

СОВРЕМЕННОЕ СОСТОЯНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ В ПРИЛОЖЕНИЯХ ОБРАБОТКИ ОДНОМЕРНЫХ СИГНАЛОВ

**Б.И. Валеев¹, А.И. Садыкова¹, А.Н. Салахутдинова¹,
А.А. Сахабутдинова², Л.А. Сахабутдинова³**
(научный руководитель: Аглиуллин Т.А., доцент КНИТУ-КАИ)

¹Казанский национальный исследовательский технический университет
им. А.Н. Туполева – КАИ
420111, Российская Федерация, г. Казань, ул. К. Маркса, 10

²МАОУ Лицей – инженерный центр
420087, Российская Федерация, г. Казань, ул. А. Кутуя, 114

³Казанский инновационный университет им. В.Г. Тимирязова
420111, Российская Федерация, г. Казань, ул. Московская, 42

Аннотация. За последнее десятилетие *сверточные нейронные сети* (CNN, англ. Convolutional Neural Networks) стали по факту стандартом для различных операций *компьютерного зрения* (Computer Vision, англ.) и *машинного обучения* (Machine Learning, англ.). Сверточные нейронные сети представляют собой *искусственные нейронные сети* (ANN, англ. Artificial Neural Networks) с прямой связью, чередующимися слоями свертки и субдискретизации. Глубокие двумерные сверточные нейронные сети (2D CNN) со многими скрытыми слоями и миллионами параметров имеют возможность обрабатывать сложные объекты и шаблоны при условии, что их можно обучать на базе данных большого размера с метками достоверности. При должном обучении, эта уникальная способность делает их основным инструментом в различных инженерных приложениях для анализа двумерных сигналов, таких как изображения и видеокдры. Тем не менее, это может быть неприемлемым вариантом во многих приложениях с одномерными сигналами, особенно когда обучающих данных недостаточно или они специфичны для конкретного приложения. Чтобы решить эту проблему, были предложены *одномерные сверточные нейронные сети* (1D CNN), которые сразу же достигли самых современных уровней производительности в многих применениях, например, таких областях как персонализированная классификация биомедицинских данных и ранняя диагностика, мониторинг состояния конструкций, обнаружение и идентификация аномалий в силовой электронике, или обнаружение неисправностей электродвигателей. Еще одно важное их преимущество заключается в том, что возможна недорогая аппаратная реализация в режиме реального времени благодаря простой и компактной конфигурации одномерных нейронных сетей, которые выполняют только скалярные умножения и сложения. Современность одномерных сверточных нейронных сетей подчеркивается их колоссальной уникальной производительностью. Проведем обзор общей принципов одномерных сверточных нейронных сетей, а также их основных инженерных приложений, уделив особое внимание достижениям в этой области.

Ключевые слова: искусственные нейронные сети, машинное обучение, сверточные нейронные сети.

Искусственные нейроны, используемые в обычных нейронных сетях, представляют собой линейные модели биологических нейронов первого порядка. В нервной системе млекопитающих биологическое обучение в основном осуществляется на клеточном уровне. Как показано на рис. 1, каждый нейрон способен обрабатывать электрический сигнал на основе трех отдельных операций [1,2]: 1) прием выходов других нейронов через синаптические связи в дендритах; 2) интеграция (или объединение) обработанных выходных сигналов в соме в ядре клетки; 3) активация конечной сигнал в первой части

аксона или так называемом аксонном холмике: если объединенные потенциалы превышают определенный предел, он «активирует» серию импульсов — потенциалов действия.




Рис. 1. Биологический нейрон (слева) с направлением потока сигнала и синапс (справа)

Как показано на рис. 1, каждая концевая точка аксона соединена с другими нейронами через небольшую щель, называемую синапсом. В 1940-х годах МакКалох и Питс (McCulloch W.S., Pitts W.) [3] предложили первую модель *искусственного нейрона*, которая впоследствии использовалась в различных искусственных нейронных сетях с прямой связью, таких как *многослойные перцептроны* (MLP, англ. Multi-Layer Perceptrons). Как показано в уравнении (1):

$$x_k^l = b_k^l + \sum_{i=1}^{N_{l-1}} w_{ik}^{l-1} y_i^{l-1} \text{ and } y_k^l = f(x_k^l) \quad (1)$$

в этой модели искусственный нейрон выполняет линейное преобразование посредством взвешенного суммирования скалярных весов.

Итак, основные операции, выполняемые в биологическом нейроне и управляющие отдельными синаптическими связями со специфическими нейрохимическими операциями и интеграцией в соме клетки, моделируются как линейное преобразование (линейная взвешенная сумма), за которым следует, возможно, нелинейная пороговая функция $f(\cdot)$, которая называется функцией активации.

Концепция *перцептрона* была предложена Розенблаттом (Rosenblatt F.) в его основополагающей работе [4]. При использовании во всех нейронах многослойного перцептрона эта линейная модель является базовой моделью биологических нейронов, приводящей к хорошо известным различиям в характеристиках обучения и обобщения для различных задач [4–8]. В литературе, предпринимались попытки изменить многослойный перцептрон путем модификации модели нейрона и/или традиционного алгоритма *обратного распространения* (BP, англ. Back Propagation algorithm) [9–11] или конфигурации многослойного перцептрона [12–14] или даже способа обновления сетевых параметров — весов и предубеждений [15]. Наиболее многообещающий вариант называется *обобщенный операционный перцептрон* (англ. Generalized Operational Perceptrons) [7,8], который представляет собой гетерогенную сеть с нелинейными операторами и, таким образом, демонстрирует значительно более высокую производительность, чем многослойного перцептрон. Тем не менее, это по-прежнему самая распространенная сетевая модель, которая вдохновила современные искусственные нейронные сети, которые используются сегодня.

Начиная с 1959 года Хьюбел и Визель (Hubel D.H., Wiesel T.N) заложили основы зрительной неврологии, изучая зрительную корковую систему кошек. Их сотрудничество длилось более 25 лет, в течение которых они описали основные ответные свойства зрительных корковых нейронов, концепцию рецептивного поля, функциональные свойства зрительной коры и роль зрительного опыта в формировании архитектуры коры [16–20]. Они были пионерами, обнаружившими иерархический механизм обработки информации в зрительном корковом пути, что в конечном итоге и привело их к Нобелевской премии по физиологии и медицине в 1981 году. Благодаря этим достижениям в нейрокогнитивной науке Фукусима и Мияке (Fukushima K., Miyake S.) [21] в 1982 году предложили предшественника сверточных нейронных сетей, в то время называемого *неокогнитроном* (англ. Neocognitron), который является само организованный, иерархической сетью, обладающей способностью распознавать образцы стимулирующих шаблонов на основе различий в их форме. Это была первая сеть, обладающая уникальной способностью биологической зрительной системы млекопитающих, позволяющей оценивать и относить сходные объекты к одной и той же категории, независимо от их положения в окружении и определенных морфологических вариаций. Однако в попытке максимизировать эффективность обучения возникла острая необходимость в контролируемом методе обучения (адаптации) сети для выполнения поставленной задачи. Новаторское изобретение обратного распространения Румельхартом и Хинтоном (Rumelhart D.E., Hinton G.E.) в 1986 году [22] стало краеугольным камнем эпохи *машинного обучения* (ML, англ. Machine Learning). Обратное распространение поэтапно оптимизирует параметры сети, переопределяя веса и смещения итеративным образом, используя метод градиентного спуска.

Эти два достижения положили начало новой волне подходов, которые в конечном итоге создали первые наивные модели сверточных нейронных сетей. Однако именно основополагающая работа Янна Лекуна (Le Cun Y.) в 1990 году сформулировала алгоритм обратного распространения для обучения первой сверточной нейронной сети, так называемой *LeNet* [23]. Этот предшественник сверточной нейронной сети стал полноценным к 1998 году, и его превосходная способность к классификации [24] была продемонстрирована на базе данных рукописных цифр MNIST [25]. Этот успех положил начало эпохе сверточных нейронных сетей и принес новую надежду в мир машинного обучения в конце 1980-х и начале 90-х годов. Сверточные нейронные сети использовались во многих приложениях в течение 90-х годов и первого десятилетия XXI века, но вскоре они вышли из моды, особенно с появлением парадигм нового поколения машинного обучения, таких как *метод опорных векторов* (SVM от англ. Support Vector Machines) и *байесовские сети* (BN, англ. Bayesian Networks). Этому есть две основные причины. Во-первых, базы данных небольшого или среднего размера были недостаточны для обучения глубокой сверточной нейронной сети с превосходной способностью к обобщению. Конечно, обучение глубокой сверточной нейронной сети требует больших вычислительных затрат и осуществимо только на современных графических процессорах, распространенных сегодня. Именно поэтому в течение этих двух десятилетий применение сверточных нейронных сетей было ограничено изображениями с низким разрешением (размером с миниатюру) или полутонными изображениями в небольших наборах данных. Напротив, методы опорных векторов и байесовские сети имеют меньше параметров, которые могут быть хорошо оптимизированы, особенно для таких малых и средних наборов данных и независимо от разрешения изображения. Ежегодное соревнование по классификации изображений ILSVRC (ILSVRC, англ. ImageNet Large Scale Visual Recognition Challenge) в 2012 году стало поворотным моментом для применения глубоких сверточных нейронных сетей в области крупномасштабной классификации изображений. Для этого соревнования Крижевский с командой (Krizhevsky A.) впервые предложили глубокую модель сверточной

нейронной сети, так называемый *AlexNet* [26], которая является родоначальником парадигмы глубокого обучения. *AlexNet* — это 8-слойная сверточная нейронная сеть с 5 сверточными и 3 полностью связанными слоями, которая достигла 16,4% ошибки в эталонной базе данных ImageNet [27], что примерно на 10% ниже, чем у второго лучшего метода, использующего традиционный подход машинного обучения с методом опорных векторов (SVM) над традиционными — масштабно-инвариантными трансформациями признаками (SIFT, англ. Scale Invariant Feature Transform) [28] и локально-бинарными шаблонами (LBP, англ. Local Binary Patterns) [29]. База данных ImageNet содержит более миллиона изображений для обучения и разделена на 1000 визуальных категорий. В том же исследовании [26] были предложены некоторые новые архитектурные особенности, такие как выпрямленную линейную функцию активации (ReLU, англ. Rectified Linear Units) вместо традиционных функций активации, таких как сигмоида (sigm, англ. Sigmoids) или гиперболический тангенс (tanh, англ. Tangent Hyperbolics). Команда *AlexNet* также предложила в [30] технику отсева для улучшения способности сети к обобщению. Однако самым важным фактором, сделавшим сверточную нейронную сеть основным методом, стала возможность их обучения на массивах данных огромного размера с помощью парадигм распараллеливания вычислений на появляющихся графических процессорах GPU.

С успешным появлением *AlexNet* началась эра глубоких двумерных сверточных нейронных сетей, которые за короткое время заменили традиционные методы классификации и распознавания. В итоге глубокие сверточные нейронные сети стали основным инструментом, используемым в любом приложении глубокого обучения (DL, англ. Deep Learning), включая современные соревнования по классификации изображений ILSVRC. В следующем году Цайлер и Фергюс (Zeiler M.D., Fergus R.) предложили новую сеть, так называемую ZFnet [31], которая стала сверточной нейронной сетью победителем ILSVRC 2013. ZFnet позволила снизить уровень ошибок до 11,7% на базе данных ImageNet. Авторы показали, как визуализировать каждый сверточный слой нейронной, что, в свою очередь, углубило наше понимание того, почему сверточные нейронные сети достигают такой превосходной способности к устранению ошибок среди различных категорий визуальных объектов. В следующем году на ILSVRC 2014 команда Google совершила новый прорыв, создав более глубокую нейронную сеть, названную *GoogLeNet* с кодовым именем *Inception*, которая почти вдвое снизила лучший коэффициент ошибок до 6,7% в базе данных ImageNet. *GoogLeNet* была разработана путем увеличения глубины (до 22 сверточных слоев) и ширины сети при сохранении постоянного вычислительного бюджета. Помимо использования более глубокой сети с разреженными связями, ключевая идея заключается в том, что *GoogLeNet* получил наивысшую производительность распознавания объектов в ILSVRC 2014 с ансамблем из 6 сверточных нейронных сетей. С тех пор популярность глубоких сверточных нейронных сетей достигла своего пика, и в итоге они де-факто стали стандартом для различных приложений машинного обучения и компьютерного зрения на протяжении многих лет. Более того, они часто использовались для обработки последовательных данных, включая обработку естественного языка и распознавание речи [32,33] и даже одномерных сигналов, например, вибрации [34,35].

Помимо высочайшего уровня производительности, которого они могут достичь, еще одно их важнейшее преимущество заключается в том, что они могут объединять задачи извлечения признаков и классификации в единый организм, в отличие от традиционных искусственных нейронных сетей (ANNs, англ. Artificial Neural Networks). В то время как обычные методы машинного обучения обычно выполняют определенные шаги предварительной обработки, а затем используют фиксированные и созданные вручную признаки, которые не только не оптимальны, но и обычно требуют высокой вычислительной сложности, методы на основе сверточных нейронных сетей могут

извлекать «выученные» признаки непосредственно из исходных данных рассматриваемой проблемы, чтобы максимизировать точность классификации. Это действительно является ключевой характеристикой для значительного повышения эффективности классификации, что сделало сверточные нейронные сети привлекательными для сложных инженерных приложений.

Тем не менее, господство традиционных подходов машинного обучения оставалось неоспоримым для одномерных сигналов, поскольку глубокие сверточные нейронные сети были смоделированы и созданы специально для двумерных сигналов, и их применение не было простым для одномерных сигналов, особенно при недостатке данных. Прямое использование глубоких сверточных нейронных сетей для обработки одномерных сигналов, естественно, требует соответствующего преобразования одномерных сигналов в двумерные. Недавно исследователи попытались использовать глубокие сверточные нейронные сети для диагностики неисправностей подшипников [34–42]. Для этого использовались различные методы преобразования одномерных вибрационных сигналов в двумерные, которые обычно используют метод прямого преобразования сигнала вибрации в матрицу $n \times t$, называемую «изображением вибрации» [39]. Другая техника была использована в [37], где два сигнала вибрации были измерены с помощью двух акселерометров, а затем было применено дискретное преобразование Фурье, и два преобразованных сигнала были представлены в виде матрицы, которая может быть подана в обычную глубокую сверточную нейронную сеть. Для классификации ударов электрокардиограммы (ЭКГ) и обнаружения аритмии общепринятый подход заключается в том, чтобы сначала рассчитать мощность или лог-спектрограмму для преобразования каждого удара ЭКГ в двумерное изображение [43,44]. Однако использование таких глубоких сверточных нейронных сетей имеет определенные недостатки и ограничения. Прежде всего, известно, что они представляют собой высокую вычислительную сложность, требующую специального оборудования, особенно в процессе обучения. Поэтому двумерные сверточные нейронные сети не подходят для приложений реального времени на мобильных устройствах и устройствах с низким энергопотреблением и малым объемом памяти. Кроме того, правильное обучение глубоких сверточных нейронных сетей требует массивного набора данных для обучения, чтобы достичь разумной способности к обобщению. Это может оказаться неприемлемым вариантом для многих практических применений одномерных сигналов, где может быть мало помеченных данных.

Чтобы устранить эти недостатки, в 2015 году Кираньяз (Kiranyaz S.) и другие [45] предложили первые компактные и адаптивные одномерные сверточные нейронные сети для работы непосредственно с сигналами ЭКГ, специфичными для пациента. За сравнительно короткое время одномерные сверточные нейронные сети стали популярными и показали самые современные результаты в различных приложениях обработки сигналов, таких как раннее обнаружение аритмии по ударам электрокардиограммы [45–47], мониторинг здоровья конструкций и обнаружение структурных повреждений [48–52] мониторинг неисправностей мощных двигателей [53] и мониторинг схем [54] в реальном времени. Кроме того, в двух недавних исследованиях использовались одномерные сверточные нейронные сети для обнаружения повреждений в подшипниках [55–58]. Однако в последнем исследовании, проведенном Чжан (Zhang W.) и др. [58], для обнаружения, локализации и количественной оценки повреждений подшипников были созданы как одиночные, так и ансамбли глубоких одномерных сверточных нейронных сетей. Глубокая конфигурация одномерной сверточной нейронной сети, использованная в этом исследовании, состояла из шести больших сверточных слоев, за которыми следовали два полностью связанных (плотных) слоя. Другие подходы к глубоким одномерным сверточным нейронным сетям были недавно предложены в [59–62] для обнаружения аномалий в сигналах ЭКГ. Эти глубокие конфигурации имеют общие недостатки

двумерных аналогов. Например, в [58] было использовано несколько «трюков» для улучшения обобщающей способности глубокой одномерной сверточной нейронной сети, таких как увеличение объема данных, нормализация пакета, отсев, мажоритарное голосование и т. д. Другой подход к решению этой проблемы заключается в использовании большей части набора данных для обучения, что может быть невыполнимо в некоторых практических приложениях. В [58] для обучения глубокой сети используется более 96% всех данных. При этом предположение о том, что такой большой набор данных для обучения будет доступен, может препятствовать использованию этого метода на практике. Поэтому в данной статье основное внимание уделяется компактным одномерным сверточным нейронным сетям с небольшим количеством скрытых слоев/нейронов и их применению для решения некоторых важных инженерных задач, предполагая, что помеченных данных мало, или для максимизации точности обнаружения и идентификации требуются решения, специфичные для конкретного приложения или устройства. Эталонные наборы данных и основное программное обеспечение одномерных сверточных нейронных сетей, использованное в этих приложениях, в настоящее время находятся в открытом доступе в [63].

Список использованных источников

1. Cochocki A., Unbehauen R. Neural Networks for Optimization and Signal Processing. 1st ed. USA: John Wiley & Sons, Inc. - 1993.
2. Simon H. Neural Networks and Learning Machines. 3rd Ed. Pearson Education, Inc, 2009.
4. Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain/ F.Rosenblatt // Psychol. Rev. US: American Psychological Association. - 1958. - Vol. 65. - P. 386–408.
5. Resop J.P. A Comparison Of Artificial Neural Networks And Statistical Regression With Biological Resources Applications: Thesis. - 2006.
6. Ince T. Evaluation of global and local training techniques over feed-forward neural network architecture spaces for computer-aided medical diagnosis /T.Ince et al. // Expert Syst. Appl.- 2010. - Vol. 37, № 12. - P. 8450–8461.
7. Kiranyaz S. Progressive Operational Perceptrons / S. Kiranyaz et al. // Neurocomputing. - 2017. - Vol. 224. - P. 142–154.
8. Kiranyaz S. et al. Generalized model of biological neural networks: Progressive operational perceptrons/S. Kiranyaz//2017 International Joint Conference on Neural Networks (IJCNN). - Anchorage, AK, USA: IEEE. - 2017. - P. 2477–2485.
9. Rauber T. Kernel Multilayer Perceptron / T.Rauber, K.Berns // 2011 24th SIBGRAPI Conference on Graphics, Patterns and Images. Alagoas, MaceiA, Brazil: IEEE. - 2011. - P. 337–343.
10. Ogai H., Bhattacharya B. Pipe Inspection Robots for Structural Health and Condition Monitoring / H. Ogai, B. Bhattacharya // New Delhi: Springer India. - 2018. - Vol. 89.
11. Mashor M.Y. Hybrid multilayered perceptron networks // Int. J. Syst. Sci. - 2000. - Vol. 31, № 6. - P. 771–785.
12. Kiranyaz S. et al. Evolutionary artificial neural networks by multi-dimensional particle swarm optimization // Neural Netw. - 2009. - Vol. 22, № 10. - P. 1448–1462.
13. Ince T. A Generic and Robust System for Automated Patient-Specific Classification of ECG Signals / T. Ince, S. Kiranyaz, M. Gabbouj // IEEE Trans. Biomed. Eng. - 2009. - Vol. 56, № 5. - P. 1415–1426.
14. Kiranyaz S., Gabbouj M., Ince T. Multidimensional Particle Swarm Optimization for Machine Learning and Pattern Recognition. 1st ed. 2014. Berlin, Heidelberg: Springer Berlin Heidelberg : Imprint: Springer. - 2014. - 1 p.

15. Mohseni S.A. Optimization of Neural Networks Using Variable Structure Systems / S.A. Mohseni, Ai Hui Tan. // IEEE Trans. Syst. Man Cybern. Part B Cybern. - 2012. - Vol. 42, № 6. - P. 1645–1653.
16. Hubel D.H. Receptive fields of single neurones in the cat's striate cortex / D.H. Hubel, T.N. Wiesel // J. Physiol. - 1959. - Vol. 148, № 3. - P. 574–591.
17. Hubel D.H. Single unit activity in lateral geniculate body and optic tract of unrestrained cats / D.N. Hubel // J. Physiol. - 1960. - Vol. 150, № 1. - P. 91–104.
18. Hubel D.H. Receptive fields, binocular interaction and functional architecture in the cat's visual cortex / D.N. Hubel, T.N. Wiesel // J. Physiol. - 1962. - Vol. 160, № 1. - P. 106-154.2.
19. Hubel D.H. Receptive fields of cells in striate cortex of very young, visually inexperienced kittens / D.N. Hubel, T.N. Wiesel // J. Neurophysiol. American Physiological Society. - 1963. - Vol. 26, № 6. - P. 994–1002.
20. Hubel D.H. Receptive fields and functional architecture of monkey striate cortex / D.N. Hubel, T.N. Wiesel // J. Physiol. - 1968. - Vol. 195, № 1. - P. 215–243.
21. Fukushima K. Neocognitron: A new algorithm for pattern recognition tolerant of deformations and shifts in position / K. Fukushima, S. Miyake // Pattern Recognit. - 1982. - Vol. 15, № 6.- P. 455–469.
22. Rumelhart D.E. Learning representations by back-propagating errors: 6088 / D.E. Rumelhart, G.E. Hinton, R.J. Williams // Nature. Nature Publishing Group. - 1986. - Vol. 323, № 6088.- P. 533–536.
23. Le Cun Y. Handwritten digit recognition with a back-propagation network / Le Cun Y. et al. // Proceedings of the 2nd International Conference on Neural Information Processing Systems.- Cambridge, MA, USA: MIT Press. - 1989. - P. 396–404.
24. Lecun Y. Gradient-based learning applied to document recognition / Lecun Y. et al. // Proc. IEEE. - 1998. - Vol. 86, № 11. - P. 2278–2324.
25. MNIST handwritten digit database, Yann LeCun, Corinna Cortes and Chris Burges [Electronic resource]. URL: <http://yann.lecun.com/exdb/mnist/> (accessed: 19.10.2022).
26. Krizhevsky A. ImageNet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G.E. Hinton // Commun. ACM. - 2017. - Vol. 60, № 6. - P. 84–90.
27. Deng J. ImageNet: A large-scale hierarchical image database / J. Deng et al. // 2009 IEEE Conference on Computer Vision and Pattern Recognition. Miami, FL: IEEE, 2009. - P. 248–255.
28. Juan L., Gwun O. A Comparison of SIFT, PCA-SIFT and SURF. - P. 10.
29. Ojala T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns / T. Ojala, M. Pietikainen, T. Maenpaa // IEEE Trans. Pattern Anal. Mach. Intell. - 2002. - Vol. 24, № 7. - P. 971–987.
30. Srivastava N. Dropout: A Simple Way to Prevent Neural Networks from Overfitting / N. Srivastava et al. // J. Mach. Learn. Res. - 2014. - Vol. 15. - P. 1929–1958.
31. Zeiler M.D., Fergus R. Visualizing and Understanding Convolutional Networks // Computer Vision – ECCV 2014 / ed. Fleet D. et al. Cham: Springer International Publishing, 2014. - P. 818–833.
32. Abdel-Hamid O. Applying Convolutional Neural Networks concepts to hybrid NN-HMM model for speech recognition / O. Abdel-Hamid et al. // 2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Kyoto, Japan: IEEE, 2012. - P. 4277–4280.
33. Kim Y. Convolutional Neural Networks for Sentence Classification: arXiv:1408.5882. arXiv, 2014.
34. Lu C. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification / C. Lu, Z. Wang, B. Zhou // Adv. Eng. Inform. - 2017. - Vol. 32. - P. 139–151.

35. Ding X. Energy-Fluctuated Multiscale Feature Learning With Deep ConvNet for Intelligent Spindle Bearing Fault Diagnosis / X. Ding, Q. He // IEEE Trans. Instrum. Meas. - 2017. - Vol. 66, № 8. - P. 1926–1935.
36. Guo X. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis / X. Guo, L. Chen, C. Shen // Measurement. - 2016. - Vol. 93. - P. 490–502.
37. Janssens O. Convolutional Neural Network Based Fault Detection for Rotating Machinery / O. Janssens et al. // J. Sound Vib. - 2016. - Vol. 377. - P. 331–345.
38. Hoang D.-T., Kang H.-J. Convolutional Neural Network Based Bearing Fault Diagnosis // Intelligent Computing Theories and Application / ed. Huang D.-S., Jo K.-H., Figueroa-García J.C. Cham: Springer International Publishing, 2017. - P. 105–111.
39. Zhang W. Bearings Fault Diagnosis Based on Convolutional Neural Networks with 2-D Representation of Vibration Signals as Input / W. Zhang, G. Peng, C. Li // MATEC Web Conf. EDP Sciences, 2017. - Vol. 95. - P. 13001.
40. Appana D.K. Speed Invariant Bearing Fault Characterization Using Convolutional Neural Networks / D.K. Appana, W. Ahmad, J.-M. Kim // Multi-disciplinary Trends in Artificial Intelligence / ed. Phon-Amnuaisuk S., Ang S.-P., Lee S.-Y. Cham: Springer International Publishing, 2017. - Vol. 10607. - P. 189–198.
41. Li S. An Ensemble Deep Convolutional Neural Network Model with Improved D-S Evidence Fusion for Bearing Fault Diagnosis: 8 /S. Li et al. // Sensors. Multidisciplinary Digital Publishing Institute, 2017. - Vol. 17, № 8. - P. 1729.
42. Lee K.B. A Convolutional Neural Network for Fault Classification and Diagnosis in Semiconductor Manufacturing Processes / K.B. Lee, S. Cheon, C.O. Kim // IEEE Trans. Semicond. Manuf. - 2017. - Vol. 30, № 2. - P. 135–142.
43. Ruiz J.T. Arrhythmia Detection Using Convolutional Neural Models / J.T. Ruiz, J.D.B. Pérez, J.R.B. Blázquez// Distributed Computing and Artificial Intelligence, 15th International Conference / ed. De La Prieta F., Omatu S., Fernández-Caballero A. Cham: Springer International Publishing, 2019. - P. 120–127.
44. Zihlmann M. Convolutional recurrent neural networks for electrocardiogram classification / M. Zihlmann, D. Perekrestenko, M. Tschannen // 2017 Computing in Cardiology (CinC).- 2017. - P. 1–4.
45. Kiranyaz S. Convolutional Neural Networks for patient-specific ECG classification/ S. Kiranyaz et al. // 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). - 2015. - P. 2608–2611.
46. Kiranyaz S. Real-Time Patient-Specific ECG Classification by 1-D Convolutional Neural Networks / S. Kiranyaz, T. Ince, M. Gabbouj // IEEE Trans. Biomed. Eng. - 2016. - Vol. 63, № 3. - P. 664–675.
47. Kiranyaz S. Personalized Monitoring and Advance Warning System for Cardiac Arrhythmias: 1 / S. Kiranyaz, T. Ince, M. Gabbouj // Sci. Rep. Nature Publishing Group, 2017. - Vol. 7, № 1. - P. 9270.
48. Avci O. Wireless and real-time structural damage detection: A novel decentralized method for wireless sensor networks / O. Avci et al. // J. Sound Vib. - 2018. - Vol. 424. - P. 158–172.
49. Avci O. Structural Damage Detection in Real Time: Implementation of 1D Convolutional Neural Networks for SHM Applications / O. Avci et al. // Structural Health Monitoring & Damage Detection, Volume 7 / ed. Niezrecki C. Cham: Springer International Publishing, 2017. - P. 49–54.
50. Abdeljaber O. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks / O. Abdeljaber et al. // J. Sound Vib. - 2017. - Vol. 388. - P. 154–170.
51. Avci O. et al. Efficiency Validation of One Dimensional Convolutional Neural Networks for Structural Damage Detection Using a SHM Benchmark Data. - 2018.

52. Abdeljaber O. 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data / O. Abdeljaber et al. // *Neurocomputing*. - 2018. - Vol. 275. - P. 1308–1317.
53. Ince T. Real-Time Motor Fault Detection by 1-D Convolutional Neural Networks / T. Ince et al. // *IEEE Trans. Ind. Electron.* - 2016. - Vol. 63, № 11. - P. 7067–7075.
54. Kiranyaz S. Real-Time Fault Detection and Identification for MMC Using 1-D Convolutional Neural Networks / Kiranyaz S. et al. // *IEEE Trans. Ind. Electron.* - 2019. - Vol. 66, № 11. - P. 8760–8771.
55. Abdeljaber O. Fault Detection and Severity Identification of Ball Bearings by Online Condition Monitoring / O. Abdeljaber et al. // *IEEE Trans. Ind. Electron.* - 2019. - Vol. 66, № 10. - P. 8136–8147.
56. Eren L. A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive 1D CNN Classifier / L. Eren, T. Ince, S. Kiranyaz // *J. Signal Process. Syst.* - 2019. - Vol. 91, № 2. - P. 179–189.
57. Eren L. Bearing Fault Detection by One-Dimensional Convolutional Neural Networks // *Math. Probl. Eng. Hindawi*, 2017. - Vol. 2017. - P. e8617315.
58. Zhang W. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load / W. Zhang et al. // *Mech. Syst. Signal Process.* - 2018. - Vol. 100. - P. 439–453.
59. Hinton G.E. Reducing the Dimensionality of Data with Neural Networks / G.E. Hinton, R.R. Salakhutdinov // *Science. American Association for the Advancement of Science*, 2006. - Vol. 313, № 5786. - P. 504–507.
60. Acharya U.R. Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network / U.R. Acharya et al. // *Inf. Sci.* 2017. - Vol. 405. - P. 81–90.
61. Xiong Z. Robust ECG signal classification for detection of atrial fibrillation using a novel neural network / Z. Xiong, M.K. Stiles, J. Zhao // *2017 Computing in Cardiology (CinC)*. - 2017. - P. 1–4.
62. Acharya U.R. A deep convolutional neural network model to classify heartbeats / U.R. Acharya et al. // *Comput. Biol. Med.* 2017. - Vol. 89. - P. 389–396.
63. M.ASCE O.A. Ph D.,P.E. Onur Avci [Electronic resource] // Onur Avci. URL: <http://onur-avci.com/> (accessed: 19.10.2022).

CURRENT STATE OF MACHINE LEARNING TECHNIQUES IN ONE-DIMENSIONAL SIGNAL PROCESSING APPLICATIONS

**B.I. Valeev¹, A.I. Sadykova¹, A.N. Salakhutdinova¹,
A.A. Sakhabutdinova², L.A. Sakhabutdinova³**
(Supervisor: Agliullin T.A. associate professor KNRTU-KAI)

¹Kazan National Research Technical University named after A.N. Tupolev –KAI
10, K. Marx, Kazan, 420111, Russian Federation

²MAEI "Lyceum - Engineering Center" of the Soviet District of Kazan
114, A. Kutuy, Kazan, 420073, Russian Federation

³Kazan Innovative University named after V. G. Timiryasov (IEML)
42, Moskovskaya, Kazan, 420111, Russian Federation

Annotation. During the last decade, *Convolutional Neural Networks* (CNNs) have become the de facto standard for various *Computer Vision* and *Machine Learning* operations. CNNs are feedforward *Artificial Neural Networks* (ANNs) with alternating convolutional and subsampling layers. Deep 2D CNNs with many hidden layers and millions of parameters have the ability to learn complex objects and patterns providing that they can be trained on a massive size visual database with ground-truth labels. With a proper training, this unique ability makes them the primary tool for various engineering applications for 2D signals such as images and video frames. However, this may not be a viable option in numerous applications over 1D signals especially when the training data is scarce or application specific. To address this issue, 1D CNNs have recently been proposed and immediately achieved the state-of-the-art performance levels in several applications such as personalized biomedical data classification and early diagnosis, structural health monitoring, anomaly detection and identification in power electronics and electrical motor fault detection. Another major advantage is that a real-time and low-cost hardware implementation is feasible due to the simple and compact configuration of 1D CNNs that perform only 1D convolutions (scalar multiplications and additions). This paper presents a comprehensive review of the general architecture and principals of 1D CNNs along with their major engineering applications, especially focused on the recent progress in this field. Their state-of-the-art performance is highlighted concluding with their unique properties. The benchmark datasets and the principal 1D CNN software used in those applications are also publicly shared in a dedicated website. While there has not been a paper on the review of 1D CNNs and its applications in the literature, this paper fulfills this gap.

Keywords: artificial neural networks, machine learning, convolutional neural networks.

Статья отправлена в редакцию 30.09.2022 г.