
СИСТЕМНЫЙ АНАЛИЗ, УПРАВЛЕНИЕ И ОБРАБОТКА ИНФОРМАЦИИ

УДК 681.518

ДЕТЕКТИРОВАНИЕ СОБЫТИЙ ДВИЖЕНИЯ РУКИ В СИГНАЛАХ ЭЭГ ГОЛОВНОГО МОЗГА

Статья поступила в редакцию 23.09.2015 г., в окончательном варианте 26.10.2015 г.

Попов Евгений Юрьевич, аспирант, Волгоградский государственный технический университет, 400005, Российская федерация, г. Волгоград, пр. им. Ленина, 28, e-mail: popov.e@hotmail.com

Фоменков Сергей Алексеевич, доктор технических наук, профессор, Волгоградский государственный технический университет, 400005, Российская федерация, г. Волгоград, пр. им. Ленина, 28, e-mail: saf@vstu.ru

Рассмотрен метод обнаружения 6 определенных событий движения руки в 32-компонентном сигнале ЭЭГ головного мозга посредством использования сверточной нейронной сети (НС) в качестве многоклассового классификатора. В работе предложены и эмпирически оценены несколько вариантов архитектуры сверточной НС, а также два варианта функций активации нейронов скрытых слоев НС. Показаны преимущества выбранного метода классификации для решаемой задачи. Полученные результаты дают возможность говорить о том, что использование данного вида классификатора позволяет эффективно выделять характерные признаки в исходных ЭЭГ сигналах, а на выходе НС получать вероятности принадлежности входного сигнала одному из заданных классов движений руки. Использование нестандартной функции активации нейронов скрытого слоя (rectified linear) обеспечивает улучшение качества классификации. Предложенная архитектура сверточной НС легко поддается модификации как в ширину (добавление новых плоскостей признаков на сверточном слое), так и в глубину (добавление новых сверточных и субдискретизационных слоев). За счет этого возможно дальнейшее улучшение полученного в исследовании качества классификации.

Ключевые слова: ЭЭГ, нейрокомпьютерный интерфейс, сверточная нейронная сеть, глубокое обучение, функция активации, классификация, ADADELTA, reclassified linear, softmax, перекрестная энтропия, вызванные потенциалы

HAND MOTIONS DETECTION IN EEG SIGNALS

Popov Yevgeniy Yu., post-graduate student, Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation, e-mail: popov.e@hotmail.com

Fomenkov Sergey A., D.Sc. (Engineering), Professor, Volgograd State Technical University, 28 Lenin Ave., Volgograd, 400005, Russian Federation, e-mail: saf@vstu.ru

This paper describes hand motions detection method in 32-component EEG signals. This method is based on using convolution neural network as multi-class classifier. In this paper we proposed and empirically evaluated several architectures of convolutional neural network as well as two versions of activation function for hidden layers neurons, shown advantages of using convolutional neural network for investigating problem. The results suggest that this type of classifier can effectively distinguish characteristic features in the initial EEG signals and provide right values of neural network outputs. Using rectifier linear activation function for hidden layers neurons increases classification quality. Convolutional neural network's architecture is agile and can be easily modified in width (adding new feature maps on convolutional layers) and in depth (adding new convolutional and pooling layers), thus allowing further improvement of classification quality.

Keywords: EEG, brain-computer interface, convolutional neural network, deep learning, activation function, classification, ADADELTA, softmax, rectified linear, cross-entropy, event-related potential

Введение. В настоящее время множество исследований посвящено вопросам хотя бы частичной реабилитации людей с утраченными или ограниченными физическими возможностями. В частности, решаются задачи создания широко доступных протезов конечностей (в основном рук), которые могли бы контролироваться посредством управляющих сигналов головного мозга. Одним из альтернативных вариантов является также использование электромиографических сигналов с культей рук. Углубленный анализ этих сигналов позволяет даже дифференцировать «желаемые» движения отдельных пальцев [1].

Исследователями предпринимаются попытки создания доступных, неинвазивных, недорогих нейрокомпьютерных интерфейсов, которые могли бы быть использованы людьми с ограниченными возможностями в повседневной жизни [15]. Однако задача использования подобных интерфейсов для управления протезами требует глубокого исследования взаимосвязей между ЭЭГ сигналами головного мозга и двигательной активностью конечностей. Эти вопросы в существующей литературе исследованы недостаточно полно. Поэтому целью данной работы является исследование возможности детектирования определенного набора событий движения руки в сигналах ЭЭГ головного мозга с помощью математических методов классификации.

Эксперимент. В своем исследовании мы использовали открытые исследовательские данные записей ЭЭГ сигналов, собранные и предоставленные университетом Умео [14]. Данные были собраны в соответствии с парадигмой «взять и поднять» объект, представленной Йоханссоном и Вестлингом в 80-е гг. XX в. [9, 10, 17]. Указанная парадигма широко используется в подобных исследованиях.

В сборе исследовательских данных приняли участие 12 человек. Каждый участник эксперимента участвовал в 10 сессиях сбора данных, примерно по 30 попыток выполнения необходимых действий в каждой сессии.

Задача одной попытки для участников эксперимента была поставлена в следующем виде: дотянуться рукой до небольшого предмета; взять его указательным и большим пальцами; поднять предмет на несколько сантиметров над поверхностью стола; удерживать предмет в воздухе несколько секунд; затем положить предмет на место; вернуть руку в исходное положение. В целях получения однородных данных моменты начала выполнения попытки и необходимости опускания предмета задавались с помощью светового сигнала (лампы).

Каждая попытка содержала 10 000–11 000 точек фиксации ЭЭГ сигнала с фиксированным шагом отсчетов по времени. Суммарный объем собранных данных составил 3 936 попыток «взять и поднять».

Во всех сессиях сбора данных без предварительного уведомления участников эксперимента несколько раз менялись свойства используемого для подъема предмета: вес (165, 330 или 660 г) и поверхности предмета (наждачная бумага, замша или шелк). Данные изменения производились с целью внесения некоторой вариативности в мышечную активность при выполнении попыток. Например, сила сжатия предмета и усилия, прикладываемые для его подъема, увеличиваются при увеличении веса предмета. Однако при неизменном весе, но разной поверхности предмета, увеличивается только сила сжатия.

Во время выполнения всех попыток данные ЭЭГ сигналов головного мозга записывались с помощью 32-электродного неинвазивного нейрокомпьютерного интерфейса ActiCap. Частота дискретизации сигналов данного нейрокомпьютерного интерфейса составляет 5 кГц, разрешение единичных значений амплитуд сигналов 0,1 мкВ. Схема расположения электродов нейрокомпьютерного интерфейса ActiCap приведена ниже (рис. 1).




Рис. 1. Схема расположения электродов нейрокомпьютерного интерфейса ActiCap [8]

Полученные данные были преобразованы специальными методами обработки сигналов [14], и каждому моменту времени в каждой попытке были сопоставлены имевшие место в этот момент события (фазы выполнения задания) из следующего набора:

- 1) начало движения руки;
- 2) начальное касание предмета пальцами;
- 3) оба пальца держат предмет;
- 4) подъем предмета;
- 5) возвращение предмета на место (поверхность стола);
- 6) оба пальца отпустили предмет.

Выбор метода классификации и его реализация. По результатам анализа методов классификации было решено использовать искусственные нейронные сети (НС), так как они могут выполнять роль классификатора, хорошо моделирующего нелинейные функции. Тем самым увеличивается точность классификации по сравнению с другими методами машинного обучения, такими как леса решающих деревьев, градиентный бустинг над линейными классификаторами, SVM [5].

Было принято решение реализовать классификатор на основе сверточной НС [7, 13], так как свойства данного вида классификаторов позволяют в автоматическом режиме выделять признаки в исходном наборе данных. Это свойство особенно полезно в исследуемой задаче, так как осуществить отбор значащих признаков в исходном наборе данных в ручном режиме в соответствии со «здоровым смыслом» практически невозможно (это значительно ограничивает возможность применения других видов классификаторов).

Кроме того, для исследуемой задачи желательно, чтобы классификатор выдавал значения вероятности принадлежности к каждому из классов событий движения руки для каждого

из наборов данных ЭЭГ в определенный момент времени. Данное условие выполняется также при использовании в качестве классификатора сверточной НС, что будет показано ниже.

В таблице 1 представлены несколько конфигураций сверточной НС, используемых в исследовании. Предложены 4 варианта конфигурации сети в зависимости от размерности входного слоя. Четвертый вариант конфигурации представляет собой плоскость, размеры которой задаются следующей формулой:

$$X = EEG_channels \times time_points, \quad (1)$$

где $EEG_channels$ – количество ЭЭГ сигналов с различных электродов используемого нейрокомпьютерного интерфейса; $time_points$ – количество моментов времени.

Таблица 1

Варианты конфигурации сверточной нейронной сети

Номер слоя	Тип слоя	Число плоскостей	Размер плоскостей
Вариант 1			
1	Входной	1	32 × 48
2	Сверточный	64	32 × 46
3	Слой субдискретизации	64	32 × 23
4	Полносвязный	128	1
5	Выходной (полносвязный)	6	1
Вариант 2			
1	Входной	1	32 × 64
2	Сверточный	64	32 × 62
3	Слой субдискретизации	64	32 × 31
4	Полносвязный	128	1
5	Выходной (полносвязный)	6	1
Вариант 3			
1	Входной	1	32 × 80
2	Сверточный	64	32 × 78
3	Слой субдискретизации	64	32 × 39
4	Полносвязный	128	1
5	Выходной (полносвязный)	6	1
Вариант 4			
1	Входной	1	32 × 96
2	Сверточный	64	32 × 94
3	Слой субдискретизации	64	32 × 47
4	Полносвязный	128	1
5	Выходной (полносвязный)	6	1

Второй слой НС является сверточным. Он состоит из набора плоскостей и предназначен для выделения характерных признаков в исходных ЭЭГ сигналах в виде карты признаков. Каждый нейрон сверточного слоя связан с определенной областью нейронов предыдущего слоя. В операции свёртки используется ограниченная матрица весов определенного размера, которую последовательно применяют ко всему обрабатываемому слою. При этом после каждого сдвига формируется сигнал активации для нейрона следующего слоя с аналогичной позицией в НС. Таким образом, для различных нейронов выходного слоя используются общие веса. Соответствующую матрицу весов называют также ядром свёртки. Это обеспечивает нахождение характерных признаков в любом «месте» ЭЭГ-сигнала по времени и уменьшает общее число весовых коэффициентов. В данном исследовании для второго слоя НС использовалось ядро свёртки размером 1 × 3. Так как предполагалось, что характерные признаки следует искать в ЭЭГ сигналах во временном измерении. Процесс функционирования нейрона сверточного слоя задается выражением:

$$y_{i,j}^k = \sigma \left(b^k + \sum_{l=0}^{N-1} \sum_{m=0}^{M-1} w_{l,m} a_{i+l,j+m} \right), \quad (2)$$

где $y_{i,j}^k$ – значение выходного сигнала нейрона k -ой плоскости сверточного слоя, b^k – нейронное смещение k -ой плоскости, $w_{l,m}$ – элемент матрицы ядра свертки, $a_{i+l,j+m}$ – значение выходов нейронов предыдущего слоя, N, M – размер ядра свертки, σ – функция активации нейрона.

Третий слой НС представляет собой слой субдискретизации и выполняет функцию уменьшения размерности сформированных на предыдущем слое карт признаков. В архитектуре сверточной НС предполагается, что информация о факте наличия искомого признака важнее точного знания его координат. Поэтому из нескольких соседних нейронов карты признаков выбирается максимальный и принимается за один нейрон карты признаков уменьшенной размерности. В данном исследовании ядро операции субдискретизации было выбрано размером 1×2 .

Последние два слоя являются полносвязными, состоящими из стандартных нейронов с определенной функцией активации. Они производят финальную классификацию признаков, выделенных в предыдущем слое. Так как набор из классифицируемых событий движения руки состоит из 6 элементов (вариантов), то выходной слой НС содержит 6 нейронов.

В качестве функции активации нейронов скрытых слоев НС (2–4 слоя) в исследовании использовались два варианта.

1. Логистическая функция активации, которая задается выражением:

$$\sigma(x) = 1/(1 + e^{-\lambda x}), \quad (3)$$

где λ – параметр, определяющий крутизну функции, x – вектор входных значений для нейрона.

2. Rectified linear – функция активации, которая задается выражением:

$$\sigma(x) = \max(0, w \cdot x + b), \quad (4)$$

где w – вектор весов, x – вектор входных значений для нейрона, b – нейронное смещение.

Так как в рассматриваемой нами задаче классификации необходимо получить на выходе НС вероятности принадлежности входного сигнала одному из классов, то в качестве функции активации нейронов выходного слоя использовалась функция softmax, которая задается выражением:

$$\sigma(x)_i = e^{x_i} / \sum_{j=1}^n e^{x_j}, \quad (5)$$

где x – вектор входных значений для нейрона, i – номер нейрона, n – количество нейронов в слое.

Данная функция преобразует вектор x размерности n , состоящий из вещественных значений, в вектор $\sigma(x)$ размерности n , состоящий из вещественных значений в интервале $(0, 1)$, сумма которых равна 1.

В качестве функции ошибки классификации использовалась перекрестная энтропия:

$$E = -1/Q \sum_{q=1}^Q \sum_{i=1}^n t_i^q \ln y_i^q, \quad (6)$$

где Q – количество примеров в обучающей выборке; n – число выходов в сети; t_i^q – требуемое (целевое) значение i -го выхода сети при подаче примера q ; y_i^q – реальное значение i -го выхода сети при подаче примера q .

Результаты экспериментов по классификации сигналов ЭЭГ с использованием нейронных сетей. Для построения НС использовался язык программирования Python и пакеты алгоритмов машинного обучения scikit-learn, Theano, Lasagne, Neon.

Для обучения всех указанных выше вариантов архитектур НС использовался алгоритм ADADELTA [18]. В качестве обучающей выборки использовались данные 1–8 сессий экспериментов для каждого из участников. Для тестовой выборки, на которой оценивалось качество классификации, использовались данные 9 и 10 сессий экспериментов для каждого из участников.

В таблицах 2–9 представлены результаты оценки качества классификации каждого исследуемого события движения руки для каждой используемой в работе архитектуры НС. Условные обозначения С.1–С.6 соответствуют исследуемым событиям движения руки.

Таблица 2

Результаты оценки качества классификации сверточной НС с архитектурой вариант 1 и логистической функцией активации нейронов скрытых слоев (%)

Классифицированные события \ Фактические события	Классифицированные события					
	С.1	С.2	С.3	С.4	С.5	С.6
С.1	88,7	3,8	0,5	2,1	4,5	0,4
С.2	2,8	85,3	3,9	3,7	3,3	1,0
С.3	0,0	1,3	82,3	8,6	7,8	0,0
С.4	0,0	0,4	6,1	81,8	11,7	0,0
С.5	4,3	1,7	2,4	3,4	88,2	0,0
С.6	10,3	4,1	0,0	0,0	0,7	84,9

Таблица 3

Результаты оценки качества классификации сверточной НС с архитектурой вариант 1 и rectified linear функцией активации нейронов скрытых слоев (%)

Классифицированные события \ Фактические события	Классифицированные события					
	С.1	С.2	С.3	С.4	С.5	С.6
С.1	92,9	2,3	0,2	0,8	3,6	0,2
С.2	2,1	89,4	2,8	3,0	2,1	0,6
С.3	0,0	0,7	87,0	6,2	6,1	0,0
С.4	0,0	0,3	5,2	87,2	7,3	0,0
С.5	3,4	0,5	1,1	1,7	93,3	0,0
С.6	6,1	2,7	0,0	0,0	0,5	90,7

Таблица 4

Результаты оценки качества классификации сверточной НС с архитектурой вариант 2 и логистической функцией активации нейронов скрытых слоев (%)

Классифицированные события \ Фактические события	Классифицированные события					
	С.1	С.2	С.3	С.4	С.5	С.6
С.1	90,9	3,2	0,3	1,7	3,7	0,2
С.2	2,3	87,5	3,3	3,0	2,9	1,0
С.3	0,0	0,6	86,4	6,9	6,1	0,0
С.4	0,0	0,3	4,6	86,2	8,9	0,0
С.5	3,5	1,1	1,6	2,7	91,1	0,0
С.6	8,9	3,1	0,0	0,0	0,5	87,5

Таблица 5

Результаты оценки качества классификации сверточной НС с архитектурой вариант 2 и rectified linear функцией активации нейронов скрытых слоев (%)

Классифицированные события Фактические события	C.1	C.2	C.3	C.4	C.5	C.6
C.1	95,8	1,2	0,1	0,4	2,4	0,1
C.2	1,2	92,7	2,1	2,3	1,4	0,3
C.3	0,0	0,4	90,3	4,6	4,7	0,0
C.4	0,0	0,1	3,6	90,5	5,8	0,0
C.5	2,2	0,2	0,7	0,9	96,0	0,0
C.6	4,7	1,9	0,0	0,0	0,2	93,2

Таблица 6

Результаты оценки качества классификации сверточной НС с архитектурой вариант 3 и логистической функцией активации нейронов скрытых слоев (%)

Классифицированные события Фактические события	C.1	C.2	C.3	C.4	C.5	C.6
C.1	89,9	3,4	0,4	1,9	4,1	0,3
C.2	2,6	86,4	3,6	3,3	3,1	1,0
C.3	0,0	0,9	84,8	7,4	6,9	0,0
C.4	0,0	0,3	5,2	84,7	9,8	0,0
C.5	3,8	1,2	1,8	2,9	90,3	0,0
C.6	9,6	3,6	0,0	0,0	0,6	86,2

Таблица 7

Результаты оценки качества классификации сверточной НС с архитектурой вариант 3 и rectified linear функцией активации нейронов скрытых слоев (%)

Классифицированные события Фактические события	C.1	C.2	C.3	C.4	C.5	C.6
C.1	95,1	1,5	0,1	0,5	2,7	0,1
C.2	1,4	91,9	2,3	2,5	1,6	0,3
C.3	0,0	0,5	89,7	4,8	5,0	0,0
C.4	0,0	0,1	3,8	89,8	6,3	0,0
C.5	2,4	0,2	0,9	1,2	95,3	0,0
C.6	4,9	2,0	0,0	0,0	0,3	92,8

Таблица 8

Результаты оценки качества классификации сверточной НС с архитектурой вариант 4 и логистической функцией активации нейронов скрытых слоев (%)

Классифицированные события Фактические события	C.1	C.2	C.3	C.4	C.5	C.6
C.1	89,5	3,5	0,4	2,0	4,3	0,3
C.2	2,7	86,1	3,7	3,4	3,1	1,0
C.3	0,0	1,0	84,4	7,6	7,0	0,0
C.4	0,0	0,3	5,3	84,2	10,2	0,0
C.5	3,9	1,3	1,9	3,1	89,8	0,0
C.6	9,8	3,6	0,0	0,0	0,6	86,0

Таблица 9

Результаты оценки качества классификации сверточной НС с архитектурой вариант 4 и rectified linear функцией активации нейронов скрытых слоев (%)

Классифицированные события / Фактические события	C.1	C.2	C.3	C.4	C.5	C.6
C.1	94,7	1,7	0,1	0,5	2,9	0,1
C.2	1,5	91,5	2,4	2,7	1,6	0,3
C.3	0,0	0,6	89,3	5,0	5,1	0,0
C.4	0,0	0,1	3,9	89,4	6,6	0,0
C.5	2,7	0,2	0,9	1,3	94,9	0,0
C.6	5,2	2,1	0,0	0,0	0,3	92,4

В таблице 10 представлены интегральные результаты оценки качества классификации для каждой используемой в исследовании архитектуры НС.

Таблица 10

Итоговые результаты оценки качества классификации сверточных НС различной архитектуры

№ варианта архитектуры сети	Тип функции активации нейронов скрытых слоев	C.1, %	C.2, %	C.3, %	C.4, %	C.5, %	C.6, %	Процент верной классификации
1	логистическая	88,7	85,3	82,3	81,8	88,2	84,9	84,8
1	rectified linear	92,9	89,4	87,0	87,2	93,3	90,7	90,0
2	логистическая	90,9	87,5	86,4	86,2	91,1	87,5	87,3
2	rectified linear	95,8	92,7	90,3	90,5	96,0	93,2	93,2
3	логистическая	89,9	86,4	84,8	84,7	90,3	86,2	86,1
3	rectified linear	95,1	91,9	89,7	89,8	95,3	92,8	92,6
4	логистическая	89,5	86,1	84,4	84,2	89,8	86,0	85,8
4	rectified linear	94,7	91,5	89,3	89,4	94,9	92,4	92,1

Таким образом, наиболее точно классифицируются события начала движения руки (С.1) и возвращения предмета на место (С.5). Это может быть объяснено наличием светового сигнала для инициации данных движений и возникающими при этом вызванными потенциалами мозга (электрическими реакциями мозга на внешний раздражитель). Лучшее качество классификации (процент верной классификации составил 93,2 %) показала сверточная НС, построенная в соответствии с архитектурой варианта 2 с rectified linear функцией активации нейронов скрытых слоев.

Выводы.

1. Использование сверточной НС в качестве многоклассового классификатора позволяет эффективно определять характерные признаки в исходных ЭЭГ сигналах без необходимости предварительного применения методов отбора и выделения признаков.

2. Использование в качестве функции активации нейронов скрытых слоев rectified linear функции позволяет значительно улучшить качество классификации.

3. Гибкая архитектура сверточной НС предоставляет возможность дальнейшего улучшения полученного в исследовании качества классификации путем изменения размеров и количества скрытых слоев.

Список литературы

1. Воротников С. А. Биометрическая система управления протезом руки / С. А. Воротников, В. С. Струнин, Н. А. Выборнов // Прикаспийский журнал: управление и высокие технологии. – 2013. – № 3 (23). – С. 147–162.

2. Друки А. А. Алгоритмы распознавания рукописных подписей на основе нейронных сетей / А. А. Друки, М. А. Милешин // *Фундаментальные исследования*. – 2014. – № 11. – С. 1906–1910.
3. Жиганов С. В. Использование каскада нейронных сетей для анализа ЭЭГ данных / С. В. Жиганов. – Режим доступа: http://www.amgpgu.ru/upload/iblock/286/zhiganov_s_v_ispolzovanie_kaskada_neuronnykh_setey_dlya_analiza_eeg_dannykh.pdf, свободный. – Заглавие с экрана. – Яз. рус.
4. Игнатов А. Глубокое обучение в задаче информационного анализа электрокардиограмм для диагностики заболеваний / А. Игнатов. – Режим доступа: <http://www.machinelearning.ru/wiki/images/5/50/Ignatov2015PresentationRus.pdf>, свободный. – Заглавие с экрана. – Яз. рус.
5. Подоприхин Д. А. Реализация игры «Лабиринт» средствами ВСИ / Д. А. Подоприхин // *Сборник Прикладная математика и информатика*. – 2014. – Т. 47. – С. 107–121.
6. Скругин В. И. Алгоритм классификации сигналов ЭЭГ на основе анализа в частотно-временной области / В. И. Скругин, А. Г. Трофимов, А. О. Роик // *Нейроинформатика – 2010 : сборник научных трудов XII Всероссийской научно-технической конференции*. – Москва : Национальный исследовательский ядерный университет «МИФИ», 2010. – Т. 1. – С. 266–276.
7. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position / K. Fukushima // *Biological Cybernetics*. – 1980. – № 36. – P. 193–202.
8. Jasper H. H. The ten-twenty electrode system of the International Federation / H. H. Jasper // *Electroencephalogr Clin Neurophysiol*. – 1958. – № 10. – P. 371–375.
9. Johansson R. S. Programmed and triggered actions to rapid load changes during precision grip / R. S. Johansson, G. Westling // *Experimental Brain Research*. – 1988. – № 71. – P. 72–86.
10. Johansson R. S. Coordinated isometric muscle commands adequately and erroneously programmed for the weight during lifting task with precision grip / R. S. Johansson, G. Westling // *Experimental Brain Research*. – 1988. – № 71. – P. 59–71.
11. LeCun Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // *Nature*. – 2015. – № 521. – P. 436–444.
12. LeCun Y. Gradient-based learning applied to document recognition / Y. LeCun, L. Bottou, Y. Bengio // *Proceedings of the IEEE*. – 1998. – № 86 (11). – P. 2278–2324.
13. LeCun Y. Convolutional Networks and Applications in Vision / Y. LeCun, K. Kavukcuoglu, C. Farabet // *International Symposium on Circuits and Systems (ISCAS 10)*. – 2010. – P. 253–256.
14. Luciw M. Multi-channel EEG recordings during 3,936 grasp and lift trials with varying weight and friction / M. Luciw, E. Jarochka, B. Edin // *Scientific Data*. – 2014. – № 1. – Available at: <http://www.nature.com/articles/sdata201447>.
15. Nielsen M. *Neural Networks and Deep Learning* / M. Nielsen // Determination Press. – 2015. – Available at: <http://neuralnetworksanddeeplearning.com/>.
16. Ranky G. N. Analysis of a Commercial EEG Device for the Control of a Robot Arm / G. N. Ranky, S. Adamovich // *Bioengineering Conference : Proceedings of the 2010 IEEE 36th Annual Northeast*. – 2010. – Available at: http://www.ieee.org/portal/innovate/search/article_details.html?article=5458188.
17. Westling G. Factors influencing the force control during precision grip / G. Westling, R. S. Johansson // *Experimental Brain Research*. – 1984. – № 53. – P. 277–284.
18. Zeiler M. D. ADADELTA: An Adaptive Learning Rate Method / M. D. Zeiler. – Available at: <http://www.matthewzeiler.com/pubs/googleTR2012/googleTR2012.pdf>.

References

1. Vorotnikov S. A., Strunin V. S., Vybornov N. A. Biometricheskaya sistema upravleniya protezom ruki [Biometric system control a prosthetic arm]. *Prikaspiyskiy zhurnal: upravlenie i vysokie tekhnologii* [Caspian Journal: Management and High Technologies], 2013, no. 3 (23), pp. 147–162.
2. Друки А. А., Милешин М. А. Алгоритмы распознавания рукописных подписей на основе нейронных сетей [Handwritten signature recognition algorithms based on neural networks]. *Fundamentalnye issledovaniya* [Fundamental Research], 2014, no. 11, pp. 1906–1910.

3. Zhiganov S. V. *Ispolzovanie kaskada neyronnykh setey dlya analiza EEG dannykh* [Using a cascade of neural networks for the analysis of the EEG data]. Available at: http://www.amgpgu.ru/upload/iblock/286/zhiganov_s_v_ispolzovanie_kaskada_neyronnykh_setey_dlya_analiza_eeg_dannykh.pdf.
4. Ignatov A. *Glubokoe obuchenie v zadache informatsionnogo analiza elektrokardiogramm dlya diagnostiki zabolevaniy* [Deep learning in information analysis of electrocardiograms for diagnosis]. Available at: <http://www.machinelearning.ru/wiki/images/5/50/Ignatov2015PresentationRus.pdf>.
5. Podoprikhin D. A. Realizatsiya igry «Labirint» sredstvami BCI [Implementation of the game "Labyrinth" means BCI]. *Sbornik Prikladnaya matematika i informatika* [Proceedings of the Applied Mathematics and Informatics], 2014, vol. 47, pp. 107–121.
6. Skrugin V. I., Trofimov A. G., Roik A. O. Algoritm klassifikatsii signalov EEG na osnove analiza v chastotno-vremennoy oblasti [EEG signal classification algorithm based on the analysis in the time-frequency domain]. *Neyroinformatika – 2010 : sbornik nauchnykh trudov XII Vserossiyskoy nauchno-tekhnicheskoy konferentsii* [Neuroinformatics – 2010. Proceedings of the VII All-Russian Scientific and Technical Conference], Moscow, National Research Nuclear University MEPhI Publ. House, 2010, vol. 1, pp. 266–276.
7. Fukushima K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 1980, no. 36, pp. 193–202.
8. Jasper H. H. The ten-twenty electrode system of the International Federation. *Electroencephalogr Clin Neurophysiol*, 1958, no. 10, pp. 371–375.
9. Johansson R. S., Westling G. Programmed and triggered actions to rapid load changes during precision grip. *Experimental Brain Research*, 1988, no. 71, pp. 72–86.
10. Johansson R. S., Westling G. Coordinated isometric muscle commands adequately and erroneously programmed for the weight during lifting task with precision grip. *Experimental Brain Research*, 1988, no. 71, pp. 59–71.
11. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*, 2015, no. 521, pp. 436–444.
12. LeCun Y., Bottou L., Bengio Y. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 1998, no. 86 (11), pp. 2278–2324.
13. LeCun Y., Kavukcuoglu K., Farabet C. Convolutional Networks and Applications in Vision. *International Symposium on Circuits and Systems (ISCAS 10)*, 2010, pp. 253–256.
14. Luciw M., Jarochka E., Edin B. Multi-channel EEG recordings during 3,936 grasp and lift trials with varying weight and friction. *Scientific Data*, 2014, no. 1. Available at: <http://www.nature.com/articles/sdata201447>.
15. Nielsen M. Neural Networks and Deep Learning. *Determination Press*, 2015. Available at: <http://neuralnetworksanddeeplearning.com/>.
16. Ranky G. N., Adamovich S. Analysis of a Commercial EEG Device for the Control of a Robot Arm. *Bioengineering Conference. Proceedings of the 2010 IEEE 36th Annual Northeast*, 2010. Available at: http://www.ieee.org/portal/innovate/search/article_details.html?article=5458188.
17. Westling G., Johansson R. S. Factors influencing the force control during precision grip. *Experimental Brain Research*, 1984, no. 53, pp. 277–284.
18. Zeiler M. D. *ADADELTA: An Adaptive Learning Rate Method*. Available at: <http://www.matthewzeiler.com/pubs/googleTR2012/googleTR2012.pdf>.