

в случае глубоких структур, требует колоссальных временных и трудовых затрат. Глубокое же обучение – подход, моделирующий человеческое абстрактное мышление (или, по крайней мере, представляет собой попытку приблизиться к нему), а не использующий его [2].

Применение нейронных сетей в области сегментации временных рядов показало плохие результаты и возможность выделять сегменты малой длительности. Для нейронной сети входными данными является фрагмент данных ЭЭГ, при этом на основе выходных данных необходимо выполнить принятие решения о том, является ли участок условно-стационарным сегментом и где находится граница сегмента [3].

Применение глубоких нейронных сетей для сегментации сигналов должно повысить скорость вычислений и выделения сегментов. Актуальность сегментации обуславливается тем, что содержательная трактовка анализа электрической активности мозга часто остается затруднительной в силу того, что ЭЭГ являются кусочно-нестационарными процессами. Обычные статистические характеристики, применимые к ЭЭГ-сигналу, имеют смысл только после предварительного сегментирования ряда на участки относительно стационарности.

Список цитированных источников

1. Артёменко, С.В. Нейросетевые алгоритмы обработки электроэнцефалограмм для диагностики эпилепсии: автореферат диссертации. Минск, 2016.
2. Хайкин, С. Нейронные сети: полный курс. – 3-е изд. – Москва: Издательский дом "Вильямс", 2014. 1104 с.
3. Wolpaw, J.R. Braincomputer interfaces for communication and control / J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, T.M. Vaughan // Clin Neurophysiol. – 2002. – Vol. 113, № 6. – P. 767.

УДК 004.032.26

ПРИМЕНЕНИЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ ОБНАРУЖЕНИЯ СОЛНЕЧНЫХ ПАНЕЛЕЙ

Крощенко А.А.

Брестский государственный университет им. А.С. Пушкина, г. Брест

Популярность использования солнечных панелей возрастает из года в год. Такая технология позволяет получать дешевую и возобновляемую энергию. Немаловажным преимуществом использования такой энергии является ее экологическая чистота, поскольку ее производство не связано с выделением диоксида углерода, являющегося одним из основных факторов глобального потепления [1]. С ростом заинтересованности в установке и эксплуатации солнечных панелей растет и потребность в своевременном анализе использования этой технологии в мире.

Для анализа и распознавания изображений с начала 2000-х годов успешно применяются сверточные нейронные сети (СНС). В последние годы, с выходом работы Дж. Хинтона [2], посвященной предобучению глубоких нейронных сетей, алгоритмы обуче-

ния сверточных сетей и их архитектуры претерпели существенные изменения в сторону усложнения. Также произошло расширение областей их применимости. В частности, глубокие сверточные сети в последнее время успешно применяются в задачах сегментации изображений и распознавания отдельных сегментов [3].

Перед нами была поставлена задача, состоящая в исследовании перспектив использования сверточных нейронных сетей для распознавания наличия солнечных панелей на изображениях. Решение такой задачи потребовало построения бинарного классификатора на основе сверточной нейронной сети. Применяемая глубокая СНС имеет архитектуру, изображенную на рис. 1.




Рисунок 1 – Структура сверточной нейронной сети

Для обучения были использованы изображения низкого качества, полученные фотографированием со спутника (Google Maps). Для обучения и тестирования была использована выборка из 3347 3-канальных изображений размером 200X200 пикселей (из которых 1643 содержали солнечные панели, а 1704 — нет). Полная выборка делилась на обучающую и тестирующую выборки в соотношении 4 к 1. На рисунке 2 отображены примеры используемых изображений.




Рисунок 2 – Примеры изображений, используемых для обучения

Сеть обучалась на протяжении 70 эпох методом обратного распространения ошибки, при этом были использованы следующие параметры: скорость обучения — 0,001, моментный параметр — 0,9, weight-decay — 0,0005, размер мини-батча — 20.

Дополнительно применялся dropout с вероятностью 0,5 для полносвязных слоев сверточной нейронной сети.

В режиме тестирования нами использовалось простое преобразование выходных данных в виде пороговой функции вида

$$b_s = y_s > 0,5,$$

где y_s задает реальный выход сети, b_s — его бинаризованную форму, $s = 1, 2, \dots, L$, где L — количество изображений в тестовой выборке.

Обобщающая способность сети определялась по формуле

$$A = \frac{S}{L} * 100,$$

$$S = \sum_{s=1}^L I(b_s = e_s),$$

где $I()$ — индикаторная функция, e_s — целевой выход нейронной сети для заданного изображения (содержит (1) или не содержит (0)).

В результате проведенных экспериментов была получена точность обнаружения объектов в 87.46% (таблица 1 представляет собой матрицу сопряженности для полученного бинарного классификатора, построенную с использованием тестирующей выборки).

Таблица 1 – Матрица сопряженности для обученного классификатора

	Предсказано «Нет»	Предсказано «Да»
«Нет»	325	32
«Да»	52	261

На основе показателей специфичности и полноты, вычисленных для разного значения порога, был построен график ROC-кривой, изображенный на рис. 3.




Рисунок 3 – ROC-кривая для обученной модели

Для указанной кривой показатель AUC составил 0,92, что соответствует отличному качеству модели.

Таким образом, нами был обучен бинарный классификатор для определения наличия солнечных панелей на фотографиях. Такая модель может быть использована для оценки масштабов применения данной технологии по аэрофотоснимкам.

Качество работы предложенного классификатора может быть улучшено привлечением к работе экспертов, которые смогут профессионально определить наличие солнечных панелей на фотографиях.

Список цитированных источников

1. Boucher, O. 2013: Clouds and Aerosols / O. Boucher, D. Randall, P. Artaxo, C. Bretherton // In: Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. – Cambridge University Press, 2013. – P. 571–657.
2. Hinton, G. A fast learning algorithm for deep belief nets / G. Hinton, S. Osindero, Y. Teh // Neural Computation. – 2006. – Vol. 18. – P. 1527–1554.
3. Long, J. Fully Convolutional Networks for Semantic Segmentation / J. Long, E. Shelhamer, T. Darrell // The IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2015. – P. 3431–3440.

УДК 004.8.032.26

ИСПОЛЬЗОВАНИЕ НЕЙРОСЕТЕВЫХ СИСТЕМ ДЛЯ ОБНАРУЖЕНИЯ ПАТОЛОГИЙ В СИГНАЛАХ ЭЛЕКТРОЭНЦЕФАЛОГРАММ

Лаврущик А.И.

*Брестский государственный технический университет, г. Брест
Научный руководитель: Артёмко С.В., к. т. н.*

Одним из направлений исследований в области искусственного интеллекта, основанном на попытках воспроизвести нервную систему человека, является нейронная сеть.

Прототипом для создания нейронных сетей послужили биологические нейронные сети. А именно: способность нервной системы обучаться и исправлять ошибки, что должно позволить смоделировать, пусть и достаточно грубо, работу человеческого мозга.

Существуют методы нестандартного применения нейронных сетей, в частности, в медицинской отрасли при диагностике возможных патологий при считывании сигналов головного мозга с помощью электроэнцефалографии.

Однако и здесь есть некоторые трудности. Первая – это правильно выбрать структуру нейронной сети. Вторая – реализовать правильное обучение выбранной модели, при котором необходимо исключить вариант «необнаружения» тревожных сигналов и минимизировать оповещение о ложных случаях.

Электроэнцефалография – метод записи электрической активности различных отделов головного мозга, которая преобразуется в соответствующую кривую, называемую электроэнцефалограммой (ЭЭГ). Прибор, с помощью которого выполняется электроэнцефалография, называется энцефалографом. Электроэнцефалограмма с помощью ря-