

На правах рукописи

Сотников

СОТНИКОВ ПЕТР ИВАНОВИЧ

**РАЗРАБОТКА МЕТОДОВ И АЛГОРИТМОВ ДЛЯ
КЛАССИФИКАЦИИ МНОГОМЕРНЫХ ВРЕМЕННЫХ РЯДОВ В
ИНТЕРФЕЙСЕ МОЗГ-КОМПЬЮТЕР**

Специальность 05.13.01 – Системный анализ, управление и обработка
информации (в технических системах)

АВТОРЕФЕРАТ
диссертации на соискание ученой степени
кандидата технических наук

Москва – 2020

Работа выполнена в федеральном государственном бюджетном образовательном учреждении высшего образования «Московский государственный технический университет имени Н.Э. Баумана (национальный исследовательский университет)» (МГТУ им. Н.Э. Баумана)

Научный руководитель: **Карпенко Анатолий Павлович**
доктор физико-математических наук, профессор,
заведующий кафедрой систем
автоматизированного проектирования
МГТУ им. Н.Э. Баумана

Официальные оппоненты: **Скобцов Юрий Александрович**
доктор технических наук, профессор, профессор
кафедры компьютерных технологий и
программной инженерии ФГАОУ ВО «Санкт-
Петербургского государственного университета
аэрокосмического приборостроения»

Демидова Лилия Анатольевна
доктор технических наук, профессор, профессор
кафедры КБ-4 «Интеллектуальные системы
информационной безопасности» ФГБОУ ВО
«МИРЭА – Российского технологического
университета» (РТУ МИРЭА)

Ведущая организация: **Федеральный исследовательский центр
«Информатика и управление» Российской
Академии Наук (ФИЦ ИУ РАН), г. Москва**

Защита диссертации состоится «12» мая 2020 г. в 14 час. 30 мин. на заседании диссертационного совета Д 212.141.02 при МГТУ им. Н.Э. Баумана по адресу: 105005, г. Москва, Госпитальный пер., д. 10.

С диссертацией можно ознакомиться в библиотеке МГТУ им. Н.Э. Баумана и на сайте <http://www.bmstu.ru>.

Отзывы на автореферат в двух экземплярах, заверенные печатью учреждения, просьба направлять по адресу: 105005, г. Москва, 2-я Бауманская ул., д. 5, стр. 1, МГТУ им. Н.Э. Баумана, ученому секретарю диссертационного совета Д 212.141.02.

Автореферат разослан «__» _____ 2020 года.

Ученый секретарь
диссертационного совета Д 212.141.02
кандидат технических наук, доцент



Муратов И.В.

ОБЩАЯ ХАРАКТЕРИСТИКА РАБОТЫ

Актуальность и разработанность темы. Диссертация посвящена исследованию способов повышения эффективности интерфейсов мозг-компьютер (ИМК), решающих задачу человеко-машинного взаимодействия путем регистрации и декодирования биоэлектрических сигналов головного мозга.

ИМК представляет собой аппаратно-программную систему, которая позволяет человеку управлять внешним техническим устройством, основываясь только на сигналах, генерируемых мозгом. ИМК были предложены и нашли свое основное применение в качестве средства помощи пациентам с тяжелыми нарушениями двигательных функций (параличом большей части тела). В перспективе ИМК могут применяться и здоровыми людьми для набора текста, управления роботизированными манипуляторами, автомобилем, объектами в виртуальной / дополненной реальности.

Среди различных типов ИМК выделяется большой класс интерфейсов, построенных на анализе и классификации сигналов электроэнцефалограммы (ЭЭГ). К преимуществам данных ИМК относятся высокая степень мобильности и эргономичности. Главной целью диссертации является проведение междисциплинарных исследований, направленных на повышение эффективности систем именно этого типа.

Об актуальности выбранной темы исследований свидетельствует значительный рост числа публикаций, посвященных созданию ИМК на основе ЭЭГ, который наблюдается в последние годы. Большое разнообразие предлагаемых авторами методических приемов направлено на совершенствование ИМК по таким показателям как: 1) число распознаваемых мысленных команд пользователя; 2) вероятность правильного распознавания команд; 3) быстродействие (время реакции) интерфейсов. За рубежом исследованиями неинвазивных ИМК занимаются научные группы под руководством Niels Birbaumer (Wyss Center, Швейцария), Jonathan Wolpaw (Wadsworth Center, США), Gert Pfurtscheller (Graz University of Technology, Австрия), Benjamin Blankertz и Klaus-Robert Müller (Technische Universität Berlin, Германия), Cuntai Guan (Nanyang Technological University, Сингапур), Xiaorong Gao (Tsinghua University, Китай) и др. В России разработкой ИМК занимаются коллективы под руководством А. Я. Каплана (МГУ им. М.В. Ломоносова, Москва), А. А. Фролова и Г.А. Иваницкого (ИВНД и НФ РАН, Москва), А. Е. Осадчего (НИУ ВШЭ, Москва), В.Н. Кироя (ЮФУ, Ростов-на-Дону) и др.

Распознавание мысленных команд пользователя в ИМК осуществляют путем решения задачи классификации многомерных временных рядов, в виде которых записи ЭЭГ сохраняются в компьютере. Принадлежность временного ряда к одному из известных классов в ИМК определяют на основе подхода, заключающегося в формировании признакового описания этого ряда и последующей классификации в пространстве признаков. Под признаковым описанием (характерными признаками) временного ряда в литературе

понимают некоторые интегральные показатели, описывающие свойства этого ряда. Примерами характерных признаков (ХП) могут служить: среднее значение и дисперсия амплитуды временного ряда, спектральная плотность мощности и др. В публикациях было предложено большое число методов выделения характерных признаков ЭЭГ. Данные методы можно условно разделить на четыре группы: методы, основанные на анализе временных рядов 1) *во временной области*, 2) *в частотной области*, 3) *в частотно-временной области*, 4) специальные методы.

К первой группе относятся следующие методы: оценка статистических показателей временного ряда (таких как среднее значение, дисперсия, коэффициенты асимметрии и эксцесса); оценка степени хаотичности сигнала (оценка энтропии или фрактальной размерности); регрессионный анализ (включая, построение моделей авторегрессии и символьной регрессии сигнала); корреляционный анализ и др.

Во вторую группу входят дискретное преобразование Фурье и дискретное вейвлет-преобразование. В качестве ХП временного ряда в данном случае выступают значения суммарной спектральной плотности мощности в заранее определенных частотных диапазонах.

Для анализа сигнала в частотно-временной области используют оконное преобразование Фурье и непрерывное вейвлет-преобразование. Преимуществом данных методов является то, что они позволяют отследить процесс изменения гармонических составляющих сигнала во времени.

Также в публикациях был предложен ряд специальных подходов к анализу ЭЭГ, учитывающих его специфику. К ним, например, относятся: метод преобразования сигнала к плотностям источников тока; модельно-ориентированный подход, основанный на определении характеристик эквивалентных токовых диполей; метод выделения характерных признаков на основе показателей бегущих волн и др.

Рассмотренные методы формирования ХП позволяют описать свойства ЭЭГ, важные для решения задачи классификации, однако эти методы обладают рядом недостатков, ограничивающих эффективность ИМК. К таким недостаткам относятся: 1) отсутствие средств для адаптации методов под особенности конкретного пользователя ИМК; 2) высокая размерность получаемых векторов ХП (как правило, большая или равная числу каналов в ЭЭГ); 3) включение в вектор ХП «шумовых» (неинформативных) признаков. Актуальной остается задача разработки методов выделения ХП, наиболее полно учитывающих свойства исследуемых временных рядов.

При разработке ИМК эксперту необходимо выбрать методы и алгоритмы обработки ЭЭГ, обеспечивающие наилучшее качество распознавания команд пользователя. Решение данной задачи требует от эксперта значительных временных затрат, что обусловлено трудоёмкостью сравнения эффективности различных методов формирования ХП и методов классификации. По этой причине актуальным является создание системы поддержки принятия решений для автоматизации исследований при разработке ИМК.

Предметом исследований диссертации служат методы и алгоритмы, применяемые для формирования характерных признаков многомерных временных рядов при решении задачи классификации этих рядов.

Целями работы являются 1) разработка методов и алгоритмов оптимизации (повышения информативности) характерных признаков многомерных временных рядов в ИМК, 2) разработка алгоритмической основы системы поддержки принятия решений для автоматизации исследований при создании ИМК.

Исходя из поставленных целей, были сформулированы следующие основные **задачи исследования**:

1) Провести анализ современных подходов к построению ИМК, основанных на регистрации и декодировании сигналов ЭЭГ.

2) Исследовать особенности методов и алгоритмов, применяемых в ИМК для решения задачи классификации многомерных временных рядов.

3) Разработать методы и алгоритмы для выделения оптимальных характерных признаков многомерных временных рядов, учитывающие различия между классами этих рядов, которые проявляются во временной, частотной и частотно-временной области.

4) Реализовать предложенные математические методы и алгоритмы в программном обеспечении для автоматизации исследований при разработке интерфейсов мозг-компьютер.

5) На основе вычислительных экспериментов провести анализ эффективности разработанного математического и программного обеспечения.

Методы исследования. Для решения поставленных задач в диссертации использованы методы цифровой обработки сигналов, теории вероятности и математической статистики, методы оптимизации и теории машинного обучения.

Научная новизна диссертационной работы состоит в следующем.

1) Предложены формализованные постановки задачи построения оптимального пространства признаков сигнала ЭЭГ во временной области, в частотной области и в частотно-временной области, имеющие целью повышение качества распознавания команд пользователя в ИМК.

2) Предложены три метода для решения задачи построения оптимального пространства признаков сигнала электроэнцефалограммы:

а) модифицированный метод поиска *шейплетов* многомерных временных рядов, особенностью которого является применение популяционного алгоритма глобальной оптимизации и вычисление характерных признаков временных рядов как расстояний от них до *шейплетов*;

б) метод поиска с помощью популяционных алгоритмов глобальной оптимизации таких *частотных диапазонов* многомерных временных рядов, в которых различия между классами этих рядов проявляются в наибольшей степени;

в) метод поиска с помощью популяционных алгоритмов глобальной оптимизации таких *областей на спектрограмме*, в которых различия между классами исследуемых временных рядов проявляются в наибольшей степени.

3) Предложен прототип системы поддержки принятия решений для автоматизации исследований при разработке интерфейсов мозг-компьютер. Особенность системы состоит в возможности выбора лицом, принимающим решения, методов и алгоритмов обработки сигналов ЭЭГ, обеспечивающих наилучшее распознавание мысленных команд пользователя для конкретного типа интерфейса.

Теоретическая и практическая значимость результатов работы заключается в следующем.

1) Предложено три метода для построения оптимального пространства характерных признаков многомерных временных рядов.

2) На основе предложенных методов и алгоритмов реализован программный комплекс, предназначенный для выбора экспертом (разработчиком интерфейса) оптимальных методов и алгоритмов обработки информации в ИМК. Программный комплекс включает модули, обеспечивающие регистрацию ЭЭГ, чтение записей из файлов, их предобработку, формирование и оптимизацию характерных признаков временных рядов, классификацию данных.

3) Использование предложенных методов и их программных реализаций позволило: сократить число ложных срабатываний в новом гибридном интерфейсе «глаз-мозг-компьютер»; решить задачу определения качества пилотирования по ЭЭГ оператора, зарегистрированной во время осуществления им заходов на посадку на полунатурном стенде.

4) Результаты работы внедрены в МГТУ им. Н.Э. Баумана, Федеральном государственном унитарном предприятии «Государственный научно-исследовательский институт авиационных систем» (ГосНИИАС).

Достоверность и обоснованность полученных в диссертации результатов обеспечивается корректностью применяемого математического аппарата и подтверждается результатами экспериментальной проверки методов на реальных тестовых данных ЭЭГ.

Апробация работы. Основные результаты и положения диссертационной работы были представлены и обсуждались на: 15-й, 17-й и 19-й Международных молодежных конференциях «Наукоемкие технологии и интеллектуальные системы» (Москва, 2013, 2015 и 2017); на междисциплинарном семинаре «Экобионика» в МГТУ им. Н.Э. Баумана (Москва, 2015); на 12-м Международном Симпозиуме «Интеллектуальные системы» (Москва, 2016).

Публикации. Основные результаты диссертационного исследования опубликованы в 10 научных работах, из них 1 работа – в сборнике, индексируемом в Scopus и Web of Science; 4 работы – в рецензируемых научных журналах, рекомендованных ВАК РФ; 1 свидетельство о регистрации программы для ЭВМ. Общий объем – 4,75 п.л.

Личный вклад автора. Исследования, результаты которых изложены в диссертации, проведены лично соискателем в процессе научной деятельности. Соискателем самостоятельно разработан программный комплекс, реализующий предложенные методы анализа, и выполнены вычислительные эксперименты.

Структура работы. Диссертация состоит из введения, пяти глав, заключения и списка используемой литературы. Общий объем диссертации составляет 170 страниц машинописного текста. Диссертация содержит 49 рисунков и 22 таблицы. Список используемой литературы включает 114 источников.

СОДЕРЖАНИЕ РАБОТЫ

В **первой главе** выполнен аналитический обзор современных подходов к построению ИМК. Дана математическая постановка задачи распознавания мысленных команд пользователя по записям ЭЭГ. Выполнен обзор подходов к её решению. Выделен классический подход, применяемый в ИМК и основанный на формировании ХП временных рядов и классификации в пространстве ХП.

Представлено описание общей структуры ИМК (Рис. 1), которая включает следующие компоненты: 1) устройство для регистрации и оцифровки сигнала, 2) блок предобработки данных, 3) блок формирования ХП сигнала, 4) блок классификации данных, 5) блок постобработки и генерации команд внешнему устройству, 6) блок обратной связи.

Приведен обзор методов *частотной* и *пространственной* фильтрации, применяемых в ИМК для подавления различного рода помех и артефактов.



Рис. 1. Структура ИМК

Приведено описание основных методов формирования признаков и методов классификации, получивших широкое распространение при анализе многомерных временных рядов в ИМК.

Установлено, что повышение точности распознавания мысленных команд пользователя в ИМК требует решения ряда проблем, возникающих при классификации электроэнцефалограмм. К таким проблемам относятся: 1) низкое соотношение «сигнал/шум», 2) высокая степень межсубъектной вариабельности ЭЭГ, 3) высокая размерность векторов ХП (как правило, большая или равная числу каналов в ЭЭГ), 4) мультиколлинеарность

характерных признаков (то есть наличие между ними линейной зависимости), 5) малый размер обучающей выборки, применяемой для построения классификатора.

Для решения указанных проблем в диссертации предложен подход, который заключается в оптимизации (повышении информативности) характерных признаков, подаваемых на вход классификаторов.

Во **второй главе** дана математическая постановка задачи построения оптимального пространства ХП многомерных временных рядов, в виде которых записи ЭЭГ сохраняются в компьютере. Предложены три метода для решения указанной задачи, учитывающие, что различия между классами временных рядов проявляются во временной, частотной и частотно-временной областях.

Пусть имеется обучающая выборка (размеченное множество) $\Omega = \{\mathbf{X}_i, k_i\}_{i=1}^P$ объема P , где $\mathbf{X}_i \in R^{M \times N}$ – i -ый многомерный временной ряд (запись ЭЭГ), $i \in [1:P]$; M – число измерений ряда (число каналов в записи ЭЭГ); N – число дискретных отсчетов в каждом из измерений; $k_i \in \{1, 2, \dots, K\}$ – номер класса, к которому принадлежит ряд \mathbf{X}_i ; K – общее число классов (распознаваемых команд пользователя).

Введем следующие обозначения:

$\mathbf{z} = (z_1, \dots, z_L)$ – вектор ХП для временного ряда \mathbf{X} , $\mathbf{z} \in R^L$;

$h: \mathbf{z} = h(\mathbf{X})$ – отображающая функция, выполняющая отображение исходного ряда \mathbf{X} в пространство ХП; $h \in H$, где H – семейство функций;

$g: k = g(\mathbf{z})$ – дискриминантная функция (решающее правило), ставящая в соответствие каждому вектору ХП \mathbf{z} номер класса k ; $g \in G$, где G – семейство дискриминантных функций (решающих правил);

$Q(h, g)$ – оценка качества распознавания классов на множестве Ω (доля числа объектов, правильно распознанных функциями h, g , от их общего числа в выборке Ω).

Отметим, что каждой отображающей функции h соответствует собственное пространство характерных признаков $Z = \{\mathbf{z} = h(\mathbf{X}), \forall \mathbf{X} \in R^{M \times N}\}$.

Предположим, что разработчиком ИМК выбрана дискриминантная функция $g = \hat{g} \in G$, тогда задачу построения оптимального пространства ХП запишем в виде

$$\max_{h \in H} Q(h, \hat{g}) = Q(h^*, \hat{g}) = Q^*, \quad (1)$$

где оптимальная отображающая функции h^* задает оптимальное пространство ХП Z^* .

Решение задачи (1) гарантирует достижение максимальной точности распознавания классов для некоторого выбранного экспертом классификатора $g = \hat{g} \in G$.

Модифицированный метод шейплетов. Во многих прикладных задачах различия между классами временных рядов проявляются в виде характерных изменений амплитуды сигнала. Идея метода шейплетов заключается в поиске таких фрагментов временных рядов, которые являются эталонными

представителями одного или нескольких классов. В диссертации предложены модификации метода, целью которых является: а) сокращение времени поиска шейплетов; б) решение задач с тремя и более классами; в) возможность классификации многомерных временных рядов. Характерные признаки ЭЭГ вычисляются как расстояния до найденных шейплетов.

Фрагмент \mathbf{S} многомерного временного ряда $\mathbf{X} \in \mathbb{R}^{M \times N}$ определим тройкой чисел (i, j, l) , где i – номер временного ряда в выборке Ω ; j – сдвиг фрагмента относительно начала ряда; l – длина фрагмента, $i, j, l \in \mathbb{Z}$. Обозначим $\mathbf{S}(i, j, l)$ кандидата в шейплеты, заданного с использованием тройки (i, j, l) .

Степень отличия многомерного временного ряда \mathbf{X} от фрагмента $\mathbf{S} \in \mathbb{R}^{M \times l}$ характеризуем с помощью M -мерного вектора расстояний

$$D(\mathbf{S}, \mathbf{X}) = \begin{pmatrix} d(S_1, X_1) \\ d(S_2, X_2) \\ \vdots \\ d(S_M, X_M) \end{pmatrix}.$$

Компоненты этого вектора есть расстояния между соответствующими измерениями фрагмента \mathbf{S} и временного ряда \mathbf{X} . При этом расстояние между одномерным фрагментом S длины l и одномерным временным рядом $X = x_1, x_2, \dots, x_N$, представленным в канале с номером $m = 1..M$, находим, как минимальное из расстояний между этим фрагментом и всеми возможными фрагментами ряда X длины l :

$$d(S, X) = \min_{S_X \in \Lambda_S} d(S, S_X),$$

$$\Lambda_S = \{x_j, x_{j+1}, \dots, x_{j+l-1}\}_{j=1}^{N-l+1}.$$

Вектор расстояний можно интерпретировать как вектор характерных признаков многомерного ряда \mathbf{X} , а функцию вычисления расстояний – как отображающую функцию $\hat{h}(\mathbf{S}, \mathbf{X}) = D(\mathbf{S}, \mathbf{X})$.

Полагаем, что разработчиком ИМК выбран некоторый алгоритм классификации $g = \hat{g} \in G$. Тогда *качество распознавания классов*, достижимое с помощью фрагмента \mathbf{S} , можно найти, как значение функционала $Q(\hat{h}(\mathbf{S}), \hat{g})$ на множестве Ω . В этих обозначениях задачу поиска шейплетов \mathbf{S}_{opt} формулируем в виде

$$\max_{i, j, l \in \Lambda} Q(\hat{h}(\mathbf{S}(i, j, l)), \hat{g}) = Q(\hat{h}(\mathbf{S}(i^*, j^*, l^*)), \hat{g}) = Q(\hat{h}(\mathbf{S}_{opt}), \hat{g}), \quad (2)$$

$$\Lambda = \begin{cases} 1 \leq i \leq P, \\ 1 \leq j \leq N - l + 1, \\ l_{min} \leq l \leq l_{max}. \end{cases}$$

Здесь константы l_{min}, l_{max} определяют границы диапазона длин кандидатов.

Таким образом, задача поиска шейплетов (2) сводится к задаче *целочисленной оптимизации*. Общая сложность её решения алгоритмом полного перебора составляет $O(P^2 N^4)$, то есть очень быстро растет с ростом величин P, N . В диссертации для сокращения времени поиска предлагаем решать задачу с помощью генетического алгоритма (ГА).

Особей s популяции задаем с помощью набора

$$s = \langle F, H, \varphi(F) \rangle,$$

где вектор F – фенотип особи; H – её генотип; $\varphi(F)$ – приспособленность. Фенотип особи задаем тройкой чисел (i, j, l) , определяющих фрагмент временного ряда, то есть полагаем $F = (i, j, l)$. Значения варьируемых параметров (i, j, l) кодируем с помощью монохромосомы $H = (h_i, h_j, h_l)$, где h_i, h_j, h_l – бинарные гены, кодирующие числа i, j, l соответственно.

Для особей s значение функции приспособленности $\varphi(F)$ находим как

$$\varphi(F) = Q(\hat{h}(\mathbf{S}(F)), \hat{g}) - \text{penalty}(F),$$

где $\text{penalty}(F)$ – штрафная функция, значение которой равно сумме штрафов за выход варьируемых параметров за границы области допустимых значений.

Качество распознавания классов Q на итерациях алгоритма определяем по итогам пятикратной перекрестной проверки с помощью классификатора, основанного на *методе k ближайших соседей*. Для того чтобы повысить вероятность отыскания глобального решения, применяем *метод мультистарта*.

Для учета при формировании ХП временных рядов информации о найденных шейплетях предлагаем использовать *шейплет-преобразование* данных, которое заключается в следующем. Из последнего поколения ГА отбираем r лучших кандидатов в шейплеты: $\mathbf{S} = (\mathbf{S}_1, \dots, \mathbf{S}_r)$. При этом в набор \mathbf{S} включаем только кандидатов, значимо отличающихся друг от друга. Для отбора кандидатов используем алгоритм иерархической кластеризации. Затем каждому временному ряду \mathbf{X} ставим в соответствие вектор ХП $\mathbf{z}(\mathbf{S})$, компоненты которого вычисляем как

$$\mathbf{z}(\mathbf{S}) = (D(\mathbf{S}_1, \mathbf{X}), \dots, D(\mathbf{S}_r, \mathbf{X})), \quad \mathbf{z}(\mathbf{S}) \in \mathbb{R}^{M \cdot r},$$

где $D(\mathbf{S}_i, \mathbf{X})$, $i = 1, \dots, r$ – векторы расстояний.

Чтобы при шейплет-преобразовании данных получить оптимальное пространство ХП, вместо отбора r лучших кандидатов, ставим задачу поиска *оптимального сочетания шейплетов* \mathbf{S}_{opt} . Решение данной задачи также предлагаем искать с помощью генетического алгоритма. Для этого расширяем фенотип особей, добавив в него характеристики всех шейплетов из набора $F = [(i, j, l)_1; (i, j, l)_2; \dots; (i, j, l)_r]$. На итерациях алгоритма поиска в векторы расстояний $D(\mathbf{S}, \mathbf{X}_i)$ включаем расстояния от многомерного временного ряда \mathbf{X}_i до всех шейплетов из набора \mathbf{S} .

Метод поиска оптимальных частотных диапазонов. В диссертации для повышения качества распознавания классов ЭЭГ предлагаем метод формирования ХП, основанный на оценке энергии сигнала в частотных диапазонах, границы которых определяем независимо для каждого из каналов (измерений) ЭЭГ. Задачу поиска частотных диапазонов рассматриваем, как задачу *однокритериальной оптимизации*, в которой варьируемыми параметрами являются границы частотных диапазонов F_1, F_2 , а в качестве целевой функции выступает качество распознавания классов $Q(\hat{h}(F_1, F_2), \hat{g})$ на множестве Ω :

$$\max_{F_1, F_2 \in \Lambda_F} Q(\hat{h}(F_1, F_2), \hat{g}) = Q(\hat{h}(F_1^*, F_2^*), \hat{g}) = Q^* \quad (3)$$

$$\Lambda_F = \{F_{min} \leq F_1 \leq F_2 \leq F_{max}\}, \Lambda_F \subset \mathbb{Z}^M.$$

Здесь $\hat{h}(F_1, F_2)$ – отображающая функция вида

$$\hat{h}(F_1, F_2) = u(F_1, F_2) \circ \mathcal{F}(\mathbf{X}),$$

где $\mathcal{F}(\mathbf{X})$ – функция вычисления спектра временного ряда \mathbf{X} , $u(F_1, F_2)$ – площадь фигуры под графиком спектра $\mathcal{F}(\mathbf{X})$ на отрезке $[F_1, F_2]$.

Для отыскания оптимальных значений варьируемых параметров предлагаем использовать *генетический алгоритм* и *алгоритм роя частиц*.

На этапе обучения ИМК после того, как энергетические спектры $E_m(f), m = 1..M$ рассчитаны для всех временных рядов $\mathbf{X}_i, i = [1:P]$, границы оптимальных частотных диапазонов находим по следующей схеме.

1) С помощью отображающей функции $\hat{h}(F_1, F_2)$ каждому временному ряду $\mathbf{X}_i \in \Omega$ ставим в соответствие вектор ХП $\mathbf{z}_i(F_1, F_2) = (z_1, \dots, z_m, \dots, z_M)$, где z_m – значение площади фигуры под графиком энергетического спектра $E_m(f)$ на отрезке $[f_{1,m}; f_{2,m}]$, то есть

$$z_m = \int_{f_{1,m}}^{f_{2,m}} E_m(f) df, \quad m = 1, \dots, M.$$

2) Используя некоторый классификатор $g = \hat{g} \in G$, определяем точность классификации, достижимую на множестве $\{\mathbf{z}_i(F_1, F_2), k_i\}_{i=1}^P$, сформированном векторами ХП $\mathbf{z}_i(F_1, F_2) \in \mathbb{R}^M$ и соответствующими им номерами классов k_i . Полученную оценку принимаем в качестве значения критерия $Q(\hat{h}(F_1, F_2), \hat{g})$.

3) Применяя *генетический алгоритм* или *алгоритм роя частиц*, находим оптимальные значения параметров F_1, F_2 , обеспечивающие максимум критерия $Q(\hat{h}(F_1, F_2), \hat{g})$.

В ГА и алгоритме роя частиц ограничения, накладываемые на варьируемые параметры F_1, F_2 , учитываем с помощью штрафной функции $penalty(F_1, F_2)$, которую рассчитываем, как сумму штрафов за выход границ диапазонов частот за пределы области допустимых значений. Итоговое значение функции приспособленности определяем, как

$$\varphi(F_1, F_2) = Q(\hat{h}(F_1, F_2), \hat{g}) - penalty(F_1, F_2).$$

Чтобы повысить обобщающие свойства найденных границ частотных диапазонов, используем стратегию поиска с контролем *переобучения* (англ. – *overfitting*). Поскольку ГА и алгоритм роя частиц являются стохастическими методами оптимизации, для повышения вероятности отыскания глобального оптимума, применяем их в сочетании с *методом мультистарта*.

На этапе применения ИМК найденные границы частотных диапазонов используем для формирования характерных признаков ЭЭГ, как это показано на Рис. 2.

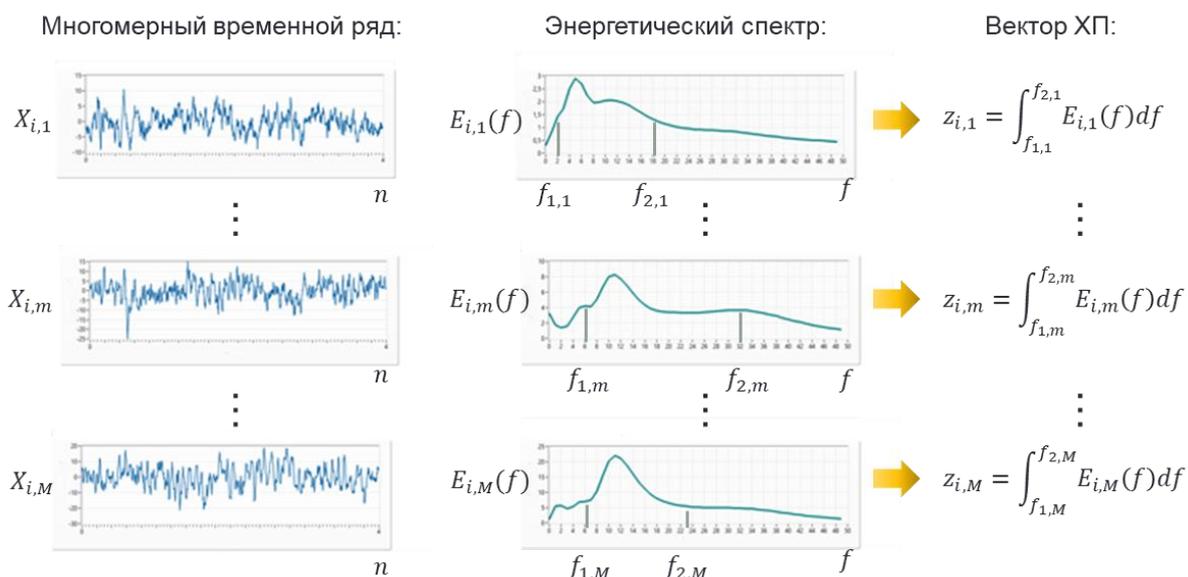


Рис. 2. Расчет значений ХП многомерного временного ряда с учетом найденных границ частотных диапазонов

Метод поиска оптимальных параметров частотно-временных окон.

Предлагаемый метод является расширением метода поиска оптимальных частотных диапазонов многомерных временных рядов и позволяет учитывать различия между классами временных рядов, проявляющиеся в частотно-временной области. Для каждого из измерений временного ряда $\mathbf{X} \in R^{M \times N}$ частотно-временное окно задает область на спектрограмме, в которой исследуются различия между классами.

Границы окон по оси частот задаем с помощью векторов $F_1, F_2 \in R^M$ размерности M , а по оси времени – с помощью векторов $T_1, T_2 \in R^M$. Задача поиска оптимальных параметров частотно-временных окон сводится к нахождению векторов $T_1^*, T_2^*, F_1^*, F_2^*$, для которых достигается максимум качества распознавания классов

$$\max_{F_1, F_2, T_1, T_2 \in \Lambda_F} Q(\hat{h}(T_1, T_2, F_1, F_2), \hat{g}) = Q(\hat{h}(T_1^*, T_2^*, F_1^*, F_2^*), \hat{g}) = Q^* \quad (5)$$

$$\Lambda_F = \begin{cases} F_{min} \leq F_1 \leq F_2 \leq F_{max}, \\ 0 \leq T_1 \leq T_2 \leq T_{max}, \end{cases} D_F \subset \mathbb{Z}^{M \times 2}.$$

Здесь $\hat{h}(T_1, T_2, F_1, F_2)$ – отображающая функция вида

$$\hat{h}(T_1, T_2, F_1, F_2) = u(T_1, T_2, F_1, F_2) \circ W(\mathbf{X}),$$

где $W(\mathbf{X})$ – функция вычисления спектрограммы временного ряда \mathbf{X} , $u(T_1, T_2, F_1, F_2)$ – объем фигуры под поверхностью спектрограммы в окне с границами $[F_1, F_2]$ и $[T_1, T_2]$.

С учетом выполненной параметризации функционала Q задача (5), как и задача (3), является задачей *однокритериальной условной глобальной оптимизации*. Для её решения используем генетический алгоритм или алгоритм роя частиц. В фенотип особей/частиц популяции дополнительно к векторам F_1, F_2 вводим векторы T_1, T_2 .

На этапе обучения ИМК после того как спектрограммы (матрицы коэффициентов вейвлет-разложения) $\mathbf{E}_m, m = 1..M$ рассчитаны для всех

временных рядов $\mathbf{X}_i, i = [1:P]$, оптимальные параметры частотно-временных окон находим по следующей схеме.

1) С помощью отображающей функции $\hat{h}(T_1, T_2, F_1, F_2)$ каждому временному ряду $\mathbf{X}_i \in \Omega$ ставим в соответствие вектор характерных признаков $\mathbf{z}_i(T_1, T_2, F_1, F_2) = (z_1, \dots, z_m, \dots, z_M)$, компоненты которого рассчитываем как

$$z_m = \iint_{\Lambda_m} \mathbf{E}_m(f, \tau) df d\tau, \quad m = 1, \dots, M$$

$$\Lambda_m = \{f_{1,m} \leq f \leq f_{2,m}; \tau_{1,m} \leq \tau \leq \tau_{2,m}\}.$$

2) Используя выбранный заранее классификатор $g = \hat{g} \in G$, определяем точность классификации, достижимую на множестве $\{\mathbf{z}_i(T_1, T_2, F_1, F_2), k_i\}_{i=1}^P$, сформированном векторами ХП $\mathbf{z}_i(T_1, T_2, F_1, F_2)$ и соответствующими им номерами классов k_i . Полученную оценку принимаем в качестве значения критерия $Q(\hat{h}(T_1, T_2, F_1, F_2), \hat{g})$.

3) Применяя *генетический алгоритм* или *алгоритм роя частиц*, находим оптимальные значения параметров T_1, T_2, F_1, F_2 , обеспечивающие максимум критерия $Q(\hat{h}(T_1, T_2, F_1, F_2), \hat{g})$.

На итерациях алгоритмов поиска используем *контроль переобучения*. В качестве решения задачи (5) принимаем значения варьируемых параметров, полученные по результатам *мультистарта*

На этапе применения ИМК найденные параметры частотно-временных окон используем для формирования характерных признаков ЭЭГ, как это показано на Рис. 3.

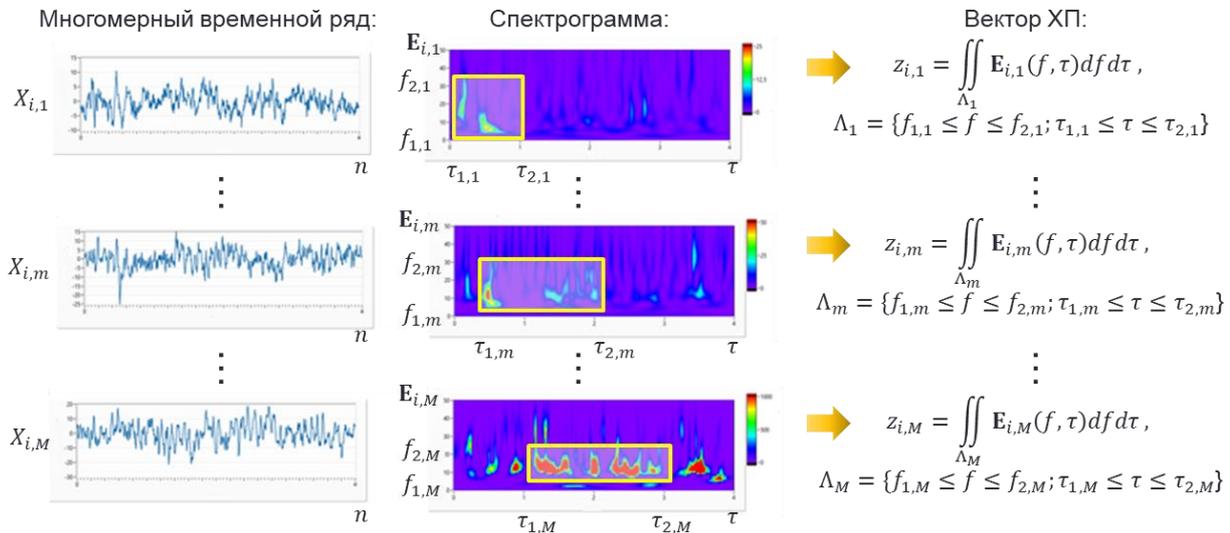


Рис. 3. Расчет значений ХП многомерного временного ряда с учетом параметров частотно-временных окон

В **третьей главе** представлено описание разработанного программного комплекса (ПК), реализующего предложенные в диссертации методы и алгоритмы анализа данных. ПК включает в себя ряд модулей, обеспечивающих взаимодействие с пользователем в диалоговом режиме.

1) «Модуль записи и просмотра ЭЭГ» предназначен для а) регистрации сигнала ЭЭГ с помощью беспроводного 14-канального энцефалографа *Emotiv Eroc*, б) отображения считанного сигнала ЭЭГ на экране, в) сохранения записей ЭЭГ в файлы для их последующего анализа.

2) «Модуль предобработки данных» реализует алгоритмы частотной и пространственной фильтрации для подавления помех в записи ЭЭГ.

3) «Модуль формирования ХП многомерных временных рядов» включает такие методы формирования ХП для записей ЭЭГ, как расчет спектральной плотности мощности сигнала в предопределенных диапазонах частот, расчет нормированной энтропии сигнала, расчет коэффициентов векторной авторегрессии и др.

4) «Модуль оптимизации ХП» реализует предложенные методы построения оптимальных характерных признаков для записей ЭЭГ. Данные методы учитывают различия между классами временных рядов, которые проявляются во временной, частотной и частотно-временной области. Критерием оптимальности служит качество распознавания классов (команд пользователя в ИМК).

5) «Модуль классификации данных» обеспечивает возможность построения и тестирования классификаторов следующих типов: метод опорных векторов (МОВ), метод k ближайших соседей, многослойный персептрон, комитет МОВ классификаторов, классификатор на основе расстояния Махаланобиса. Обучающая и тестовые выборки формируются из векторов характерных признаков, полученных для записей ЭЭГ.

Для хранения многомерных временных рядов и их характерных признаков были предложены специальные форматы, основанные на языке разметки XML. Описание данных форматов также приводится в третьей главе диссертации.

Программный комплекс выполнен в среде разработки NI LabVIEW. Тестирование ПК на модельных данных показало его работоспособность и функциональную полноту. Для всех модулей ПК приведено описание типовых сценариев работы с ними.

Четвертая глава посвящена оценке эффективности разработанных методов, алгоритмов и программного обеспечения в задаче распознавания по записи ЭЭГ мысленных команд пользователя ИМК.

В диссертации использовались известные наборы тестовых данных *Dataset Ia* и *Dataset Ib*, предоставленные для проведения соревнования *BCI Competition IV*, а также набор данных *Visual P300 speller*, полученный исследовательской группой Кристофа Гугера (<http://bnci-horizon-2020.eu/>, раздел *Database*). Наборы *Dataset Ia* и *Dataset Ib* содержат записи ЭЭГ, зарегистрированные в процессе работы пользователей с сенсомоторными ИМК, имеющими соответственно четыре и две степени свободы. Записи ЭЭГ из набора *Visual P300 speller* были сняты при работе пользователей с ИМК на основе волны P300.

Модифицированный метод шейплетов. Эффективность предлагаемых модификаций метода шейплетов исследовалась на наборе тестовых данных

Visual P300 speller. При этом решалась задача бинарной классификации записей ЭЭГ, целью которой было определение, содержит запись реакцию в виде волны P300 на предъявляемый стимул или нет.

Для всех испытуемых из набора данных *Visual P300 speller* поиск шейплетов осуществлялся среди записей *обучающей сессии*. Записи ЭЭГ, снятые во время *тестовой сессии*, использовались для оценки обобщающих свойств шейплетов.

Показано, что по сравнению с известным алгоритмом поиска, основанным на отбрасывании кандидатов, близких к уже рассмотренным фрагментам временных рядов, предложенная схема ГА обеспечивает лучшее приближение к глобальному оптимуму и при этом позволяет сократить множество перебора на 99%.

Для записей ЭЭГ, входящих в обучающую и тестовую выборку, было выполнено *шейплет-преобразование* данных на основе шейплетов, найденных с помощью ГА и метода полного перебора. Сгенерированные векторы ХП использовались для построения и тестирования комитета МОВ-классификаторов. По результатам тестирования было установлено, что применение шейплетов, найденных ГА и методом полного перебора, в среднем дает сопоставимые значения точности классификации, то есть полученные в обоих случаях шейплеты обладают одинаковыми обобщающими свойствами.

Методы поиска оптимальных частотных диапазонов сигнала и оптимальных параметров частотно-временных окон. В диссертации выполнено сравнение эффективности методов с другими известными методами формирования ХП, а также исследовано влияние выбора алгоритма классификации на итоговое качество распознавания классов.

Для сравнения был выбран ряд методов формирования ХП, широко применяемых в ИМК.

Методы без оптимизации ХП: расчет нормированной энтропии сигнала (метод h_1); расчет дисперсии сигнала после применения общего пространственного фильтра (метод h_2); расчет коэффициентов векторной авторегрессии (метод h_3); оценка энергии сигнала в пяти предопределенных диапазонах частот (метод h_4).

Методы, предусматривающие оптимизацию ХП: отбор наиболее информативных признаков с помощью генетического алгоритма (метод h_5); метод поиска оптимальных частотных диапазонов (метод h_6); метод поиска оптимальных параметров частотно-временных окон (метод h_7). Для методов h_6, h_7 в вектор ХП включались значения энергии сигнала в границах найденных частотных диапазонов / частотно-временных окон.

Перед вычислением характерных признаков сигнал ЭЭГ подвергался частотной и пространственной фильтрации.

Для вычисления вероятности правильного распознавания классов были выбраны следующие методы классификации: ν -SVM классификатор (модификация метода опорных векторов, предусматривающая допуск ошибок на обучающей выборке, метод g_1); метод k ближайших соседей (метод g_2); многослойный персептрон (метод g_3).

Оценки точности распознавания классов, полученные на наборах тестовых данных *Dataset Ia* и *Dataset Ib* для всех сочетаний методов формирования ХП и методов классификации, приведены в Таблице 1. В таблице указаны средние значения точности и их среднеквадратичные отклонения, рассчитанные по наборам данных *Dataset Ia* и *Dataset Ib*. В диссертации использовался состав обучающих и тестовых выборок, определенный организаторами соревнования *BCI Competition IV*.

Таблица 1.

Сравнение средней точности классификации (%) для различных методов формирования ХП и методов классификации

Метод формирования признаков	Набор <i>Dataset Ia</i>			Набор <i>Dataset Ib</i>		
	Метод классификации			Метод классификации		
	g_1	g_2	g_3	g_1	g_2	g_3
h_1	58 ±13	46 ±12	59 ±15	71 ±15	71 ±15	72 ±14
h_2	52 ±17	48 ±12	52 ±13	68 ±16	67 ±17	69 ±16
h_3	47 ±9	39 ±7	41 ±8	68 ±14	65 ±15	69 ±13
h_4	59 ±16	45 ±12	54 ±16	75 ±13	71 ±15	76 ±13
h_5	60 ±14	49 ±13	53 ±15	74 ±14	70 ±11	75 ±12
h_6	61 ±13	50 ±12	60 ±14	77 ±13	73 ±13	75 ±14
h_7	57 ±16	49 ±11	56 ±15	75 ±12	72 ±12	74 ±13

На основании результатов, представленных в Таблице 1, установлено, что на обоих наборах данных *Dataset Ia* и *Dataset Ib* наибольшие значения точности классификации достигаются при сочетании метода формирования ХП на основе поиска оптимальных частотных диапазонов (метод h_6) с ν -SVM классификатором (метод g_1).

Меньшая эффективность метода поиска оптимальных параметров частотно-временных окон (метод h_7) можно объяснить более высокой размерностью вектора варьируемых параметров, что является одним из факторов сложности в задачах оптимизации.

В пятой главе приведены результаты исследования эффективности предложенных методов формирования ХП в гибридном интерфейсе «глаз-мозг-компьютер», сочетающим в себе свойства ИМК и систем, отслеживающих направление взгляда («айтрекеров»). Экспериментальные данные содержат записи ЭЭГ, полученные в процессе игры испытуемых в игру «Линии» с помощью «айтрекера». Целью исследования являлся выбор такого метода формирования ХП, который позволит сократить число ложных срабатываний «айтрекера» за счет корректного распознавания паттернов сигнала ЭЭГ, связанных со спонтанными и управляющими фиксациями взгляда.

Для сравнения были выбраны следующие методы формирования ХП: расчет усредненных значений амплитуды сигнала в перекрывающихся окнах (метод $M1$); оценка энергии сигнала в пяти предопределенных диапазонах частот (метод $M2$); отбор наиболее информативных признаков с помощью

генетического алгоритма (*метод M3*); модифицированный метод шейплетов (*метод M4*); метод поиска оптимальных частотных диапазонов (*метод M5*). Для метода *M3* исходный набор признаков формировался с помощью расчета усреднённых значений амплитуды сигнала в перекрывающихся окнах (*метод M3:M1*) и оценки энергии сигнала в пяти predeterminedных диапазонах частот (*метод M3:M2*).

Эффективность методов извлечения ХП оценивалась с помощью таких показателей, как чувствительность и специфичность. Для каждого из испытуемых значения показателей определялись по результатам *пятикратной перекрестной проверки* с помощью классификатора, основанного на методе *k* ближайших соседей. Полученные результаты представлены в Таблице 2.

Таблица 2.

Сравнение точности классификации (%) для различных методов формирования признаков ЭЭГ в гибридном интерфейсе «глаз-мозг-компьютер»

Метод построения признаков	Показатели точности							
	Чувствительность				Специфичность			
	\bar{x}	σ	min	max	\bar{x}	σ	min	max
<i>M1</i>	59	4	53	65	56	6	48	64
<i>M2</i>	57	10	44	75	60	17	41	82
<i>M3:M1</i>	59	2	57	62	59	4	56	65
<i>M3:M2</i>	59	11	48	74	67	14	50	85
<i>M4</i>	63	6	55	74	59	8	45	68
<i>M5</i>	57	9	47	68	71	12	54	83

В среднем по группе из шести испытуемых метод формирования ХП *M5*, заключающийся в поиске оптимальных частотных диапазонов ЭЭГ, позволяет достичь наибольших значений специфичности. Прирост специфичности по сравнению с другими методами построения признаков составляет от 4 до 15%, что способствует уменьшению числа ложных срабатываний интерфейса.

В **заключении** диссертации приведены основные результаты работы, выводы и предложения по совершенствованию рассмотренных методов.

ОСНОВНЫЕ РЕЗУЛЬТАТЫ И ВЫВОДЫ

1) Для решения задачи классификации многомерных временных рядов разработаны новые методы построения оптимального пространства характерных признаков. Модифицированный метод шейплетов позволил формировать ХП многомерных временных рядов путем вычисления расстояний от них до найденных шейплетов. Предложенная схема генетического алгоритма для поиска шейплетов позволила существенно сократить множество перебора, снизив время решения задачи до приемлемых значений. Метод поиска оптимальных частотных диапазонов позволил при построении ХП более полно учесть информацию о различии частотных составляющих многомерных временных рядов, принадлежащих к разным классам, что, в результате,

способствовало повышению средней точности классификации.

2) На основе предложенных методов разработан программный комплекс «BCI Design», который может быть использован для автоматизации исследований в области ИМК. Программный комплекс включает модули, обеспечивающие регистрацию сигнала, чтение записей из файлов, предобработку, анализ и классификацию данных.

3) Проведено исследование эффективности предложенных методов на известных наборах тестовых данных, а также в новом гибридном интерфейсе «глаз-мозг-компьютер». Установлено, что метод формирования ХП на основе поиска оптимальных частотных диапазонов временных рядов обеспечивает лучшие значения точности классификации и, таким образом, позволяет достичь основной цели диссертации – повысить эффективность классификации временных рядов в ИМК.

4) Ввиду того, что представленные в диссертации подходы к анализу данных обладают достаточной степенью универсальности, полученные теоретические и практические результаты, помимо ИМК, могут быть использованы для решения других практических задач, связанных с анализом многомерных временных рядов.

СПИСОК ОСНОВНЫХ ПУБЛИКАЦИЙ ПО ТЕМЕ ДИССЕРТАЦИИ

1. Сотников П.И. Выделение характерных признаков сигнала электроэнцефалограммы с помощью анализа энтропии // Наука и Образование. МГТУ им. Н.Э. Баумана. Электронный журнал. 2014. № 11. С. 555–570. DOI:10.7463/1114.0739919 (1 п.л.).

2. Сотников П.И. Выбор оптимальных частотных диапазонов сигнала электроэнцефалограммы в интерфейсе мозг-компьютер // Наука и Образование. МГТУ им. Н.Э. Баумана. Электронный журнал. 2015. № 6. С. 217-234. DOI: 10.7463/0615.0778091 (1,125 п.л.).

3. Карпенко А.П., Сотников П.И. Модифицированный метод классификации многомерных временных рядов с использованием шейплетов // Вестник МГТУ им. Н.Э. Баумана. Серия: Приборостроение. 2017. № 2 (113). С. 46-65. DOI: 10.18698/0236-3933-2017-2-46-65 (1,25 п.л. / 1 п.л.).

4. Sotnikov P., Vidunova S., Finagin K. Selection of optimal frequency bands of the electroencephalogram signal in eye-brain-computer interface // Procedia Computer Science 12th. Сер. «12th International Symposium Intelligent Systems, INTELS 2016» 2017. pp. 168-175. DOI: 10.1016/j.procs.2017.01.049 (0,5 п.л. / 0,375 п.л.)

5. Сотников П.И. Методы построения пространства признаков сигнала ЭЭГ в гибридном интерфейсе «глаз-мозг-компьютер» // Математика и математическое моделирование. 2018. № 2. С. 33–52. DOI: 10.24108/mathm.0218.0000118 (1,25 п.л.).