

ИССЛЕДОВАНИЕ ПОДХОДОВ К СОЗДАНИЮ НАБОРОВ ДАННЫХ НА ОСНОВЕ ВРЕМЕННЫХ РЯДОВ, РЕГИСТРИРУЕМЫХ ПРИ РАБОТЕ С 14-КАНАЛЬНЫМ НЕЙРОИНТЕРФЕЙСОМ EMOTIV EPOC+

¹Зуев А.С., ¹Исаев Р. А., ²Салямков Р.Р.

¹МИРЭА - Российский технологический университет 119454, Россия, г. Москва, проспект Вернадского, 78, e-mail: zuev_a@mirea.ru, isaev@mirea.ru.

²ООО «ИТМ-Миокард», 121467, Россия, г. Москва, Молодогвардейская ул., 10, e-mail: gizmo22505@yandex.ru.

Рассматривается задача поиска подходов к созданию наборов данных на основе признаков, извлекаемых из временных рядов, регистрируемых при работе с 14-канальным нейроинтерфейсом EMOTIV EPOC+ в процессе формирования независимыми субъектами моторных образов по управлению курсором мыши компьютера. Целью работы является исследование ряда показателей, значения которых вычисляются посредством выполнения тех или иных математических операций над различными фрагментами 14 временных рядов, в качестве инструментов для формирования значений признаков. Исследование должно помочь выявить те показатели, использование которых для формирования признаков в наборах данных обеспечивает разработку классификаторов моторных образов, отличающихся максимально возможным качеством классификации данных. Предварительно временные ряды подвергались фильтрации с применением фильтра Баттварта 5-го порядка, что позволило решить проблему удаления шумовых артефактов из временных рядов. Для оценки влияния длины фрагмента временного ряда, используемого при формировании значения признака на основе того или иного показателя, на итоговое качество классификации данных были рассмотрены интервалы времени (таймфреймы) размером в 1, 2 и 3 секунды. В ходе исследований была выполнена разработка SVM (Support Vector Machine), RF (Random Forest) и MLP (Multi Layer Perceptrone) классификаторов моторных образов. Результаты экспериментов показали целесообразность работы показателями, вычисляемыми на основе энтропии Шеннона и фрактальной размерности Хигучи при таймфрейме размером в 3 секунды. В этом случае удается обеспечить высокое качество классификации моторных образов, оцениваемое с применением F-меры. В частности, максимальные значения F-меры имеют SVM, RF и MLP классификаторы разработанные на основе наборов данных, признаки в которых вычислены с применением энтропии Шеннона. Эти значения F-меры равны соответственно 0.82, 0.88 и 0.73.

Ключевые слова: нейроинтерфейс, электроэнцефалография, моторный образ, временные ряды, извлечения признаков, машинное обучение.

EXPLORING APPROACHES TO DATASETS CREATION BASED ON TIME SERIES RECORDED DURING OPERATION WITH 14-CHANNEL NEURAL INTERFACE EMOTIV EPOC+

¹Zuev A.S., ¹Isaev R.A., ²Salyamov R.R.

¹MIREA - Russian Technological University, 119454, Russia, Moscow, Vernadsky Avenue, 78, e-mail: zuev_a@mirea.ru, isaev@mirea.ru

²LLC «ITM-Myocard», 121467, Russia, Moscow, Molodogvardeyskaya st., 10, e-mail: gizmo22505@yandex.ru

The problem of finding approaches to creating data sets based on features extracted from time series recorded when working with the 14-channel neural interface EMOTIV EPOC+ in the process of formation of motor imageries by independent subjects for controlling the computer mouse cursor is considered. The purpose of the work is to study a number of indicators, the values of which are calculated by performing certain mathematical operations on various fragments of 14 time series, as tools for generating feature values. The study should help to identify those indicators, the use of which to form features in datasets ensures the development of motor imagery classifiers that differ in the highest possible quality of data classification. Previously, the time series were filtered using a 5th order Butterworth filter, which made it possible to solve the problem of removing noise artifacts from the time series. To assess the influence of the length of a fragment of a time series used to form the value of a feature based on a particular indicator on the final quality of data classification, time intervals (time frames) of 1, 2 and 3 seconds were considered. During the research, the development of SVM (Support Vector Machine), RF (Random Forest) and MLP (Multi Layer Perceptrone) classifiers of motor imageries was carried out. The

experimental results showed the feasibility of working with indicators calculated based on Shannon entropy and Higuchi fractal dimension on a time frame of 3 seconds. In this case, it is possible to ensure high quality of classification of motor imageries, assessed using the F-measure. In particular, SVM, RF and MLP classifiers developed on the basis of datasets in which features are calculated using Shannon entropy have the maximum F-measure values. These F-measure values are 0.82, 0.88 and 0.73, respectively.

Keywords: neural interface, electroencephalography, motor imagery, time series, feature extraction, machine learning.

Введение

Классификация данных является одной из наиболее распространенных задач в машинном обучении. Она заключается в определении класса объекта на основе набора признаков. Однако, в реальных задачах часто возникает проблема дисбаланса классов, когда размеры классов существенно отличаются. Например, в задаче детектирования мошеннических операций в банковских данных [1], количество мошеннических операций может быть значительно меньше, чем количество обычных операций.

Дисбаланс классов приводит к снижению качества модели, так как происходит смещение в сторону предсказания большего класса и не учитывает меньший класс. В результате модель может неверно классифицировать объекты меньшего класса. Решение проблемы дисбаланса классов является актуальной областью исследований в машинном обучении. Существуют различные методы балансировки классов, которые позволяют бороться с этой проблемой. В данной статье рассматриваются различные методы балансировки классов и их применение в задачах классификации данных.

Воображение движения части тела без фактического физического движения или воображение перемещения объектов – умственный процесс, с помощью которого человек репетирует или моделирует определенное действие, формируя тот или иной моторный образ (МО).

Практика формирования моторных образов является эффективным инструментом для улучшения физических навыков и развития моторной координации. Она позволяет умственно тренировать и воображать выполнение определенных действий, что может привести к лучшим результатам при фактическом выполнении этих действий.

Так, например, в спорте моторные образы используются для тренировки физических навыков и развития моторной координации у атлетов с целью улучшения техники движений и, как следствие, достижения более высоких результатов. Практика формирования моторных образов может быть полезна и в таких сферах, как музыка, танцы и актерское мастерство.

Исследования показывают, что воображение движений может иметь положительный эффект на физическую подготовку и восстановление человека после травмы: воображение движений может помочь восстановить связь между мозгом и мышцами, улучшить координацию и силу.

Задача формирования моторных образов представляет собой одну из самых активно решаемых когнитивных задач. Она основывается на идее использования сенсомоторных ритмов (СМР) в качестве управляющего сигнала. СМР – электрические сигналы (паттерны), которые возникают в мозге и связаны с активностью его сенсорно-моторных областей. Эти сигналы могут быть обнаружены и записаны с помощью электроэнцефалографии (ЭЭГ), которая позволяет измерять электрическую активность мозга.

Формирование моторных образов предполагает обучение человека произвольно генерировать определенные паттерны СМР, связанные с конкретными движениями. Например, человек может учиться генерировать моторные образы, связанные с воображаемым поднятием руки или движением конкретной конечности.

Паттерны СМР, полученные при формировании моторных образов, могут быть использованы, например, для реабилитации людей с двигательными нарушениями. В частности, такие паттерны могут быть преобразованы в команды для управления протезами или экзоскелетами, что позволит людям с ограниченными двигательными возможностями восстановить или усилить свои способности к выполнению движений.

При формировании МО, т.е. при воображении движения, человек активизирует те же области мозга, которые активируются при реальном физическом движении. Этот факт делает взаимодействие с внешними устройствами, использующими МО, более естественным и интуитивно-понятным для пользователя с ограниченными двигательными возможностями.

В настоящее время сигналы мозга активно применяются в инновационной технологии, известной как интерфейс «мозг-компьютер» (ИМК, Brain-Computer Interface, BCI), для контроля и реабилитации людей в обход нервной и мышечной систем организма [1]. Эта технология позволяет человеку управлять электронными устройствами, такими как компьютерный курсор, роботизированная рука и даже мобильный телефон, используя только свои мысли [2]. В системах с ИМК сигналы мозга передаются непосредственно устройству, что позволяет эффективно обойти поврежденные ткани (системы) организма [3]. Эта передовая технология

способна распознавать и интерпретировать мозговую активность, связанную с намерениями пользователя, и преобразовывать ее в команды для управления устройствами.

Первые разработки в области ИМК были субъектно-зависимыми, что сильно ограничивало их эффективность. Даже у одного и того же человека сигналы мозга могут отличаться между сеансами записи. Вариабельность же сигналов мозга у разных людей очень высока. Разработка ИМК для каждого конкретного субъекта требует значительного времени. При этом она практически не возможна для людей с физическими или умственными ограничениями. Кроме того, разработка таких ИМК проблематична в случае ограниченных ресурсов компьютеров [4].

В последние годы были предложены принципы разработки субъектно-независимых (СН, Subject Independent, SI) ИМК. В СН ИМК обучение универсальной модели ИМК осуществляется с привлечением данных группы субъектов, а не одного отдельного человека. СН ИМК способны хорошие результаты с минимальным периодом обучения, что позволяет отказаться от многочисленных утомительных сеансов обучения, характерных для субъектно-зависимых ИМК. В результате удастся значительно упростить процесс разработки и применения ИМК, так как они становятся более гибкими и обобщающими. При этом ИМК становятся более устойчивыми к изменчивости сигналов мозга и могут быть успешно применены в различных ситуациях. Это открывает новые возможности для использования ИМК в медицине, реабилитации, коммуникации и других сферах, где требуется взаимодействие мозга с компьютерными системами.

Развитие ИМК в качестве практического клинического инструмента сталкивается с существенными техническими проблемами, которые препятствуют его широкому применению на практике. При этом главное беспокойство вызывают проблемы, связанные с недостаточной производительностью ИМК и высокой сложностью алгоритмов и оборудования, используемых в разработке ИМК [5]. Решение этих проблем затруднено множеством факторов, среди которых следует назвать поддержание приемлемого отношения сигнал/шум [6], заметные краткосрочные и долгосрочные вариации сигналов мозга как для одного субъекта, так и между субъектами [7], а также необходимость частых и утомительных тренировок (занятий) по формированию МО и сеансов калибровки, связанных с конкретными задачами, для обеспечения правильной работы ИМК.

При разработке ИМК особое внимание уделяют разработке методов и алгоритмов, связанных с задачами отбора признаков [8] и классификации [9], используемых при формировании наборов данных, применяемых при создании классификаторов, обеспечивающих высокую точность классификационных решений для ИМК.

Для решения задач классификации в ИМК используют как давно известные и хорошо зарекомендовавшие себя инструменты машинного обучения [9] (такие как SVM-алгоритм (машина опорных векторов, Support Vector Machine) [9], алгоритм случайного леса (Random Forest, RF) [9] и нейронные сети [9]), так и относительно новые (такие как адаптивные классификаторы [10], методы, основанные на переносе обучения [11], и матричные методы [12]).

Важно отметить, что точность классификации является критическим фактором для успешной работы ИМК. Поэтому необходимо детальное изучение возможностей различных типов классификаторов. Так, например, недавние исследования показали, что сверточные нейронные сети (Convolutional Neural Networks, CNNs) демонстрируют высокую эффективность при классификации сигналов мозга в ИМК [9]. Такие сети способны автоматически извлекать иерархические признаки из временных или пространственных шаблонов сигналов мозга, что улучшает качество классификации.

Кроме того, при разработке ИМК активно применяются методы передачи знаний [11] и обучения [11] с малым количеством размеченных данных, в частности, особое внимание уделяется использованию моделей, предобученных на больших наборах данных, с последующей их адаптацией к задаче классификации в ИМК [11]. Это позволяет улучшить производительность ИМК при ограниченном количестве доступных размеченных данных.

Одной из ключевых проблем, с которыми сталкиваются разработчики ИМК при создании классификаторов данных, является выбор наиболее информативных признаков из большого числа признаков, доступных к использованию. В настоящее время предложено большое число различных подходов к формированию признаков, используемых при решении задач разработки ИМК, однако вопросы их одновременного исследования и использования до сих пор не были изучены в полном объеме. Следует отметить, что одновременное использование большого числа признаков чревато проявлением так называемой проблемы «проклятия размерности», что может негативно сказаться на точности классификационных решений и, кроме того, потребовать значительных вычислительных ресурсов.

Для решения задачи отбора признаков с целью повышения точности классификации в ИМК применяют, в частности, методы на основе пространственных шаблонов (Common Spatial Patterns, CSP) [12],

пространственной фильтрации [13], анализа главных компонент [14] и вейвлет-разложения [14]. Хотя эти методы вполне эффективны для получения адекватных результатов классификации, они зачастую сложны в своей реализации и, как следствие, увеличивают вычислительные затраты на разработку искомого классификатора в целом.

Многие из перечисленных методов были исследованы в работах различных авторов независимо друг от друга. Однако на настоящий момент времени отсутствуют глубокие исследования по их совместному применению, в том числе, в СН ИМК.

1. Постановка задачи

Целью работы является исследование ряда показателей, значения которых вычисляются посредством выполнения тех или иных математических операций над различными фрагментами 14 временных рядов, в качестве инструментов для формирования значений признаков. Исследование должно помочь выявить те показатели, использование которых для формирования признаков в наборах данных обеспечивает разработку классификаторов моторных образов, отличающихся максимально возможным качеством классификации данных.

Данные ЭЭГ, сопоставленные 14 временным рядам, были записаны у пяти здоровых субъектов (испытуемых) с использованием 14 каналов (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4) нейроинтерфейса «Emotiv Eros +» с частотой дискретизации 128 измерений в секунду. Схема наложения нейроинтерфейса «Emotiv Eros +» на голову испытуемого представлена на рисунке 1.

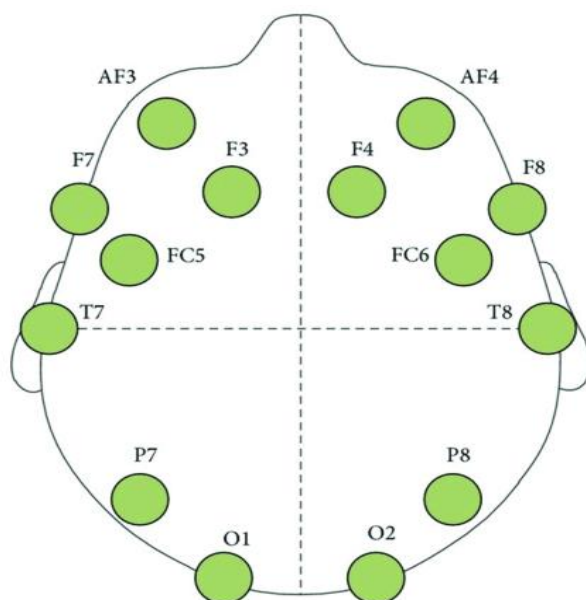


Рисунок 1 – Схема расположения электродов нейроинтерфейса «Emotiv Eros+»

Во время сеанса записи данных ЭЭГ каждого испытуемого просили выполнить 5 заданий: 4 задания на воображение движений мышкой влево, вправо, вверх, вниз, а также – задание воображение состояния покоя.

Во время записи данных ЭЭГ каждый испытуемый сидел на удобном стуле, положив руки на его подлокотники. Каждому заданию был сопоставлен класс, характеризующий тип движения, и соответствующая ему метка:

- воображение движения мышкой влево – класс с меткой Left;
- воображение движения мышкой вправо – класс с меткой Right;
- воображение движения мышкой вниз – класс с меткой Down;
- воображение движения мышкой вверх – класс с меткой Up;
- воображение состояния покоя – класс с меткой Neutral.

Для каждого испытуемого был получен набор данных, описывающий временные ряды, полученные в процессе выполнения заданий. В результате было сформировано 5 наборов данных.

Общая длительность записей по всем испытуемым и по всем заданиям составила 47.54 мин. Задания предполагают решение 5 задач на формирование МО, соответствующих движениям курсора мышки влево, вправо, вниз, вверх, а также – состоянию покоя.

В таблице 1 для каждого набора данных приведена информация по длительности записей временных рядов, соответствующих 5 заданиям (и, следовательно, 5 классам) в минутах.

Таблица 1 – Описание наборов данных, сформированных для 5 испытуемых

Набор данных	Длительность записи временного ряда, соответствующего заданию, в наборе данных, мин.					Общая длительность по набору данных, мин.
	Класс с меткой Left, мин.	Класс с меткой Right, мин.	Класс с меткой Down, мин.	Класс с меткой Up, мин.	Класс с меткой Neutral, мин.	
Набор №1	2	1,85	2	2	2	9,85
Набор №2	2	1,87	2	2	2	9,87
Набор №3	2	1,87	2	2	2	9,87
Набор №4	1,5	1,82	2	2	1,5	8,82
Набор №5	1,85	1,82	1,98	1,5	1,98	9,13
Общая длительность по классу, мин.	9,35	9,23	9,98	9,5	9,48	47,54

2. Теоретические исследования

2.1. Предварительная обработка данных

Многие исследования показывают, что большое количество шума, присутствующего в сигналах ЭЭГ, снижает точность классификации сигналов мозга. При разработке ИМК на основе МО для удаления шума из сигналов ЭЭГ используют временно-полосовые фильтры, в частности, применяют фильтр Баттерворта пятого порядка [15 – 17].

Именно такой фильтр при частоте дискретизации, равной 128 измерений в секунду, наиболее эффективен для решения задачи удаления шумов из сигналов ЭЭГ по сравнению с другими инструментами фильтрации Баттерворта.

2.2. Извлечение признаков

Задача извлечения репрезентативных признаков является одной из наиболее важных задач процесса подготовки данных для последующей классификации временных рядов многомерных ЭЭГ-подобных сигналов головного мозга, поступающих через нейроинтерфейс от независимого субъекта [2].

В предлагаемом исследовании признаки, извлекаемые из данных, регистрируемых гарнитурой нейроинтерфейса «Emotiv Eros +», формировались с привлечением показателей, значения которых вычисляются посредством выполнения тех или иных математических операций над различными участками временных рядов.

Были использованы такие показатели, как: фрактальная размерность Хигучи; спектральная плотность энергии; энтропия Шеннона; среднее арифметическое; медиана; среднее абсолютное отклонение; среднеквадратичное отклонение; максимальное значение; минимальное значение.

Рассматриваемые признаки позволяют описать участки временных рядов многомерных ЭЭГ-подобных сигналов с применением различных подходов к анализу временных рядов, предполагающих работу с показателем на основе фрактальной размерности, с показателями, вычисляемыми в частотной области данных, а также – со статистическими показателями.

Очевидна необходимость выполнения исследований, которые позволили бы оценить, какие из вышеуказанных признаков и в каком сочетании обеспечивают максимально возможное качество классификации сигналов головного мозга независимых субъектов, проводимой с применением классификаторов, разработанных на основе различных алгоритмов машинного обучения.

Далее приведено описание различных показателей, используемых при вычислении значений признаков на основе временных рядов многомерных ЭЭГ-подобных сигналов, описывающих процессы формирования испытуемыми субъектами моторных образов, соответствующих одному из 5 вариантов движения движений курсора мышки.

При этом предполагается, что при вычислении каждого нового значения некоторого признака используется N наблюдаемых (фактических) последовательных значений элементов x_i ($i = \overline{1, N}$) соответствующего временного ряда.

Показатель, описываемый в п. 2.2.1, основан на расчете фрактальной размерности Хигучи; показатель, описываемый в п. 2.2.2, основан на обработке информации в частотной области данных; показатели, описываемые в п. 2.2.3 – 2.2.9, основаны на учёте статистической информации.

2.2.1. Фрактальная размерность Хигучи

Фрактальная размерность Хигучи вычисляется на основе значений элементов x_i ($i = \overline{1, N}$) временного ряда в соответствии со следующей последовательностью шагов.

1. Определить величину $a = \text{int} \left[\frac{N}{n} \right]$, где $\text{int}[v]$ – функция выделения целой части числа v ; n – число

подинтервалов во временном ряду, содержащем N элементов.

2. Сформировать из элементов x_i ($i = \overline{1, N}$) исходного временного ряда новые временные ряды вида: $x_m, x_{m+a}, x_{m+2a}, \dots, x_{m+int[(N-m)/a]}$ ($m = \overline{1, a}$).

3. Вычислить длину кривой

$$L_m(a) = \frac{N-1}{int[(N-m)/a]} \cdot \sum_{i=1}^{int[(N-m)/a]} |x_{m+ia} - x_{m+(i-1)a}| \quad (m = \overline{1, a}).$$

4. Вычислить среднее значение $L(a)$ по всем m и построить зависимость $\log(L(a))$ от $\log(a)$.

5. Выполнить аппроксимацию построенной зависимости $\log(L(a))$ от $\log(a)$ прямой линией $y = k \cdot z + b$ по методу наименьших квадратов.

6. Вычислить значение фрактальной размерности Хигучи HFD (Higuchi Fractal Dimension) как тангенс угла наклона прямой линии.

2.2.2. Энтропия Шеннона

Энтропия Шеннона в контексте работы с временными рядами вычисляется как элементарная энтропия выборки (выборочная энтропия). При этом под выборкой обычно понимают конечную последовательность значений элементов временного ряда, выбранных по определенному правилу. Например, выборкой может быть и фрагмент ВР, содержащий некоторое число последовательных элементов (например, N элементов).

Энтропия Шеннона вычисляется на основе значений элементов x_i ($i = \overline{1, N}$) временного ряда в соответствии со следующей последовательностью шагов.

1. Определить минимальное и максимальные значения элементов временного ряда элементов x_i ($i = \overline{1, N}$): F_{min} и F_{max} .

2. Разбить интервал $[F_{min}, F_{max}]$ на n подинтервалов (уровней) таким образом, чтобы величина интервала Δx была не меньше доверительного интервала данных наблюдений.

3. Предположить, что выборка – это некоторое «сообщение» длиной N , состоящее из «букв», а подинтервалы j ($j = \overline{1, n}$) образуют «алфавит». Найти число Δn_j ($j = \overline{1, n}$) значений выборки, попавших в каждый из подинтервалов, и определить относительные «заполненности» подинтервалов (уровней) – p_j ($j = \overline{1, n}$):

$$p_j = \frac{\Delta n_j}{n} \quad (\sum_{j=1}^n p_j = 1; \sum_{j=1}^n \Delta n_j = N),$$

т.е. оценки вероятностей попадания значений из выборки в подинтервал j ($j = \overline{1, n}$), описывающие относительную частоту встречаемости «буквы» «алфавита» в «сообщении».

4. Вычислить энтропию Шеннона (выборочную энтропию) как

$$H = - \sum_{j=1}^n p_j \cdot \log(p_j),$$

где p_j – оценка вероятности попадания значений из выборки размером N в подинтервал j ($j = \overline{1, n}$); n – число подинтервалов, на которые разбит интервал, охватывающий все значения анализируемого временного ряда.

2.2.3. Среднее арифметическое

Среднее арифметическое $Mean$ вычисляется как

$$Mean = \frac{1}{N} \sum_{i=1}^N x_i,$$

где x_i – значение i -го элемента временного ряда ($i = \overline{1, N}$); N – число наблюдаемых последовательных значений элементов временного ряда.

2.2.4. Медиана

Медиана $Median$ вычисляется на основе значений элементов временного ряда x_i ($i = \overline{1, N}$), отсортированного по их возрастанию, т.е. на основе значений x'_i ($i = \overline{1, N}$) ($x'_{i-1} \leq x'_i$ при $i = \overline{2, N}$).

Если число N , определяющее число наблюдаемых последовательных значений элементов временного ряда, нечетно, то медиана $Median$ соответствует центральному значению отсортированного ряда, номер которого определяется как $\frac{N+1}{2}$. В этом случае медиана $Median$ вычисляется как

$$Median = x'_{\frac{N+1}{2}}.$$

Если число N , определяющее число наблюдаемых последовательных значений элементов временного ряда, четно, то медиана $Median$ вычисляется как среднее арифметическое двух центральных значений отсортированного ряда, т.е. значений с номерами $\frac{N}{2}$ и $\frac{N}{2} + 1$. В этом случае медиана $Median$ вычисляется как

$$Median = \frac{x'_{\frac{N}{2}} + x'_{\frac{N}{2} + 1}}{2}.$$

2.2.5. Среднее абсолютное отклонение

Среднее абсолютное отклонение MAD (mean absolute deviation) вычисляется как

$$MAD = \frac{1}{N} \sum_{i=1}^N |x_i - m|,$$

где x_i – значение i -го элемента временного ряда ($i = \overline{1, N}$); m – среднее значение элементов временного ряда (при этом в качестве среднего значения может использоваться среднее арифметическое, медиана, мода); N – число наблюдаемых последовательных значений элементов временного ряда.

Среднее абсолютное отклонение MAD характеризует арифметическое среднее для абсолютных отклонений значений элементов временного ряда от среднего значения m .

2.2.6. Среднеквадратичное отклонение

Среднеквадратичное (среднеквадратическое, стандартное) отклонение SD (standard deviation) вычисляется как

$$SD = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2},$$

где x_i – значение i -го элемента временного ряда ($i = \overline{1, N}$); $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ – среднее арифметическое элементов временного ряда; N – число наблюдаемых последовательных значений элементов временного ряда.

Среднеквадратичное (среднеквадратическое, стандартное) отклонение SD характеризует рассеивание значений элементов временного ряда относительно среднего арифметического элементов временного ряда.

2.2.7. Максимальное значение

Максимальное значение Max (maximum) вычисляется как

$$Max = \max_{i=1, N} x_i,$$

где x_i – значение i -го элемента временного ряда ($i = \overline{1, N}$); N – число наблюдаемых последовательных значений элементов временного ряда.

2.2.8. Минимальное значение

Минимальное значение Min (minimum) вычисляется как

$$Min = \min_{i=1, N} x_i,$$

где x_i – значение i -го элемента временного ряда ($i = \overline{1, N}$); N – число наблюдаемых последовательных значений элементов временного ряда.

Минимальное значение Min используется совместно с максимальным значением Max для описания границ диапазона наблюдаемых значений временного ряда.

2.3. Методика расчета значений признаков

Значения признаков в том или ином наборе данных, используемом для обучения классификаторов моторных образов, в предлагаемом исследовании вычисляются на основе одного из методов, представленных в п. 2.2, в соответствии с методикой, описываемой следующей последовательностью шагов.

1. Взять один из 5 наборов данных, описанных в п. 1 (таблица 1).
2. Выполнить фильтрацию данных с использованием метода Баттерворта 5-го порядка.
3. Выбрать из набора данных поднаборы, содержащие строки, маркированные определенной меткой класса (Right, Left, Up, Down, Neutral).
4. Осуществить проход по каждому из поднаборов с размером окна N ($N = 1, 2$ или 3 секунды) и шагом h ($h = 0.25$ секунды), выбирая последовательно данные, сформированные в течение N секунд, и обрабатывая их с применением одного из методов, представленных в п. 1.3 для формирования значений признаков, а затем смещаясь по данным на величину шага h .

На шаге 4 в каждом поднаборе, полученном на шаге 3, при $N = 1$ (т.е. для таймфрейма размером в 1 секунду) последовательно с применением того или иного метода, представленного в п. 1.3, обрабатываются строки с номерами 0 – 128, 32 – 160, 64 – 192, ...; при $N = 2$ последовательно обрабатываются строки с номерами 0 – 256, 32 – 288, 64 – 320, ...; при $N = 3$ последовательно обрабатываются строки с номерами 0 – 384, 32 – 416, 64 – 448, Если в какой-то момент прохода по данным уже не удастся извлечь данные, сформированные в течение N секунд (т.е. данных меньше, чем необходимо), то проход по данным рассматриваемого поднабора (а, следовательно, и формирование значений признаков) завершается.

Так как каждый набор данных (таблица 1.1) содержит информацию о 14 временных рядах, то действия, описанные на шаге 4, выполняются для каждого временного ряда, т.е. на основе каждого временного ряда формируются значения признака, соответствующего этому временному ряду.

В результате прохода по данным на основе фрагмента этих данных размером $N \times 14$, где N – число строк, 14 –

число столбцов, формируется строка нового набора данных, содержащего значения признаков.

При этом в случае работы со всеми методами, кроме метода, предполагающего рассмотрение спектральной плотности энергии, будут вычисляться значения 14 признаков, т.е. строка нового набора данных будет содержать 14 значений.

Результаты применения описанной методики при фиксированном размере окна N к каждому из 5 наборов данных, представленных в таблице 1, объединяются в один новый интегральный набор данных, который содержит извлеченные из временных рядов признаки.

Т.к. в предлагаемом исследовании рассматриваются 3 варианта размера окна N , а число способов извлечения признаков равно 8, то в итоге будет сформировано 24 новых набора данных, которые и будут в дальнейшем использоваться при обучении классификаторов моторных образов.

2.4. Разработка классификаторов

Для классификации моторных образов обычно используются различные методы распознавания образов [18]. В данном исследовании используются три метода распознавания образов, предполагающих разработку классификаторов на основе таких инструментов машинного обучения, как машина опорных векторов (Support Vector Machine, SVM), случайный лес (Random Forest, RF) и многослойный перцептрон (MultiLayer Perceptron, MLP).

Машина опорных векторов осуществляет построение гиперплоскости, разделяющей классы данных, максимизируя при этом ширину полосы (зазора) между классами [19]. Машина опорных векторов может работать с различными функциями ядра для перехода в пространство более высокой размерности с целью обеспечения более точного разделения точек данных на классы.

Кроме того, при использовании машины опорных векторов можно в явном виде выписать правило классификации данных.

Машина опорных векторов решает задачу бинарной классификации, но может быть легко адаптирована для решения задачи многоклассовой классификации.

Случайный лес использует ансамблевое обучение, в котором задействованы несколько деревьев решений, итоговое классификационное решение принимается по результатам голосования деревьев [20]. При этом можно оперировать выбором функции измерения качества разбиения данных, максимальной глубиной дерева, а также максимальным числом признаков, которые следует учитывать при поиске лучшего разбиения данных, и др. Случайный лес позволяет решать задачу многоклассовой классификации.

Многослойный перцептрон состоит из одного или нескольких скрытых слоев, содержащих некоторое число нейронов, и выходного слоя с функцией активации, которая определяет классификационное решение [21].

При этом можно оперировать выбором функции активации, выбором метода оптимизации для поиска весов нейронов, числом эпох, в течение которого происходит обучение, и др.

Многослойный перцептрон также позволяет решать задачу многоклассовой классификации.

3. Экспериментальные исследования

Экспериментальные исследования были выполнены с использованием языка программирования Python 3.10 в среде Google Colab. Разработка программного обеспечения осуществлялась с применением библиотеки `scikit-learn` для разработки классификаторов.

При разработке классификаторов использовалось 24 набора данных, полученных с применением методики, описанной в п. 2.3. При поиске лучших классификаторов осуществлялся поиск значений параметров по сетке.

В таблице 2 для каждого параметра, сопоставленного тому или иному классификатору, указаны списки значений, перебиравшихся при проходе по сетке при разработке классификаторов с целью выбора лучшего с точки зрения максимизации F -меры.

Для параметров, не указанных в таблице 2, использовались значения, заданные по умолчанию.

В таблице 3 представлены результаты оценки качества классификации данных с использованием лучших SVM-, RF-, MLP-классификаторов с применением F -меры в случае k -fold кросс-валидации при $k = 5$.

Анализ результатов оценки качества разработанных классификаторов позволяет сделать следующие выводы.

Классификаторы, при разработке которых использовались наборы данных на основе таймфреймов размером в 3 секунды, имеют более высокое качество, чем одноименные классификаторы, разработанные с применением наборов данных на основе таймфреймов размером в 1 и 2 секунды, при применении одного и того же метода обработки временных рядов.

Таблица 2 – Значения параметров классификаторов для обучения

Классификатор	Значения параметров
SVM	параметр регуляризации C : [1, 10, 100]; тип функции ядра $kernel$: ["rbf", "poly"]; параметр радиальной базисной функции $gamma$: [1, 0.1, 0.001]; степень полинома для полиномиальной функции ядра $degree$: [3, 4].
RF	число деревьев $n_estimators$: [25, 50, 100]; максимальное число признаков $max_features$: ['sqrt', 'log2']; максимальная глубина дерева max_depth : [3, 6, 9, 12].
MLP	оптимизатор весов $solver$: ['adam', 'sgd']; функция активации $activation$: ['logistic', 'relu', 'alpha': [0.0001, 0.001, 0.005]; максимальное количество эпох max_iter : [500]; кортеж, описывающий число скрытых слоёв и элементов в скрытых слоях, $hidden_layer_sizes$: [(100, 100), (50, 50), (100, 50, 100)].

Таблица 3 – Оценка качества классификаторов

Показатель	F-мера, k-fold-валидация при k=5, таймфрейм – 1 сек			F-мера, k-fold-валидация при k=5, таймфрейм – 2 сек			F-мера, k-fold-валидация при k=5, таймфрейм – 3 сек		
	SVM	RF	MLP	SVM	RF	MLP	SVM	RF	MLP
Фракт. разм. Хигучи	0.58	0.60	0.50	0.68	0.76	0.59	<i>0.74</i>	<i>0.84</i>	<i>0.64</i>
Энтропия Шеннона	0.67	0.70	0.60	0.77	0.84	0.69	0.82	0.88	0.73
Средн. арифм.	0.21	0.29	0.22	0.22	0.28	0.20	0.21	0.28	0.21
Медиана	0.26	0.33	0.27	0.29	0.41	0.26	0.30	0.52	0.29
Среднее абс. откл.	0.57	0.73	0.55	0.64	0.85	0.61	<i>0.69</i>	<i>0.89</i>	<i>0.71</i>
Среднеквадр. отклонение	0.53	0.74	0.53	0.64	0.84	0.66	0.62	0.91	0.65
Макс. значение	0.40	0.70	0.40	0.42	0.90	0.41	0.43	0.95	0.44
Мин. значение	0.48	0.75	0.27	0.50	0.90	0.28	0.50	0.94	0.29

Кроме того, видно, что наиболее высокое качество обеспечивает RF-классификатор при таймфрейме размером в 3 секунды в случае использования методов обработки временных рядов на основе среднеквадратичного отклонения, максимального и минимального значений (соответствующие значения оценок качества классификаторов выделены в таблице 3 жирным курсивом).

Однако SVM- и MLP-классификаторы при использовании этих же методов обработки временных рядов имеют существенно более низкое качество.

Более стабильное качество классификации (в смысле близости оценок качества классификации с применением для SVM-, RF- и MLP) обеспечивают методы обработки временных рядов на основе фрактальной размерности Хигучи и энтропии Шеннона – соответствующие значения оценок качества классификаторов выделены в таблице 3 курсивом и жирным шрифтом соответственно.

При этом явное преимущество – на стороне метода обработки временных рядов на основе энтропии Шеннона.

В таблице 4 приведены значения параметров лучших классификаторов, разработанных с применением наборов данных на основе таймфреймов размером в 3 секунды и метода обработки временных рядов на основе энтропии Шеннона.

Таблица 4 – Значения параметров лучших классификаторов

Классификатор	Значения параметров
SVM	параметр регуляризации C : 1; тип функции ядра $kernel$: "rbf"; параметр радиальной базисной функции $gamma$: 1
RF	число деревьев $n_estimators$: 100; максимальное число признаков $max_features$: 'sqrt'; максимальная глубина дерева max_depth : 12.
MLP	оптимизатор весов $solver$: 'adam'; функция активации $activation$: ['logistic', 'relu'], $alpha$: 0.0001; максимальное количество эпох max_iter : 500; кортеж, описывающий число скрытых слоёв и элементов в скрытых слоях, $hidden_layer_sizes$: (100, 100).

Следует отметить, что лучший классификатор – RF-классификатор – был получен при максимальном числе деревьев и максимальной глубине дерева.

Заключение

Результаты выполненных исследований по разработке классификаторов моторных образов позволили сделать выводы о целесообразности использования таймфреймов размером в 3 секунды при формировании признаков, применяемых в наборы данных, используемых при разработке классификаторов. При этом наиболее перспективным является применение энтропии Шеннона, а затем – фрактальной размерности Хигучи для формирования признаков в наборах данных.

Целью дальнейших исследований является введение в рассмотрение дополнительных методов обработки временных рядов, в частности, спектральной плотности энергии. В этом случае будет использоваться не 14-мерный, а 56-мерный набор данных, сформированный с учетом данных из 4 диапазонов частот (дельта, тета, альфа, бета). Кроме того, планируется исследовать вопросы целесообразности снижения размерности используемых наборов данных посредством применения алгоритмов нелинейного снижения размерности [22, 23].

Список литературы

1. Борисова В.А. Возможности интерфейса «мозг-компьютер» в коррекции постинсультных когнитивных нарушений / В. А. Борисова, Е. В. Исакова, С. В. Котов // Журнал неврологии и психиатрии им. С.С. Корсакова, 2022. – Т. 122, № 12-2. – С. 60–66.
2. Зуев А.С., Исаев Р.А. Нейроинтерфейсы – новый инструментальный человеко-компьютерного взаимодействия // Научные технологии, 2022. – Т. 23. – № 2. – С. 70–82.
3. Бирюкова Е.В., Бобров П.Д. Нейрореабилитация с применением экзоскелета руки, управляемого интерфейсом «мозг-компьютер»: реализованный междисциплинарный проект // Авиакосмическая и экологическая медицина, 2020. – Т. 54. – № 6. – С. 117–124.
4. Левицкая О.М., Лебедев М.А. Интерфейс мозг–компьютер: будущее в настоящем // Вестник РГМУ, 2016. №2. С. 4–16.
5. Федотчев А.И., Парин С.Б., Полевая С.А., Великова С.Д. Технологии «Интерфейс мозг-компьютер» и нейробиоуправление: современное состояние, проблемы и возможности клинического применения (обзор) // Современные технологии в медицине, 2017. – №1. – С. 175–184.
6. Saha S., Mamun K., Ahmed K., Mostafa R., Naik G.R., Darvishi S., Khandoker A.H., Baumert M. Progress in Brain Computer Interface: Challenges and Opportunities // Frontiers in Systems Neuroscience, 2021. – Vol. 15. – P. 578875.
7. Ahn M., Jun S.C. Performance variation in motor imagery brain–computer interface: a brief review // Journal of Neuroscience Methods, 2015. – Vol. 243. – P. 103–110.
8. Vega R., Sajed T., Mathewson K.W., Khare K., et al. Assessment of feature selection and classification methods for recognizing motor imagery tasks from electroencephalographic signals // Artificial Intelligence Research, 2017. Vol.

6(1). P. 37–51.

9. Lotte F., Bougrain L., Cichocki A., Clerc M., et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update // *Journal of Neural Engineering*, 2018. – Vol. 16. – P. 031005.

10. Shenoy P., Krauledat M., Blankertz B., Rao R.P.N., Müller K.R. Towards adaptive classification for BCI // *Journal of Neural Engineering*, 2006. – Vol. 3(1). – P. 13–23.

11. Jayaram V., Alamgir M., Altun Y., Scholkopf B., Grosse-Wentrup M. Transfer Learning in Brain-Computer Interfaces // *IEEE Computational Intelligence Magazine*, 2016. – Vol. 11(1). P. 20–31.

12. Wu W., Chen Z., Gao X., Li Y., Brown E.N., Gao S. Probabilistic Common Spatial Patterns for Multichannel EEG Analysis // *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015. – Vol. 37(3). P. 639–653.

13. Sannelli C., Vidaurre C., Müller K.R., Blankertz B. Ensembles of adaptive spatial filters increase BCI performance: an online evaluation // *Journal of Neural Engineering*, 2016. – Vol. 13(4). – P. 046003.

14. Kevric J., Subasi A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system // *Biomed Signal Process Control*, 2017. – Vol. 31. – P. 398–406.

15. Kamousi B., Liu Z., He B. Classification of motor imagery tasks for brain-computer interface applications by means of two equivalent dipoles analysis // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2005. – Vol. 13(2). – P. 166–171.

16. Shan H., Yuan H., Zhu S., He B. EEG-based motor imagery classification accuracy improves with gradually increased channel number // *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, San Diego, CA, USA, 2012.* – P. 1695–1698.

17. Lotte F., Guan C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms // *IEEE Transactions on Biomedical Engineering*, 2011. – Vol. 58(2). – P. 355–362.

18. Wang H., Zhang Y. Detection of motor imagery EEG signals employing Naïve Bayes based learning process // *Measurement*, 2016. – Vol. 86. – P. 148–158.

19. Richhariya B., Tanveer M. EEG signal classification using universum support vector machine // *Expert Systems with Applications*, 2018. – Vol. 106. P. 169 – 182.

20. Edla D.R., Mangalorekar K., Gauri Dhavalikar and Shubham Dodia. Classification of EEG data for human mental state analysis using Random Forest Classifier // *Procedia Computer Science*, 2018. – Vol. 132. – P. 1523–1532.

21. Сергеев А.П. Введение в нейросетевое моделирование: учеб. пособие / А.П. Сергеев, Д.А. Тарасов ; под общ. ред. А.П. Сергеева. – Екатеринбург: Изд-во Урал. ун-та, 2017. – 128 с.

22. McInnes L., Healy J. Melville J. UMAP: Uniform manifold approximation and projection for dimension reduction // *arXiv:1802.03426*, 2018.

23. Demidova L.A., Gorchakov A.V. Fuzzy Information Discrimination Measures and Their Application to Low Dimensional Embedding Construction in the UMAP Algorithm // *Journal of Imaging*, 2022. – Vol. 8(4). – P. 113. <https://doi.org/10.3390/jimaging8040113>.

References

1. Borisova V.A. Possibilities of the brain-computer interface in the correction of post-stroke cognitive impairment / V.A. Borisova, E.V. Isakova, S.V. Kotov // *Journal of Neurology and Psychiatry named after. C.C. Korsakova*, 2022. – Vol. 122, No. 12-2. – P. 60–66.

2. Zuev A.S., Isaev R.A. Neurointerfaces – a new toolkit for human-computer interaction // *Science-intensive technologies*, 2022. – Vol. 23. – No. 2. – P. 70–82.

3. Biryukova E.V., Bobrov P.D. Neurorehabilitation using a hand exoskeleton controlled by a brain-computer interface: a completed interdisciplinary project // *Aerospace and environmental medicine*, 2020. – Vol. 54. – No. 6. – P. 117–124.

4. Levitskaya O.M., Lebedev M.A. Brain-computer interface: the future in the present // *Bulletin of the Russian State Medical University*, 2016. No. 2. – P. 4–16.

5. Fedotchev A.I., Parin S.B., Polevaya S.A., Velikova S.D. “Brain-computer interface” technologies and neurofeedback: current state, problems and opportunities for clinical application (review) // *Modern technologies in medicine*, 2017. – No. 1. – P. 175–184.

6. Saha S., Mamun K., Ahmed K., Mostafa R., Naik G.R., Darvishi S., Khandoker A.H., Baumert M. Progress in Brain Computer Interface: Challenges and Opportunities // *Frontiers in Systems Neuroscience*, 2021. – Vol. 15. – P. 578875.

7. Ahn M., Jun S.C. Performance variation in motor imagery brain–computer interface: a brief review // *Journal of Neuroscience Methods*, 2015. – Vol. 243. – P. 103–110.
8. Vega R., Sajed T., Mathewson K.W., Khare K., et al. Assessment of feature selection and classification methods for recognizing motor imagery tasks from electroencephalographic signals // *Artificial Intelligence Research*, 2017. Vol. 6(1). P. 37–51.
9. Lotte F., Bougrain L., Cichocki A., Clerc M., et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update // *Journal of Neural Engineering*, 2018. – Vol. 16. – P. 031005.
10. Shenoy P., Krauledat M., Blankertz B., Rao R.P.N., Müller K.R. Towards adaptive classification for BCI // *Journal of Neural Engineering*, 2006. – Vol. 3(1). – P. 13–23.
11. Jayaram V., Alamgir M., Altun Y., Scholkopf B., Grosse-Wentrup M. Transfer Learning in Brain-Computer Interfaces // *IEEE Computational Intelligence Magazine*, 2016. – Vol. 11(1). P. 20–31.
12. Wu W., Chen Z., Gao X., Li Y., Brown E.N., Gao S. Probabilistic Common Spatial Patterns for Multichannel EEG Analysis // *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015. – Vol. 37(3). P. 639–653.
13. Sannelli C., Vidaurre C., Müller K.R., Blankertz B. Ensembles of adaptive spatial filters increase BCI performance: an online evaluation // *Journal of Neural Engineering*, 2016. – Vol. 13(4). – P. 046003.
14. Kevric J., Subasi A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system // *Biomed Signal Process Control*, 2017. – Vol. 31. – P. 398–406.
15. Kamousi B., Liu Z., He B. Classification of motor imagery tasks for brain-computer interface applications by means of two equivalent dipoles analysis // *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2005. – Vol. 13(2). – P. 166–171.
16. Shan H., Yuan H., Zhu S., He B. EEG-based motor imagery classification accuracy improves with gradually increased channel number // *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, San Diego, CA, USA, 2012.* – P. 1695–1698.
17. Lotte F., Guan C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms // *IEEE Transactions on Biomedical Engineering*, 2011. – Vol. 58(2). – P. 355–362.
18. Wang H., Zhang Y. Detection of motor imagery EEG signals employing Naïve Bayes based learning process // *Measurement*, 2016. – Vol. 86. – P. 148–158.
19. Richhariya B., Tanveer M. EEG signal classification using universum support vector machine // *Expert Systems with Applications*, 2018. – Vol. 106. P. 169 – 182.
20. Edla D.R., Mangalorekar K., Gauri Dhavalikar and Shubham Dodia. Classification of EEG data for human mental state analysis using Random Forest Classifier // *Procedia Computer Science*, 2018. – Vol. 132. – P. 1523–1532.
21. Sergeev A.P. Introduction to neural network modeling: textbook. allowance / A.P. Sergeev, D.A. Tarasov; under general ed. A.P. Sergeeva. – Ekaterinburg: Ural Publishing House. University, 2017. – 128 p.
22. McInnes L., Healy J. Melville J. UMAP: Uniform manifold approximation and projection for dimension reduction // *arXiv:1802.03426*, 2018.
23. Demidova L.A., Gorchakov A.V. Fuzzy Information Discrimination Measures and Their Application to Low Dimensional Embedding Construction in the UMAP Algorithm // *Journal of Imaging*, 2022. – Vol. 8(4). – P. 113. <https://doi.org/10.3390/jimaging8040113>.