

Ф.В. ГУНДЕЛАХ, Л.А. СТАНКЕВИЧ
**КЛАССИФИКАЦИЯ ПРОСТРАНСТВЕННО-ВРЕМЕННЫХ
ПАТТЕРНОВ НА ОСНОВЕ НЕЙРОМОРФНЫХ СЕТЕЙ**

Гунделах Ф.В., Станкевич Л.А. Классификация пространственно-временных паттернов на основе нейроморфных сетей.

Аннотация. Эта работа посвящена проблемам разработки нейроморфных классификаторов пространственно-временных паттернов, а также их применению в нейроинтерфейсах для решения задачи управления робототехническими устройствами. Рассматриваются классификаторы пространственно-временных паттернов на основе нейронных сетей, метода опорных векторов, глубоких нейронных сетей, римановой геометрии. Проводится сравнительное исследование этих классификаторов на точность многоклассового распознавания электроэнцефалографических сигналов, показывающих зависимость от времени биоэлектрическую активность в различных зонах мозга при воображении разных движений. Показано, что такие классификаторы могут обеспечить точность 60-80% при распознавании от двух до четырех классов воображаемых движений. Предложен новый тип классификатора на основе нейроморфной сети, биоподобные нейроны которой построены на модели Ижикевича. Исходный электроэнцефалографический сигнал кодируется в импульсные потоки на основе алгоритма временного кодирования. Предложенная нейроморфная сеть обрабатывает импульсные входные последовательности и формирует на выходах импульсные потоки разной частоты. Обучение сети проводится по размеченной информации, содержащей примеры правильного распознавания нужных классов паттернов воображаемых движений с применением алгоритма Supervised STDP. Распознанный класс паттерна воображаемого движения определяется по максимальной частоте импульсного потока выходной последовательности. Нейроморфный классификатор показал среднюю точность классификации 90% для 4-х классов воображаемых двигательных команд, а максимальная точность составила 95%. Путем моделирования задачи управления роботом в виртуальной среде показано, что такая точность классификации достаточна для эффективного применения классификатора в составе неинвазивного интерфейса «мозг-компьютер» при бесконтактном управлении робототехническими устройствами.

Ключевые слова: пространственно-временные паттерны, классификация, нейронные сети, опорные вектора, риманова геометрия, нейроморфные сети, нейроинтерфейс, электроэнцефалография, воображаемые движения, бесконтактное управление.

1. Введение. В настоящее время при контроле сложных процессов, а также диагностике и управлении сложными устройствами часто требуется решать задачи комплексного распознавания сигналов, имеющих определенную продолжительность во времени и снятых в разных точках пространства. Совокупность таких сигналов можно определить, как пространственно-временные паттерны (ПВП). Классификация таких паттернов позволяет определить ситуации процессов или действия объектов.

Одним из примеров ПВП является набор сигналов, полученных в определенном временном интервале от нескольких пространственно

разделенных датчиков, фиксирующих разные параметры технологического процесса [1, 2]. Классификация таких паттернов позволяет осуществлять контроль правильности протекания процесса. Другим примером является видеонаблюдение за несколькими объектами, траектории движения которых во времени вычисляются с помощью системы технического зрения, следящей за этими объектами [3, 4]. Классификация ПВП, составленных из таких сигналов, позволяет выявить ситуации, соответствующие опасным действиям наблюдаемых объектов.

В последнее время большое внимание уделяется разработке различных вариантов нейроинтерфейсов, в которых требуется распознавать сигналы биоэлектрической активности мозга или информации, передаваемой по нервам, в пространственно разделенных зонах мозга и периферийной нервной системы и определенных временных интервалах. Классификация таких ПВП дает возможность диагностировать состояния мозга, распознавать передаваемые по нервам команды и даже выявлять воображаемые человеком действия [5, 6]. Одним из распространенных применений нейроинтерфейсов является их использование для бесконтактного управления робототехническими устройствами, которые могут обеспечить лучшее качество жизни людям с ограниченными возможностями или расширить возможности здоровых людей. Так, обездвиженные люди могут через нейроинтерфейсы управлять электрическими инвалидными креслами, специализированными мобильными платформами, протезами верхних и нижних конечностей, манипуляторами типа третьей руки, экзоскелетами нижних и верхних конечностей, а также тела в целом [7, 8, 9]. Здоровые люди также могут использовать нейроинтерфейсы, например, для управления или роботизированными бытовыми устройствами, такими как пылесосы или стиральные машины, а также персонажами компьютерных игр и тренажеров [10]. Предполагается, что в ближайшем будущем нейроинтерфейсы могут быть использованы для бесконтактного управления аватарами, например, в виртуальной реальности [11] или виде автономных антропоморфных роботов, которые, в 21-м веке могут стать полноценными помощниками человека в быту и на производстве.

Классификация ПВП разного типа включает, как правило, этапы регистрации и подготовки набора входящих в них сигналов, а также использование различных методов вычисления степени принадлежности паттернов к определенным классам, на которые настроен классификатор. Каждый из этапов имеет свои особенности.

Так, для регистрации параметров технологических процессов используются набор отдельных датчиков, а параметры траекторий наблюдаемых объектов вычисляются по изображениям, получаемым с помощью видеокамеры. Такие средства регистрации используются давно, хорошо изучены и относительно просты в применении. В нейроинтерфейсах чаще всего в качестве средств получения информации о биоэлектрической активности мозга используются приборы, регистрирующие электроэнцефалографические (ЭЭГ) сигналы, а с нервов снимаются электромиографические (ЭМГ) сигналы. Популярность этих средств обусловлена тем, что при регистрации ЭЭГ или ЭМГ не требуется хирургическое вмешательство, т.е. средства регистрации являются неинвазивными и, как правило, недорогими.

Этап вычисления степени принадлежности ПВП к определенному классу из заданного набора классов также имеет свои особенности. ПВП, содержащие наборы параметров технологических процессов, классифицируются относительно просто и точно, например, с использованием метода опорных векторов, поскольку состояния процессов, как правило, хорошо различимы. Более сложно и с меньшей точностью можно классифицировать ПВП, полученные от системы технического зрения при видеонаблюдении, поскольку вычисление параметров движений объектов может производиться с ошибками. При этом наилучшие результаты по точности, как правило, могут дать классификаторы на основе нейронных сетей. Наиболее сложно классифицировать ПВП в нейроинтерфейсах, поскольку сигналы ЭЭГ и ЭМГ вариативны и сильно зашумлены. Для классификации таких паттернов могут использоваться различные методы, среди которых можно выделить методы, основанные на методе опорных векторов, нейронных сетях с глубоким обучением, римановой геометрии и различных комбинациях этих методов.

В последнее время начали разрабатывать и применять классификаторы, основанные на нейроморфных сетях, компоненты которых реализованы на биоподобных моделях нейронов. Предполагается, что такие нейроморфные классификаторы могут обеспечить высокую точность классификации ПВП и могут быть использованы в нейроинтерфейсах в системах управления устройствами в реальном времени и при большой вариативности и зашумленности сигналов.

Целью этой работы является разработка классификатора ПВП на основе нейроморфных сетей и оценка эффективности его

применения в нейроинтерфейсах для бесконтактного управления роботизированными устройствами.

Далее в секции 2 этой работы рассматриваются классификаторы пространственно-временных паттернов на основе нейронных сетей, опорных векторов, глубоких нейронных сетей, римановой геометрии. Проводится сравнительное исследование этих классификаторов на точность многоклассового распознавания электроэнцефалографических сигналов, показывающих зависимость от времени биоэлектрическую активность в различных зонах мозга при воображении разных движений. Показано, что такие классификаторы пока не могут обеспечить достаточную для бесконтактного управления точность для четырех классов воображаемых движений. В секции 3 описан специально разработанный классификатор повышенной точности на нейроморфной сети, биоподобные нейроны которой построены на модели Ижикевича. В секции 4 на основе моделирования показано, что достигнутая точность достаточна для эффективного применения классификатора в составе нейроинтерфейсов при бесконтактном управлении робототехническими устройствами. Секция 5 является заключительной, где подведены итоги исследования, даны некоторые рекомендации по разработке и применению нейроморфных классификаторов и намечены будущие исследования по их совершенствованию.

2. Классификаторы пространственно-временных паттернов.

Существующие классификаторы ПВП используют разные принципы обработки исходной информации. В первых вариантах классификаторов каждая последовательность регистрируемых отсчетов в определенном интервале времени подвергалась фильтрации для уменьшения уровня шума и удаления артефактов, после чего по специальным алгоритмам вычислялись векторы признаков, отображающие временные и пространственные особенности паттерна. При этом размерности векторов признаков были значительно меньше размерности исходной последовательности. По вычисленному набору векторов признаков и производилась собственно классификация ПВП. Так обычно делается в классификаторах на основе метода опорных векторов (МОВ) или искусственных нейронных сетей (ИНС) типа многослойных персептронов. В последних вариантах фаза вычисления специальных признаков была исключена, и классификацию стали проводить сразу после фильтрации и удаления артефактов. Это стало возможным в классификаторах на сверточных нейронных сетях (СНС), римановой геометрии и спайковых нейронных сетях (СпНС). В таких классификаторах происходит автоматическое снижение размерности

паттерна и перевод его в матрицу весов (для СНС), набор коэффициентов ковариации (для римановой геометрии) или импульсные последовательности (для СпНС). В настоящее время для классификации ПВП используются разные методы, такие как опорные вектора, нейронные сети типа персептронов, сверточные нейронные сети, риманова геометрия и нейроморфные сети.

В этой секции представлены результаты сравнительного исследования разных методов классификации с позиций точности классификации ПВП и возможности принятия решений в реальном времени.

Первым вариантом был двухуровневый комитет классификаторов, основанный на ИНС типа многослойного персептрона и МОВ [12, 13]. Первый уровень состоял из двух локальных классификаторов на ИНС типа многослойного персептрона с двумя скрытыми слоями и выходным слоем (в скрытых слоях использовалась сигмоидальная функция, а в выходном слое – линейная функция), а также и двух классификаторов на основе МОВ с ядром в виде радиально-базисной функции. Второй уровень представлял собой ИНС для объединения результатов классификаторов первого уровня. Классификаторы первого уровня анализировали отдельные векторы признаков: длина под кривой и кепстральные коэффициенты, полученные для 20 сегментов входного сигнала (всего 40 признаков) и выдавали ответы принадлежности сигнала пробы к тому или иному классу (4 класса). На основе этих сигналов формировался вектор признаков (16 компонентов) для ИНС второго уровня, который принимал окончательное решение о принадлежности данного ПВП к определенному классу из числа обученных.

Второй вариант классификатора был построен на базе специализированной СНС с глубоким обучением. В нашем случае для исследований была выбрана архитектура нейронной сети типа *Shallow ConvNet* с 4-мя слоями, способная классифицировать сырые сигналы ЭЭГ [14]. СНС включала: (1) слой свертки во времени (*Temporal Convolution Layer*): форма входного сигнала 21×300 ; размер ядра – 1×25 ; используется 40 фильтров; окно в 25 отсчетов выбрано исходя из формы сигнала ЭЭГ; (2) слой свертки в пространстве (*Spatial Convolution Layer*): размер входного тензора – 40 (количество фильтров) $\times 21$ (количество каналов) $\times 276$ (количество отсчетов после свертки по времени), размер ядра – 40×21 ; (3) усреднение в окне (*Mean Pooling*): размер входной матрицы – 40×276 , размера ядра – 1×75 ; (4) решающий слой (*softmax*): размер входной матрицы после *Mean Pooling* 40×14 . В качестве функции активации в скрытых и выходном

слоях использована экспоненциальная линейная функция (Exponential Linear Unit – ELU).

Третьим вариантом был специально разработанный классификатор на основе римановой геометрии, который, как и классификатор на СНС, не требует предварительного вычисления признаков, т.к. они вычисляются автоматически внутри классификатора [15]. Классификатор на римановой геометрии использует специфичное определение расстояния для сравнения ковариационных матриц, благодаря которому матрицы проб, относящихся к одному классу, оказываются ближе друг к другу, нежели матрицы проб из разных классов. Для реализации классификатора на основе римановой геометрии в данной работе использован алгоритм Minimum Distance to Mean, который является обобщением метода ближайших соседей для случая ковариационных матриц. Этот алгоритм вычисляет среднюю точку в пространстве признаков для каждого из классов. Данный подход интересен тем, что он работает одинаково для любого количества классов и имеет хорошую способность к обобщению при значительной вариативности исходных данных.

Четвертый вариант – классификатор ПВП, реализованный на СпНС [16]. Заметим, что использование СпНС для классификации временных последовательностей является относительно новым. В описанном классификаторе использована двухслойная СпНС, построенная на импульсных нейронах на основе самой простой модели Интегрирования и поджигания (Leaky-Integrate-and-Fire – LIF), включающей одно дифференциальное уравнение.

При исследовании этих классификаторов распознавались ПВП, содержащие наборы сигналов ЭЭГ, соответствующие различным воображаемым движениям. Тестирование проводилось на 10-ти испытуемых сначала с первыми 3-мя вариантами описанных классификаторов.

При тестировании комитета классификаторов в автономных сеансах при классификации паттернов ЭЭГ воображаемых команд без накопления проб вероятность успешной классификации 2-х типов воображаемых команд (сжатие левой и правой кисти) для испытуемых, обучившимся использованию нейроинтерфейса, точность классификации в среднем составляла $63 \pm 9\%$. Если считать только сессии, выполненные после овладения испытуемым навыком обращения с нейроинтерфейсом, то средняя точность составляла $70 \pm 10\%$. В процессе тестирования системы максимальная точность классификации составила 93% (таблица 1). В то же время

исследования показали, что небольшая часть испытуемых (около 30%) не способна научиться эффективно работать с нейроинтерфейсом на основе сигналов ЭЭГ (таблица 1). Кроме того, исследования показали, что характеристики классификатора соответствуют требованиям реального времени. Временные задержки, необходимые для получения ответа от классификатора, находились в пределах 150 мс, что является приемлемым для использования нейроинтерфейсов с биологически обратной связью.

При тестировании классификатора на основе СНС на его вход подавались очищенные от артефактов сырые сигналы ЭЭГ от выбранных каналов. Используя эти сигналы, сеть настраивалась на классификацию воображаемых команд, соответствующих сжатию и разжатию кисти левой и правой рук. На выходе сети формировался индекс воображаемой команды, на распознанное движение. Тестирование показало самые низкие точности классификации. В автономных сессиях, когда классификация паттернов воображаемых команд проводилась по одной попытке, вероятность успешной классификации команд при случайном пороге 50% в среднем составила $54 \pm 10\%$. После овладения испытуемым навыком обращения с нейроинтерфейсом средняя точность составляла $63 \pm 6\%$, а максимальная достигала 72% (таблица 1).

Тестирование классификаторов на основе римановой геометрии показало результаты несколько ниже, чем у комитетного классификатора. В автономных сессиях, когда классификация ЭЭГ-паттернов воображаемых команд проводилась по одной попытке, вероятность успешной классификации 2-х типов команд (сжатие левой и правой кисти) при случайном пороге 50% в среднем составила $60 \pm 8\%$. После овладения испытуемым навыком обращения с нейроинтерфейсом средняя точность составляла $64 \pm 8\%$, тогда как максимальная точность классификации достигала 83% (таблица 1).

Нужно отметить, что похожие результаты были получены при сравнительном исследовании подобных типов классификаторов другими исследователями [17].

Результаты тестирования нейроморфного классификатора взяты из работы [16]. Классификатор на СпНС описанной архитектуры показал наибольшую точность при распознавании двух классов ментальных состояний (стресса и расслабления): средняя точность составила $90\% \pm 8\%$, а максимальная точность достигала 95% (таблица 1).

Таблица 1. Результаты тестирования классификаторов

| | Комитет классификаторов | Сверточная сеть | Риманова геометрия | Нейро-морфная сеть |
|-----------------------|-------------------------|-----------------|--------------------|--------------------|
| Средняя точность | 70 ± 10% | 63 ± 6% | 64 ± 8% | 90 ± 5% |
| Максимальная точность | 93% | 72% | 83% | 95% |

Приведенные результаты показывают относительно низкую точность распознавания у первых трех типов классификаторов и существенно более высокую точность у нейроморфного классификатора. Однако все испытания проводились только для двух классов ПВП. При практическом использовании нейроинтерфейсов с такими классификаторами, например, для управления робототехническими устройствами, требуется распознавать более двух классов ПВП с точностью более 90%. Поэтому для развития этого направления были проведены дополнительные исследования для разработки нейроморфного классификатора, способного распознавать 4 и более ПВП, соответствующие воображаемым командам, с точностью не менее 90%.

3. Нейроморфный классификатор. Как видно из таблицы 1, классификатор на основе СпНС показал наибольшую точность классификации ПВП по сравнению с тремя типами других классификаторов. Вероятно, это может быть связано с некоторыми особыми свойствами, наследуемыми от биологических нейронных сетей, которые эффективно решают задачи классификации пространственно-временных сигналов, имеющих вид импульсных потоков. В каждом нейроне биологической сети множественные входные импульсные потоки кодируются в непрерывные величины (мембранные потенциалы) и после суммирования и порогового преобразования декодируются в импульсный поток на выходе нейрона. Импульсные потоки передаются от нейрона к нейрону, прежде всего, по причине экономии энергии.

В классификаторах на СпНС сначала выполняется кодирование входной информации – преобразование непрерывных сигналов в импульсные потоки. При этом часто применяется простой способ кодирования, когда каждому значению сигнала устанавливается определенная частота импульсов. Однако при этом игнорируется временная информация. Более сложные методы используют временное кодирование, например, кодирование с задержкой, фазовое кодирование на уровне одного нейрона или популяционное

кодирование для группы нейронов. Далее работает сама СпНС, на выходах которой формируются импульсные потоки, которые затем декодируются, например, с использованием частотной схемы: выходной нейрон сети с наибольшей частотой генерации импульсов рассматривается как превалирующий класс, соответствующий распознанному состоянию объекта.

Применение СпНС позволяет обойти ограничения ИНС на формальных нейронах за счет улучшения адаптации к новым условиям с сохранением предыдущих полученных навыков. Кроме того, имеет место большая устойчивость разрабатываемых систем к помехам и переменным данным, а также низкое энергопотребления в случае аппаратной реализации СпНС за счет передачи данных импульсными потоками.

Учитывая описанные свойства классификатора на СпНС, был разработан его новый вариант. В отличие от описанного в работе [16] варианта нейроморфного классификатора с простейшими спайковыми нейронами на модели LIF, в предлагаемом варианте СпНС строился как множество связанных биоподобных спайковых нейронов, модель которых описывается более сложными системами дифференциальных уравнений (модель Ижикевича). Предполагалось, что в таком варианте СпНС возможно достижение большей точности классификации, чем в предыдущем варианте с упрощенными нейронами.

Так, модель LIF, хотя требует меньше вычислительных затрат, но игнорирует форму потенциала действия и обращает внимание только на выбор времени (тайминг) спайка. Она описывается уравнением [18]:

$$\tau_m \frac{du}{dt} = u_{rest} - u(t) + RI(t).$$

Потенциал действия немедленно становится u_{rest} после поджигания. Абсолютный невосприимчивый период может быть определен как $u = -u_{abs}$ в течение периода после поджигания и затем потенциал действия устанавливается как u_{rest} .

По сравнению с этой простейшей моделью биоподобного нейрона, модель Ижикевича обеспечивает баланс между стоимостью вычислений и биологической реальностью. Она дает возможность описать много разных типов поджиганий. Эта феноменологическая модель описывает динамику мембранного потенциала. По критериям биологической релевантности она приближается к известной модели Ходжкина – Хаксли, но требует при этом гораздо меньше вычислительных ресурсов, что особенно важно при моделировании

нейронных сетей больших размеров. Модель описывается следующей системой уравнений [19]:

$$\frac{dv}{dt} = 0.04v^2 + 5v + 140 - I(t),$$

$$\frac{du}{dt} = a(bv - u),$$

с дополнительным условием сброса переменных при достижении пика импульса:

$$\text{if}(v \geq +30)\text{then}(v \leftarrow c) \wedge (u \leftarrow u + d),$$

где v – трансмембранный потенциал, u – переменная восстановления, a , b , c , d – параметры модели, $I(t)$ – ток, приложенный к мембране извне. При достижении потенциалом 30 мВ регистрируется спайк, и переменные сбрасываются до значений, описанных в уравнениях. В данной работе использовались следующие значения: $a = 0.02$; $b = 0.2$; $c = -65$ и $d = 8$. При таких параметрах в отсутствии внешнего воздействия нейрон находится в состоянии покоя, а при приложении внешнего постоянного тока генерирует регулярные импульсы, что характерно, например, для кортикальных нейронов.

В первом уравнении при моделировании сети нейронов внешний ток может быть представлен следующим образом:

$$I(t) = \varepsilon(t) + I_{syn}(t) + I_{stim}(t),$$

где $\xi(t)$ – некоррелированный белый гауссовский шум со средним 0 и стандартным отклонением D , $I_{syn}(t)$ – синаптический ток, $I_{stim}(t)$ – ток внешней стимуляции. В качестве внешней стимуляции может использоваться последовательность импульсов с частотой 10 Гц, с длительностью 3 мс и амплитудой, достаточной для возбуждения нейрона.

Синаптический ток вычислялся как сумма взвешенных выходных сигналов нейронов, посылающих связи к данному нейрону:

$$I_{syn}(t) = \sum_j g_j w_{ij} y_{ij}(t),$$

где g_j – коэффициент трансформации выходного сигнала нейрона j в синаптический ток (в работе использовались значения $g = 20$ для возбуждающих нейронов и $g = -20$ для тормозных), w_{ij} – вес связи,

идушей от пресинаптического нейрона j к постсинаптическому нейрону i , $y_{ij}(t)$ – выходной сигнал пресинаптического нейрона, в качестве которого подразумевается порция нейромедиатора, выбрасываемого в синапсах с каждым импульсом.

Первая задача, возникшая при проектировании нейроинтерфейса с классификатором на СпНС – импульсное кодирование непрерывных сигналов на входах – была решена выбором способа временного кодирования [20, 21].

Перед подачей данных в СпНС происходит преобразование спайков. Уравнение (1) обеспечивает вычисление порога, где $M(dif)$ и $Std(dif)$ означают среднее и стандартное отклонения временной разницы сигналов (dif). Значение dif конкретного канала ЭЭГ рассчитывается путем вычитания амплитуды в момент времени t на амплитуду в момент $t - 1$. Пороговый коэффициент f устанавливается пользователем (в наших экспериментах он был установлен на 0,5). После расчета Tr в соответствии с (1) сравниваются dif амплитуды в каждый момент времени. Если амплитуда dif превышает Tr в момент времени t , излучается возбуждающий спайк, а если амплитуда dif падает ниже Tr , излучается тормозной спайк.

$$Tr = M(dif) + f \times Std(dif). \quad (1)$$

Как показано на рисунке 1, где пики исходного сигнала представлены серией пиков, этот алгоритм кодирования придает особое значение флуктуациям амплитуды, позволяя сохранять характерные события в сигнале ЭЭГ. Этот метод может отфильтровать мельчайшие колебания, вызванные шумом сигнала.

Решение второй задачи – синтез структуры классификатора на СпНС – привело к выбору трехслойной прямонаправленной СпНС (рисунок 2). Первый слой сети включал 2 нейрона, которые принимали сигналы от двух выбранных предварительно каналов. Второй слой включал 5 и более нейронов, число которых определялось экспериментально и зависело от числа примеров, используемых при обучении классификатора. Третий слой сети в нашем случае включал 4 нейрона, что соответствовало количеству классов распознаваемых состояний. Задача обучения, т.е. настройки параметров СпНС с такой архитектурой, решалась на основе метода Supervised Spike Timing Dependent Plasticity (SSTDP) [22].

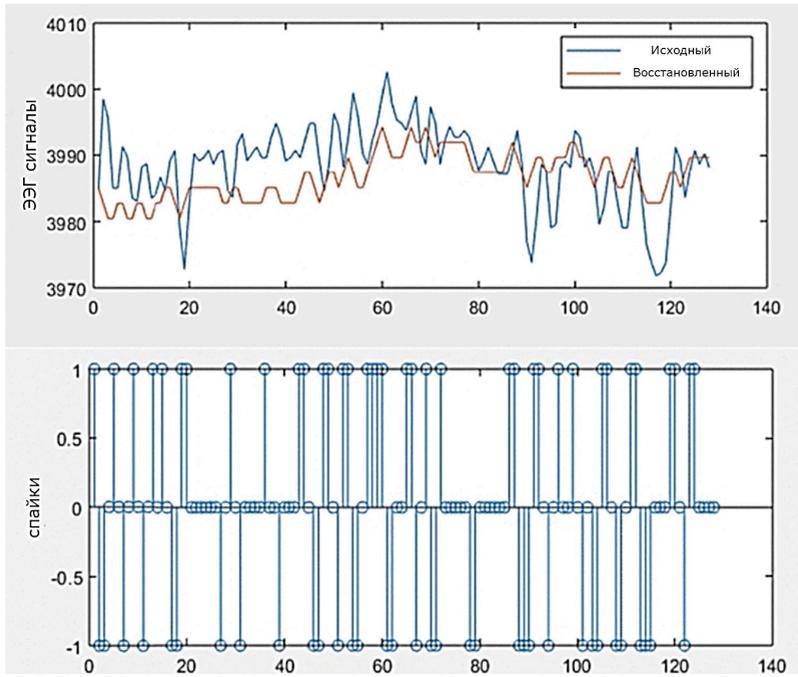


Рис. 1. Спайковое представление канала, экстрагированного из сигнала ЭЭГ. Верхние графики иллюстрируют оригинальный сигнал ЭЭГ (голубой) и реконструированный сигнал (красный)

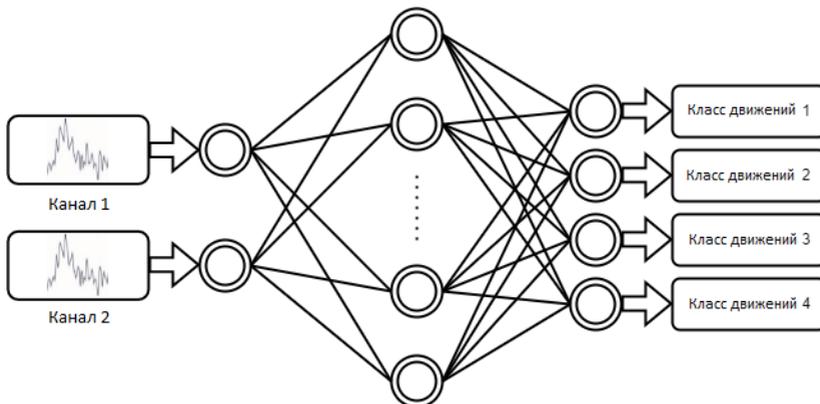


Рис. 2. Структура нейроморфного классификатора

Обучение и тестирование классификатора на СпНС проводилось на ПВП, содержащих волны вызванных потенциалов Р300, возникающих при поочередном отображении на мониторе 4-х стрелок, соответствующих направлениям движений, воображаемых испытуемым. Тестирование показало среднюю точность при 4-х классах ПВП $90 \pm 5\%$, а максимальную точность – до 95%, что в определенной степени соответствует нейроморфному классификатору, но настроенному на распознавание только двух классов ПВП (таблица 1).

4. Пример применения нейроморфного классификатора. Как показано в предыдущей секции, разработанный нейроморфный классификатор продемонстрировал достаточную точность и способность работать в реальном времени. На следующем этапе он был исследован на возможность использования в системе прямого бесконтактного управления мобильным роботом. Для практической реализации системы управления использовалась обратная связь в визуальной форме, которая позволяла пользователю научиться в процессе тренинга управлять роботом путем генерации воображаемых моторных команд. При этом требовалось, чтобы задержки ответов системы были достаточно малыми, чтобы мозг пользователя смог правильно ассоциировать ответы с событиями. Показано, что максимальный период задержки при формировании сигналов, определяющих распознанное состояние, не должен превышать 150 мс, что позволяет использовать обратную связь при работе оператора. Для выполнения этого условия в системе была реализована многопоточность, позволяющая записывать и обрабатывать одновременно несколько сигналов в заданном интервале времени без потери данных и выполнять онлайн классификацию.

Предварительные исследования, проведенные авторами этой работы, заложили основу для разработки универсальной структуры системы бесконтактного управления роботами с использованием классификации ПВП, содержащих сигналы ЭЭГ, регистрируемые в разных отведениях сенсомоторной зоны коры мозга [23, 24, 25]. На рисунке 3 представлена структура такой системы для управления передвижениями робота в виде мобильной платформы. ЭЭГ-прибор регистрирует текущие сигналы ЭЭГ по выбранным каналам, а нейроинтерфейс на основе классификатора ПВП производит предобработку данных для определения ЭЭГ-паттернов соответствующих воображаемым командам, после чего происходит расчёт характерных признаков этих паттернов и выполняется

их классификация, формируя на выходе класс движения, к которому относится воображаемая команда. Распознанные команды подаются на блок управления (БУ Перемещения), который формирует команды перемещения мобильной платформы (Вперед, Назад, Влево, Вправо).

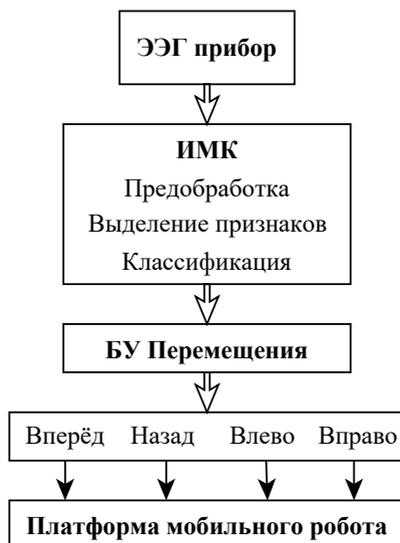


Рис. 3. Структура системы бесконтактного управления мобильным роботом

При проведении экспериментов согласно разработанной методике, пользователям предлагалось последовательно представлять 4 типа направлений движения (вперед, назад, вправо, влево) в соответствии с присвоенными им командами управления перемещением роботизированного устройства. При тренировке пользователи сначала должны мысленно реагировать на выбранные ими стрелки, последовательно отображаемые на мониторе, Тренировка была ориентирована на воображение выбранного направления движения мобильного робота. Тренировочная серия воображаемых направлений движения повторялась несколько раз до тех пор, пока классификатор не начнет уверенно распознавать вызванные потенциалы P300, соответствующие воображаемым направлениям движения. В результате пользователь должен был выполнить несколько десятков воображений направлений движений в одном блоке серии. Количество блоков серии должно соответствовать количеству типов выполняемых движений (движения по 4-м

направлениям). Таким образом, имитировалось прямое управление движением мобильного робота с помощью вызванных потенциалов.

Регистрация ПВП, содержащих сигналы ЭЭГ в разных отведениях выполнялась с помощью нейрогарнитуры «Muse headset 2016». Использовались 4 электрода: TP9, TP10, AF7, AF8 которые были расположены по системе 10-5. Сигналы ЭЭГ длительностью 800 мс регистрировались в полосе частот 1 Гц – 30 Гц. Частота дискретизации составляла 256 Гц. При анализе записей ЭЭГ были исключены артефакты, такие как движения глаз, медленные и быстрые волны, фрагменты сигналов ЭЭГ с амплитудой более 100 мкВ. Однако для последующей обработки использовались только два выбранных канала.

Для определения возможности управления мобильным роботом в соответствии со схемой, структура которой представлена на рисунке 3, был проведен эксперимент, в котором операторы, используя специальную нейрогарнитуру, управляли виртуальной моделью мобильной платформы.

Для управления был разработан программный модуль, преобразующий распознанные с помощью нейроинтерфейса воображаемые направления движения по стрелке на мониторе (рисунок 4) в команды управления виртуальной моделью робота в соответствии с таблицей 2. При управлении движениями: Вперед, Назад, Вправо, Влево было возможно выполнять воображение выбранного движения с заданным шагом (вперед или назад – 10 см, вправо или влево 10 градусов) неоднократно для выполнения дискретного движения или поворота мобильного робота. На этом этапе испытуемые некоторое время учились управлять моделью мобильного робота, многократно воображая нужные направления движения и повороты. Первые попытки управления движением робота показали, что для уверенного прохождения трассы было недостаточно распознавания одной попытки воображения выбранного действия, и робот мог уйти в сторону от трассы. Это было связано с недостаточной точностью распознавания движений в реальном времени по одной попытке. Далее удалось несколько улучшить результат прохождения трассы за счет усреднения трех попыток воображения выбранного движения.

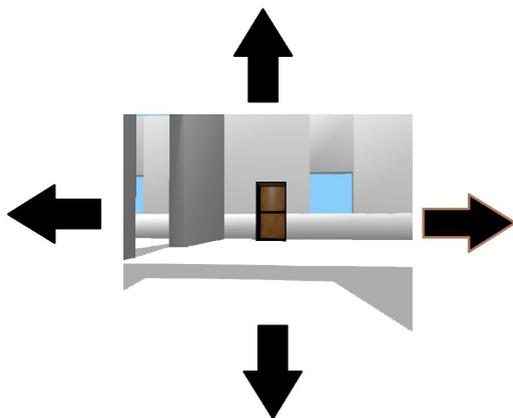


Рис. 4. Стрелки на мониторе для выбора направления движений

Таблица 2. Соответствие отображаемых символов и воображаемых и команд управления

| Номер команды | Отображаемые на мониторе символы | Воображаемые команды |
|---------------|----------------------------------|----------------------|
| 1 | Стрелка вправо | Вправо |
| 2 | Стрелка влево | Влево |
| 3 | Стрелка вверх | Вперед |
| 4 | Стрелка вниз | Назад |

Эксперимент по управлению виртуальной моделью мобильного робота проводился в среде Gazebo [26, 27] с использованием предварительно обученного классификатора на нейроморфной сети. Для эксперимента была создана модель робота на трехколесном шасси (два колеса ведущих, одно – флюгерное). Модель имитировала сервисного робота для развозки лекарств и пищи обездвиженным пациентам. На рисунке 5 показан вид модели, выполненной в программе «gobot» и функционирующей в среде Gazebo. Здесь же показана траектория движения робота при бесконтактном управлении.

В эксперименте участвовали 5 здоровых испытуемых. Предварительно производилось обучение классификатора на распознавание ПВП, соответствующих выбранным пользователем воображаемым направлениям движения по стрелкам на мониторе отдельно для каждого из испытуемых.

При этом была достигнута средняя точность классификации в онлайн режиме – 90%. Предполагается, что при тщательной настройке классификатора, они должны улучшиться.

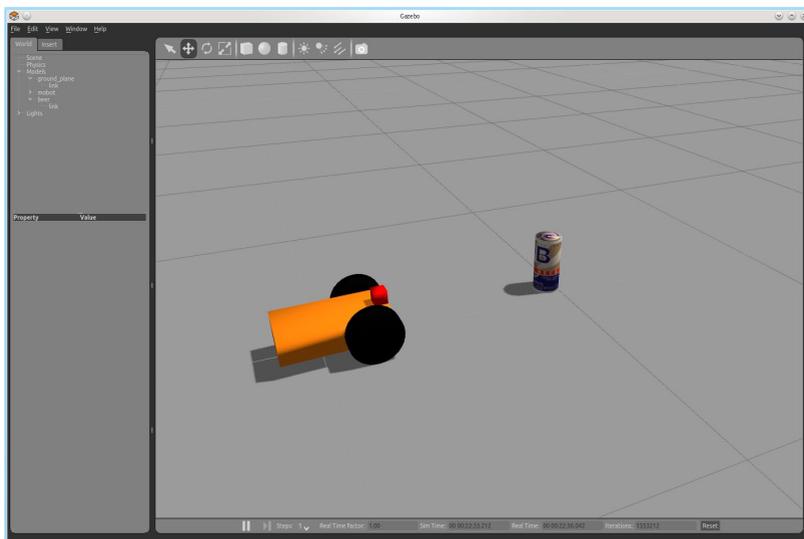


Рис. 5. Робот в среде Gazebo

5. Заключение. Классификация пространственно-временных паттернов, содержащих совокупность сигналов, имеющих определенную продолжительность во времени и снятых в разных точках пространства, выявляет ситуации процессов или действия объектов. Это позволяет эффективно решать задачи контроля сложных процессов, а также диагностики и управления устройствами со сложным поведением.

Сравнительное исследование различных методов классификации пространственно-временных паттернов, проведенное на данных биоэлектрической активности мозга, соответствующих двум классам ментальных состояний (например, воображаемых движений), показало, что все тестированные классификаторы после обучения способны различать эти состояния, но имеют разную точность. Классификатор на нейроморфных сетях показал лучшую точность по сравнению с классификаторами на нейронных сетях, методе опорных векторов и римановой геометрии. Однако эта точность показана только на двух классах состояний, что является недостаточным для практического использования, например, при управлении устройствами. Кроме того, этот классификатор формирует ответы с относительно большой задержкой, что затрудняет его использование в контурах обратной связи с оператором. Это привело

к необходимости разработки нового варианта нейроморфного классификатора, более пригодного для управляющих приложений.

Разработанный нейроморфный классификатор пространственно-временных паттернов позволяет распознавать 4 и более классов состояний с точностью $90 \pm 5\%$. Чтобы удовлетворять условию реального времени, максимальный период задержки при формировании сигналов, определяющих распознанное состояние, не должен превышать 150 мс, что позволяет использовать обратную связь при работе оператора. Для этого в системе управления реализована многопоточность, позволяющая записывать и обрабатывать одновременно несколько сигналов в заданном интервале времени без потери данных и выполнять онлайн классификацию.

Эксперимент показал, что 4 из 5-ти испытуемых после нескольких тренировочных сессий справились с управлением мобильной платформой в режиме прямого командного управления. Можно сделать предварительный вывод о том, что реальный мобильный робот такого типа может использоваться для подвоза по командам лежачего человека лекарства и воды, а также отвоза использованных приборов. Дополнительное оснащение платформы манипулятором необходимо, чтобы реализовать погрузку и разгрузку требуемых предметов. Решение этих задач позволит создать эффективные роботизированные средства, которые обеспечат людям с ограниченными двигательными функциями возможности управления робототехническими устройствами, используя сигналы мозга, что может значительно улучшить их функционирование в мире здоровых людей.

Нужно отметить, что на практике решение задач на импульсных моделях нейронов затруднено из-за высокой вычислительной сложности при их реализации, основанной на решении дифференциальных уравнений. Для снижения вычислительной сложности и ускорения работы импульсных нейронов можно применять различные приближения решений и даже аппаратные реализации СпНС. Эти подходы предполагается исследовать в дальнейшем.

Литература

1. Лисовский А.Л. Применение нейросетевых технологий для разработки систем управления. Стратегические решения и риск-менеджмент. 2020. Т. 11. № 4. С. 378–389. DOI: 10.17747/2618-947X-923.
2. Благовещенский В.Г., Благовещенский И.Г., Благовещенская М.М., Адноворцев А.М., Головин В.В. Управление технологическими процессами производства кондитерских изделий с использованием нейросетевого регулятора. Труды Всероссийской НТК «Информатизация и автоматизация

- в пищевой промышленности». Курск: Изд-во ЗАО «Университетские книги», 2022. С. 78–83.
3. Ульев А.Д., Розалиев В.Л., Заболеева-Зотова А.В., Орлова Ю.А. Интеллектуальная система видеонаблюдения за поведением человека // Искусственный интеллект и принятие решений. 2020. № 4. С. 21–32. DOI: 10.14357/20718594200403.
 4. Богущ Р.П., Захарова И.Ю. Алгоритм сопровождения людей на видеопоследовательностях с использованием сверточных нейронных сетей для видеонаблюдения внутри помещений // Компьютерная оптика. 2020. Т. 44. № 1. С. 109–116. DOI: 10.18287/2412-6179-CO-565.
 5. Brunner C., Birbaumer N., Blankertz B., Guger C., Kubler A., Mattia D., del R. Millan J., Miralles F., Nijholt A., Opisso E., Ramsey N., Salomon P., Muller-Putz G.R. BNCI Horizon 2020: towards a roadmap for the BCI community // Brain-Computer Interfaces. 2015. vol. 2. no. 1. pp. 1–10. DOI: 10.1080/2326263X.2015.1008956.
 6. Sharmila A. Hybrid control approaches for hands-free high level human-computer interface-a review // Journal of Medical Engineering & Technology. 2021. Т. 45. № 1. pp. 6–13.
 7. Diez P. Smart Wheelchairs and BCI. Mobile Assistive Technologies // Academic Press, 2018. 492 p.
 8. Кагиров И.А., Карпов А.А., Кипяткова И.С., Ключев К.С., Кудрявцев А.И., Кудрявцев И.А., Рюмин Д.А. Интеллектуальный интерфейс для управления роботизированным медицинским экзоскелетом нижних конечностей Remotion // Авиакосмическая и экологическая медицина, 2019. Т. 53. № 5. С. 92–98.
 9. Li Z., Li B., Luo W., Cao J. Design and Implementation of P300 Brain-Controlled Wheelchair with a Developed Wireless DA Converter. International journal of computers & technology. 2023. vol. 23. pp. 93–104. DOI: 10.24297/ijct.v23i.9485.
 10. Yakovlev L., Kaplan A., Sirov N. Gortz, N. BCI-Controlled Motor Imagery Training Can Improve Performance in e-Sports. HCI International 2020-Posters: 22nd International Conference. 2020. pp. 581–586. DOI: 10.1007/978-3-030-50726-8_76.
 11. Zhu H.Y., Hieu N.Q., Hoang D.T., Nguyen D.N., Lin C.-T. A Human-Centric Metaverse Enabled by Brain-Computer Interface: A Survey. arXiv preprint arXiv:2309.01848. 2023.
 12. Станкевич Л.А., Сонькин К.М., Нагорнова Ж.В., Хоменко Ю.Г., Шемякина Н.В. Классификация электроэнцефалографических паттернов воображаемых движений пальцами руки для разработки интерфейса мозг-компьютер. Труды СПИИРАН. 2015. Т. 3(40). С. 163–182. DOI: 10.15622/sp.40.11.
 13. Stankevich L.A., Sonkin K.M., Shemyakina N.V., Nagornova Zh.V., Khomenko Ju.G., Perets D.S., Koval A.V. EEG Pattern Decoding of Rhythmic Individual Finger Imaginary Movements of one Hand. Human Physiology. 2016. vol. 42. no. 1. pp. 32–42.
 14. Schirrmester R.T., Springenberg J.T., Fiederer L.D.J., Glasstetter M., Eggenberger K., Tangermann M., Hutter F., Burgard W., Ball T. Deep learning with convolutional neural networks for brain mapping and decoding of movement-related information from the human EEG. arXiv:1703.05051v5. 2018.
 15. Congedo M., Barachant A., Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces: a primer and a review // Brain-Computer Interfaces. 2017. vol. 4. no. 3. pp. 155–174. DOI: 10.1080/2326263X.2017.1297192.
 16. Weerasinghe M.M., Espinosa-Ramos J.I., Wang G.Y., Parry D. Incorporating Structural Plasticity Approaches in Spiking Neural Networks for EEG Modelling // IEEE Access. 2021. vol. 10. pp. 117338–117348. DOI: 10.1109/ACCESS.2021.3099492.

17. Капралов Н.В., Нагорнова Ж.В., Шемякина Н.В. Методы классификации ЭЭГ-паттернов воображаемых движений // Информатика и автоматизация. 2021. Т. 20. № 1. С. 94–132. DOI: 10.15622/ia.2021.20.1.4.
18. Gerstner W., Kistler W.M., Naud R., Paninski L. Neuronal dynamics: From single neurons to networks and models of cognition. Cambridge: Cambridge University Press, 2014. 578 p.
19. Izhikevich E.M. Simple model of spiking neurons. IEEE Trans. Neural Networks. 2003. vol. 14. no. 6. pp. 1569–1572. DOI: 10.1109/TNN.2003.820440.
20. Cui Y., Ahmad S., Hawkins J. The HTM spatial pooler—a neocortical algorithm for online sparse distributed coding // Frontiers in computational neuroscience. 2017. vol. 11. DOI: 10.3389/fncom.2017.00111.
21. Auge D., Hille J., Mueller E., Knoll A. A Survey of Encoding Techniques for Signal Processing in Spiking Neural Networks // Neural Processing Letters. 2021. vol. 53. no. 6. pp. 4693–4710. DOI: 10.1007/s11063-021-10562-2.
22. Liu F., Zhao W., Chen Y., Wang Z., Yang T., Jiang L. SSTDP: Supervised Spike Timing Dependent Plasticity for Efficient Spiking Neural Network Training. Frontiers in Neuroscience. 2021. vol. 15. DOI: 10.3389/fnins.2021.756876.
23. Станкевич Л.А., Гунделах Ф.В. Управление роботом с использованием интерфейса «мозг-компьютер» // Робототехника и техническая кибернетика. 2017. № 2(15). С. 52–56.
24. Гунделах Ф.В., Станкевич Л.А., Сонькин К.М., Шемякина Н.В., Нагорнова Ж.В. Применение интерфейсов «мозг-компьютер» в ассистивных технологиях // Труды СПИИРАН. 2020. Т. 19. № 2. С. 277–301.
25. Gundelakh F., Stankevich L., Kapralov N.V., Ekimovskii J.V. Cyber-Physical System Control Based on Brain-Computer Interfaces. Springer International Publishing, 2020. pp. 458–469.
26. Tutorial: ROS integration overview. URL: https://classic.gazebosim.org/tutorials?tut=ros_overview (дата обращения: 09.12.2023).
27. Ackerman E. Latest Version of Gazebo Simulator Makes It Easier Than Ever to Not Build a Robot. IEEE Spectrum. IEEE. 2016.

Гунделах Филипп Викторович — аспирант, кафедра мехатроники и роботостроения, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ). Область научных интересов: робототехника, интеллектуальные системы управления, обработка данных, интерфейсы «мозг-компьютер». Число научных публикаций — 26. f.gundelakh@yandex.su; улица Политехническая, 21, 195251, Санкт-Петербург, Россия; р.т.: +7(812)297-6780.

Станкевич Лев Александрович — канд. техн. наук, доцент, высшая школа автоматизации и робототехники, Санкт-Петербургский политехнический университет Петра Великого (СПбПУ). Область научных интересов: искусственный интеллект, когнитивные системы, антропоморфная робототехника, интерфейсы «мозг-компьютер». Число научных публикаций — 280. Stankevich_lev@inbox.ru; улица Политехническая, 21, 195251, Санкт-Петербург, Россия; р.т.: +7(812)552-9686.

Поддержка исследований. Исследование выполнено за счет гранта Российского научного фонда № 23-21-00287, <https://rscf.ru/project/23-21-00287>.

F. GUNDELAKH, L. STANKEVICH
**CLASSIFICATION OF SPATIAL TEMPORAL PATTERNS BASED
ON NEUROMORPHIC NETWORKS**

Gundelakh F., Stankevich L. Classification of Spatial Temporal Patterns Based on Neuromorphic Networks.

Abstract. This work is devoted to the problems of developing neuromorphic classifiers of spatiotemporal patterns, as well as their application in neurointerfaces. Classifiers of spatiotemporal patterns based on neural networks, support vector machines, deep neural networks, and Riemannian geometry are considered. A comparative study of these classifiers is carried out in the plane of the accuracy of multiclass recognition of electroencephalographic signals showing time-dependent bioelectrical activity in different areas of the brain during the imagination of different movements. It is shown that such classifiers can provide an accuracy of 60-80% when recognizing from two to four classes of imaginary movements. A new type of classifier based on a neuromorphic network, based on the biosimilar neurons built on the Izhikevich model, is proposed. The network processes input spike sequences and generates pulse streams of different frequencies at the outputs. The network is trained using the Supervised STDP algorithm based on labeled information containing examples of the correct recognition of the required pattern classes. The recognized pattern class is determined by the maximum frequency of the output sequence. The neuromorphic classifier showed an average classification accuracy of 90% for 4 classes of imaginary commands and a maximum of 95%. By modeling the robot control task in the virtual environment it is shown that such accuracy is sufficient for the effective use of the classifier as part of a non-invasive brain-computer interface for non-contact control of robotic devices.

Keywords: spatiotemporal patterns, classification, neural networks, support vectors, Riemannian geometry, neuromorphic networks, neurointerface, electroencephalography, imaginary movements, non-contact control.

References

1. Lisovsky A.L. Application of neural network technologies for management development of systems. Strategic decisions and risk management. 2020. vol. 11. no. 4. pp. 378–389. DOI: 10.17747/2618-947X-923. (In Russ.).
2. Blagoveshhenskij V.G., Blagoveshhenskij I.G., Blagoveshhenskaja M.M., Adnodorcev A.M., Golovin V.V. [Control of technological product processes for confection wares using neural network regulator] Upravlenie tehnologicheskimi processami proizvodstva konditerskih izdelij s ispol'zovaniem nejrosetevogo reguljatora [Proceedings of the All-Russian Scientific and Technical Committee «Informatization and automation in the food industry»]. Kursk: Published: Books of Universities, 2022. pp. 78–83.
3. Uliev A.D., Rozaliev V.L., Zaboleeva-Zotova A.V., Orlova Y.A. [An Intelligent Video Surveillance System for Human Behavior]. Iskusstvennyj intellekt i prinjatje reshenij – Artificial intelligence and decision making. 2020. no. 4. pp. 21–32. DOI: 10.14357/20718594200403. (In Russ.).
4. Bohush R.P., Zakharava I.Y. Person tracking algorithm based on convolutional neural network for indoor video surveillance. Computer Optics. 2020. vol. 44. no. 1. pp. 109–116. DOI: 10.18287/2412-6179-CO-565. (In Russ.).
5. Brunner C., Birbaumer N., Blankertz B., Guger C., Kubler A., Mattia D., del R. Millan J., Miralles F., Nijholt A., Opisso E., Ramsey N., Salomon P., Muller-

- Putz G.R. BNCI Horizon 2020: towards a roadmap for the BCI community. *Brain-Computer Interfaces*. 2015. vol. 2. no. 1. pp. 1–10. DOI: 10.1080/2326263X.2015.1008956.
6. Sharmila A. Hybrid control approaches for hands-free high level human–computer interface—a review. *Journal of Medical Engineering & Technology*. 2021. vol. 45. no. 1. pp. 6–13.
 7. Diez P. *Smart Wheelchairs and BCI. Mobile Assistive Technologies*. Academic Press, 2018. 492 p.
 8. Kagirov I.A., Karpov A.A., Kipyatkova I.S., Klyuzhev K.S., Kudryavtsev A.I., Kudryavtsev I.A., Ryumin D.A. [Intellectual Interface to Control a Robotic Medical Exoskeleton of the Lower Limbs «Remotion»]. *Aviakosmicheskaja i jekologicheskaja medicina – Aviacosmos and ecological medicine*. 2019. vol. 53. no. 5. pp. 92–98. (In Russ.).
 9. Li Z., Li B., Luo W., Cao J. Design and Implementation of P300 Brain-Controlled Wheelchair with a Developed Wireless DA Converter. *International journal of computers & technology*. 2023. vol. 23. pp. 93–104. DOI: 10.24297/ijct.v23i.9485.
 10. Yakovlev L., Kaplan A., Sirov N., Gortz, N. BCI-Controlled Motor Imagery Training Can Improve Performance in e-Sports. *HCI International 2020-Posters: 22nd International Conference*. 2020. pp. 581–586. DOI: 10.1007/978-3-030-50726-8_76.
 11. Zhu H.Y., Hieu N.Q., Hoang D.T., Nguyen D.N., Lin C.-T. A Human-Centric Metaverse Enabled by Brain-Computer Interface: A Survey. *arXiv preprint arXiv:2309.01848*. 2023.
 12. Stankevich L., Sonkin K., Nagornova Z., Khomenko J., Shemyakina N. Classification of Electroencephalographic Patterns of Imaginary One-hand Finger Movements for Brain-Computer Interface Development. *SPIIRAS Proceedings*. 2015. vol. 3(40). pp. 163–182. DOI: 10.15622/sp.40.11. (In Russ.).
 13. Stankevich L.A., Sonkin K.M., Shemyakina N.V., Nagornova Zh.V., Khomenko Ju.G., Perets D.S., Koval A.V. EEG Pattern Decoding of Rhythmic Individual Finger Imaginary Movements of one Hand. *Human Physiology*. 2016. vol. 42. no. 1. pp. 32–42.
 14. Schirrmester R.T., Springenberg J.T., Fiederer L.D.J., Glasstetter M., Eggenberger K., Tangemann M., Hutter F., Burgard W., Ball T. Deep learning with convolutional neural networks for brain mapping and decoding of movement-related information from the human EEG. *arXiv:1703.05051v5*. 2018.
 15. Congedo M., Barachant A., Bhatia R. Riemannian geometry for EEG-based brain-computer interfaces: a primer and a review // *Brain-Computer Interfaces*. 2017. vol. 4. no. 3. pp. 155–174. DOI: 10.1080/2326263X.2017.1297192.
 16. Weerasinghe M.M., Espinosa-Ramos J.I., Wang G.Y., Parry D. Incorporating Structural Plasticity Approaches in Spiking Neural Networks for EEG Modelling. *IEEE Access*. 2021. vol. 10. pp. 117338–117348. DOI: 10.1109/ACCESS.2021.3099492.
 17. Kapralov N., Nagornova Z., Shemyakina N. Classification Methods for EEG Patterns of Imaginary Movements. *Informatics and Automation*. 2021. vol. 20. no. 1. pp. 94–132. DOI: 10.15622/ia.2021.20.1.4. (In Russ.).
 18. Gerstner W., Kistler W.M., Naud R., Paninski L. *Neuronal dynamics: From single neurons to networks and models of cognition*. Cambridge: Cambridge University Press, 2014. 578 p.
 19. Izhikevich E.M. Simple model of spiking neurons. *IEEE Trans. Neural Networks*. 2003. vol. 14. no. 6. pp. 1569–1572. DOI: 10.1109/TNN.2003.820440.
 20. Cui Y., Ahmad S., Hawkins J. The HTM spatial pooler—a neocortical algorithm for online sparse distributed coding. *Frontiers in computational neuroscience*. 2017. vol. 11. DOI: 10.3389/fncom.2017.00111.

21. Auge D., Hille J., Mueller E., Knoll A. A Survey of Encoding Techniques for Signal Processing in Spiking Neural Networks. *Neural Processing Letters*. 2021. vol. 53. no. 6. pp. 4693–4710. DOI: 10.1007/s11063-021-10562-2.
22. Liu F., Zhao W., Chen Y., Wang Z., Yang T., Jiang L. SSTDP: Supervised Spike Timing Dependent Plasticity for Efficient Spiking Neural Network Training. *Frontiers in Neuroscience*. 2021. vol. 15. DOI: 10.3389/fnins.2021.756876.
23. Stankevich L.A. Gundelakh F.V. Robot control with use brain-computer interface. *Robotics and technical cybernetics*. 2017. no. 2(15). pp. 52–56. (In Russ.).
24. Gundelakh F., Stankevich L., Sonkin K., Nagornova G., Shemyakina N. Application of Brain-computer Interfaces in Assistive Technologies. *SPIIRAS Proceedings*. 2020. vol. 19. no. 2. pp. 277–301. (In Russ.).
25. Gundelakh F., Stankevich L., Kapralov N.V., Ekimovski J.V. *Cyber-Physical System Control Based on Brain-Computer Interfaces*. Springer International Publishing, 2020. pp. 458–469.
26. Tutorial: ROS integration overview. Available at: https://classic.gazebosim.org/tutorials?tut=ros_overview (accessed: 09.12.2023).
27. Ackerman E. Latest Version of Gazebo Simulator Makes It Easier Than Ever to Not Build a Robot. *IEEE Spectrum*. IEEE. 2016.

Gundelakh Filipp — Ph.d. student, Mechatronics and robotics department, Peter the Great Saint-Petersburg Polytechnic University (SPbPU). Research interests: robotics, intellectual control systems, data processing, brain-computer interfaces. The number of publications — 26. f.gundelakh@yandex.su; 21, Polytechnic St., 195251, St. Petersburg, Russia; office phone: +7(812)297-6780.

Stankevich Lev — Ph.D., Associate professor, High school of automation and robotics, Peter the Great Saint-Petersburg Polytechnic University (SPbPU). Research interests: artificial intelligence, cognitive systems, anthropomorphic robotics, brain-computer interfaces. The number of publications — 280. Stankevich_lev@inbox.ru; 21, Polytechnic St., 195251, St. Petersburg, Russia; office phone: +7(812)552-9686.

Acknowledgements. This research is supported by a grant of the Russian Science Foundation (RCF) No. 23-21-00287, <https://rscf.ru/en/project/23-21-00287>.