

## ПОВЫШЕНИЕ ЭФФЕКТИВНОСТИ ИНТЕРФЕЙСОВ «МОЗГ-КОМПЬЮТЕР», СОЗДАВАЕМЫХ НА ОСНОВЕ СИГНАЛОВ ЭЭГ

### IMPROVING THE EFFICIENCY OF BRAIN-COMPUTER INTERFACES CREATED ON THE BASIS OF EEG SIGNALS

*Al-Duhaidahawi Murtadha Ahmed Luti*  
*Al-Nasrawi Faris Hazim*  
*Yu. Tomashevsky*

*Summary.* The paper is devoted to the topical topic of building a non-invasive brain-computer interface system (BCI). The way to increase the efficiency of BCI by solving the problem of mute speech, in which the subject speaks mentally without generating acoustic signals, is considered. EEG signals are used to recognize vowels. The process of training and classification of 5 groups of data using a periodogram, a decision tree and a support vector machine is described. An approximate view of the error matrix is given, and some recommendations for future work are given.

*Keywords:* brain-computer interface, electroencephalogram, support vector machine, error matrix.

*Аль-Духейдахави Муртадха Ахмед Лутти*

*Аспирант, Саратовский государственный  
технический университет имени Гагарина Ю.А.,  
г. Саратов  
murtazalute7@gmail.com*

*Аль-Насрави Фарис Хазим*

*Аспирант, Саратовский государственный  
технический университет имени Гагарина Ю.А.,  
г. Саратов  
farisiraq21@gmail.com*

*Томашевский Юрий Болеславович*

*Д.т.н., профессор, Саратовский государственный  
технический университет имени Гагарина Ю.А.,  
г. Саратов  
tomash@sstu.ru*

*Аннотация.* Работа посвящена актуальной теме построения неинвазивной системы интерфейса «мозг-компьютер» (ИМК). Рассмотрен путь повышения эффективности ИМК путем решения задачи немой речи, при которой субъект мысленно говорит, не генерируя акустических сигналов. Для распознавания гласных используются сигналы ЭЭГ. Описан процесс обучения и классификации 5 групп данных с использованием периодограммы, дерева решений и метода опорных векторов. Приведен примерный вид матрицы ошибок, даны некоторые рекомендации для будущей работы.

*Ключевые слова:* интерфейс «мозг-компьютер», электроэнцефалограмма, метод опорных векторов, матрица ошибок.

### Введение

**И**нтерфейс «мозг-компьютер» (ИМК) представляет собой систему, которая позволяет человеку управлять внешним техническим устройством без участия нервов и мышц, основываясь только на сигналах, генерируемых мозгом. Фактически ИМК формирует искусственные выходы нервной системы, что является сравнительно новым и перспективным подходом к обеспечению человеко-машинного взаимодействия. ИМК были предложены и нашли свое основное применение в качестве средства помощи пациентам с тяжелыми нарушениями двигательных функций (параличом большей части тела). Для повышения качества жизни таких пациентов были разработаны ИМК, обеспечивающие набор текста, управление протезами конечностей, инвалидными креслами, экзоскелетами и пр. Также в настоящее

время ИМК может применяться и здоровыми людьми для управления роботизированными манипуляторами, автомобилем, квадрокоптером, 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 исследования является 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 [1–8]. Большое разноо-

бразии 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.

Основу математического обеспечения ИМК составляют методы теории цифровой обработки сигналов и теории машинного обучения. Задача распознавания мысленных команд пользователя сводится в ИМК к задаче классификации многомерных временных рядов, в виде которых записи ЭЭГ сохраняются в компьютере. Принадлежность временного ряда к одному из известных классов определяют на основе следующих подходов: 1) измерение сходства временных рядов путем нахождения расстояния между ними (с помощью евклидова расстояния или алгоритма динамической трансформации временной шкалы (Jeong, Jeong, & Omitaomu, 2011)); 2) выделение характерных признаков временного ряда и классификация в пространстве признаков (Fulcher, 2017; Vasimalla, 2014); 3) формирование модели процесса, порождающего временной ряд (с помощью скрытых марковских моделей (Esmael, Arnaout, Fruhwirth, & Thonhauser, 2012), рекуррентных нейронных сетей (Che, Purushotham, Cho, Sontag, & Liu, 2018) и др.). Второй подход получил широкое распространение в исследованиях ИМК и рассматривается в статье.

1. Анализ разработок в сфере неинвазивных ИМК показал, что процедура распознавания мысленных команд пользователя по записи ЭЭГ включает в себя три основных этапа: а) предобработка ЭЭГ, б) формирование характерных признаков многомерных временных рядов, в виде которых записи ЭЭГ сохраняются в компьютере, в) классификация в пространстве характерных признаков (ХП). Установлено, что качество распознавания команд пользователя в ИМК зависит как от выбора алгоритма классификации, так и от выбора метода формирования ХП.

2. Проведен анализ известных методов формирования ХП и выявлены их недостатки, ограничивающие эффективность ИМК. К таким недостаткам относятся: а) отсутствие средств для адаптации методов под особенности конкретного пользователя ИМК; б) высокая размерность получаемых векторов ХП (как правило, большая или равная числу каналов в ЭЭГ); в) включение в вектор ХП «шумовых» (неинформативных) признаков.
3. Для преодоления указанных недостатков в статье описан подход, который заключается в оптимизации (повышении информативности) характерных признаков, подаваемых на вход классификаторов.

## Постановка и решение задачи

Рассмотрим первый шаг реализации метода распознавания гласных и согласных, например, в распознавании слов и предложений, а именно — распознавание английских гласных с использованием сигналов ЭЭГ.

Решение данной задачи может помочь безмолвным людям общаться с окружающей средой. В некоторой литературе этот процесс называется немой речью, при которой субъект мысленно говорит, не генерируя акустических сигналов [9]. Важной частью идентификации слов, отличающихся друг от друга, является различение разных гласных. Поскольку на разные участки мозга возложены разные функции, то при мысленном произнесении слова человеком будут происходить изменения в определенных зонах левого полушария. Рассмотрим пять английских гласных /a/, /e/, /i/, /o/ и /u/.

На рисунке 1 показан график набора из 21 усиленного сигнала ЭЭГ, снятого в одном эксперименте у одного испытуемого.

На рисунке 2 показан сигнал от испытуемого при первой попытке подумать о /a/ до и после этапа фильтрации, реализованного с помощью полосового фильтра, технические характеристики которого представлены на рисунке 3.

Так как используемые данные являются стохастическими, то для определения частотного спектра сигналов будем использовать спектральную плотность мощности (power spectral density (PSD), англ.). Чтобы уменьшить размер матрицы данных, использовался метод периодограммы, заключающийся в разбиении данных временного ряда на небольшие части, работе с каждой частью отдельно, а затем объединении всех частей.

Рис. 4 иллюстрирует среднее значение периодограммы у одного из испытуемых. Сравнивая результаты, можно заметить некоторое сходство между изменением по-

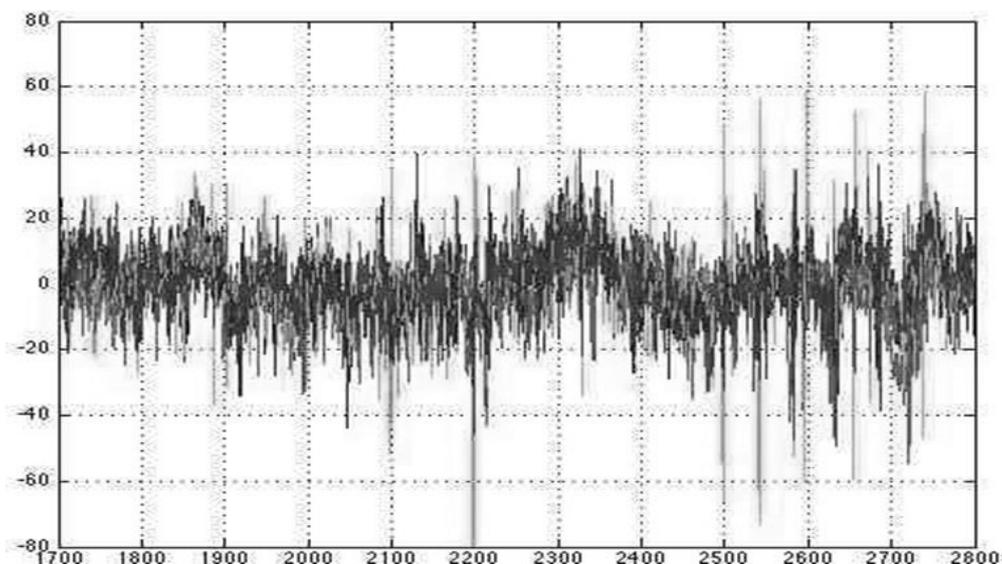


Рис. 1. Необработанные сигналы для 21 канала в одном испытании

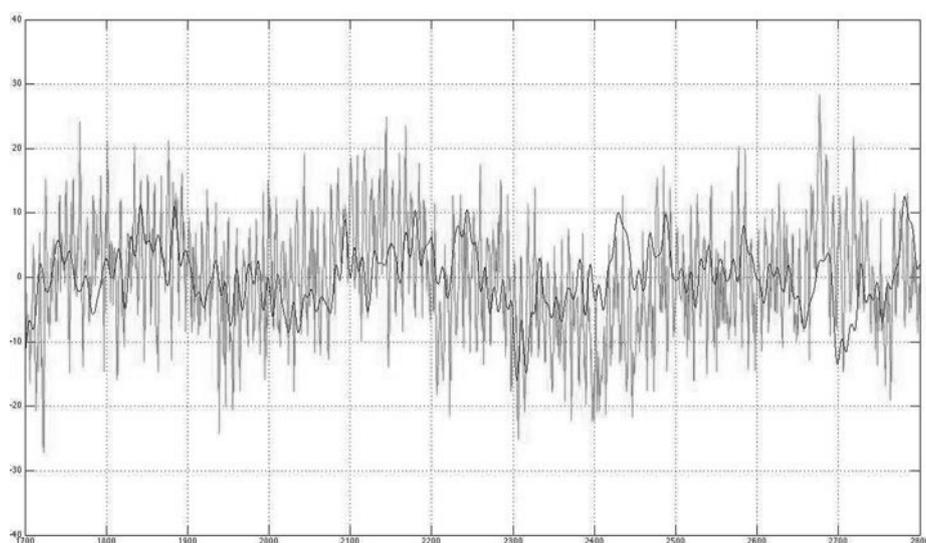


Рис. 2. Сигнал от одного электрода до и после фильтрации

ведения значений PSD. Похоже, что между электродами в каждом классе существует связь, которая отличается от других классов. Это можно использовать в качестве входных данных для последующей классификации.

Поскольку данные содержат 5 классов, воспользуемся методами «один против всех» и «один против одного».

Подход «один против всех» формирует отличия выборки каждого класса от всех других классов. Используя этот подход, задача N-класса будет разбита на  $n$  задач двух классов. В каждой из этих бинарных задач метки классов будут установлены как  $y=1$  для тех данных, кото-

рые помещаются в указанный класс, и  $y=-1$  для остальных данных.

Подход «один к одному» использует метод опорных векторов (support vector machine (SVM), англ.) для классификации всех возможных пар классов [10]. В конце точки данных будет помещена в класс, выбранный максимальным количеством бинарных SVM.

Выполним следующие шаги для создания дерева решений, когда каждый классификатор в каждом узле отделяет некоторый класс от остальных классов, используя евклидово расстояние.

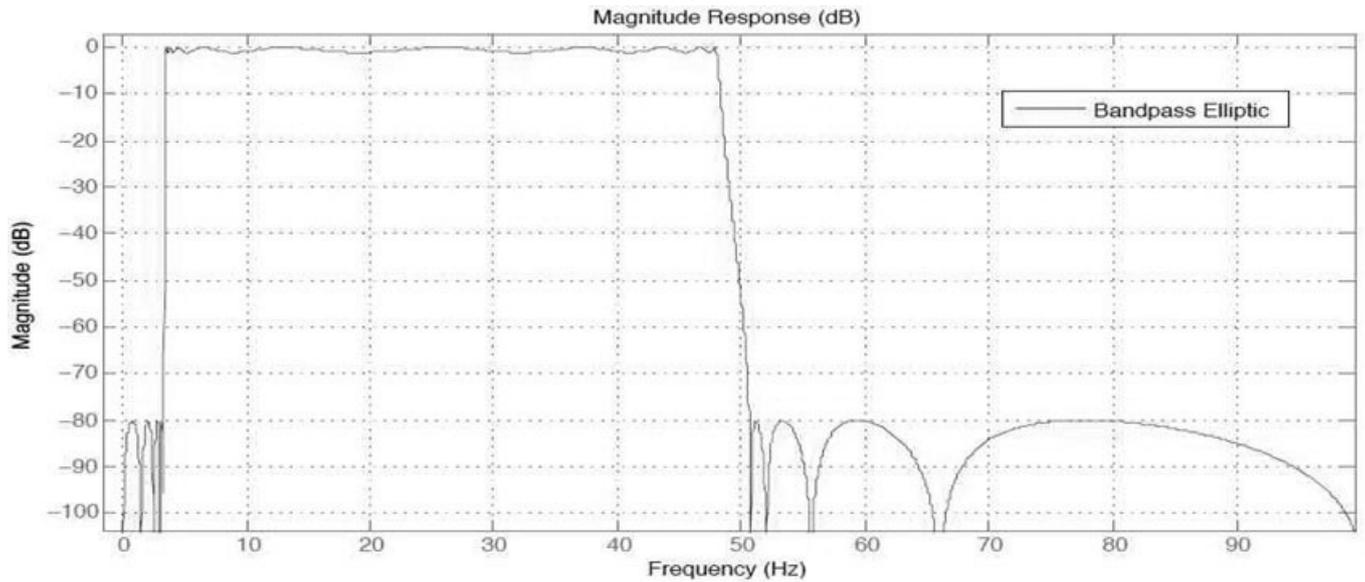


Рис. 3. Полосовой фильтр

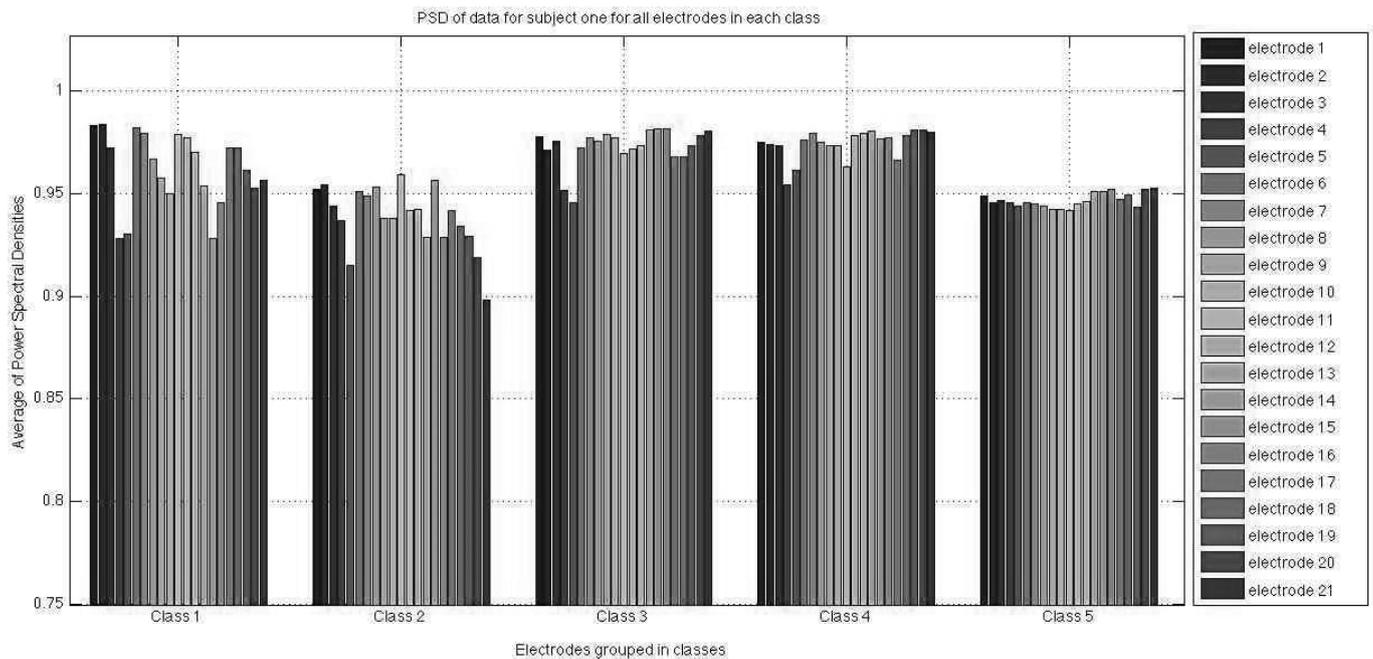


Рис. 4. Усреднение периодограмм по всем точкам данных для каждого канала

Шаг 1. Расчет центра каждого класса с использованием уравнения

$$c_i = \frac{1}{N} \sum_{x \in X_i} x,$$

где  $c_i$  — центр класса  $i$ ,  $x_i$  — набор обучающих данных, включенных в класс  $i$ , а  $N$  — количество элементов в классе  $i$  и расстояния между каждыми двумя классами с использованием уравнения

$$d_{ij} = \|c_i - c_j\|,$$

где  $d_{ij} = d_{ji}$  — расстояние между центрами классов  $i$  и  $j$ .

На этом шаге все классы отделяются друг от друга.

Шаг 2. Нахождение наименьшего расстояния между классом  $i$  и всеми другими классами с помощью уравнения

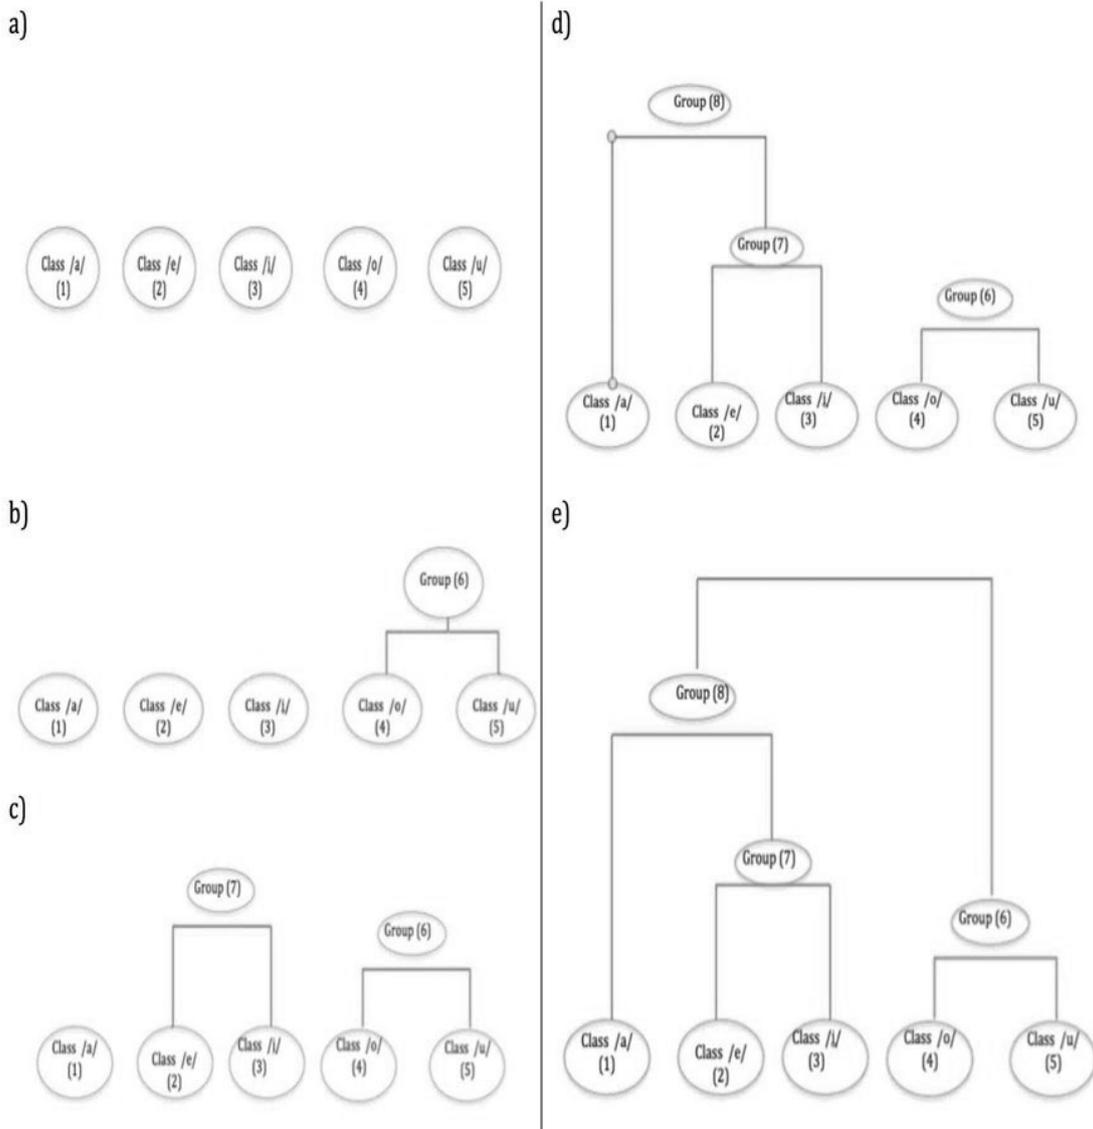


Рис. 5. а) группы обучающих данных, б) первая итерация применения древовидного алгоритма создает новую группу (6), в) вторая итерация применения древовидного алгоритма создает группу (7), д) третья итерация алгоритма дерева, применяемый к группам (7), (3) и (6), создает новую группу (8), е) наконец, есть только две группы (6) и (8) для классификации

$$l_i = \min_{j=1, \dots, N, i \neq j} d_{ij}$$

На основе рассчитанного списка мы помещаем связанные классы в один и тот же кластер.

Шаг 3. Повторяем с шага 1 (N-2) раза, пока не получим только два кластера.

Шаг 4. Использование SVM для разделения двух кластеров из шага 3.

Шаг 5. Проверка, имеет ли каждый кластер два или более двух классов. Если это два класса, обучаем SVM

разделять эти два класса. Если у него более двух классов, рассматриваем каждый класс в отдельном кластере и повторяем шаги с 3 по 5.

На рисунке 5 показано, как описанный выше алгоритм работает на каждом этапе для наших данных ЭЭГ. В соответствии с алгоритмом сначала вычисляется среднее значение всех выборок данных в каждом классе. Это среднее будет представителем всей группы. Например, среднее значение всех выборок из группы /a/ (или группы (1) на рисунке 5) возвращает вектор  $\bar{x}_1$ . С этого момента и до конца первой итерации вектор  $\bar{x}_1$  представляет группу (1). Делая это для всех групп данных, мы

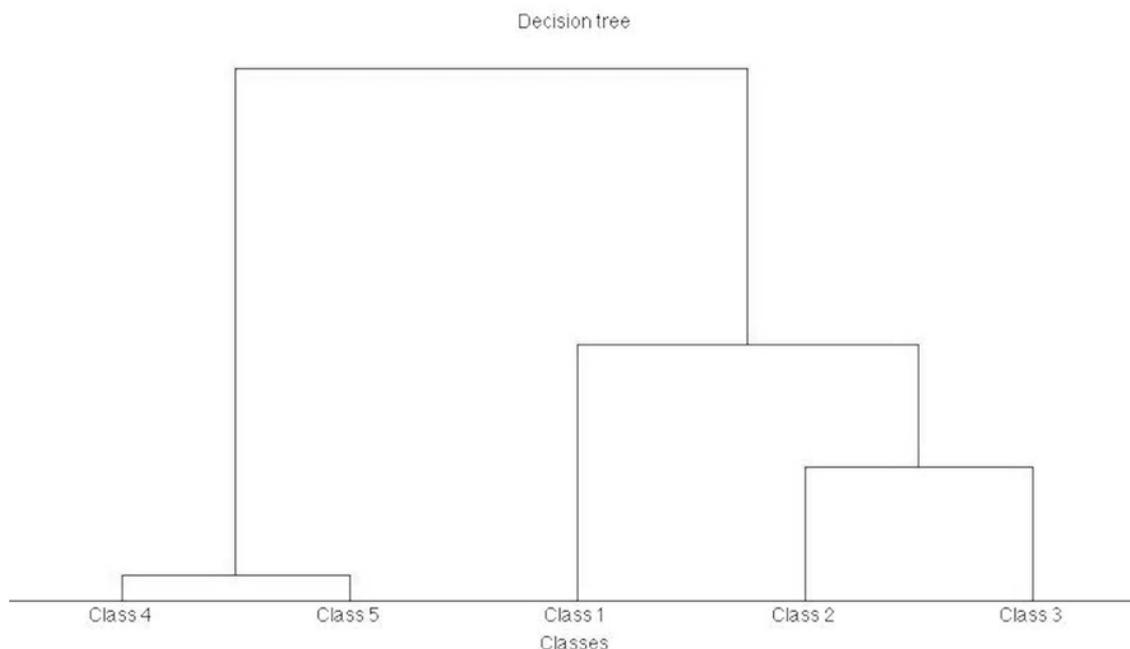


Рис. 6. Группировка классов по расстоянию между их центрами

получили бы вектора  $\bar{x}_1, \bar{x}_2, \bar{x}_3, \bar{x}_4$ , и  $\bar{x}_5$ , представляющие классы *a/*, */e/*, */i/*, */o/* и */y/* соответственно. Во-вторых, расстояние векторов будет рассчитано и сравнено. Минимальное расстояние определяет ближайшие группы. Как показано на рисунке 5, группы (4) и (5) находятся как наиболее близкие среди всех возможных пар. Объединение их в одну группу создает группу (6). На данный момент необходимо разделить только четыре группы данных вместо пяти групп, которые представляют собой группы (1), (2), (3) и (6), как показано на рисунке 5, b.

Результатом второй итерации алгоритма являются векторы  $\bar{x}_1, \bar{x}_2, \bar{x}_3$ , и  $\bar{x}_6$  как представители групп (1), (2), (3) и (6). Вычисляя расстояния всех возможных пар и сравнивая их друг с другом, группы (2) и (3) добиваются минимального расстояния. Таким образом, они будут помещены в один кластер как группа (7). Это превращает исходную задачу классификации с 5 классами в задачу классификации с 3 классами, как показано на рисунке 5, c.

Хотя исходная задача упрощается до новой с меньшим количеством групп данных, все же нужно выполнить еще одну итерацию алгоритма, чтобы решить проблему классификации бинарных классов. Вычисление среднего значения всех выборок в каждой из новых групп (1), (6) и (7) создает усредненные векторы  $\bar{x}_1, \bar{x}_6$ , и  $\bar{x}_7$ . Среди всех возможных пар этого шага минимальное расстояние составляет расстояние между группами (1) и (7). Помещение выборочных данных группы (1) и (7) в новую группу (8) (см. рисунок 5, d) уменьшает количество классов с трех до двух.

На этот момент необходимо разделить только две группы (6) и (8). Алгоритм дерева можно остановить от выполнения еще одной итерации, поскольку достигнута цель, заключающаяся в проблеме бинарной классификации, и нет необходимости проходить алгоритм дерева для еще одной итерации. Дерево решений было создано таким образом, что все исходные группы располагаются на листьях дерева, а каждый родительский узел может иметь только два дочерних узла. Кроме того, на каждом уровне дерева только один родительский узел может создавать своих потомков. Запуск алгоритма в MATLAB дает дерево, показанное на рисунке 6.

Наличие только одного родительского узла на каждом уровне дерева означает, что на каждом уровне существует проблема бинарного класса. Начиная с корневого узла дерева, можно обучить SVM-классификатор для разделения групп (6) и (8). Следующий уровень — это место, где должна быть обучена SVM разделить группы (1) и (7). Третий SVM-классификатор обучен для разделения групп (2) и (3). Наконец, группы (4) и (5) будут использоваться для обучения классификатора SVM4. Это показано на рисунке 7.

После обучения всех классификаторов SVM классификация новых данных должна быть легкой. На данный момент обучено четыре SVM разделять группы на каждом уровне. Как показано на рисунке 8, чтобы предсказать класс нового набора данных, требуется двигаться сверху вниз. Принять  $x_k$  за новый набор данных ЭЭГ, который хочет попасть в один из пяти классов */a/*, */e/*, */i/*, */o/* или */u/*.

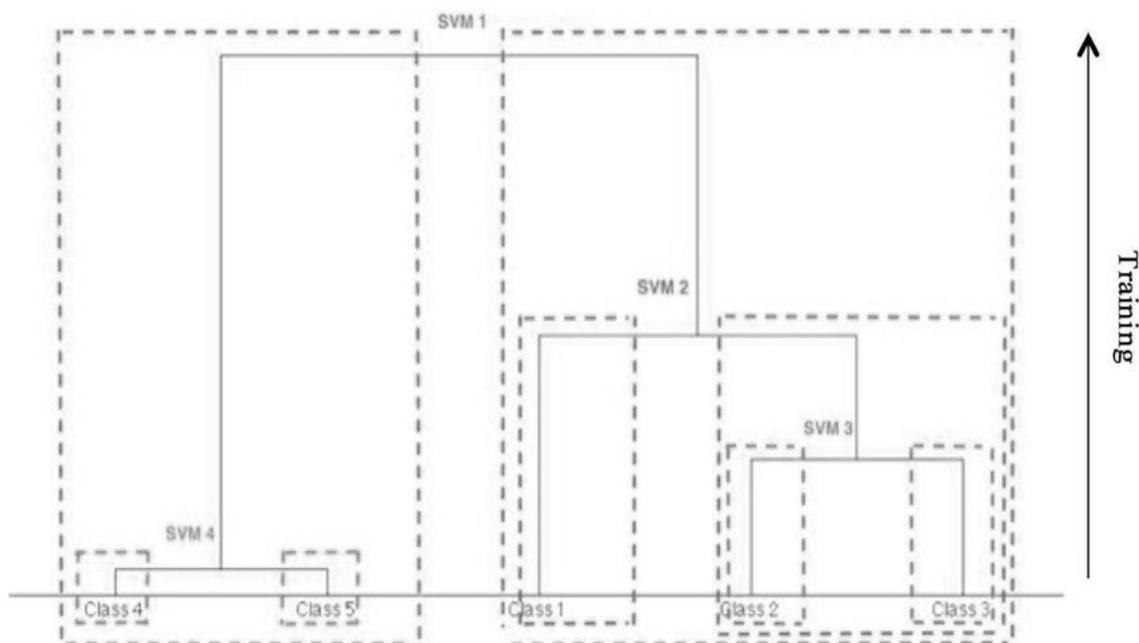


Рис. 7. Обучение SVM для групп классов

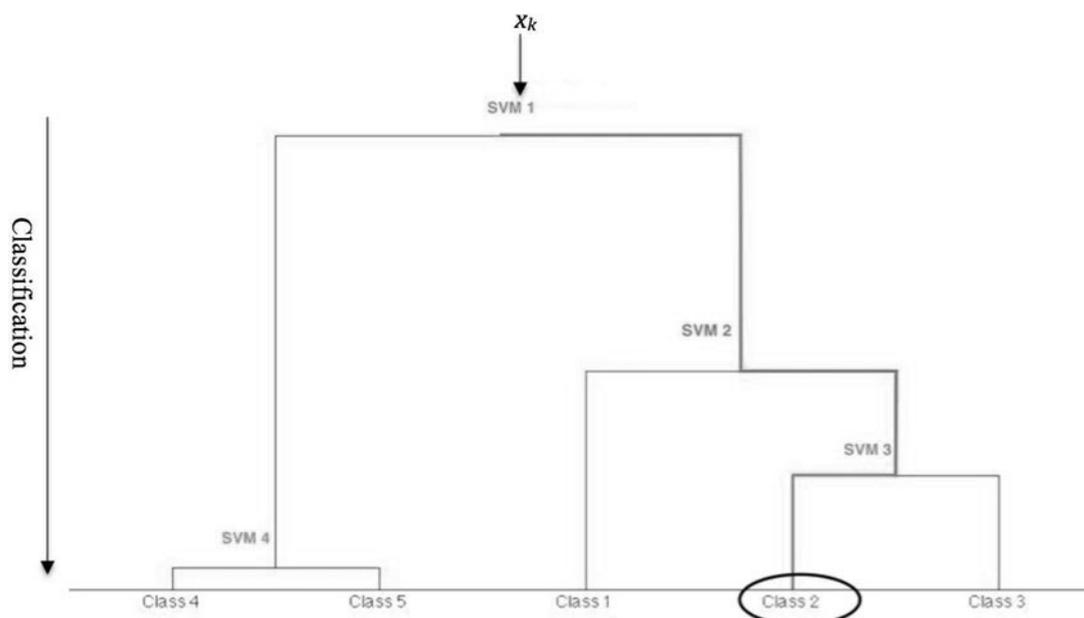


Рис. 8. Классификация нового набора входных данных  $x_k$

Начиная с вершины дерева, следует активировать SVM1, чтобы поместить новый набор данных либо в группу (6), либо в группу (8). На втором шаге, в зависимости от предсказания SVM1, будет выбран один из SVM2 или SVM4. Если представить, что SVM2 выбран для активации, в зависимости от обнаружения этого классификатора  $x_k$  будет помещен либо в группу (1), либо в группу (7). Если

выбрана группа (1), процесс завершится, и  $x_k$  перейдет в класс (1) или /a/. Если нет, SVM3 начинает определять, находится ли  $x_k$  в группе (2) или (3).

Примерный вид матрицы ошибок (confusion matrix), демонстрирующей результат классификации при для 90% всех данных и тестовом наборе, содержащем 10%

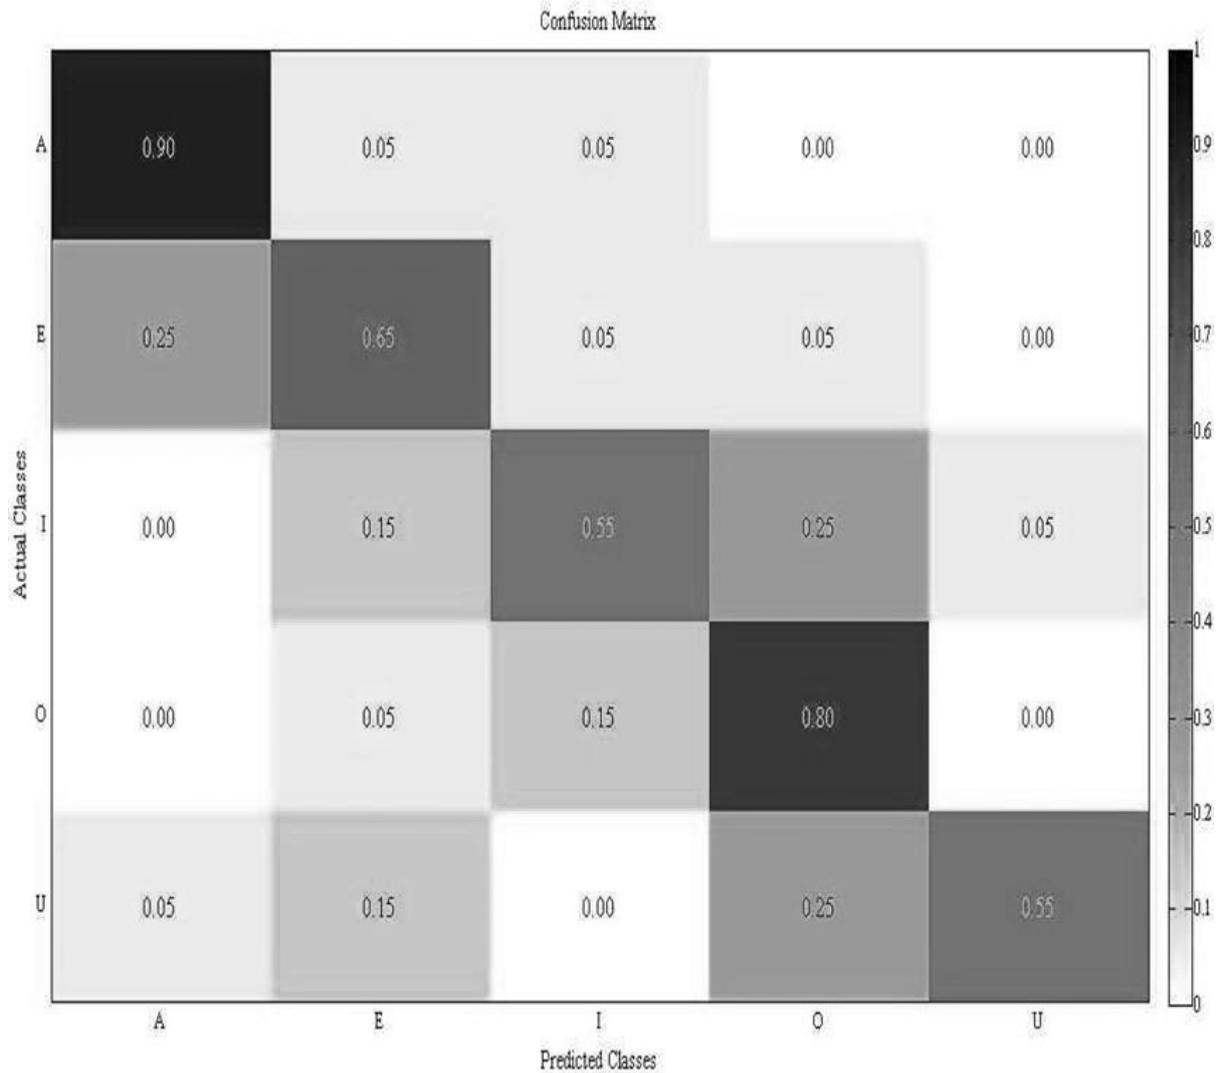


Рис. 9. Матрица ошибок

Интерпретация матрицы ошибок

	Class A	Class E	Class I	Class O	Class U
Correctly Detected	90%	65%	55%	80%	55%
Incorrectly Detected	5% <i>in E</i> 5% <i>in I</i>	25% <i>in A</i> 5% <i>in I</i> 5% <i>in O</i>	15% <i>in E</i> 25% <i>in O</i> 5% <i>in U</i>	5% <i>in E</i> 15% <i>in I</i>	5% <i>in A</i> 15% <i>in E</i> 25% <i>in O</i>

всех данных, представлен на рисунке 9. В таблице показаны детали матрицы ошибок.

Заключение

1. Показан путь повышения эффективности неинвазивной системы ИМК путем решения задачи немой речи, при которой субъект мысленно го-

ворит, не генерируя акустических сигналов. Отмечено, что важным компонентом в этом случае является распознавание гласных на базе использования сигналов ЭЭГ.

2. Описана процедура распознавания мысленных команд пользователя по записи ЭЭГ, включающая в себя три основных этапа: а) предобработка ЭЭГ, б) формирование характерных признаков много-

мерных временных рядов, в виде которых записи ЭЭГ сохраняются в компьютере, в) классификация в пространстве характерных признаков (ХП).

3. Установлено, что качество распознавания команд пользователя в ИМК зависит как от выбора алгоритма классификации, так и от выбора метода

формирования ХП. Представлен процесс обучения и классификации 5 групп данных с использованием периодограммы, дерева решений и метода опорных векторов.

4. Приведен примерный вид матрицы ошибок, даны некоторые рекомендации для будущей работы.

---

#### ЛИТЕРАТУРА

1. J. Wolpaw and E.W. Wolpaw, *Brain Computer Interfaces: Principles And Practice*. Oxford University Press, 2012.
2. J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, and T.M. Vaughan, "Brain Computer Interfaces For Communication And Control," *Clinical Neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
3. B.Z. Allison, E.W. Wolpaw, and J.R. Wolpaw, "Brain Computer Interface Systems: Progress And Prospects," *Expert Review of Medical Devices*, vol. 4, no. 4, pp. 463–474, 2007.
4. S. Silvoni, A. Ramos-Murguialday, M. Cavinato, C. Volpato, G. Cisetto, A. Tur-olla, F. Piccione, and N. Birbaumer, "Brain Computer Interface In Stroke: A Review Of Progress," *Clinical EEG and Neuroscience*, vol. 42, no. 4, pp. 245–252, 2011.
5. D. Xiao, Z. Mu, and J. Hu, "Classification Of Motor Imagery EEG Signals Based On Energy Entropy," *International Symposium on Intelligent Ubiquitous Computing and Education*. IEEE, pp. 61–64, 2009.
6. M.A. Lebedev and M.A. Nicolelis, "Brain Machine Interfaces: Past, Present And Future," *TRENDS in Neurosciences*, vol. 29, no. 9, pp. 536–546, 2006.
7. S. Siuly and Y. Li, "Improving The Separability Of Motor Imagery EEG Signals Using A Cross Correlation-Based Least Square Support Vector Machine For Brain Computer Interface," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 4, pp. 526–538, 2012.
8. R. Kus, D. Valbuena, J. Zygierewicz, T. Malechka, A. Graeser, and P. Durka, "Asynchronous BCI Based On Motor Imagery With Automated Calibration And Neurofeedback Training," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 6, pp. 823–835, 2012.
9. B. Denby, T. Schultz, K. Honda, T. Hueber, J.M. Gilbert, and J.S. Brumberg, "Silent Speech Interfaces," *Speech Communication*, vol. 52, no. 4, pp. 270–287, 2010.
10. Вьюгин В. Математические основы теории машинного обучения и прогнозирования / В. Вьюгин. — МЦМНО, 2013. 390 с.

---

© Аль-Духейдахи Муртадха Ахмед Лути ( murtazalute7@gmail.com ),  
Аль-Насрави Фарис Хазим ( farisiraq21@gmail.com ), Томашевский Юрий Болеславович ( tomash@sstu.ru ).  
Журнал «Современная наука: актуальные проблемы теории и практики»