

В. В. Сапунов, мл. науч. сотр., e-mail: wallowind@gmail.com,
С. А. Ботман, мл. науч. сотр., e-mail: stepan.botman@gmail.com,
Г. В. Камышов, инженер, e-mail: gv.kamyshov@mail.ru,
Н. Н. Шушарина, канд. пед. наук, руководитель службы организации НИД,
e-mail: nnshusharina@gmail.com,
Балтийский федеральный университет имени Иммануила Канта, г. Калининград

Применение свертки с периодическим граничным условием для обработки данных от цилиндрических массивов электродов¹

Предлагается модификация искусственной нейронной сети сверточного типа для работы с электромиографическими данными, полученными от цилиндрических массивов электродов. Для учета пространственной симметрии массива операция свертки переопределяется с использованием периодических граничных условий, что позволяет построить сеть, инвариантную к вращениям массива электродов вокруг своей оси. Для проверки применимости предложенного подхода нейронная сеть, содержащая сверточный слой нового типа, была обучена на данных открытого датасета UC2018 DualMyo. При этом решалась задача классификации жестов по сигналам от одного миобрассета. Сеть, основанная на новом типе свертки, показала лучшие результаты при тестировании на данных без аугментации по сравнению со стандартными свертками, что позволило сделать вывод об инвариантности такой сети к циклическим сдвигам во входных данных.

Ключевые слова: искусственная нейронная сеть, сверточная нейронная сеть, свертка, эквивариантность, инвариантность, циклический сдвиг, электромиография, массив электродов

Введение

Искусственные нейронные сети сверточного типа показывают превосходные результаты при работе с изображениями и другими сигналами, которые обладают свойством локальной связности. Операция свертки (в практической реализации основных библиотек машинного обучения — кросскорреляции) позволяет эффективно выделять информацию из окрестностей каждой точки сигнала, а иерархическая структура сети, усиленная слоями субдискретизации, обеспечивает возможность глубокого обучения, при котором сеть самостоятельно определяет признаки на всех уровнях [1]. Следствием особенностей архитектуры таких сетей является наличие инвариантности по отношению к пространственным сдвигам и масштабированию обрабатываемых данных [2]. Сверточные нейронные сети успешно применяются для обработки данных

различной размерности, включая изображения разных масштабов: от спутниковых снимков до цифровых микрофотографий, томографических сканов, данных спектрометрии и т.д. [3–5]. Другой перспективной областью применения является работа с временными рядами, включая распознавание и синтез звуков и речи, анализ данных с сетей датчиков, а также обработка электрофизиологических сигналов [6, 7].

Одним из перспективных приложений для сверточных нейронных сетей является обработка миографических сигналов для применения в спорте, медицине, системах управления и виртуальной реальности [8]. В последнее время с развитием электроники и компонентной базы число каналов систем регистрации электромиограммы возрастает [9, 10]. Это приводит к тому, что на каждой мышце удается разместить вместо одного электрода массив электродов, что, в свою очередь, позволяет использовать эти дополнительные данные совместно с информацией о геометрии массива для более детального анализа функционирования ин-

¹Работа выполнена в рамках государственного задания № FZWM-2020-0013.

тересующей мышцы или мышечной группы. Одним из распространенных вариантов конфигурации электродов для систем распознавания жестов и движений рук является сетка электродов, свернутая в цилиндр вокруг предплечья, таким образом, что электроды равномерно распределены по цилиндру. Сверточные сети при работе способны принимать на вход сырые данные напрямую от таких массивов, что позволяет реализовывать сквозные (end-to-end) модели машинного обучения. Вместе с тем, при применении этого подхода напрямую к массивам электродов цилиндрической геометрии будут возникать проблемы, связанные с представлением данных, включая краевые эффекты [11]. Еще одной проблемой является то, что при эксплуатации неизбежно возникают сдвиги электродов от исходных позиций, а кроме того, выставление электродов в четко заданные позиции трудозатратно и поэтому неоправданно в прикладных применениях. Для устранения таких сдвигов используются дополнительные операции, такие как, например, явное вычисление угла поворота [12, 13].

В рамках данной работы предлагается компенсировать сдвиги непосредственно нейронной сетью путем надления указанной сети инвариантностью по отношению к пространственным вращениям массивов электродов. Для этого стандартная операция свертки модифицируется с учетом периодических граничных условий. Для проверки эффективности нового типа свертки использовались открытые данные, полученные с использованием миоэлектрографа потребительского класса с восемью парами электродов, объединенных в кольцо.

Материалы и методы

Будем рассматривать цилиндрический массив электродов, представленный на рис. 1, а. Такой массив может быть получен из прямоугольного массива a_{ij} размером $K \times N$ путем сшивания двух его краев (столбцов $j = 1$ и $j = N$) путем наложения периодического граничного условия: $a_{ij+N} = a_{ij}$ для $i = 1 \dots K$, $j = 1 \dots N$ (см. рис. 1, б). Электроды, расположенные на поверхности полученного цилиндра, направ-

лены внутрь, в сторону исследуемого объекта (например предплечья человека), который расположен вдоль оси Z цилиндра. Несмотря на то что геометрия массива электродов обладает пространственной симметрией (группа вращений C_N), сам сигнал, в силу биологической природы, симметрией не обладает. Также на практике необходимость наличия надежного контакта между электродом и поверхностью кожи будет приводить к отклонениям от идеальной цилиндрической симметрии.

При работе с такими данными полезно учитывать информацию о локальной связности данных, обусловленной физической близостью соответствующих электродов. В таком случае регистрируемые за фиксированный промежуток времени данные удобно представлять в виде трехмерных массивов a_{ijt} , где $t = \overline{1, T}$ нумерует временные отсчеты. Поскольку данные локально связаны вдоль всех трех направлений массива, их можно эффективно обрабатывать с использованием нейронных сетей сверточного типа. Одним из преимуществ такого подхода является наличие эквивариантности по отношению к операциям трансляции входных данных [14], что в рассматриваемом случае будет соответствовать сдвигам по времени, сдвигам вдоль оси Z и вращениям вокруг оси Z . Проблемой при этом является тот факт, что обычная свертка не будет эквивариантна по отношению к циклическому сдвигу (т. е. вра-

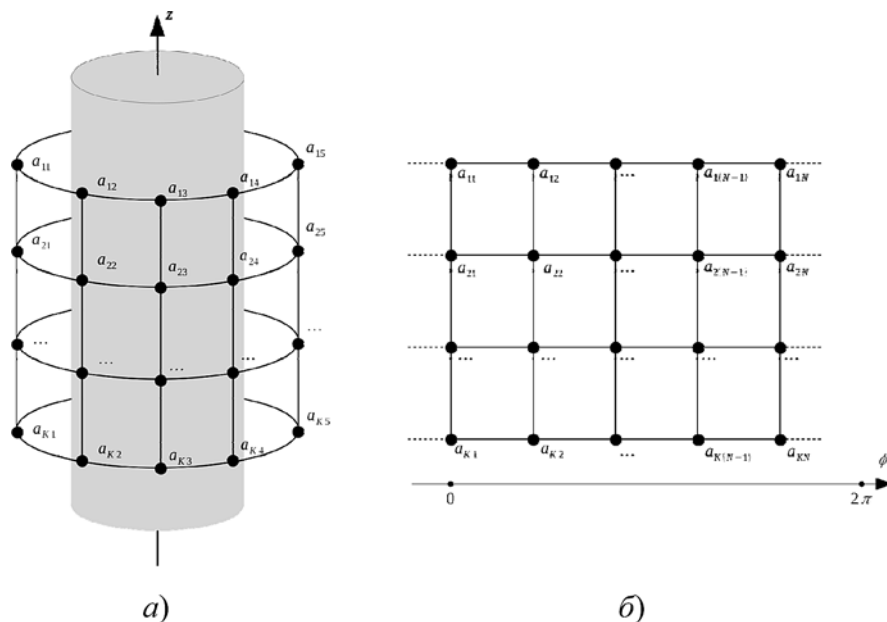


Рис. 1. Геометрия рассматриваемого массива электродов:

а — условное расположение электродов в пространстве относительно руки (ось руки совпадает с осью цилиндра, в котором расположены электроды); б — структура регистрируемых данных




Рис. 2. Сравнение обычной свертки с паддингом (а) и свертки с периодическим граничным условием (б) на примере массива данных размером 4×4 и ядром 3×3 .

шению электродных массивов вокруг оси Z), что будет приводить к появлению различного рода краевых эффектов и негативно скажется на эффективности работы сети, построенной на стандартной операции свертки.

Предлагаемым в данной работе решением указанной проблемы является введение свертки с периодическим граничным условием. Основным отличием такой свертки от обычной является работа с крайними ячейками, для которых недостающие данные добиваются с противоположной стороны массива данных, как показано на рис. 2. При этом обычные свертки можно напрямую заменять свертками нового типа, тем самым адаптируя проверенные архитектуры искусственных нейронных сетей для работы с данными, имеющими циклические связи.

Основным преимуществом такого подхода является получаемая естественным образом эквивариантность отдельных сверточных слоев и, потенциально, инвариантность для всей сети. Это важное свойство, учитывая что сдвиги являются одним из основных видов артефактов для электромиографических сигналов. Альтернативно для достижения того же эффекта достаточно большую нейронную сеть можно обучить с использованием аугментации тренировочных данных. В частности, в качестве операций аугментации можно использовать вращение в пространстве на углы $2\pi/n$, где $n = \overline{1, N}$, кратные ячейке электродной сетки. В этом случае для произвольного $n < N$, где N — полное число точек массива данных вдоль угловой компоненты, новая матрица генерируется по следующему правилу: $a'_{ij} = a_{ij}$, где $j' = (j + n) \bmod N$. Другим возможным вариантом является применение аугментации на базе вращения на произвольный угол, в которой новые данные задаются как линейная

комбинация данных для соседних электродов. Несмотря на то что в теории аугментация позволяет добиться схожих результатов, тренировка на аугментированных данных повышает затраты вычислительных ресурсов в разы.

Для апробации предложенного подхода упрощенная реализация свертки с периодическим граничным условием была реализована с использованием библиотеки Tensorflow и языка программирования Python. Реализация базируется на последовательном применении операций конкатенации и обычной свертки с необходимыми параметрами. Для оценки сравнения с обычной сверткой были созданы две эквивалентные по форме нейронные сети, отличающиеся друг от друга используемым типом свертки. В качестве данных для обучения использовался открытый датасет UC2018 DualMyo Hand Gesture Dataset [15], содержащий данные ЭМГ, полученные с пары устройств Myo Armband во время последовательного выполнения человеком восьми жестов. Всего в этом датасете содержится 110 повторений по две секунды для каждого жеста. Данные снимались на частоте 200 Гц, число каналов ЭМГ — по восемь для каждого устройства, из которых для апробации использовались восемь (только первое устройство).

Обе нейронные сети состояли из одного сверточного слоя, глобального усредняющего слоя субдискретизации и одного полносвязного слоя. На сверточный слой с восемью ядрами размером 10×3 и активацией Relu подаются входные данные размером $400 \times 8 \times 1$. Слой субдискретизации усредняет выход сверточного слоя до размеров 200×8 и передает эти данные на полносвязный слой из восьми нейронов с активацией Softmax. В качестве оптимизатора использовался Adam со скоростью обучения

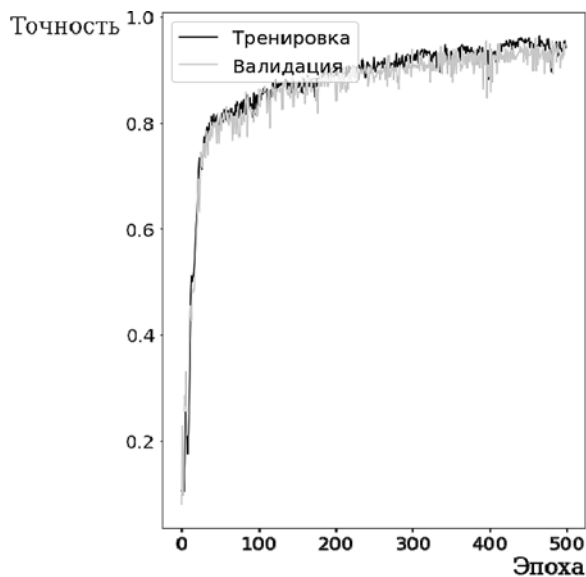
0,01, в качестве функцией потерь была выбрана категориальная кросс-энтропия.

Для разделения данных на обучающую, проверочную и тестовую выборки в соотношении 6:2:2 использовался скрипт, поставляемый вместе с датасетом. Чтобы проверить, насколько хорошо созданная сеть на основе нового типа сверточного слоя справляется с устранением граничного разрыва между каналами ЭМГ, было проведено два испытания — с использованием аугментации исключительно те-

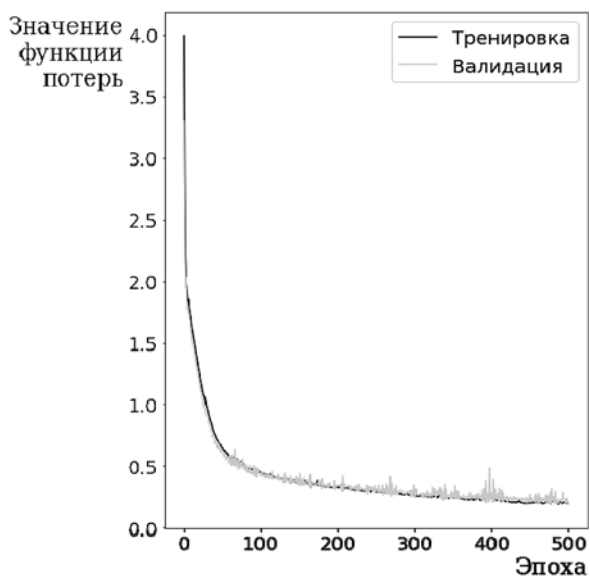
стовых данных, а также с аугментацией всех данных. Для аугментации использовалась операция вращения на кратный угол.

Результаты и выводы

После обучения на протяжении 200 эпох для сети с модифицированной сверткой было получено значение f1-метрики 0,96, для обычной сети — 0,65. При последующем обучении

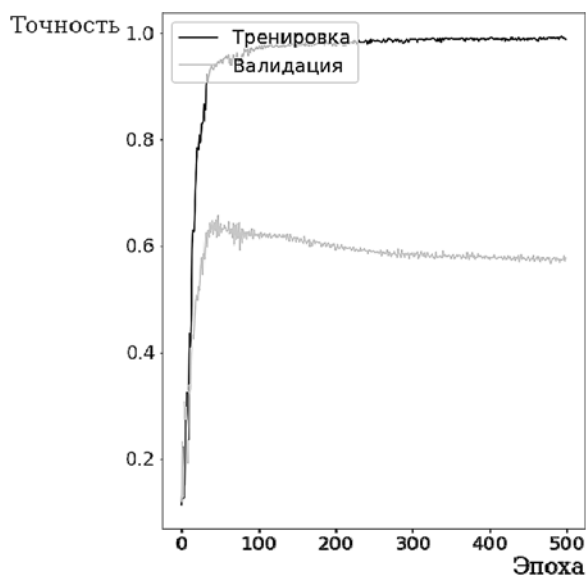


а)

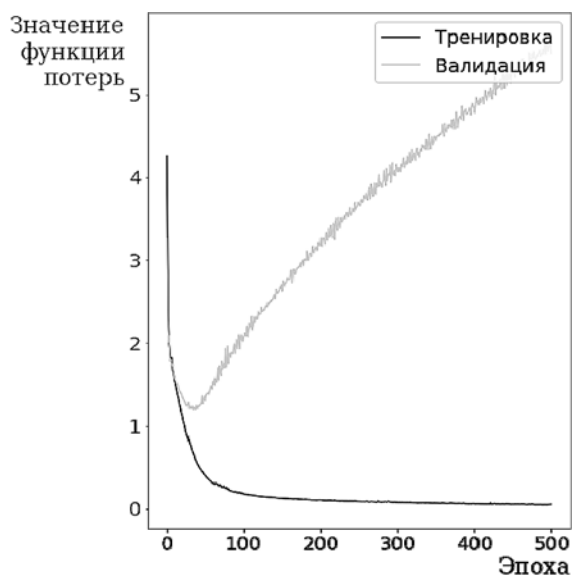


б)

Рис. 3. Графики изменения точности (а) и функции потерь (б) для модифицированной сверточной сети в процессе обучения по данным без аугментации



а)



б)

Рис. 4. Графики изменения точности (а) и функции потерь (б) для обычной сверточной сети в процессе обучения по данным без аугментации

на отметке в 500 эпох было получено значение f1-метрики 0,98, в то время как результат обычной сети снизился до 0,62. Графики для метрик, рассчитанных на основе валидационных данных, представлены на рис. 3 и 4 для модифицированной и обычной сети соответственно.

Как видно из рис. 3, нейросеть на основе свертки с периодическим граничным условием успешно классифицирует аугментированные данные, несмотря на то, что тренировочные данные аугментированы не были — точность

и значение функции потерь для тренировочных и проверочных данных практически идентичны. В то же время для обычной сверточной сети аугментация тестовых данных эквивалентна добавлению новых. Как видно из рис. 4, точность и значение функции потерь на тренировочных данных ведут себя так же, как у сети с модифицированной сверткой, но результаты для проверочных данных свидетельствуют о том, что вращение данных не просто затрудняет верное предсказание, но практиче-

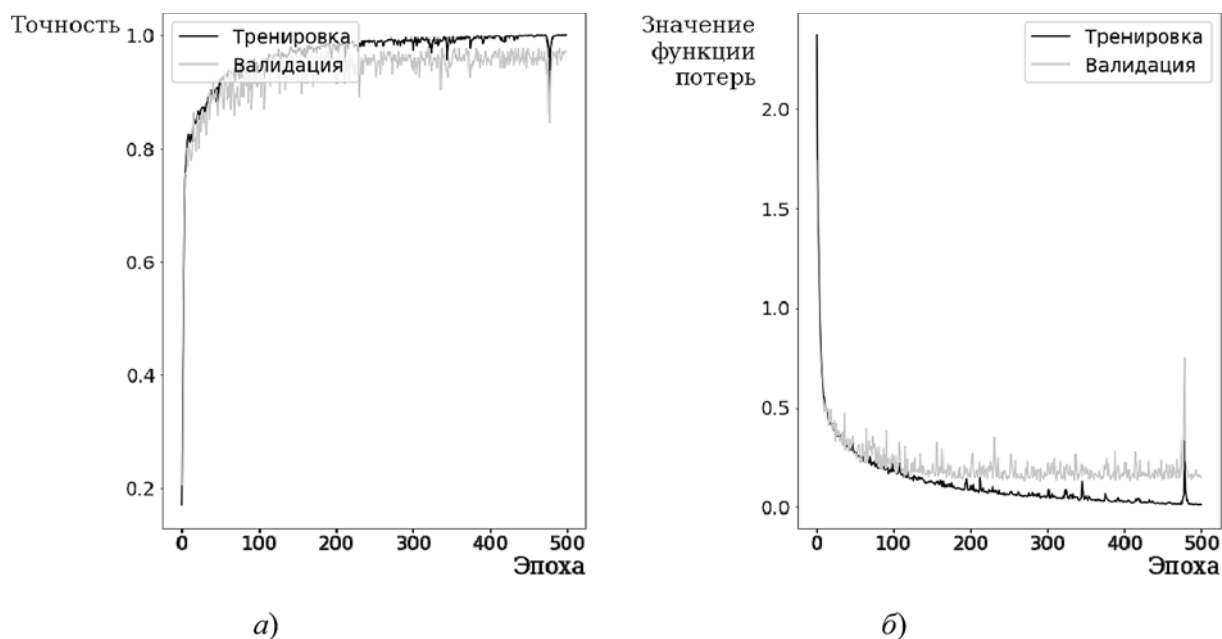


Рис. 5. Графики изменения точности (а) и функции потерь (б) для модифицированной сверточной сети в процессе обучения по аугментированным данным

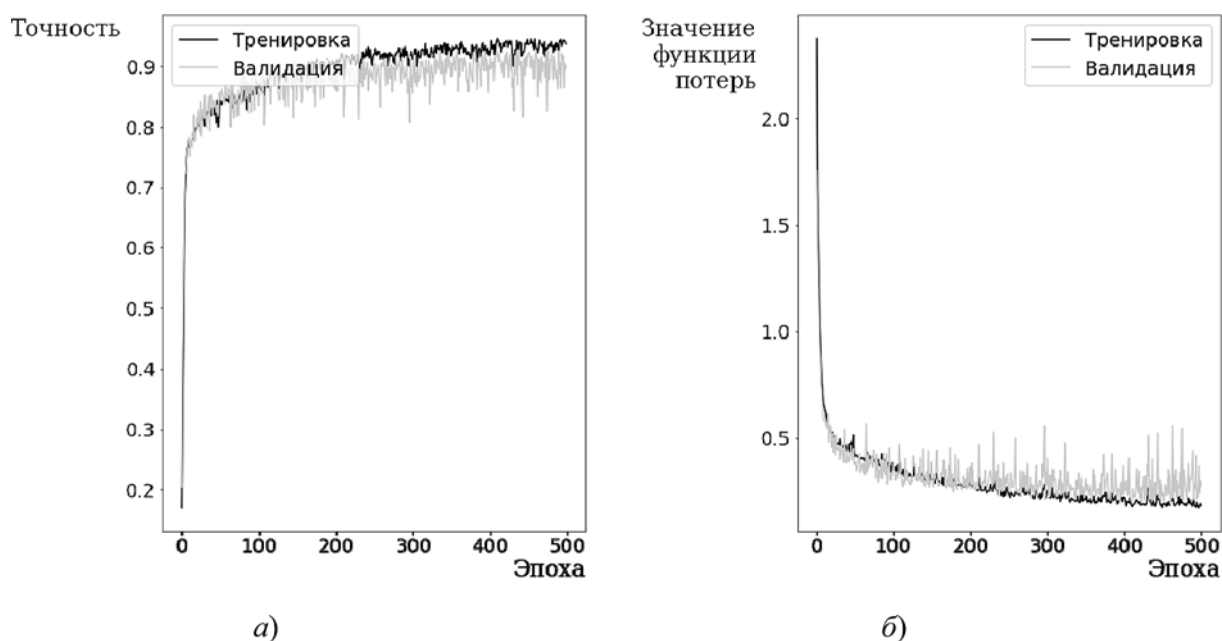


Рис. 6. Графики изменения точности (а) и функции потерь (б) для обычной сверточной сети в процессе обучения по аугментированным данным

ски делает его невозможным, ведь чем дольше идет обучение, тем выше значение функции потерь и ниже точность. Таким образом, вне зависимости от длительности обучения сеть со стандартной сверткой не обучается распознавать данные ЭМГ, подвергшиеся вращению.

В случае обучения на аугментированных данных сеть со стандартной сверткой достигает значения f1-метрики на уровне 0,94 после 500 эпох обучения. Сеть с модифицированной сверткой в аналогичных условиях достигла значения 0,98, что практически совпадает с результатами для этой сети при обучении без аугментации. Это служит индикатором того, что сеть на основе свертки с периодическим граничным условием способна достичь инвариантности по отношению к циклическим сдвигам (вращениям вокруг оси z) даже при обучении без использования аугментации обучающих данных. При этом следует отметить, что обучение на аргументированных данных длилось в два раза дольше, что объясняется фактическим увеличением числа сэмплов в восемь раз. Графики обучения для обеих сетей приведены на рис. 5 и 6.

Заключение

Таким образом, показано, что предложенный подход на основе сверток с периодическим граничным условием предоставляет преимущества в скорости обучения искусственной нейронной сети для решения задач анализа электромиографических сигналов с цилиндрических массивов электродов. Более точный учет геометрии и локальной связности данных позволяет получать искусственные нейронные сети, инвариантные к вращениям массива электродов. При этом можно ожидать, что для массивов электродов большего размера выигрыш за счет экономии вычислительных ресурсов может быть значительным. Вклад от таких изменений будет тем больше, чем выше соотношение числа электродов на виртуальной линии разрыва к полному числу электродов в массиве. В перспективе предложенную свертку можно применять для анализа любых данных, имеющих циклические связи такого же типа, при этом можно адаптировать уже проверенные архитектурные решения для сетей или даже целые сети, заменяя

в них обычную свертку модифицированной. Используемая в данной работе примитивная реализация свертки с периодическим граничным условием не оптимальна, однако при необходимости можно создать более эффективную программную реализацию, чтобы минимизировать привносимые накладные вычислительные расходы.

Список литературы

1. **Dumoulin V., Visin F.** A guide to convolution arithmetic for deep learning // arXiv preprint arXiv:1603.07285. 2016.
2. **Tensmeyer C., Martinez T.** Improving invariance and equivariance properties of convolutional neural networks // ICLR. 2016.
3. **Pedrycz W., Chen S. M.** (ed.). Deep Learning: Algorithms and Applications. Springer, 2020.
4. **Balas V. E.** et al. (ed.). Handbook of deep learning applications. New York: Springer, 2019. Т. 136.
5. **Khan A.** et al. A survey of the recent architectures of deep convolutional neural networks // Artificial Intelligence Review. 2019. С. 1—62.
6. **Wang S., Cao J., Yu P. S.** Deep learning for spatio-temporal data mining: A survey // arXiv preprint arXiv:1906.04928. 2019.
7. **Faust O. et al.** Deep learning for healthcare applications based on physiological signals: A review // Computer methods and programs in biomedicine. 2018. Vol. 161. С. 1-13.
8. **Phinyomark A., Scheme E.** EMG pattern recognition in the era of big data and deep learning // Big Data and Cognitive Computing. 2018. Vol. 2, No. 3. С. 21.
9. **Moin A. et al.** An EMG gesture recognition system with flexible high-density sensors and brain-inspired high-dimensional classifier // 2018 IEEE International Symposium on Circuits and Systems (ISCAS). IEEE, 2018. P. 1—5.
10. **Lara J., Paskaranandavadivel N., Cheng L. K.** Effect of Segmentation Parameters on Classification Accuracy of High-Density EMG recordings // 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2019. P. 6229—6232.
11. **Afsharipour B., Soedirdjo S., Merletti R.** Two-dimensional surface EMG: The effects of electrode size, interelectrode distance and image truncation // Biomedical Signal Processing and Control. 2019. Vol. 49. P. 298—307.
12. **Xu Z.** et al. Advanced Hand Gesture Prediction Robust to Electrode Shift with an Arbitrary Angle // Sensors. 2020. Vol. 20. N. 4. P. 11—13.
13. **Kim M., Chung W. K.** Muscle activation source model-based SEMG signal decomposition and recognition of interface rotation // 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018. P. 2780—2786.
14. **Goodfellow I., Bengio Y., Courville A.** Deep learning. MIT press, 2016.
15. **Simão M. A., Neto P., Gibaru O.** UC2018 DualMyo Hand Gesture Dataset (Version 1.0-alpha) [Data set]. 2018. URL: <http://doi.org/10.5281/zenodo.1320922>

V. V. Sapunov, Junior Researcher, e-mail: wallowind@gmail.com,
S. A. Botman, Junior Researcher, e-mail: stepan.botman@gmail.com,
G. V. Kamyshev, Engineer, e-mail: gv.kamyshev@mail.ru,
N. N. Shusharina, Ph.D., Head of Research Organization Department, e-mail: nnshusharina@gmail.com,
Immanuel Kant Baltic Federal University, Kaliningrad, 236016, Russian Federation

Application of Convolution with Periodic Boundary Condition for Processing Data from Cylindrical Electrode Arrays

In this paper, modification of convolutional neural networks for purposes of processing electromyographic data obtained from cylindrical arrays of electrodes was proposed. Taking into account the spatial symmetry of the array, convolution operation was redefined using periodic boundary conditions, which allowed to construct a neural network that is invariant to rotations of electrodes array around its axis. Applicability of the proposed approach was evaluated by constructing a neural network containing a new type of convolutional layer and training it on the open UC2018 DualMyo dataset in order to classify gestures basing on data from a single myobracelet. The network based on the new type of convolution performed better compared to common convolutions when trained on data without augmentation, which indicates that such a network is invariant to cyclic shifts in the input data. Neural networks with modified convolutional layers and common convolutional layers achieved $f-1$ scores of 0.96 and 0.65 respectively with no augmentation for input data and $f-1$ scores of 0.98 and 0.96 in case when train-time augmentation was applied. Test data was augmented in both cases. Potentially, proposed convolution can be applied in processing any data with the same connectivity in such a way that allows to adapt time-tested architectural solutions for networks by replacing common convolutions with modified ones.

Keywords: artificial neural network, convolutional neural network, convolution, equivariance, invariance, cyclic shift, electromyography, electrodes array

Acknowledgements: The work was performed within the framework of the state assignment No. FZWM-2020-0013.

DOI: 10.17587/it.27.125-131

References

1. Dumoulin V., Visin F. A guide to convolution arithmetic for deep learning, arXiv preprint arXiv:1603.07285, 2016.
2. Tensmeyer C., Martinez T. Improving invariance and equivariance properties of convolutional neural networks, *International Conference on Learning Representations, Toulon*, 2016.
3. Pedrycz W., Chen S. M. Deep Learning: Algorithms and Applications, Springer, 2020.
4. Balas V. E., Roy S. S., Sharma D., Samui P. Handbook of deep learning applications (Vol. 136), New York, Springer, 2019.
5. Khan A., Sohail A., Zahoora U., Qureshi A. S. A survey of the recent architectures of deep convolutional neural networks, *Artificial Intelligence Review*, 2019, pp. 1–62.
6. Wang S., Cao J., Yu P. S. Deep learning for spatio-temporal data mining: A survey, arXiv preprint arXiv:1906.04928, 2019.
7. Faust O., Hagiwara Y., Hong T. J., Lih O. S. Deep learning for healthcare applications based on physiological signals: A review, *Computer Methods and Programs in Biomedicine*, 2018, Vol. 161, pp. 1–13.
8. Phinyomark A., Scheme E. EMG pattern recognition in the era of big data and deep learning, *Big Data and Cognitive Computing*, 2018, vol. 2, no. 3, p. 21.
9. Moin A., Zhou A., Rahimi A., Benatti S., Menon A., Tamakloe S., Ting J., Yamamoto N., Khan Y., Burghardt F., Benini L. An EMG gesture recognition system with flexible high-density sensors and brain-inspired high-dimensional classifier, *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*, IEEE, 2018, pp. 1–5.
10. Lara J., Paskaranandavadi N., Cheng L. K. Effect of Segmentation Parameters on Classification Accuracy of High-Density EMG recordings, *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, IEEE, 2019, pp. 6229–6232.
11. Afsharipour B., Soedirdjo S., Merletti R. Two-dimensional surface EMG: The effects of electrode size, interelectrode distance and image truncation, *Biomedical Signal Processing and Control*, 2019, Vol. 49, pp. 298–307.
12. Xu Z., Shen L., Qian J., Zhang Z. Advanced Hand Gesture Prediction Robust to Electrode Shift with an Arbitrary Angle, *Sensors*, 2020, Vol. 20, No. 4, pp. 11–13.
13. Kim M., Chung W. K. Muscle activation source model-based SEMG signal decomposition and recognition of interface rotation, *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, IEEE, 2018, pp. 2780–2786.
14. Goodfellow I., Bengio Y., Courville A. Deep learning, MIT press, 2016.
15. Simão M. A., Neto P., Gibaru O. UC2018 DualMyo Hand Gesture Dataset (Version 1.0-alpha) [Data set], 2018.