

НОВЫЙ НЕЙРОСЕТЕВОЙ ПОДХОД К СОЗДАНИЮ ИМК НА ОСНОВЕ ЭЭГ-ПАТТЕРНОВ ПРОИЗВОЛЬНЫХ МЫСЛЕННЫХ ДВИЖЕНИЙ

© 2017 г. И.Е. Шепелев, Д.М. Лазуренко, В.Н. Киров,
Е.В. Асланян, О.М. Бахтин, Н.Р. Миняева

*НИТЦ нейротехнологий Южного федерального университета,
г. Ростов-на-Дону, Россия
e-mail: mityasky@ya.ru*

Поступила в редакцию 28.02.2017 г.
Принята в печать 03.05.2017 г.

Предложен новый нейросетевой подход к детекции и классификации пространственно-временных паттернов ЭЭГ, сопровождающих реализацию воображаемых (мысленных) движений, в режиме реального времени, основанный на методе локальной аппроксимации с использованием радиально-базисных функций и оригинальном алгоритме интерпретации временной последовательности ответов нейронной сети. На его основе создан и протестирован асинхронный нейроинтерфейс, базовым элементом которого является классификатор, включающий комитет из пяти нейронных сетей, обеспечивающих детекцию паттернов ЭЭГ, сопровождающих четыре типа мысленных движений. Проведена сравнительная оценка эффективности распознавания ЭЭГ-паттернов мысленных движений разработанным методом и классическими нейросетевыми методами, в частности, радиально-базисными сетями, многослойным перцептроном и методом опорных векторов. Экспериментально показан эффект обучения пользователей на повышение точности распознавания и классификации ЭЭГ-паттернов, а также скорости управления.

Ключевые слова: нейронная сеть, радиально-базисные функции, интерпретатор, мозговой интерфейс, электроэнцефалограмма, мысленные движения.

DOI: 10.7868/S0044467717040141

ВВЕДЕНИЕ

Одной из наиболее актуальных задач при создании интерфейсов мозг-компьютер (ИМК) является разработка алгоритмов и методов детекции, интерпретации и классификации специфических ЭЭГ-паттернов, способных обеспечить надежное управление внешними устройствами в режиме реального времени [Шепелев, Владимирский, 2010; Фролов и др., 2013; Wang et al., 2004; Wolpaw, Wolpaw, 2011; Cano-Izquierdo et al., 2012; Park et al., 2013; Pfurtsceller et al., 2013; Bhalla, Agrawal, 2014; Kirov et al., 2015]. Существующие методы и алгоритмы позволяют устойчиво идентифицировать не более 2–3 типов паттернов ЭЭГ, имеют более чем скромные показатели точности и скорости работы [Brunner et al., 2015; Aliakbarhosseinabadi et al., 2017]. Все это существенно ограничивает возможность выведения ИМК в среду конечных пользователей.

Большинство из них являются лабораторными прототипами или находятся лишь на начальных этапах клинического тестирования [Hill et al., 2014; Brunner et al., 2015; Ramadan, Vasilakos, 2017].

Одно из наиболее перспективных направлений решения указанной проблемы связано с разработкой алгоритмов и методов адаптивной фильтрации и классификации многомерных ЭЭГ-паттернов, реализованных на основе искусственных нейронных сетей [Erguzel et al., 2014; Hamed et al., 2014; Kumar et al., 2014; Sonkin et al., 2016; Yang et al., 2014]. Эффективность последних связана со способностью генерировать практически всё множество моделей, применяемых при решении задач классификации [Aguilar et al., 2015]. Реализуя процедуру классификации, т.е. отнесения вектора, компонентами которого являются характеристики входных сигналов, к одному из не пересекающихся или пересекающихся

множеств (классов) многомерного признакового пространства, оси которого соответствуют компонентам входного вектора, нейронные сети способны строить разделяющие границы произвольной сложности, что является их существенным преимуществом, по сравнению с традиционными статистическими моделями.

В архитектуре нейронных сетей, используемых в существующих классификаторах, обычно выделяют скрытый и выходной слои вычислительных элементов – искусственных нейронов. Входной вектор нейронной сети последовательно преобразуется ими в выходной вектор, указывающий на принадлежность входного образца к одному из заданных классов. При этом, преобразования скрытого слоя можно интерпретировать как вычисления уникальных признаков классов, а выходного – вероятности принадлежности входного образа к одному из них. Показано [Yuksel, Olmez, 2015; Jiang et al., 2015; Mateo et al., 2015; Vedavathi et al., 2015], что такие обучаемые нейросетевые классификаторы демонстрируют более высокую точность распознавания целевых паттернов ЭЭГ, что позволяет надеяться на появление уже в обозримом будущем более эффективных ИМК, прежде всего, с точки зрения точности управления.

Целью настоящего исследования являлась разработка и экспериментальная апробация нового нейросетевого подхода к решению задачи идентификации и классификации ЭЭГ-паттернов, связанных с выполнением мысленных движений, в режиме реального времени в контуре ИМК.

МЕТОДИКА

Экспериментальное исследование включало 2 сессии. В *первой (обучающей) сессии* приняли участие 24 практически здоровых лица (16 мужчин и 8 женщин) в возрасте от 18 до 25 лет (средний возраст 21.5 ± 3.5 года). В соответствии с этическими нормами, утвержденными комитетом по этике Южного федерального университета, все они подписывали протокол о добровольном согласии на участие в исследовании. Целью этой сессии являлось обучение нейросетевого классификатора.

Сессия состояла из 2 серий. В первой серии обследуемые в произвольном темпе выполняли реальные и мысленные движения руками,

ногами и языком без регистрации ЭЭГ. Движения руками представляли собой сгибания предплечья в вертикальной плоскости с фиксацией локтевого сустава на подлокотнике кресла и сжатия кисти в кулак. Движения ногами представляли собой сгибание и разгибание ступней в вертикальной плоскости. При движениях языком обследуемый касался им нёба или зубов. Элементарный цикл включал выполнение того или иного реального движения и его мысленное повторение (без паузы), после чего обследуемый должен был нажимать на кнопку компьютерной мыши, сигнализируя об окончании цикла. Участники адаптировались к условиям обследования и обучались работать в заданном темпе.

Во второй серии (в двух повторных обследованиях) сначала регистрировали ЭЭГ в условиях осуществления обследуемыми указанных движений в любой последовательности с интервалом 5–10 с (всего по 70 движений каждого типа). Затем вслед за реальным движением обследуемому следовало в течение не более 2 с выполнить аналогичное движение мысленно. Сигнализировать об окончании мысленного выполнения движения не требовалось. Всего выполнялось по 70 указанных циклов для каждого типа движений.

Целью *второй (тестирующей) сессии* являлась апробация нейросетевого классификатора. В ней приняли участие 10 обследуемых (5 мужчин и 5 женщин) в возрасте от 21 до 28 лет (средний возраст 24.5 ± 3.5 года), не принимавшие участие в первой сессии. Каждый из них участвовал в 10 тренингах. Исследование было выполнено в рамках 1-го открытого ИМК-чемпионата ЮФУ. Каждый тренинг включал 2 серии – калибровочную и собственно управления. В калибровочной серии обследуемые управляли столбиковыми диаграммами (рис. 1, А), используя для этого 4 типа мысленных движений (правой и левой руками, ногами и языком). Их задача состояла в увеличении высоты диаграммы посредством представления соответствующего движения. Процесс калибровки включал вычисление пороговых амплитудно-временных характеристик четырёх ЭЭГ-паттернов, соответствующих указанным движениям.

В управляющей серии обследуемые перемещали “пакмена” в лабиринте, содержащем 20 поворотов (рис. 1, Б). Конфигурация




Рис. 1. Экранные интерфейсы, используемые на стадии калибровки (А) и управления (Б) нейросетевым классификатором.

Fig. 1. Graphic screen of the user interface in the calibration mode (А) and in the main test (Б).

лабиринта генерировалась каждый раз случайным образом с тем, чтобы исключить запоминание последовательности действий обследуемыми. В конце лабиринта располагалась цель (клубника), которую “пакмену” требовалось “съесть”, затратив на его прохождение минимальное время. Управление осуществлялось мысленным представлением движений языка (движение курсора вверх), ног (вниз) и рук (направо и налево).

Регистрацию электромиограммы (ЭМГ) обеих рук осуществляли в области поверхностных мышц, сгибающих предплечье в локтевом суставе (*m. brachioradialis*), поверхностных сгибателей пальцев (*m. flexor digitorum superficialis*), ног – в области передней большеберцовой мышцы (*m. tibialis anterior*), языка – челюстно-подъязычной мышцы (*m. mylohyoideus*).

Для обнаружения и последующей автоматической режекции артефактов, связанных с движением глаз и морганием, регистрировалась электроокулограмма (горизонтальная и вертикальная).

Регистрацию ЭЭГ осуществляли непрерывно и монополярно относительно ушных референтных электродов (референт объединенный) с использованием электроэнцефалографа “Энцефалан-131–03” (“Медиком МТД”, г. Таганрог) от 17 стандартных отведений (F7, F8, F3, Fz, F4, C3, Cz, C4, P3, Pz, P4, O1, O2, T3, T4, T5, T6) в соответствии с международной системой “10–20”. ЭЭГ регистрировалась как при выполнении движений, так и в покое с открытыми и закрытыми глазами (в течение 30 с) непосредственно перед и по окончании каждой сессии. Частота дискретизации электрограмм составляла 250 Гц по каждому из

каналов, полоса пропускания частотных фильтров – 1–70 Гц, режекторный фильтр – 50 Гц. В основу разработанного нейросетевого классификатора был положен модифицированный метод нейросетевой аппроксимации функциональных зависимостей радиально-базисными функциями и оригинальный алгоритм интерпретации временной последовательности ответов нейронной сети. Классификатор представлял собой комитет из пяти искусственных нейронных сетей: четыре нейронные сети были предназначены для классификации четырех типов мысленных движений, пятая нейронная сеть выполняла дискриминацию целевых ЭЭГ-паттернов от фоновой активности мозга. Входом для каждой из первых четырех нейронных сети являлись мгновенные значения амплитуды ЭЭГ, регистрируемой от 17 отведений. Необходимость наличия сети для каждого типа мысленного движения была обусловлена возможностью перекрытия кластеров, представленных многомерными




Рис. 2. Проекция признакового пространства на плоскость (А) для четырех первых нейронных сетей, (Б) для пятой нейронной сети.

Примечания. На рисунке (А) черные точки соответствуют мгновенным значениям амплитуды ЭЭГ мысленных движений левой рукой, серые точки правой рукой. На рисунке (Б) черные точки временные разности амплитуды ЭЭГ мысленных движений левой рукой, серые точки временные разности амплитуды фоновой активности мозга (Покой). Проекции признаковых пространств на плоскость выполнены методом многомерного масштабирования с помощью отображения Сэммона (Sammon’s mapping).

Fig. 2. The projection of the feature space on the plane (А) for the first four neural networks, (Б) for the fifth neural network.

Notes. Black dots on the figure (А) correspond to instantaneous values of EEG amplitude of left hand motor imagery, grey points right hand motor imagery. Black dots on the figure (Б) represent the temporary difference of EEG amplitude of the left hand motor imagery, grey points temporary difference of amplitude of the background brain activity (Rest). The projection of the feature space into the plane made by the method of multidimensional scaling using Sammon’s mapping.

векторами, в признаковом пространстве (рис. 2, А), что при использовании одной нейронной сети приводило к появлению ошибок распознавания.

При обучении каждой из четырёх нейронных сетей использовалась обучающая выборка, включающая всех обследуемых, состоящая только из экземпляров данных одного класса (конкретного воображаемого движения) — одно мысленное движение для каждой сети. Пятая нейронная сеть служила для дискриминации ЭЭГ-паттернов, соответствующих четырём мысленным движениям, от фоновой активности, для чего было сформировано новое признаковое пространство, которое представляло собой разности между предыдущими и текущими временными отсчётами амплитудных значений многомерных векторов ЭЭГ (рис. 2, Б). Такое новое пространство позволяло с большей надёжностью выполнять разделение мысленных движений и фоновой активности, чем в пространстве мгновенных значений амплитуды ЭЭГ. Для учета временной структуры ЭЭГ-паттернов, представленных 17-мерными (по числу отведений) векторами мгновенных амплитуд, применялся интерпретатор последовательности ответов нейронных сетей. Кроме того, интерпретатор организовывал совместную работу нейронных сетей, в т.ч., с целью минимизации ошибок распознавания.

Каждая из пяти нейронных сетей состояла из трех слоев нейронов — входного, скрытого и выходного.

Первый слой осуществлял передачу входного сигнала в скрытый слой. Количество нейронов входного слоя для всех пяти нейронных сетей составляла 17 (по числу отведений ЭЭГ).

Скрытый слой осуществлял нелинейное преобразование входного сигнала посредством активационных функций своих нейронов, представляющих собой функцию Гаусса:

$$y_j = \exp\left(-\sum_i \frac{(I_i - c_{ji})^2}{d_{ji}}\right), \quad (1)$$

где y_j — выход j -го скрытого нейрона, I_i — компоненты входного вектора сети, c_{ji} — компоненты вектора координат центра j -го нейрона сети, d_{ji} — компоненты ширины j -го нейрона сети.

Четыре первых нейронных сети имели один нейрон в скрытом слое, пятая — 4 нейрона

(в соответствие с количеством детектируемых классов), поскольку входные данные каждого из четырех мысленных движений имели гауссово распределение с собственными характеристиками центра и ширины.

Все нейронные сети комитета имели один нейрон в выходном слое. Он вычислял скалярное произведение вектора выходов нейронов скрытого слоя y с вектором собственных весовых коэффициентов w , формируя выход сети O :

$$O = \sum_j (w_j y_j), \quad (2)$$

где w_j — весовой коэффициент связи j -го нейрона скрытого слоя с нейроном выходного слоя, y_j — выход j -го нейрона скрытого слоя.

Настраиваемыми параметрами сети являлись центр (c) и ширина (d) нейронов скрытого слоя. Весовые коэффициенты нейронов выходного слоя были фиксированы и равны единице для всех нейронных сетей. Традиционное решение настройки параметров заключается в последовательном применении соревновательного алгоритма для настройки центров (c) нейронов скрытого слоя сети, а затем градиентного алгоритма для настройки весов связей w нейронов выходного слоя. Ширина (d) нейронов скрытого слоя обычно имеет вид скаляра, устанавливается заранее или рассчитывается при инициализации и в последующем итерационном процессе обучения не изменяется [Хайкин, 2006]. Данная схема была модифицирована таким образом, что соревновательный и градиентный режимы работали параллельно. Вместо весовых коэффициентов выходных нейронов градиентным методом настраивалась ширина нейронов скрытого слоя, которая была представлена вектором, а настройка производилась для каждого компонента вектора ширины. Это позволило иметь в скрытом слое каждой из четырёх сетей, детектирующих мысленные движения, только один нейрон, и ограничить число нейронов пятой нейронной сети (всего четыре).

Таким образом, обучение комитета состояло в подборе единственного центра и ширины для каждой из четырёх нейронной сети, поскольку все они имели один скрытый нейрон. Центр и ширина соответствовали 17-мерным входным векторам. Центром являлся вектор, имеющий минимальное среднеквадратичное отклонение от всех других входных векторов

обучающей выборки. Ширина (d) нейронов скрытого слоя подбиралась таким образом, чтобы при означенном центре нейронная сеть на каждый вектор обучающей выборки имела значение, равное 1. Детальное описание обучения настраиваемых параметров нейронных сетей представлено в приложении 1.

Решение классификатора о наличии во входном сигнале паттерна, связанного с мысленным выполнением того или иного движения, принималось *интерпретатором* в 2 этапа. На первом этапе ответы нейрона выходного слоя всех нейронных сетей комитета на каждый входной вектор бинаризовались:

$$o_k = \begin{cases} 1, & \text{if } O_k \geq \tau_1 \\ 0, & \text{if } O_k < \tau_1 \end{cases} \quad (3)$$

где O_k – выходное значение k -ой нейронной сети комитета, $k = 1, \dots, 5$. В качестве порогового уровня τ_1 была выбрана величина 0.5 при линейной нормировке выходных значений сети в диапазоне значений $[0;1]$. Единичный ответ ($o_k = 1$) нейронной сети указывал на принадлежность входного вектора к конкретному целевому (*Target*) классу, нулевой ответ – к условному классу “Не знаю”. Пятую нейронную сеть обучали сходным образом, но с тем отличием, что использовали ЭЭГ-эпохи всех четырёх воображаемых движений. Единичный ответ пятой нейронной сети указывал на принадлежность входного вектора к одному из четырёх целевых классов, нулевой ответ – к условному классу “Покой”. Таким образом, четыре первые нейронные сети осуществляли классификацию входных векторов по типу “класс мысленного движения/покой”, пятая нейронная сеть – “мысленное движение/покой”.

При интерпретации ответов нейронных сетей на втором этапе учитывалась временная структура электрографических паттернов. Дискретные бинаризованные ответы каждой из сетей представлялись в виде последовательностей $o_k(t)$. Из пяти исходных последовательностей формировались четыре как конъюнкция ответов первой и пятой, второй и пятой, третьей и пятой, четвёртой и пятой нейронных сетей (рис. 3). Конъюнкция ответов нейронной сети, выполняющей классификацию “класс мысленного движения/покой”, с нейронной сетью, выполняющей классификацию

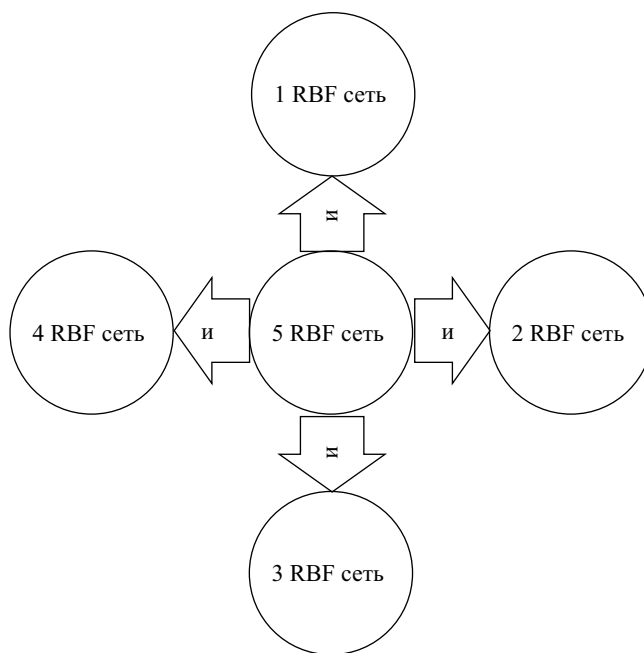


Рис. 3. Граф логики решений комитета нейросетей.
 Fig. 3. The graph of the decision logic of the neural network committee.

“мысленное движение/покой” позволила минимизировать ошибку первого рода (ложные распознавания входных векторов, относящихся к паттернам, связанным с движением). Каждая из четырёх специфических последовательностей закреплялись за соответствующим классом мысленного движения. Решение о наличии паттерна, соответствующего определенному мысленному движению, классификатор принимал при появлении в одной из четырех последовательностей подпоследовательности, которая состояла из идентичных ответов и имела непрерывную длину τ_2 . Анализ производится для четырех последовательностей одновременно. При наличии таких подпоследовательностей одновременно в двух и более классах приоритет отдавался классу с наибольшей длиной подпоследовательности. Для каждого класса мысленного движения определялось индивидуальное значение величины τ_2 . Поиск оптимальной величины τ_2 для каждого класса производился методом перебора с 5-кратной кросс-валидацией.

Для обучения и тестирования нейронной сети использовали ЭЭГ-эпохи каждого обследуемого, зарегистрированные в первой сессии непосредственно перед выполнением реальных движений, о которых судили по ЭМГ, во

временных окнах $-500 \div -150$ мс (поздний компонент Bereitschaftspotential, ВР), и в интервале $+2500 \div +4500$ мс – при их мысленном повторении (спустя 500 мс после окончания ЭМГ). Эпохи ЭЭГ длительностью 5–6 с, зарегистрированные в паузах между движениями (оперативный покой – ОП), составляли первую верификационную выборку. Вторую верификационную выборку составили эпохи ЭЭГ, зарегистрированной в покое с открытыми и закрытыми глазами.

Обучающая, верификационные и тестовые выборки содержали каждая не менее 350 экземпляров данных для каждого обследуемого. Всего для обучения классификатора было отобрано более 1400 безартефактных ЭЭГ-эпох, для тестирования – более 1200.

Оценка эффективности разработанного нейросетевого классификатора осуществлялась как во второй экспериментальной сессии, так и на дополнительной тестовой выборке электрограмм мозга 10 условно здоровых обследуемых, представленной в базе PhysioNet, созданной для разработки систем на основе VCI2000 (<http://physionet.org/pn4/eegmidb/>). Использовались фрагменты ЭЭГ, соответствующие состояниям покоя (№ 1, 2) и мысленного представления движений (№ 4, 6, 8, 10, 12, 14), зарегистрированные у обследуемых S001-S010. Каждый фрагмент содержал по 28–29 записей каждого из 3 типов движений и 14–15 записей, сделанных в состоянии оперативного покоя. Всего было протестировано 1746 записей, сопровождающих различные мысленные движения, и 1021 фоновых записей. Полученные при тестировании нейросетевого классификатора оценки точности классификации паттернов ЭЭГ, соответствующих различным типам движений, сравнивались с теми, которые были рассчитаны при использовании нейронной сети на основе радиально-базисных функций (RBF), многослойного персептрона (MLP) и метода опорных векторов с ядром радиально-базисных функций (SVM-RBF), представленных в пакете прикладных программ Statistica 10.

При апостериорной обработке многомерные паттерны ЭЭГ, выделенные нейросетевым классификатором в течение всего периода управления, и таблицы результатов классификации мысленных движений анализировали с использованием многофакторного

дисперсионного анализа (MANOVA), реализованного в пакете прикладных программ Statistica 10, в рамках процедуры повторных измерений (Repeated Measures). Выделяли следующие факторы: Класс (К; уровни: Я – язык, ПР – правая рука, Н – ноги, ЛР – левая рука, П – покой), Тренинги (Т; уровни: с 1 по 10), в качестве переменных служили Отведения (О-17).

Во всех случаях различия считали достоверными при $p \leq 0.05$, при $0.05 < p \leq 0.08$ констатировали наличие жесткого тренда.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Обучение нейросетевого классификатора осуществлялось на ЭЭГ-эпохах, зарегистрированных у всех обследуемых во второй экспериментальной серии первой сессии и отобранных описанным выше способом.

Точность работы классификатора после обучения с установленным (оптимальным) порогом на длину непрерывной последовательности ответов каждой нейронной сети, равной 200 ± 48 мс (50 ± 12 квантов времени), составила $91.3 \pm 3\%$ на тестовой выборке для четырех типов мысленных движений (рис. 2). Временной порог был несколько короче для движений, выполняемых правой рукой (180 ± 28 мс), длиннее – языком (352 ± 68 мс), и максимальной – левой рукой и ногами (460 ± 40 мс). Индивидуальные паттерны, регистрируемые у различных обследуемых в режиме управления, отличались от указанных значений, но, в целом, весьма незначительно.

Тестирование классификатора off-line на отрезках ЭЭГ, зарегистрированной в первой экспериментальной сессии в состояниях покоя с открытыми и закрытыми глазами, показало, что специфические паттерны, соответствующие мысленным движениям, в них практически не обнаруживаются. В состоянии оперативного покоя (в паузах между движениями) классификатор обнаруживал соответствующие паттерны, в среднем, 1–2 на интервале 15 ± 2 с, что соответствовало ошибке не более 4% от общей длины выборки.

Сравнительный анализ различных нейросетевых методов в апостериорном режиме показал (табл. 1), что, в целом, наиболее эффективно задачу классификации паттернов ЭЭГ, соответствующих четырём типам мысленных движений, решали модели, использующие

Таблица 1. Результат анализа показателей точности классификации (в %) 4 классов мысленных движений с использованием стандартных нейросетевых методов.

Table 1. The result of the analysis of classification accuracy (in %) for four classes of motor imagery using standard neural network methods.

SSummary of active networks							
Index	Net. name	Training perf.%	Test perf.%	Training algorithm	Error function	Hidden activation	Output activation
1	RBF 17–20–4	87.3786	84.0909	RBFT	SOS	Gaussian	Identity
2	RBF 17–25–4	79.6117	68.1818	RBFT	SOS	Gaussian	Identity
3	RBF 17–9–4	56.3107	50	RBFT	SOS	Gaussian	Identity
4	RBF 17–21–4	49.5146	43.1818	RBFT	Entropy	Gaussian	Softmax
5	RBF 17–5–4	54.3689	47.7273	RBFT	SOS	Gaussian	Identity
6	RBF 17–17–4	80.5825	77.2727	RBFT	SOS	Gaussian	Identity
7	RBF 17–7–4	53.3981	45.4545	RBFT	Entropy	Gaussian	Softmax
8	RBF 17–3–4	58.2524	56.8182	RBFT	SOS	Gaussian	Identity
9	MLP 17–9–4	65.0485	56.8182	BFGS12	Entropy	Exponential	Softmax
10	RBF 17–26–4	87.2881	82.7586	RBFT	SOS	Gaussian	Identity
11	MLP 17–14–4	88.9831	86.7586	BFGS26	Entropy	Exponential	Softmax
12	RBF 17–24–4	85.4369	81.8182	RBFT	SOS	Gaussian	Identity
13	RBF 17–9–4	60.1942	59.0909	RBFT	SOS	Gaussian	Identity
14	RBF 17–20–4	93.2039	90.9091	RBFT	SOS	Gaussian	Identity
15	RBF 17–25–4	93.2039	86.3636	RBFT	SOS	Gaussian	Identity
16	RBF 17–16–4	74.7573	70.4545	RBFT	SOS	Gaussian	Identity

Примечания. Факторы: Net. name тип сети и порядковый номер, Training perf.% точность классификации после обучения, Test perf.% точность после тестирования, Training algorithm алгоритм обучения, Error function функция ошибок, Hidden activation скрытая активационная функция, Output activation активационная функция выхода. Жирным шрифтом выделены сети (MLP, RBF), выбранные для дальнейшего детального тестирования.

Notes. Factors: Net. name network type and number; Training perf.% classification accuracy after training; Test perf.% accuracy after testing, Training algorithm; Error function; Hidden activation function; Output activation function. Dedicated networks have chosen for the further detailed testing (MLP, RBF).

радиальную базисную функцию Гаусса и выходную активационную функцию тождества (*Identity*). Среди многослойных персептронов наиболее эффективными оказались сети на основе нормализованной экспоненциальной активационной функции выходного слоя (*Softmax*).

Детальный анализ показал (табл. 2), что нейросетевые модели, в целом, имели приемлемый уровень точности классификации целевых паттернов как на этапе обучения, так и тестирования. Точность классификации при использовании модели радиальной базисной функции на этапе тестирования несколько снижалась (на 5–7%), тогда как сеть на основе многослойного персептрона, напротив, показала некоторый рост при распознавании мысленных движений ногами, правой и левой руками (на 3–10%). Точность распознавания

паттернов ЭЭГ с использованием классификатора на основе метода опорных векторов (*support vector machine, SVM*) с ядром радиально-базисной функции оказалась существенно ниже (на 20–30%), чем протестированных нейросетевых моделей, причем, даже с использованием процедуры регуляризации входных данных.

Разработанный нами нейросетевой классификатор устойчиво демонстрировал высокую вероятность правильного распознавания целевых паттернов, сопоставимую со стандартными нейросетевыми моделями и существенно превосходящую метод линейной многоклассовой дискриминации (*SVM*), как на этапе обучения, так и тестирования. Вероятность классификации четырёх классов мысленных движений составила от 85 до 94%.

Таблица 2. Результаты апостериорного сравнительного анализа эффективности классификации 4 классов мысленных движений (правая рука, левая рука, ноги, язык), выполненной при помощи 3 нейросетевых моделей и линейного классификатора.

Table 2. The results of a posteriori comparative analysis of the classification efficiency for four classes of motor imagery (right hand, left hand, foot, tongue). The analysis performed using three neural network models and linear classifier.

Classification summary (Multilayer perceptron, Radial basis function, Support Vector Machine, KRINC-BCI)					
Models	Class				
	Trials	Left Hand	Feet	Right Hand	Tongue
11 MLP 17-14-4	Total	482	368	364	381
	Correct	462	332	324	314
	Incorrect	20	36	40	67
	Correct (%)	96	90	89	82
	Incorrect (%)	4	10	11	18
14 RBF 17-20-4	Total	482	368	364	381
	Correct	421	339	316	317
	Incorrect	61	29	48	64
	Correct (%)	87	92	86	83
	Incorrect (%)	13	8	14	17
SVM	Total	482	368	364	381
	Correct	337	209	229	213
	Incorrect	145	159	135	168
	Correct (%)	70	57	63	56
	Incorrect (%)	30	43	37	44
KRINC-BCI	Total	482	368	364	381
	Correct	453	320	331	323
	Incorrect	29	48	33	58
	Correct (%)	94	87	91	85
	Incorrect (%)	6	13	9	15

Примечания: Факторы: Models тип сети, Class анализируемые классы (Left Hand левая рука, Foot ноги, Right Hand правая рука, Tongue язык). Приведена точность работы моделей в %, количество проанализированных случаев, корректно распознанных экземпляров данных, а также ошибок.

Notes. Factors: Models the network; Class (left hand, feet, right hand, tongue). The accuracy of the models (correctly recognized EEG-patterns and errors) is given in percent (%) and the number of analyzed cases.

Тестирование разработанного классификатора online показало, что в ЭЭГ покоя с открытыми и закрытыми глазами обнаруживаются




Рис. 4. Проекция ложноположительных паттернов ЭЭГ на плоскость. Примечание: 4 класса, ЛР- левая рука; ПР правая рука; Н ноги; Я язык.

Fig. 4. The projection of the false positive EEG patterns on the plane. Notes: Class 4: LH Left hand; RH Right hand; F Feet; T Tongue. Ellipse coefficient = 0.95.

квази-паттерны движений (рис. 4). Несмотря на известное сходство характеристик последних с паттернами, соответствующими произвольным мысленным движениям, они были значительно короче (не более 40 мс), что позволило далее не рассматривать их как ЭЭГ-команды и снизить ошибку первого рода, в среднем, до 5–6% для данных состояний. Использование интерпретатора последовательности ответов нейронной сети и динамического вычисления пороговых значений для измеряемых ЭЭГ сигналов (индивидуально для каждого обследуемого) позволило свести к минимуму ложноотрицательные ошибки (второго рода) классификации.

Результаты управления “Пакменом” в реальном времени при прохождении лабиринта с использованием ЭЭГ-паттернов, соответствующих различным мысленным движениям, показали, что эффективность генерации команд носит, в целом, индивидуальный характер. У двух обследуемых (из 10), продемонстрировавших наихудшие результаты, точность управления (с учётом ошибок) составила лишь $11.3 \pm 5.5\%$ при условии, что наименьшая приемлемая точность работы сети, интерпретируемая как неслучайная, составляла 25% (табл. 3, рис. 5, Б), и не повышалась в ходе тренингов. У 3 обследуемых точность управления находилась на минимально приемлемом

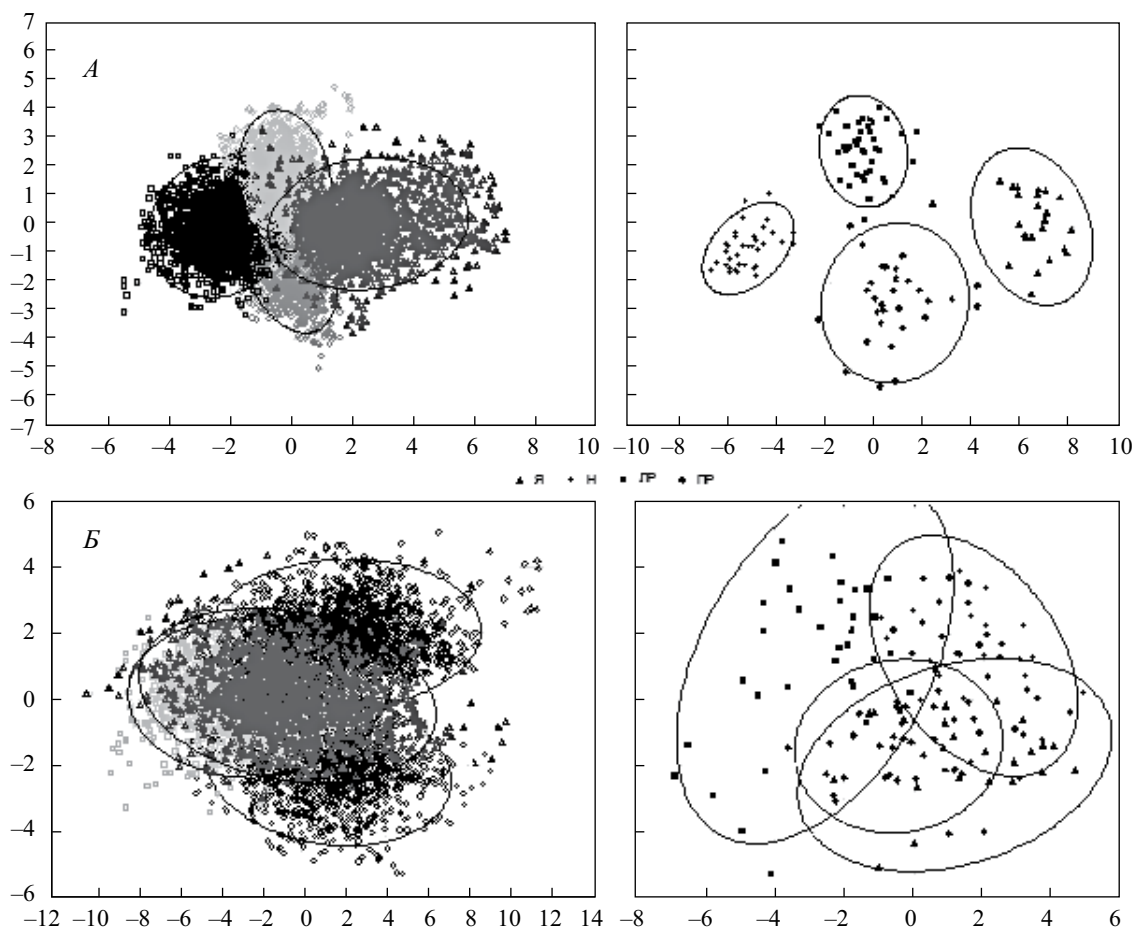


Рис. 5. Проекция целевых ЭЭГ-паттернов на плоскость при работе классификатора в режиме реального времени при высокой (А, 5 обследуемых) и низкой (Б, 2 обследуемых) точности распознавания 4 целевых ЭЭГ-команд, выполненные с помощью многомерного масштабирования. Слева в рамках всего обучения и 3 тренировок – справа. Обозначения: Как на рис. 4.

Fig. 5. The projection of four target EEG patterns on the plane when in the real time classification with high (А, 5 subjects) and low (Б, 2 subjects) recognition accuracy. The projection executed using multi-dimensional scaling. Across all training on the left and three training sessions on the right. Designations: As in fig. 4.

уровне ($31.6 \pm 8.7\%$), лишь незначительно увеличиваясь к концу тренировок. Наконец, у 5 обследуемых средняя точность управления составила $54.1 \pm 19.9\%$ при вероятности ложноположительных реакций $22 \pm 9.6\%$ (табл. 3, рис. 5, А). Наиболее эффективные тренировки демонстрировали эффект обучения и точность управления в них достигала $89-92\%$ (табл. 4). Анализ показал, что повышение точности управления в динамике обучения было связано с непрерывной генерацией целевых команд на интервале времени до 1 с. Наряду с этим, наблюдалось повышение амплитуды ЭЭГ-паттернов, соответствующих мысленным движениям. К концу обучения у восьми (из 10) обследуемых, в среднем, она возросла на $0.65 \pm 0.25\sigma$, ещё у двоих практически не

изменилась, оставаясь на уровне $0.09 \pm 0.05\sigma$ от своих исходных значений.

Наряду с точностью, эффективность управления оценивалась по скорости прохождения лабиринта (рис. 6, А). Анализ показал, что шести обследуемым из 10 удалось существенно сократить время прохождения лабиринта (в среднем, в 2 раза и более) уже к 5–7 тренингу (табл. 5, рис. 6, Б), прежде всего, за счёт повышения точности генерации управляющих команд. Увеличение скорости управления по группе в целом составило в пятом и десятом тренингах, соответственно, в 1.53 и 1.91 раза.

Таблица 3. Результат анализа показателей точности классификации (в %) 4 классов мысленных движений для 10 обследуемых в динамике 10 тренингов

Table 3. The result of the analysis of classification accuracy (in %) for four classes of motor imagery in 10 subjects in the course of ten trainings.

O	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	M	MED	25%	75%	SD
1	10.6	5.7	12.6	5.2	8.7	10.8	9.4	23.3	27.6	21.2	13.51	10.7	8.7	21.2	±7.7
2	6	4.8	5.1	8.5	10.8	11.2	9.3	9.2	12.2	15.2	9.23	9.25	6	11.2	±3.3
3	27.4	20.7	19.6	38.5	29.2	37.7	44.7	47.2	39.5	49.7	35.42	38.1	27.4	44.7	±10.6
4	21.4	23.7	19.7	18.8	29	27.8	37.1	39.3	42.2	44.1	30.31	30.4	21.4	37.1	±9.2
5	19.6	24.4	21.8	25.6	37.1	36.6	38.5	30.4	19.7	39.1	29.28	29.55	23.8	34.6	±6.4
6	36.5	45.4	67.2	51.5	70.2	89.1	86.1	88.5	52.4	80.4	66.73	69.7	51.5	84.1	±19.1
7	32.4	37.1	53.4	36.3	38.8	57.5	38.7	67.1	72	80.4	51.37	47.55	37.1	64.1	±16.7
8	32.9	24.5	39.1	33.8	53.7	67.1	55.5	82.3	79.6	76	54.45	54.6	33.8	76	±21.2
9	21.3	29.8	27.6	39.7	47	35.2	59	69.5	82.4	77.5	48.9	43.35	29.8	69.5	±21.9
10	27.3	22.4	21.6	49	49.2	43.2	75.1	72.4	92.2	57.5	50.99	53.25	32.4	62.4	±21.0
M	23.5	23.8	28.7	30.6	37.4	41.6	45.3	52.9	51.9	54.1	39.0	38.6	27.2	50.5	±13.7

Примечания. Факторы: Т Тренинг (10), О Обследуемые (10). Жирным шрифтом выделены значения, достоверно превышающие минимум 1 SD (стандартное отклонение) от среднего на протяжении 3 тренингов и более. М среднее, MED медиана, 25–75% диапазон измерений в выборке, SD стандартное отклонение.

Notes. Factors: T Training (10), S Subject (10). Bold values are significantly exceed of at least one SD (standard deviation) from the mean for 3 trainings. M mean; MED median, 25–75% the range of the measurements in the sample, SD standard deviation.

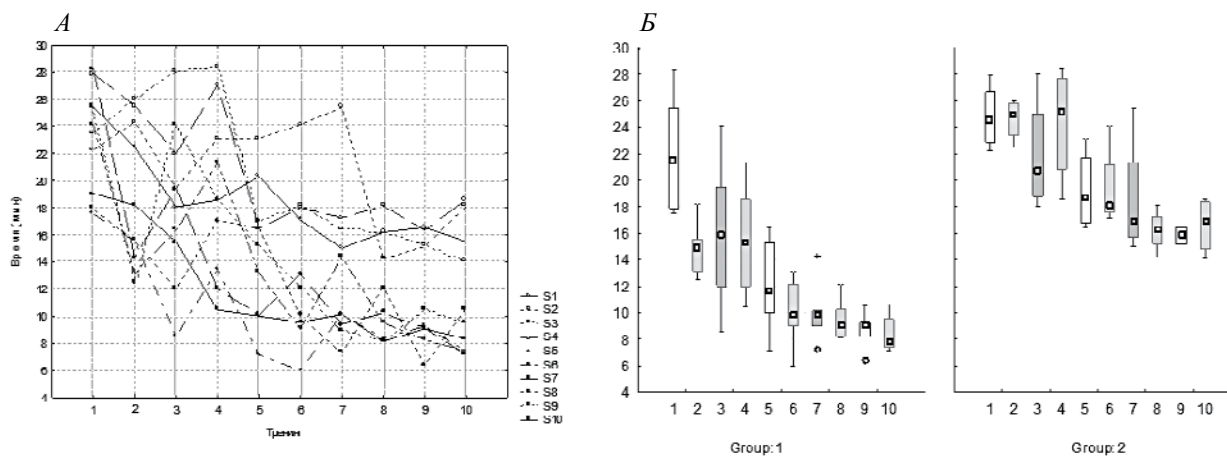


Рис. 6. (А) Графическое изображение индивидуальных профилей динамики обучения 10 обследуемых по параметру скорости управления в контуре нейроинтерфейса и (Б) групповой профиль при наиболее (слева) и наименее (справа) эффективном управлении. *Обозначения:* по оси абсцисс Тренинги (1–10), по оси ординат время (мин). Median медиана, 25–75% диапазон измерений в выборке, N-O Range доверительный интервал, Outliers выбросы, Extremes экстремумы.

Fig. 6. A graphic presentation of the individual profiles of training dynamics in 10 subjects by the parameter of speed control in the closed-loop neural interface. B group profile with the most (left) and least (right) recognition accuracy. *Designations:* X-axis Trainings (1–10), and the Y-axis time (min). Median, 25–75% the range of the measurements in the sample, N-O Range confidence interval, Outliers, Extremes.

Апостериорный (многофакторный дисперсионный) анализ усреднённых амплитудных характеристик 4 ЭЭГ-паттернов, выделенных классификатором в процессе управления, показал, что имел место Main Effects для фактора К и его значимое взаимодействие с фактором Т (табл. 6). Это указывало на то, что в динамике обучения различия между

детектируемыми ЭЭГ-паттернами существенно увеличивались. Наряду с этим, отмечались значимые взаимодействия анализируемых факторов с переменными (O).

Детальный анализ на уровне взаимодействия основных факторов (К и Т), а также переменных (O) показал, что между ними также имели место значимые взаимодействия

Таблица 4. Результат анализа показателей точности классификации (в %) 4 целевых мысленных движений для 5 обследуемых в 3 наиболее успешных тренингах (с 6 по 9).

Table 4. The result of the analysis of classification accuracy (in %) for four target motor imagery classes in five subjects in the most three successful trainings (up 6 to 9).

Classification Matrix. Rows: Observed classifications Columns: Predicted classifications					
МД	Percent Correct	ЛР <i>p</i> =.25197	Н <i>p</i> =.24847	ПР <i>p</i> =.25022	Я <i>p</i> =.24934
ЛР	94.22408	1354	35	43	5
Н	90.89626	52	1288	77	8
ПР	92.57183	68	31	1321	7
Я	84.03657	122	4	101	1195
Total	90.44363	1596	1358	1542	1207

Примечания. Фактор: МД мысленное движение (Левая рука, Ноги, Правая рука, Язык, 4 уровня).

Notes. Factor: MI motor imagery (Left hand, Feet, Right hand, Tongue, four levels).

(Main Effect, Interaction: $F_{O*К*Т}(3;432)=7.2493$, $p=0.022$), отражающие изменение амплитудных характеристик детектируемых паттернов в динамике тренингов (рис. 7). Эти изменения касались фронтальных (управляющих), центральных (двигательных) и теменных (ассоциативных) областей мозга (Planned comparison: $F_{OТВ}(1;143)=254.808$; $p=0.000$; Main Effect, Interaction: $F_{O*Т}(1;144)=5.074$; $p=0.007$).

Анализ результатов эффективности нейросетевой классификации паттернов ЭЭГ, соответствующих различным мысленным движениям, показал, что, в целом, значимый рост вероятности их распознавания достигался обследуемыми уже к 4–5 тренингу, а в ряде

случаев – уже 2 (рис. 8). В случае наименее точного управления (2 обследуемых) в первой половине обучения наблюдался прирост ошибок, тогда как во второй их доля значительно снижалась.

Дополнительный анализ эффективности работы классификатора на тестовой выборке из 10 обследуемых, состоящей из 2-минутных записей ЭЭГ, находящейся в открытом доступе (PhysioNet-BCI2000), включал псевдо-онлайн детектирование 3 целевых паттернов, соответствующих движениям левой и правой руками и обеими ногами. Вычислительные эксперименты показали (табл. 7), что наибольшая точность классификации мысленных движений (70% и выше) наблюдалась у четырех обследуемых. Для 6 обследуемых она составляла 50–70%. В отдельных пробах эффективность работы классификатора составляла 30–40%, что соответствовало минимально приемлемому уровню, интерпретируемому как неслучайный. Уровень ложноположительных ошибок классификатора, в среднем, составил $21.0 \pm 6.3\%$, при этом, количество таких ошибок в 4 случаях из 10 положительно коррелировало с точностью распознавания. Минимальное количество ошибок наблюдалось для записей ЭЭГ с точностью распознавания мысленных команд на уровне среднего и ниже среднего.

ОБСУЖДЕНИЕ РЕЗУЛЬТАТОВ

Как известно, развитие технологии ИМК в значительной степени связано с разработкой более эффективных методов идентификации и классификации паттернов ЭЭГ,

Таблица 5. Абсолютные и средние значения времени прохождения лабиринта 10 обследуемыми при управлении курсором в режиме реального времени в 10 тренингах.

Table 5. Absolute and averaged time of the maze transit in the real-time cursor control in 10 subjects within 10 trainings.

О	T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	M	MED	25%	75%	SD
1	25.43	24.47	18.06	18.57	22.28	17.11	15.01	14.2	14.55	15.51	18.51	17.58	16.2	20.28	±3.3
2	27.9	25.55	22.01	27.09	16.47	18.01	17.27	18.14	16.36	18.6	20.74	18.37	17.27	25.55	±4.5
3	22.26	24.33	19.46	23.12	23.11	24.12	25.41	14.23	15.14	18.12	20.93	22.68	18.12	24.12	±3.9
4	23.54	26.02	28	28.35	17.03	18.21	16.44	16.31	15.23	14.13	20.32	17.62	16.31	26.02	±5.5
5	19.06	18.2	15.48	10.46	10.01	9.55	11.15	8.14	8.07	8.33	11.84	10.08	9.07	15.48	±4.1
6	17.54	15.54	8.54	13.45	7.14	6.01	7.42	10.11	8.4	9.25	10.34	8.89	7.42	13.45	±3.8
7	24.14	13.17	16.34	23.34	13.18	8.05	8.24	6.42	14.37	9.51	13.67	13.17	9.05	16.34	±5.6
8	19.9	15.55	14.01	18.09	16.47	10.01	7.27	8.14	6.36	9.6	12.54	12.07	10.01	16.47	±4.0
9	25.43	13.47	24.06	18.57	16.28	12.11	8.01	8.2	7.51	11.55	14.51	12.29	9.51	18.57	±6.2
10	28.26	14.33	19.46	12	10.11	13.12	9.41	10.23	9.14	7.12	13.31	11.11	9.41	14.33	±6.2
M	23.35	19.06	18.54	19.3	15.21	13.63	12.56	11.42	11.51	12.17	15.67	14.39	12.24	19.06	±4.7

Примечания: Факторы: Т Тренинг (10), О Обследуемые (10). Остальные обозначения как в таблице 3.

Notes: Factors: T Training (10), S Subject (10). Table 3 for other designations.

Таблица 6. Результат многофакторного MANOVA-анализа с повторными измерениями усреднённых амплитудных характеристик ЭЭГ 4 целевых команд, выделенных нейросетевым классификатором в процессе управления (для группы из 10 обследуемых)

Table 6. Multifactor analysis of variance (MANOVA) of the averaged EEG amplitude characteristics of four motor imagery classes during ten training sessions in ten subjects (Main Effects).

Repeated Measures Analysis of Variance					
Current effect: $F(4, 117)=10,063, p=,00000$					
Sigma-restricted parameterization Effective hypothesis decomposition					
	SS	Degr. of Freedom	MS	F	p
Intercept	137681.0	1	137681.0	2513.295	0.000
Класс (К)	7786.6	3	2595.5	47.380	0.000
Тренинг (Т)	3322.5	9	369.2	6.739	0.183
К*Т	6867.3	27	254.3	4.643	0.000
Еггог	9148.4	167	54.8		
Отведение (О)	15168.9	16	948.1	103.977	0.000
О*К	38348.1	48	798.9	87.620	0.000
О*Т	6661.8	144	46.3	5.074	0.007
О*К*Т	28554.9	432	66.1	7.249	0.022
Еггог	24363.2	2672	9.1		

Примечания. Факторы: К Класс, Т Тренинг, О Отведения. SS дисперсия ошибки, MS среднеквадратическая ошибка. Остальные обозначения как в таблице 1. Полужирным шрифтом выделены значения, достоверные при $p \leq 0.05$.

Notes. Factors: C Class, T Training, L Leads, SS variance error, MS mean square error, F Fisher's test; p significance level. Values significant at $p \leq 0.05$ are in bold.

произвольно генерируемых пользователем [Bobrov, Frolov, 2011; Ushiba et al., 2016; Wu et al., 2016], прежде всего, по показателям надежности и скорости. Последнее требует проведения сравнительного анализа новых подходов с уже существующими алгоритмами и их программными реализациями, а также базами исходных данных. Такой анализ показал, что разработанный нами нейросетевой классификатор способен обеспечить высокую точность и скорость произвольного управления в контуре ИМК после относительно непродолжительного (8–10 тренировок) обучения. Еще треть пользователей способны демонстрировать среднюю скорость управления при относительно невысокой точности, интерпретируемой, по крайней мере, как неслучайная. В ряде случаев (около 20%) эффективное управление с использованием нейросетевого классификатора даже после обучения пользователей

оказалось невозможно. Это могло быть связано как с недостаточно точным соблюдением инструкции, так и индивидуальными особенностями последних [Grosse-Wentrup et al., 2011; Halder et al., 2011; Mullinger et al., 2014]. Показано существование так называемых ИМК-заблокированных обследуемых (BCI-illiteracy) [Vuckovic, Osuagwu, 2013; Ahn et al., 2014, Zich et al., 2015], доля которых в популяции может достигать (по разным оценкам) 15–30%. В целом в этой части полученные результаты согласуются с уже имеющимися данными, указывающими на то, что нейроинтерфейсы, использующие для управления мысленные представления движений, требуют более тщательной подготовки и обучения пользователей [Kaiser et al., 2014].

Анализ показал, что, в целом, у обследуемых в динамике обучения имело место существенное увеличение как точности, так и скорости управления нейроинтерфейсом. С одной стороны, это было обусловлено усилением выраженности и различий в регистрируемых паттернах ЭЭГ, связанных с различными типами мысленных движений. Они касались, прежде всего, управляющих (фронтальных), ассоциативных (париетальных) и собственно двигательных зон коры. С другой стороны, это определялось способностью нейроинтерфейса учитывать индивидуальные особенности генерируемых пользователями управляющих паттернов, а также фильтровать квази-паттерны мысленных движений, которые регистрировались, в т.ч. в состоянии покоя. Известно, что даже в состоянии покоя в ЭЭГ могут регистрироваться эффекты, связанные с реализацией мысленных действий, поскольку оно характеризуется достаточно высоким уровнем активации структур неокортекса, связанным с процессами внимания или реализацией релевантной задачи, особенно при наличии нейрообратной связи [Медведев и др., 1996; Zich et al., 2015].

В целом предложенный нами подход к созданию нейросетевого классификатора паттернов ЭЭГ, соответствующих произвольным мысленным движениям, на основе модифицированного метода нейросетевой аппроксимации с помощью радиально-базисных функций и оригинального алгоритма интерпретации ЭЭГ-паттернов продемонстрировал высокую точность и скорость работы

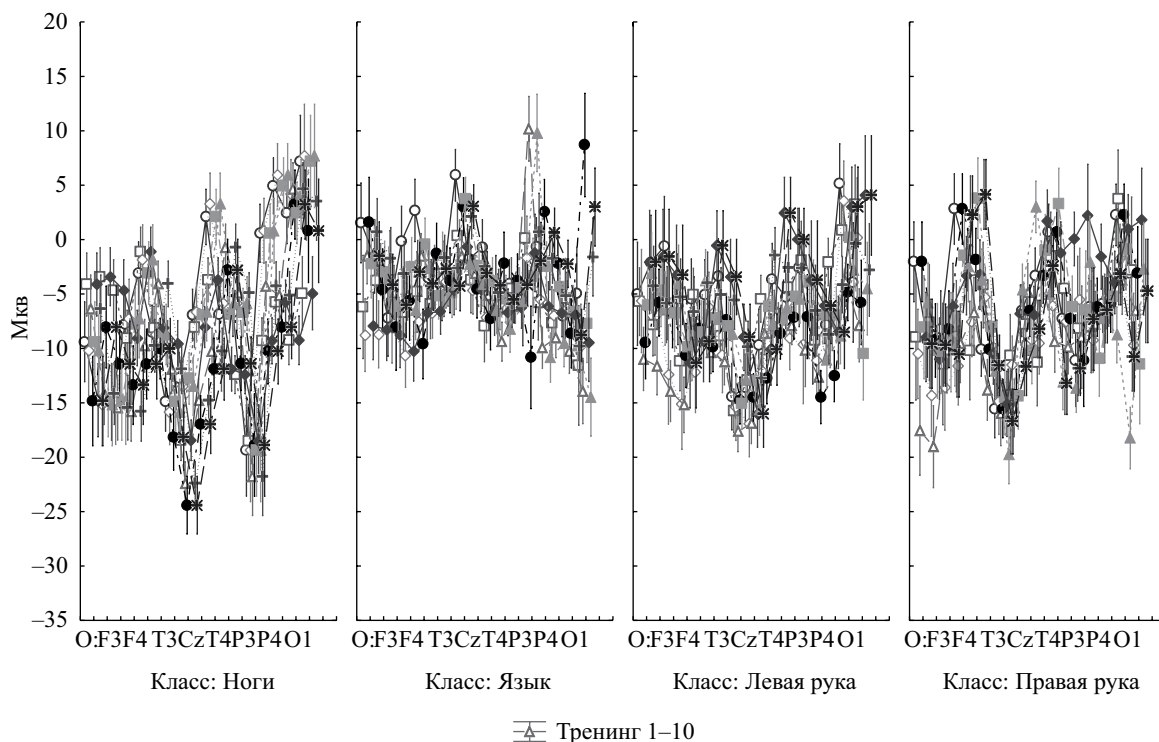


Рис. 7. Результат трёхфакторного MANOVA-анализа усреднённых амплитудных характеристик паттернов ЭЭГ, соответствующих 4 классам мысленных движений, выделенных нейросетевым классификатором в процессе обучения 10 обследуемых в течение 10 тренингов. *Примечания.* По оси абсцисс Отведения (O) 17, по оси ординат амплитуда в мкВ.

Fig. 7. Graphic presentation of the results obtained by three factor MANOVA of the averaged amplitude characteristics for the four motor imagery classes in ten subjects in the course of ten training sessions. *Notes.* X-axis Lead (L) 17, Y-axis is amplitude in μV .

практически у половины пользователей, что позволяет рассматривать его как перспективный для решения указанной задачи. Модифицированный параллельный соревновательно-градиентный алгоритм настройки сети позволял быстро и однократно оптимизировать её архитектуру непосредственно на этапе обучения. Еще одно преимущество связано с использованием оригинального алгоритма анализа временной структуры целевых паттернов, позволяющего интерпретировать временную динамику ответов сети. Традиционное решение в стандартных моделях состоит в применении линии задержки [Walker et al., 2015], посредством которой методом перебора определяют оптимальное значение длины искомого паттерна, что увеличивает время обучения сети и требует поиска оптимальной архитектуры, в том числе, её перестройки. Наконец, еще одним фактором, положительно влияющим на эффективность управления, стала автоматизация процесса калибровки обученного комитета

нейронных сетей, учитывающая индивидуальные особенности ЭЭГ пользователей.

Нами показано, что повышение качества управления в динамике тренингов было связано, прежде всего, с усилением выраженности в ЭЭГ (в частности, ростом амплитуды) паттернов, соответствующих различным типам мысленных движений. Пролонгированность таких эффектов нуждается в дальнейшей оценке, однако сходные изменения, в том числе, реорганизация пространственно-временной структуры биоэлектрической активности мозга при работе в контуре нейроинтерфейса, были описаны нами и ранее [Асланян и др., 2013; Kirov et al., 2015]. В частности, было показано, что использование нейро-БОС-тренинга приводит к сопряжённому с обучением росту мощности альфа- и бета-частот как непосредственно в процессе управления, так и в фоновой ЭЭГ. Аналогичные сведения приводятся и другими авторами. Так, было показано [Kaiser et

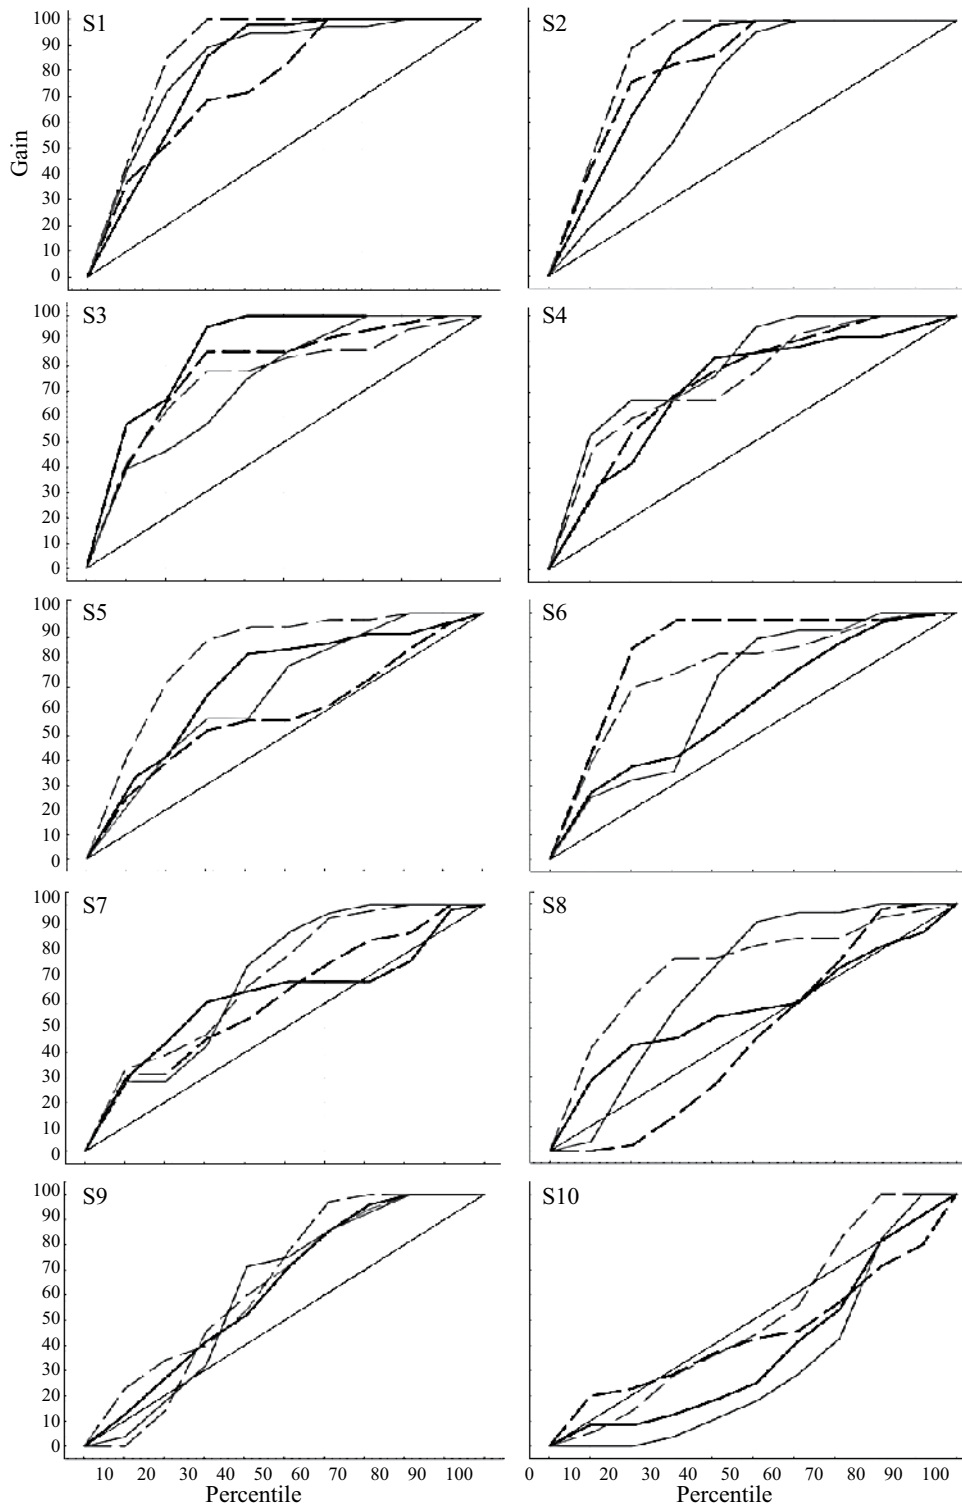


Рис. 8. Индивидуальные профили результатов классификации 4 типов мысленных движений в группе из 10 обследуемых в 10 тренингах. *Обозначения.* S Subject (обследуемый). Результаты выражены в процентах (%). Синяя линия базовая (baseline). Сплошная чёрная линия левая рука; пунктирная чёрная линия ноги; пунктирная серая линия правая рука; сплошная серая линия язык. Достоверно значимый прирост правильных ответов сети 90% и выше.

Fig. 8. Graphic presentation of individual profiles during classification of 4 types of motor imagery in a group of 10 subjects and 10 trainings. *Designations.* S Subject (subjects). The results are expressed in percent (%). Blue line is baseline. Solid black line left hand; the dotted black line feet; dotted grey line right hand; solid gray line the tongue. Significantly increase of the correct network answers is 90% and above.

Таблица 7. Результат анализа показателей точности классификации (в %) 3 классов мысленных движений у 10 обследуемых в динамике 6 проб с использованием комитета нейросетей.

Table 7. The result of the analysis of classification accuracy (in %) for three motor imagery classes in the dynamics of six datasets in ten subjects using a neural network committee.

Classification summary of SERIES (1 to 6)									
Subject	P4	P6	P8	P10	P12	P14	Mean	SD	Error (FP)
1	78	77	66	75	61	59	69.3	8.406	16
2	57	60	66	60	71	61	62.5	5.089	26
3	79	73	86	88	93	79	83	7.293	24
4	71	65	59	76	88	79	73	10.334	21
5	55	61	56	48	58	60	56.3	4.676	13
6	59	47	55	62	85	69	62.8	13.090	19
7	61	49	68	71	82	72	67.1	11.196	23
8	76	81	79	89	94	87	84.3	6.801	31
9	68	79	100	66	68	71	75.3	12.925	26
10	33	52	59	49	67	48	51.3	11.445	11
Mean	63.7	64.4	69.4	68.4	76.7	68.5	Total Mean. SD. Error		
SD	13.96	12.677	14.653	14.245	13.283	11.645	68.49	9.128	21

Примечания. Факторы: P проба (6), Subject Обследуемые (10). Жирным шрифтом выделены значения, достоверно превышающие одно стандартное отклонение (SD) от среднего в течение 3 проб и более, минимум для двух классов в пробе. Mean среднее, SD стандартное отклонение, Error (FP) уровень ошибки нейронной сети первого рода.

Notes. Factors: P dataset (6), Subject (10). Values significantly exceed of one SD (standard deviation) from the mean for three datasets or more, at least for two classes in dataset. Mean average accuracy in all datasets, SD standard deviation, Error (FP) α error level of the neural network (false positives).

al., 2014], что в ходе обучения обследуемых управлению нейроинтерфейсом с помощью двух мысленно представляемых движений (правой рукой и ногами) наблюдалось усиление активации двигательных областей в форме, связанной с событием десинхронизации (*Event-Related Desynchronization – ERD*) мю и бета-частот ЭЭГ. Полученные результаты свидетельствуют в пользу предположения о том, что обучение мысленному представлению движений способно сформировать новые корковые модели активации двигательных программ [Aflalo et al., 2014; Vasilyev et al., 2017].

В связи с изложенным выше, развитие предлагаемой технологии видится в разработке самообучающихся искусственных нейронных сетей, способных самостоятельно обнаруживать и использовать в качестве команд управления устойчиво генерируемые субъектом паттерны ЭЭГ, в том числе, благодаря оригинальным методам детекции и интерпретации сигналов мозга человека, разработка которых активно ведётся нами в настоящее время.

ЗАКЛЮЧЕНИЕ

Использование ЭЭГ-феноменов, связанных с мысленным представлением движений, является достаточно перспективным подходом для создания нейроинтерфейсов, поскольку позволяет (1) использовать для управления специфичные ЭЭГ-паттерны и избежать двойного кодирования, (2) расширять алфавит управляющих команд за счёт использования новых уникальных ЭЭГ-паттернов, (3) генерировать управляющие команды в произвольные моменты времени, (4) формировать пользователю собственный темп и ритм работы. Эффективность такого подхода была продемонстрирована с использованием нейросетевого подхода, в основу которого положен метод локальной аппроксимации с помощью радиально-базисных функций и оригинальный алгоритм интерпретации временной последовательности ответов нейронной сети. Дальнейшее повышение скорости и надежности управления с использованием разработанного нейроинтерфейса может быть обеспечено за счет повышения эффективности и надежности функционирования как “человеческого”,

так и “машинного” звена. Для этого должны быть разработаны самообучающиеся нейросетевые модели и алгоритмы идентификации многомерных ЭЭГ-паттернов, специфичных для различных видов произвольной мыслительной деятельности, способные работать в режиме реального времени, а также эффективные методы обучения пользователей генерации высокоспецифичных ЭЭГ-паттернов. Указанные направления развития технологии нейрорегуляции являются предметом ведущихся нами в настоящее время исследований.

Работа выполнена при финансовой поддержке базовой части Госзадания – № 6.5961.2017/8.9, проектной части Госзадания – № 2.955.2017/4.6.

СПИСОК ЛИТЕРАТУРЫ

- Асланян Е. В., Киной В. Н., Лазуренко Д. М., Бахтин О. М. Свойства нервных процессов и эффективность Бос-тренинга. Психологический журнал. 2013. 34. 002: 08–116.
- Киной В. Н., Бахтин О. М., Миняева Н. Р., Лазуренко Д. М., Асланян Е. В., Киной Р. И. Электрографические корреляты внутренней речи. Журн. высш. нервн. деят. 2015. 65(5): 1–10.
- Медведев С. В., Пахомов С. В., Рудас М. С., Алхо К., Терваниemi М., Рейникайен К., Наатанен Р. О выборе состояния спокойного бодрствования как референтного при психологических пробах. Физиология человека. 1996. 22 (1): 5–10.
- Шепелев И. Е., Владимирский Б. М. «Построение нейросетевого классификатора для интерфейса “мозг–компьютер”». Нейрокомпьютеры: разработка, применение. 2010. 2: 4–10.
- Фролов А. А., Бирюкова Е. В., Бобров П. Д., Мокиенко О. А., Платонов А. К., Пряничников В. Е., Черникова Л. А. Принципы нейрореабилитации, основанные на использовании интерфейса “мозг–компьютер” и биологически адекватного управления экзоскелетом. Физиология человека. 2013. 39(2): 99–113.
- Хайкин С. Нейронные сети: полный курс 2-е изд. М.: “Вильямс”, 2006. 1104 с.
- Aflalo T., Kellis S., Klaes C., Lee B., Shi Y., Pejsa K., ... & Andersen R. A. Decoding motor imagery from the posterior parietal cortex of a tetraplegic human. *Science*. 2015. 348(6237): 906–910.
- Agüilar J. M., Castillo J., Elias D. EEG Signals Processing Based on Fractal Dimension Features and Classified by Neural Network and Support Vector Machine in Motor Imagery for a BCI. In: VI Latin American Congress on Biomedical Engineering CLAIB2014, Paraná, Argentina, October 2014: 615–618.
- Ahn S., Ahn M., Cho H., Jun S. C. Achieving a hybrid brain–computer interface with tactile selective attention and motor imagery. *Journal of neural engineering*. 2014. V. 11. №. 6: 066004.
- Aliakbaryhosseinabadi S., Kostic V., Pavlovic A., Radovanovic S., Farina D., Mrachacz-Kersting N. Effect of Attention Variation in Stroke Patients: Analysis of Single Trial Movement-Related Cortical Potentials. In: *Converging Clinical and Engineering Research on Neurorehabilitation II* Springer International Publishing. 2017: 983–987.
- Bhalla A., Agrawal R. K. Relevant Feature Extraction by Combining Independent Components Analysis and Common Spatial Patterns for EEG Based Motor Imagery Classification. In: *International Journal of Engineering Research and Technology*. V. 3. No. 7. July-2014. ESRSA Publications: 246–252.
- Bobrov P., Frolov A., Cantor C., Bakhnyan M., Zhavoronkov A. Brain-computer interface based on generation of visual images. *PloSone*. 2011. 6(6), e20674.
- Brunner C., Birbaumer N., Blankertz B., Guger C., Kübler A., Mattia D., Müller-Putz G. R. BNCI Horizon 2020: towards a roadmap for the BCI community. *Brain-Computer Interfaces*, (ahead-of-print). 2015. P. 1–10.
- Cano-Izquierdo J. M., Ibarrola J., Almonacid M. Improving motor imagery classification with a new BCI design using neuro-fuzzy S-dFasArt. *Neural Systems and Rehabilitation Engineering*. IEEE Transactions on. 2012. 20(1). P. 2–7.
- Erguzel T. T., Ozekes S., Gultekin S., Tarhan N. Ant colony optimization based feature selection method for QEEG data classification. *Psychiatry investigation*. 2014. 11(3): 243–250.
- Grosse-Wentrup M., Schölkopf B., Hill J. Causal influence of gamma oscillations on the sensorimotor rhythm. *NeuroImage*. 2011. 56 (2). P. 837–842.
- Halder S., Agorastos D., Veit R., Hammer E. M., Lee S., Varkuti B., Kübler A. Neural mechanisms of brain–computer interface control. *NeuroImage*. 2011. 55 (4). P. 1779–1790.
- Hamed M., Salleh S. H., Noor A. M., Mohammad-Rezazadeh I. Neural network-based three-class motor imagery classification using time-domain features for BCI applications. In: *Region 10 Symposium*. 2014 IEEE. P. 204–207.
- Hill N. J., Häuser A. K., Schalk G. A general method for assessing brain–computer interface performance and its limitations. *Journal of neural engineering*. 2014. 11(2). 026018.
- Jiang G. J., Fan S. Z., Abbod M. F., Huang H. H., Lan J. Y., Tsai F. F., Shieh J. S. Sample Entropy Analysis of EEG Signals via Artificial Neural Networks to Model Patients' Consciousness Level Based on Anesthesiologists Experience. *BioMed research international*, 2015: 343–350.
- Kaiser V., Bauernfeind G., Kreiling A., Kaufmann T., Kübler A., Neuper C., Müller-Putz G. R. Cortical effects of user training in a motor imagery based brain–computer

- interface measured by fNIRS and EEG. *Neuroimage*. 2014. 85: 432–444.
- Kiroy V.N., Lazurenko D.M., Shepelev I.E., Minyaeva N.R., Aslanyan E.V., Bakhtin O.M., Vladimirovskiy B. M.* Changes in EEG spectral characteristics in the course of neurofeedback training. *Human Physiology*. 2015. 41(3): 269–279.
- Kumar Y., Dewal M.L., Anand R.S.* Epileptic seizures detection in EEG using DWT-based ApEn and artificial neural network. *Signal, Image and Video Processing*. 2014. 8(7): 1323–1334.
- Mateo J., Torres A.M., García M.A., Santos J.L.* Noise removal in electroencephalogram signals using an artificial neural network based on the simultaneous perturbation method. *Neural Computing and Applications*. 2015: 1–17.
- Mullinger K.J., Mayhew S.D., Bagshaw A.P., Bowtell R., Francis S.T.* Evidence that the negative BOLD response is neuronal in origin: a simultaneous EEG–BOLD–CBF study in humans. *Neuroimage*. 2014. 94: 263–274.
- Park C., Looney D., Ahrabian A., Mandic D.P.* Classification of motor imagery BCI using multivariate empirical mode decomposition. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*. 2013. 21(1): 10–22.
- Pfurtscheller G., Solis-Escalante T., Barry R.J., Klobassa D.S., Neuper C., Müller-Putz G.R.* Brisk heart rate and EEG changes during execution and withholding of cue-paced foot motor imagery. *Frontiers in human neuroscience*. 2013. 7: 379.
- Ramadan R.A., Vasilakos A.V.* Brain computer interface: control signals review. *Neurocomputing*. 2017. 223: 26–44.
- Rumelhart D.E., Hinton G.E. and Williams R.J.* Learning internal representations by error propagation. In *Parallel distributed processing*, London: MIT Press. 1986. 1: 318–362.
- Sonkin K., Stankevich L., Khomenko Y., Nagornova Z., Shemyakina N., Koval A., Perets D.* Neurological Classifier Committee Based on Artificial Neural Networks and Support Vector Machine for Single-Trial EEG Signal Decoding. In: *International Symposium on Neural Networks* 2016, July. Springer International Publishing: 100–107.
- Ushiba J., Miyashita S., Ono T., Aono K., Kodama M., Masakado Y.* Feeling of Bodily Congruence to Visual Stimuli Improves Motor Imagery Based Brain-Computer Interface Control. In: *Converging Clinical and Engineering Research on Neurorehabilitation II2017*. Springer International Publishing. 2017. 907–911.
- Vedavathi B.S., Hiremath S.G., Biradar S., Thippeswamy G.* Wavelet transform based neural network model to detect and characterise ECG and EEG signals simultaneously. In: *Advance Computing Conference (IACC), 2015 IEEE International IEEE*: 743–748.
- Vasilyev A., Liburkina S., Yakovlev L., Perepelkina O., & Kaplan A.* (2017). Assessing motor imagery in brain-computer interface training: psychological and neurophysiological correlates. *Neuropsychologia*. <http://dx.doi.org/10.1016/j.neuropsychologia.2017.02.005>.
- Vuckovic A., Osuagwu B.A.* Using a motor imagery questionnaire to estimate the performance of a Brain–Computer Interface based on object oriented motor imagery. *Clinical Neurophysiology*. 2013. 124. 8: 1586–1595.
- Walker I., Deisenroth M., Faisal A.* Deep Convolutional Neural Networks for Brain Computer Interface using Motor Imagery. Imperial college of science, technology and medicine department of computing. 2015. 68.
- Wang Y., Zhang Z., Li Y., Gao X., Gao S., Yang F.* BCI competition 2003-data set IV: An algorithm based on CSSD and FDA for classifying single-trial EEG. *IEEE Transactions on Biomedical Engineering* 2004. 51(6): 1081–1086.
- Wolpaw J., Wolpaw E.W.* (ed.). *Brain-computer interfaces: principles and practice*. Oxford University Press, 2011. 393 p.
- Wu S.L., Liu Y.T., Hsieh T.Y., Lin Y.Y., Chen C.Y., Chuang C.H., Lin C.T.* Fuzzy Integral with Particle Swarm Optimization for a Motor-Imagery-based Brain-Computer Interface. *IEEE Transactions on Fuzzy Systems*. 2016: 334–340.
- Yang B.H., Wu T., Wang Q., Han Z.J.* Motor Imagery EEG Recognition Based on WPD-CSP and KF-SVM in Brain Computer Interfaces. In: *Applied Mechanics and Materials*. 2014. 556: 2829–2833.
- Yuksel A., Olmez T.* A Neural Network-Based Optimal Spatial Filter Design Method for Motor Imagery Classification. 2015, DOI: 10.1371/journal.pone.0125039
- Zich C., Debener S., Kranczjoch C., Bleichner M.G., Gutberlet I., De Vos M.* Real-time EEG feedback during simultaneous EEG–fMRI identifies the cortical signature of motor imagery. *NeuroImage*. 2015. 114: 438–447.

Приложение 1.

СОРЕВНОВАТЕЛЬНО-ГРАДИЕНТНЫЙ МЕТОД ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ

Соревновательно-градиентный метод обучения состоял в настройке параметров центра c и ширины d нейронов скрытого слоя, соответственно, соревновательным и градиентным методом в рамках одной итерации прямопоточных-обратнопоточных вычислений в нейронной сети.

Вначале обучения нейронных сетей производилась инициализация центров случайно выбранными входными векторами. Для первых четырех нейронных сетей выбирались четыре входных вектора, каждый из которых принадлежал отдельному классу мысленного движения и выбранные входные вектора присваивались

центрам единственных скрытых нейронов. Для пятой нейронной сети четыре входных вектора, каждый из которых также принадлежал отдельному классу мысленного движения, присваивались центрам четырех скрытых нейронов. Ширина нейронов скрытого слоя инициализировалась малыми значениями.

Соревновательная настройка центров нейронов скрытого слоя выполнялась на этапе прямопоточных вычислений. Целевая функция, имеющая вид:

$$E_c = \frac{1}{2} \sum_{i,j} (I_i - c_{ji})^2,$$

минимизировалась методом градиентного спуска:

$$\Delta c_{ji} = -\eta_c \frac{\partial E_c}{\partial c_{ji}},$$

где η_c – коэффициент скорости обучения параметра центра, индекс j для первых четырех нейронных сетей комитета с одним скрытым нейроном всегда имел единичное значение, для пятой нейронной сети индекс j определялся в результате прямопоточных вычислений. В ходе прямопоточных вычислений для предъявляемого входного вектора I послойно рассчитывались выходные значения нейронов скрытого и выходного слоя нейронной сети в соответствии с формулами 1) и 2). Соревновательный метод состоял в том, что после вычисления выходных значений нейронов скрытого слоя определялся нейрон j с максимальным выходным значением:

$$j: \max_{j=1,\dots,J} (y_j),$$

где J – количество нейронов скрытого слоя, и производилась модификация компонент вектора его центра:

$$c_{ji}(n+1) = c_{ji}(n) + \Delta c_{ji}(n),$$

$$\Delta c_{ji}(n) = \eta_c (I_i - c_{ji}(n)),$$

где n – номер итерации обучения.

Градиентная настройка параметра ширины d нейронов скрытого слоя выполнялась в ходе обратнопоточных вычислений в соответствии с методом обратного распространения ошибки (Rumelhart et al., 1986). С учетом единственности выходного нейрона в нейронных сетях, целевая функция имела вид:

$$E_d = \frac{1}{2} (O - t)^2 + \gamma \frac{1}{2} \sum_{i,j} d_{ji}^2,$$

где t – целевое выходное значение нейронной сети, γ – коэффициент регуляризации. Второе слагаемое ответственно за регуляризацию значений ширины, т.е. накладывало штраф за большие значения ширины. Величина штрафа контролировалась значением коэффициента регуляризации γ , которое определялось методом перебора с 5-кратной кросс-валидацией для каждой из нейронных сетей комитета. Целевая функция минимизировалась методом градиентного спуска:

$$\Delta d_{ji} = -\eta_d \frac{\partial E_d}{\partial d_{ji}},$$

где η_d – коэффициент скорости обучения параметра ширины. Обратнопоточные вычисления позволяли выполнить модификацию компонент вектора ширины нейронов скрытого слоя следующим образом:

$$d_{ji}(n+1) = d_{ji}(n) + \Delta d_{ji}(n),$$

$$\Delta d_{ji}(n) = y_j (O - t) \frac{(I_i - c_{ji})^2}{d_{ji}^2(n)} + \gamma d_{ji}(n),$$

где n – номер итерации обучения.

При обучении комитета каждая нейронная сеть проходила не менее 1000 итерационных циклов (n), но не более 10000.

A NEW MOTOR IMAGERY BASED BCI NEURAL NETWORKS APPROACH

**I. E. Shepelev, D. M. Lazurenko, V. N. Kiroy,
E. V. Aslanyan, O. M. Bakhtin, N. R. Minyaeva**

The center of neurotechnology Southern Federal University

Rostov-on-Don, Russia

e-mail: mityasky@ya.ru

A new neural network approach for the detection and classification motor imagery related EEG patterns in real-time has been proposed. The approach is based on the method of radial basis functions (RBF), the original interpretation algorithms of temporal sequence of responses and activation functions of neural networks. A new model of motor imagery-based asynchronous neural interface with a classifier consisted of a committee of five neural networks was tested. A comprehensive comparison of the efficiency of motor imagery recognition using radial-basis networks, multilayered perceptron, and support vector was performed. Experiments have shown a significant user training effects related with accuracy of recognition and classification of target EEG patterns, as well as speed control.

Keywords: neural network, radial basis functions, the interpreter, brain-computer interface, EEG, motor imagery.