. по нейрокибернетике. 2009 г. Изд-во ЮФУ, 2009. – Т. 2. Симпозиум "Интерфейс мозг-компьютер". – С. 30-33.
28. Al-ani T., Trad D. Signal Processing and Classification Approaches for Brain-computer Interface. – INTECH Open Access Publisher, 2010.
29. Anderson C.W., Stolz E.A., and Shamsunder S. Multivariate autoregressive models for classification of spontaneous electroencephalogram during mental tasks // IEEE Transactions on Biomedical Engineering. – 1998. – Vol. 45. – № 3. – P. 277-286.
30. Ang K.K., Guan C., Chua K.S., Ang B.T., Kuah C.W., Wang C., Phua K.S., Chin Z.Y., Zhang H.A. Large Clinical Study on the Ability of Stroke Patients in Using EEG-Based Motor Imagery Brain-Computer Interface // Clinical EEG and Neuroscience. – 2011. - Vol. 42. – № 4. – P. 253-258.
31. Asensio-Cubero J., Gan J. Q., Palaniappan R. Multiresolution analysis over graphs for a motor imagery based online BCI game // Computers in biology and medicine. – 2016. – Vol. 68. – P. 21-26.
32. Basul I., Kaplan A. Changes in the n200 and p300 components of event-related potentials on variations in the conditions of attention in a brain-computer interface system // Neuroscience and Behavioral Physiology. – 2015. – Vol. 45. – № 9. – P. 1038-1042.
33. Bell A.J. & Sejnowski T.J. An information-maximization approach to blind separation and blind deconvolution // Neural Computation. – 1995. – Vol. 7. – P. 1129-1159.
34. Bishop C. M. Neural networks for pattern recognition. – Oxford university press, 1995.
35. Blankertz B., Curio G., Muller K. R. Classifying single trial EEG: Towards brain computer interfacing // Advances in neural information processing systems. – 2002. – Vol. 1. – P. 157-164.

36. Blankertz B., Tangermann M., Vidaurre C., Fazli S., Sannelli C., Haufe S., Maeder S., Ramsey L., Sturm I., Curio G., Müller K.R. Berlin brain–computer interface: non-medical uses of BCI technology // *Frontiers in neuroscience*. – 2010. – Vol. 4. P. 1-17.
37. Bobrov P., Frolov A. A., Húsek D. Brain Computer Interface Enhancement by Independent Component Analysis // *Proceedings of the Third International Conference on Intelligent Human Computer Interaction (IHCI 2011)*, Prague, Czech Republic, August, 2011. – Springer Berlin Heidelberg. – 2013. – P. 51-60.
38. Bobrov P.D., Korshakov A.V., Roshchin V., Frolov A.A. Bayesian classifier for brain-computer interface based on mental representation of movements // *Zhurnal vysshei nervnoi deiatelnosti imeni IP Pavlova*. – 2011.– Vol. 62.– № 1.– P. 89-99.
39. Brunner, C., Birbaumer, N., Blankertz, B., et al., BNCI Horizon 2020: Towards a roadmap for the BCI community // *Brain-computer interfaces*. – 2015. – Vol. 2. – №. 1. – P. 1-10.
40. Burges C. J. A tutorial on support vector machines for pattern recognition // *Knowledge Discovery and Data Mining*. – 1998. – Vol. 2. – №2. – P. 121-167.
41. Cerný V. Thermodynamical approach to the traveling salesman problem: An efficient simulation algorithm // *Journal of Optimization Theory and Applications*. – 1985. – Vol. 45. – P. 41–51.
42. Cincotti F., Scipione A., Tiniperi A., Mattia D., Marciani M.G., Millan J. del R., S. Salinari, Bianchi L., and Babiloni F. Comparison of different feature classifiers for brain computer interfaces // *Neural Engineering, 2003. Conference Proceedings. First International IEEE EMBS Conference on*. – IEEE, 2003. – P. 645-647.
43. Daly I, Billinger M, Laparra-Hernandez J, Aloise F, Garcia ML, Faller J, Scherer R, Muller-Putz G. On the control of brain-computer interfaces by users with cerebral palsy // *Clinical Neurophysiology*. – 2013. – Vol. 124. – №. 9. – P. 1787–1797.
44. Decety J., Michel F. Comparative analysis of actual and mental movement times in two graphic tasks // *Brain and cognition*. – 1989. – Vol. 11. – №. 1. – P. 87-97.

45. Doud A.J., Lucas J.P., Pisansky M.T., He B. Continuous three-dimensional control of a virtual helicopter using a motor imagery based brain-computer interface // PLoS One. – 2011. – Vol. 6. – № 10. – P. e26322.
46. Duda R. O., Hart P. E., Stork D. G. Pattern classification. – John Wiley & Sons, 2012. – 654 p.
47. Efron B. Computers and the theory of statistics: thinking the unthinkable //SIAM review. – 1979. – Vol. 21. – №. 4. – P. 460-480.
48. Farwell LA, Donchin E. Taking off the top of your head: toward a mental prosthesis utilizing event-related potentials. // Electroencephalogr. Clinical Neurophysiology. – 1988. – Vol.70. – P. 510-523.
49. Friedrich EVC, Neuper C, Scherer R, Whatever Works: A Systematic User-Centered Training Protocol to Optimize Brain-Computer Interfacing Individually. PLoS one. – 2013. – Vol. 8. – № 9. – P. e76214.
50. Frolov A. Husek D., Bobrov P., Korshakov A., Chernikova L., Konovalov R., Mokienko O. Sources of EEG activity most relevant to performance of brain-computer interface based on motor imagery // Neural Network World. – 2012. – Vol. 22. – №. 1. – P. 21-37.
51. Fukunaga K. Introduction to Statistical Recognition Second Edition (Computer Science and Scientific Computing Series). – Boston: Academic Press, 1990.
52. Garcia G., Ebrahimi T., Vesin J. Support Vector EEG Classification in the Fourier and Time-Frequency Correlation // Proceedings of the IEEE-EMBS First International Conference on Neural Engineering 2003. – IEEE, 2003. – №. LTS-CONF-2003-030. – P. 591-594.
53. Gath I., Lehmann D., Bar-On E. Fuzzy clustering of the EEG signal and vigilance performance // International journal of neuroscience. – 1983. – Vol. 20. – №. 3-4. – P. 303-312.
54. Ge S, Wang R, Yu D. Classification of four-class motor imagery employing single-channel electroencephalography //PloS one. – 2014. – Vol. 9. – №. 6. – p. e98019

55. Geman S., Bienenstock E., Doursat R. Neural networks and the bias/variance dilemma //Neural computation. – 1992. – Vol. 4. – №. 1. – P. 1-58.
56. Gu Y., Dremstrup K., Farina D. Single-trial discrimination of type and speed of wrist movements from EEG recordings //Clinical Neurophysiology. – 2009. – Vol. 120. – №. 8. – C. 1596-1600.
57. Hajipour S.S., Shamsollahi M.B. Selection of efficient features for discrimination of hand movements from MEG using a BCI competition IV data set // Frontiers in Neuroscience. – 2012. – Vol. 6. – №. 42.
58. Hoffmann U. et al. A boosting approach to P300 detection with application to brain-computer interfaces //Neural Engineering, 2005. Conference Proceedings. 2nd International IEEE EMBS Conference on. – IEEE, 2005. – P. 97-100.
59. Hsu W. Embedded Grey Relation Theory in Hopfield Neural Network Application to Motor Imagery EEG Recognition // Clinical EEG and neuroscience. – 2013. – Vol. 44. – № 4. – P. 257-264.
60. Jiang J., Zhou Z., Yin E. et al. A novel Morse code-inspired method for multiclass motor imagery brain-computer interface (BCI) design // Computers in biology and medicine. – 2015. – Vol. 66. – P. 11-19.
61. Jung T.-P., Makeig S., Stensmo M., Sejnowski T.J. Estimating alertness from the EEG power spectrum // IEEE Trans. Biomed. Eng. – 1997. – Vol. 44. – № 1. – P. 60-69.
62. Kaper M., Meinicke P., Grossekhoefer U., Lingner T., and Ritter H. BCI competition 2003-data set IIb: support vector machines for the P300 speller paradigm //Biomedical Engineering, IEEE Transactions on. – 2004. – Vol. 51. – №. 6. – P. 1073-1076.
63. Kaiser V., Kreilinger A., Muller-Putz G.R., Neuper C. First steps toward a motor imagery based stroke BCI: new strategy to set up a classifier // Frontiers in Neuroscience. – 2011. – Vol. 5. – № 86. – P. 1-10.
64. Kayser J., Tenke C. Issues and considerations for using the scalp surface Laplacian in EEG/ERP research: A tutorial review //International Journal of Psychophysiology. – 2015. – Vol. 97. – №. 3. – P. 189-209.

65. Keirn Z.A., Aunon J.I. A new mode of communication between man and his surroundings //Biomedical Engineering, IEEE Transactions on. – 1990. – Vol. 37. – № 12. – P. 1209-1214.
66. Krusienski D. J., McFarland D. J., Wolpaw J. R. Value of amplitude, phase, and coherence features for a sensorimotor rhythm-based brain–computer interface //Brain research bulletin. – 2012. – Vol. 87. – № 1. – P. 130-134.
67. Krusienski D.J., McFarland D.J., Wolpaw J.R. An evaluation of autoregressive spectral estimation model order for brain-computer interface applications //Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE. – IEEE, 2006. – P. 1323-1326.
68. Kubler A., Mattia D. Brain-computer interface based solutions for end-users with severe communication disorders. In S. Laureys, O. Gosseries & G. Tononi (Eds.), The Neurology of Consciousness, 217-233, 2nd Ed, Amsterdam, The Netherlands, Elsevier, 2015.
69. Kulkarni S. R., Harman G. Statistical learning theory: a tutorial //Wiley Interdisciplinary Reviews: Computational Statistics. – 2011. – Vol. 3. – № 6. – P. 543-556.
70. Kuo C.C., Luu P., Morgan K.K. et al. Localizing movement-related primary sensorimotor cortices with multi-band EEG frequency changes and functional MRI // PLoS one. – 2014. – Vol. 9. – № 11. – P. e112103.
71. LaConte S. M. Decoding fMRI brain states in real-time //Neuroimage. – 2011. – Vol. 56. – № 2. – P. 440-454.
72. Lehmann D. Fluctuation of functional state: EEG patterns, and perceptual and cognitive strategies // Functional states of the brain: their determinants / Koukkou M. et al. (Eds.), Elsevier, Amsterdam. – 1980. – P. 189-202.
73. Lemos M.S., Fisch B.J. The weighted average reference montage // Electroencephalography and Clinical Neurophysiology. – 1991. – Vol. 79. – № 5. – P. 361-370.
74. Leocani L., Toro C., Manganotti P., et al. Event-related coherence and event-related desynchronization/synchronization in the 10 Hz and 20 Hz EEG during

- self-paced movements // *Electroencephalography and Clinical Neurophysiology*. – 1997. – Vol. – 104. – № 3. – P. 199-206.
75. Liao K., Xiao R., Gonzalez J., Ding L. Decoding individual finger movements from one hand using human EEG signals // *PLoS one*. – 2014. – Vol. 9. – № 1. – p. e85192.
76. Lotte F., Congedo M., Lecuyer A. et al. Review of classification algorithms for EEG-based brain-computer interfaces // *Journal of Neural Engineering*. – 2007. – Vol. 4. – P. 1-24.
77. Mahalanobis P. C. On the generalised distance in statistics // *Proceedings of the National Institute of Sciences of India*. – 1936. – Vol. 2. – № 1. – P. 49-55.
78. Makeig S, Bell AJ, Jung T-P, Sejnowski TJ. Independent Component Analysis of Electroencephalographic data // *Advances in Neural Information Processing Systems*. – 1996. – Vol. 8. – P. 145-151.
79. Malada H.R., Ivakhnenko A.G. *Inductive Learning Algorithms for Complex Systems Modeling*. – Boca Raton: CRC press, 1994. – 368 p.
80. Mokiienko O. A., Lyukmanov R. Kh., Chernikova L. A., Suponeva N. A., M. A. Piradov, and A. A. Frolov. Brain–Computer Interface: The First Experience of Clinical Use in Russia // *Human Physiology*. – 2016. – Vol. 42. – № 1. – P. 24-31
81. Morash V., Bai O., Furlani S. et al. Classifying EEG signals preceding right hand, left hand, tongue, and right foot movements and motor imageries // *Clinical neurophysiology* – 2008. – Vol. 119. – № 11. – P. 2570-2578.
82. Muller K. R., Krauledat M., Dornhege G., Curio G., and Blankertz B. Machine learning techniques for brain-computer interfaces // *Biomedical Technologies*. – 2004. – Vol. 49. – P. 11-22.
83. Neuper C., Scherer R., Reiner M., Pfurtscheller G. Imagery of motor actions: Differential effects of kinesthetic and visual–motor mode of imagery in single-trial EEG // *Cognitive Brain Research*. – 2005. – Vol. 25. – № 3. – P. 668-677.
84. Nicholson C., Freeman J. A. Theory of current source-density analysis and determination of conductivity tensor for anuran cerebellum // *Journal of Neurophysiology*. – 1975. – Vol. 38. – № 2. – P. 356-368.

85. Nunez P.L. *Electric Fields of the Brain: The Neurophysics of EEG*, N-Y: Oxford University Press, 1981. – 484 p.
86. Obermeier B., Guger C., Neuper C., and Pfurtscheller G. Hidden Markov models for online classification of single trial EEG data // *Pattern recognition letters*. – 2001. – Vol. 22. – № 12. – P. 1299-1309.
87. Palaniappan R., Raveendran P., Nishida S., and Saiwaki N. A New Brain-Computer Interface Design Using Fuzzy ARTMAP // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*. – 2002. – Vol. 10. – № 3. – P. 140-148.
88. Parsons L.M. Integrating cognitive psychology, neurology and neuroimaging // *Acta psychologica*. – 2001. – Vol. 107. – № 1. – P. 155-181.
89. Perrin F., Bertrand O., Pernier J. Scalp current density: value and estimation from potential data // *IEEE Trans. Bio-med. Eng.* – 1987. – Vol. 34. – P. 283-288.
90. Perrin F., Pernier J., Bertrand O., Echallier J.F. Spherical splines for scalp potential and current density mapping // *Electroencephalography and clinical neurophysiology*. – 1989. – Vol. 72. – № 2. – P. 184-187.
91. Pfurtscheller G. Spatiotemporal ERD/ERS patterns during voluntary movement and motor imagery // *Suppl. Clin. Neurophysiol.* – 2000. – Vol. 53. – P. 196-198.
92. Pfurtscheller G., Lopes da Silva F.H. Event-related EEG/EMG synchronization and desynchronization. Basic principles // *Clin. Neurophysiol.* – 1999. – Vol. 110. – № 11. – P. 1842-1857.
93. Pfurtscheller G., Neuper C. Motor imagery activates primary sensorimotor area in humans // *Neurosci. Lett.* – 1997. – Vol. 239. – P. 65-68.
94. Ponomarev V.A., Mueller A., Candrian G. et al. Group Independent Component Analysis (gICA) and Current Source Density (CSD) in the study of EEG in ADHD adults // *Clinical Neurophysiology*. – 2014. – Vol. 125. – № 1. – P. 83-97.
95. Porro C.A., Cettolo V., Francescato M.P., Baraldi P. Ipsilateral involvement of primary motor cortex during motor imagery // *European Journal of Neuroscience*. – 2000. – Vol. 12. – № 8. – P. 3059-3063.

96. Porro C.A., Francescato M.P., Cettolo V. et al. Primary motor and sensory cortex activation during motor performance and motor imagery: a functional magnetic resonance imaging study //The Journal of neuroscience. – 1996. – Vol. 16. – № 23. – P. 7688-7698.
97. Quandt F., Reichert C., Hinrichs H. et al. Single trial discrimination of individual finger movements on one hand: a combined MEG and EEG study //NeuroImage. – 2012. – Vol. 59. – №. 4. – P. 3316-3324.
98. Rabiner L.R. A tutorial on hidden Markov models and selected applications in speech recognition //Proceedings of the IEEE. – 1989. – Vol. 77. – № 2. – P. 257-286.
99. Roth M., Decety J., Raybaudi M. et al. Possible involvement of primary motor cortex in mentally simulated movement: a functional magnetic resonance imaging study //Neuroreport. – 1996. – Vol. 7. – № 7. – P. 1280-1284.
100. Sanei S., Chambers J. A. EEG signal processing. – John Wiley & Sons, 2013.
101. Sirigu A., Duhamel J.R., Cohen L. et al. The mental representation of hand movements after parietal cortex damage // Science. – 1996. – Vol. 273. – № 5281. – P. 1564-1568.
102. Sitaram R., Caria A., Birbaumer N. Hemodynamic brain–computer interfaces for communication and rehabilitation //Neural networks. – 2009. – Vol. 22. – № 9. – P. 1320-1328.
103. Schalk G., Leuthardt E.C. Brain-computer interfaces using electrocorticographic signals // IEEE Rev. Biomed. Eng. – 2011. – Vol. 4. – P. 140-154.
104. Shan H, Xu H, Zhu S, He B. A novel channel selection method for optimal classification in different motor imagery BCI paradigms //Biomedical engineering online. – 2015. – Vol. 14. – № 1. – P. 93.
105. Sharkey A. J. C. Multi-net systems //Combining artificial neural nets. – Springer London, 1999. – P. 1-30.
106. Sharkey, A. J. C. Types of multinet system // Multiple Classifier Systems. – Springer Berlin Heidelberg, 2002. – P. 108-117.

107. Sonkin K.M., Stankevich L.A., Khomenko Ju.G., Nagornova Zh.V., Shemyakina N.V. Development of electroencephalographic pattern classifiers for real and imaginary thumb and index finger movements of one hand //Artificial intelligence in medicine. – 2015. – Vol. 63. – № 2. – P. 107-117.
108. Stone J. V. Independent component analysis: a tutorial introduction (Bradford Books). – The MIT Press, 2004.
109. Tenke C.E., Kayser J. Generator localization by current source density (CSD): implications of volume conduction and field closure at intracranial and scalp resolutions //Clinical neurophysiology. – 2012. – Vol. 123. – № 12. – C. 2328-2345.
110. Tenke C.E., Kayser J. Reference-free quantification of EEG spectra: combining current source density (CSD) and frequency principal components analysis (fPCA) // Clinical Neurophysiology. – 2005. – Vol. 116. – № 12. – P. 2826-2846.
111. Tresp V. Committee machines //Handbook for neural network signal processing. – CRC Press, 2001. – P. 135-151.
112. Vapnik V. N., Vapnik V. Statistical learning theory. – New York: Wiley, 1998. – Vol. 1.
113. Vidal J. J. Towards direct brain-computer communication //Annual review of Biophysics and Bioengineering. – 1973. – Vol. 2. – № 1. – P. 157-180.
114. Vigário R.N. Extraction of ocular artefacts from EEG using independent component analysis //Electroencephalography and clinical neurophysiology. – 1997. – Vol. 103. – № 3. – P. 395-404.
115. Wolpaw J.R., Birbaumer N., McFarland D.J., Pfurtscheller G., Vaughan T.M. Brain-computer interfaces for communication and control // Clin. Neurophysiol. – 2002. – Vol. 113. – P. 767-791.
116. Wolpaw J.R., Flotzinger D., Pfurtscheller G., McFarland D.J. Timing of EEG-based cursor control // J. Clin. Neurophysiol. – 1997. – Vol. 6. – P. 529–538.
117. Wolpaw J.R., McFarland D.J., Neat G.W., Forneris C.A. An EEG-based brain-computer interface for cursor control // Electroenceph. Clin. Neurophysiol. – 1991. – Vol. 78. – P. 252-259.

118. Wolpaw J.R., Wolpaw E.W. Brain-computer interfaces: principles and practice. NY: Oxford University Press, 2012. – 400 p.
119. Wolpert D.H. Stacked generalization // Neural networks. – 1992. – Vol. 5. – P. 241-259.
120. Wright J.J., Kydd R.R., Liley D.T.J. EEG models: Chaotic and linear // Psychology. – 1993. – Vol. 4. – №. 60.
121. Xiao, R., Ding, L. EEG resolutions in detecting and decoding finger movements from spectral analysis //Frontiers in neuroscience. – 2015. – Vol. 9. – p. 308.
122. Xiao R., Ding L. Evaluation of EEG features in decoding individual finger movements from one hand // Computational and Mathematical Methods in Medicine. – 2013. – Vol. 2013. – p. 243257.
123. Yin X., Xu B., Jiang C. et al. A hybrid BCI based on EEG and fNIRS signals improves the performance of decoding motor imagery of both force and speed of hand clenching //Journal of neural engineering. – 2015. – Vol. 12. – №. 3. – p. 036004.
124. Zhou J., Yao J., Deng J., Dewald J.P. EEG-based classification for elbow versus shoulder torque intentions involving stroke subjects // Computers in biology and medicine. – 2009. – Vol. 39. – № 5. – P. 443-452.
125. Zhukov L.E., Weinstein D.M., Johnson C.R. Independent component analysis for EEG source localization //Engineering in Medicine and Biology Magazine, IEEE. – 2000. – Vol. 19. – № 3. – P. 87-96.
126. Zich C., Vos Maarten De, Kranczioch C., Debener S. Wireless EEG with individualized channel layout enables efficient motor imagery training //Clinical Neurophysiology. – 2015. – Vol. 126. – № 4. – P. 698-710.