

Д. О. ЗУБАРЄВ, магістр, СНУ ім. В. Даля, Сєверодонецьк,
І. С. СКАРГА-БАНДУРОВА, д-р техн. наук, доц., зав.каф., СНУ
ім. В. Даля, Сєверодонецьк

АНАЛІЗ ЕФЕКТИВНОСТІ НАВЧАННЯ CNN ЗА ПРИНЦИПОМ "ВЧИТЕЛЬ-УЧЕНЬ" З ВИКОРИСТАННЯМ НЕПІДГОТОВЛЕНОГО IMAGE-DATASET

Штучні нейронні мережі з кожним роком розширюють спектр існуючих та потенційних сфер використання. Якість навчання штучних нейронних мереж є основою якості їх подальшого функціонування. Стаття присвячена аналізу ефективності навчання штучних нейронних мереж класу CNN для розпізнавання непідготовленого набору зображень (Image-Dataset) за принципом "вчитель-учень", де у ролі вчителя виступає попередньо навчена діюча штучна нейронна мережа CNN-1, що завдає алгоритм навчання, а учнем є непідготовлена штучна нейронна система CNN-2. Доведено, що CNN-1 є більш ефективною для пошуку великого спектра об'єктів на зображеннях, а CNN-2 найкраще працює для вузько направлених надточних пошуків завданих об'єктів. Іл.: 7. Бібліогр.: 22 назв.

Ключові слова: штучна нейронна мережа; CNN; зображення; Image-Dataset.

Опис проблеми. Штучні нейронні мережі та мережі нервових клітин живого організму – це обчислювальні системи з надвеликою кількістю паралельно функціонуючих процесорів з певною множиною зв'язків. Штучний аналог біологічних нейронних мереж є значно простішим, але здатен переймати деякі важливі ознаки функціонування мозку живої істоти: навчатися згідно з досвідом, знаходити корисні дані з надлишкової інформації, робити узагальнення, тощо. Сфери використання штучних нейронних мереж різноманітні: розпізнавання рукописних текстів, розпізнавання мовних команд, мовне введення тексту в комп'ютер, розпізнавання осіб, ідентифікація осіб за відбитками пальців, розпізнавання автомобільних номерів, асоціативний пошук інформації, фільтрація і блокування спаму, розпізнавання captcha, оптимізація режимів виробничого процесу та інші. Штучні нейронні мережі, з їх здатністю розпізнавати раціональне ядро із масиву ускладнених або недостовірних даних, можуть використовуватися для пошуку моделей та виявлення тенденцій, що занадто складні, щоб бути одразу поміченими людьми або комп'ютерною технікою. Підготовлену, тобто навчену, штучну нейронну мережу можна розглядати у якості

"експерта" по тим категоріям інформації, що були їй надані для аналізу. Така штучна нейронна мережа потім може бути використана для вивчення нових ситуацій, щоб відповісти на питання "що-якщо" при моделюванні тих чи інших теоретичних та прикладних гіпотез [1]. Властивістю нейронних мереж також є те, що вони можуть змінювати поведінку в залежності від навколишнього середовища. Навчена нейронна мережа є більш стійкою до деяких викривлень вхідних даних, що дає можливість коректно розпізнавати образи та закономірності.

Попри широке застосування, штучні нейронні мережі поки що не можуть гарантувати абсолютну точність, навіть при їх вірному функціонуванні [2]. Інша існуюча проблема полягає в тому, що штучні мережі часто дуже великі за глибиною і шириною і містять велику кількість параметрів [3]. Окрім того, ніхто не спроможний пояснити, яким саме чином вони вирішують задачі [2, 4]. Оскільки штучні нейронні мережі є дуже складними моделями, що враховують надзвичайно велику кількість різноманітних параметрів для моделювання складних відносин, котрі містяться у надвеликих об'ємах даних, здебільшого внутрішні представлення результатів є настільки складними, що їх навіть неможливо проаналізувати, окрім деяких найлегших задач, але аналіз таких даних немає великого сенсу. Це призвело до швидкозростаючої області досліджень з пошуку більш компактних та ефективних моделей.

Аналіз літератури. Згідно з [5] значне поліпшення продуктивності може бути досягнуте різними способами. Так, автори [6] пропонують збільшення тренувальних даних з різними типами варіацій – наприклад, з кількома видами шумів на різних рівнях штучної мережі замість використання попередньо очищених даних для навчання моделей. Для покращення роботи мереж, що використовуються для аналізу зображень та відео, ефективними способами покращення продуктивності є кластеризація [7] та сегментація [8, 9]. В роботі [5] запропоновано компактні моделі що формуються шляхом дистиляції знань або стиснення моделей. Технології поєднання різних функцій на входах, їх спільне використання та об'єднання різних архітектур розглядалися в роботі [10]. Компактні моделі або мережі учнів навчаються на виходах вчителів, використовуючи критерії навчання, що мінімізують різницю між розподілами учнів та вчителів. Ця технологія показала гарні результати в різних умовах – повністю керованому середовищі [11], напівкерованому середовищі [12], послідовному тренінгу [13], дозволяючи навчати мережі учнів працювати краще, ніж в умовах, коли аналогічні моделі тренувалися з нуля. Разом з тим, варто відзначити, що хоча ці методики ефективно використовуються для навчання, часто трапляється, що вони не можуть бути розгорнуті для обробки поточних

даних у режимі реального часу через обмеження, які вони становлять в термінах затримки та обчислень, особливо для непідготовлених систем [14]. Таким чином, з огляду на те, що якість підготовки штучних нейронних мереж є основою їх подальшого функціонування, удосконалення існуючих та пошук нових методик більш ефективного процесу їх навчання залишається досить актуальним завданням.

Мета. Аналіз ефективності навчання штучних нейронних мереж класу CNN розпізнаванню непідготовленого Image-Dataset за допомогою принципу "вчитель-учень", де у ролі вчителя виступає вже навчена діюча штучна нейронна мережа, що задає алгоритм навчання, а учнем є непідготовлена штучна нейронна система.

Матеріали і результати дослідження. Існує велика кількість різних типів штучних нейронних мереж, котрі відрізняються принципами функціонування, в залежності від яких штучні нейронні мережі вирішують певну окреслену низку задач та проблем. Не вдаючись у типологізацію, для нашого дослідження візьмемо згорткову нейронну мережу (Convolutional Neural Network, або CNN), що використовується для ефективного розпізнавання зображень. Згорткова нейронна мережа – це спеціальна архітектура штучних нейронних мереж, яка використовує різновид багат шарових перцептронів, створений так, щоб вимагати використання мінімального обсягу попередньої обробки. Вона складається з шарів входу та виходу, а також з кількох прихованих шарів. Приховані шари складаються зі згорткових шарів, шарів нормалізації, повноз'єднаних шарів та агрегувальних шарів [6].

Перед початком практичного використання штучної нейронної мережі потрібно її навчити. Безпосередньо сам процес навчання полягає у налаштуванні її внутрішніх параметрів під конкретне завдання. Процес навчання здійснюється на навчальній вибірці. Навчальна вибірка включає вхідні значення і відповідні їм вихідні значення Dataset. В ході навчання нейронна мережа знаходить певні залежності вихідних полів від вхідних. Оскільки алгоритм роботи штучної нейронної системи є ітеративним, тобто таким, що повторюється, його кроки називаються епохами або циклами. Епоха – це одна ітерація в процесі навчання, що включає пред'явлення всіх прикладів з навчальної множини і, можливо, перевірку якості навчання на контрольному Dataset [15].

Інструментарій. В дослідженнях використовувалась мова програмування Python із залученням наступних модулів: os, re, argparse, cv2, numpy, time, math та бібліотека Keras [16]. Для визначення об'єктів на зображенні ми використовували наступні технології: OpenCV 3.4.3 [17], Deep neural network (DNN) module from OpenCV, Caffe prototxt file,

MobileNet SSD [18], Python script for downloads images from Google [19], Keras CNN.

Характеристики CNN-"вчитель" (далі CNN-1). В якості CNN-1 обрано глибоку нейронну мережу DNN з opencv. Надалі до неї було під'єднано вже навчену модель Caffe model від Tensorflow, яка визначає до 20 запрограмованих об'єктів на вхідному зображенні. Для виявлення об'єктів на зображенні, було об'єднано мереживну архітектуру MobileNet і структуру єдиного детектора (SSD), внаслідок чого отримано швидкий і ефективний метод глибокого навчання для виявлення об'єктів.

Характеристики CNN-"учень" (далі CNN-2). Для створення CNN-2 була використана бібліотека Keras. Процес побудови згорткової нейронної мережі відбувається в чотири етапи: згортка, об'єднання, оптимізація, повне об'єднання. Формула згортки (конволюції), що демонструє "рух" ядра w^l по вхідному зображенню або карті ознак y^{l-1} для CNN-2 виглядає наступним чином [20]:

$$x_{ij}^l = \sum_{a=-\infty}^{+\infty} \sum_{b=-\infty}^{+\infty} \omega_{ab}^l \cdot y_{(i-s-a)(j-s-b)}^{l-1} + b^l,$$

$$\forall i \in (0, \dots, N), \forall j \in (0, \dots, M),$$

де підрядкові індекси i, j, a, b – це індекси елементів в матрицях; s – величина кроку конволюції; ℓ та $\ell - 1$ – індекси шарів мережі; $x^{\ell-1}$ – вихід певної попередньої функції або вхідне зображення мережі; $y^{\ell-1}$ – це $x^{\ell-1}$ після проходження функції активації; w^l – ядро згортання; b^l – зміщення; x^l – результат операції конволюції. Операції проходять роздільно для кожного елемента i, j матриці мережі x^l розмірність якої N, M .

Графічне відображення побудованої CNN-2 представлено на рис. 1.

Вхідні дані для створення Image-Dataset:

– keyword – обов'язковий параметр. Ключове слово, за яким відбувається створення Image-Dataset та навчання CNN-2. Keyword має входити в діапазон допустимих елементів, тобто тих, що вмiє розпізнавати CNN-1;

– limit – максимальна кількість результатів пошуку зображень;

– confidence – межа мінімального відсоткового відношення, при якому CNN-1 буде визначати – навчати чи ні CNN-2.

Формування Image-Dataset. Навчальна вибірка була поділена на два не тотожних типи Image-Dataset:

1) навчальний Image-Dataset-L1 та навчальний Image-Dataset-L2;

2) тестовий Image-Dataset-T, за допомогою яких відбувалося безпосереднє навчання CNN-2 та перевірка її адекватності.

До вибірки Image-Dataset-L1 увійшли відібрані CNN-1 та обрізані нею за допомогою сегментації, згідно з вказаними параметрами, зображення потрібного елемента у форматі .jpg у кількості 100 файлів, з яких перед початком навчання видалялись пошкоджені. В процесі сегментації зображення, що обробляється, розділяється на фрагменти за допомогою змінної маски, що може рухатися з довільним кроком від 1 пікселя до 32, в результаті чого підсумковий набір може містити різну кількість фрагментів [8, 21]. Кожен з отриманих фрагментів є зображенням, яке CNN може віднести до того чи іншого класу. Підсумкове зображення може бути перефарбоване відповідно до результатів розпізнавання, як показано на рис. 2. Як правило, якість сегментації залежить від якості навчання мережі.

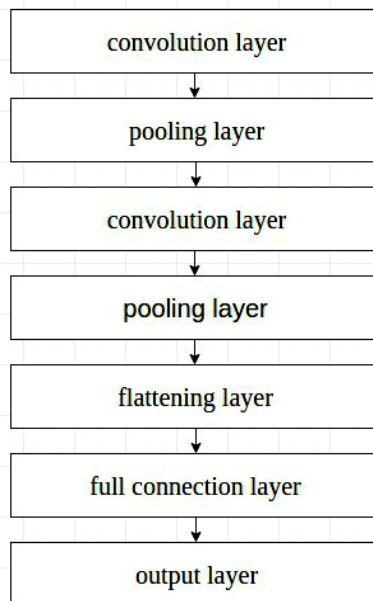


Рис. 1. Архітектура CNN-2

Сегментація завданого елемента відбувалася за допомогою алгоритму семантичної сегментації [21]. До вибірки Image-Dataset-L2 увійшли відібрані CNN-1 не обрізані зображення, що містили потрібний елемент, у форматі .jpg у кількості 100 файлів.

Кількість початкових зображень Image-Dataset-T у форматі .png становила 100. Пошкоджених та обрізаних файлів у цій вибірці не було. Кількість зображень з потрібним елементом становила 5.



a



б

Рис. 2 (а) – Початкове зображення, (б) – Результат сегментації зображення штучною нейронною мережею

Навчання CNN-2 за допомогою CNN-1 з використанням Image-Dataset-L1 та Image-Dataset-L2

Як було вказано вище, одна епоха являє собою один крок в навчанні штучної нейронної мережі. Тобто, коли CNN навчається на всіх навчальних зразках за один прохід, це означає, що одну епоху закінчено. Для отримання показових результатів процес навчання повинен складатися з кількох епох. Для навчання CNN-2 було обрано 25 епох в обох випадках. У результаті навчання CNN-2 за допомогою CNN-1 отримано наступні результати (рис. 3).

За 25 епох навчання CNN-2 з використанням Image-Dataset-L1 тривалість кожної коливалася від 117 до 160 секунд, при тривалості одного кроку 1 – 2 секунди; сума помилок, що розраховувалася згідно

[22], для кожного циклу становила від 0,2250 до 0,0406 на останньому циклі; точність розпізнавання коливалася від 93,41% на першому циклі до 99,16% на останньому циклі: Графічне представлення результатів навчання CNN-2 з використанням Image-Dataset-L1 надано на рис. 4 та рис. 5.

```

Epoch 1/25
82/82 ----- 126s 2s/step - loss: 0.2250 - acc: 0.9341
Epoch 2/25
82/82 ----- 124s 2s/step - loss: 0.2132 - acc: 0.9421
Epoch 3/25
82/82 ----- 122s 1s/step - loss: 0.1788 - acc: 0.9398
Epoch 4/25
82/82 ----- 121s 1s/step - loss: 0.1528 - acc: 0.9478
Epoch 5/25
82/82 ----- 119s 1s/step - loss: 0.1383 - acc: 0.9428
Epoch 6/25
82/82 ----- 117s 1s/step - loss: 0.1224 - acc: 0.9512
Epoch 7/25
82/82 ----- 118s 1s/step - loss: 0.1367 - acc: 0.9520
Epoch 8/25
82/82 ----- 120s 1s/step - loss: 0.0972 - acc: 0.9607
Epoch 9/25
82/82 ----- 122s 1s/step - loss: 0.1047 - acc: 0.9619
Epoch 10/25
82/82 ----- 123s 1s/step - loss: 0.0960 - acc: 0.9653
Epoch 11/25
82/82 ----- 120s 1s/step - loss: 0.0926 - acc: 0.9680
Epoch 12/25
82/82 ----- 123s 1s/step - loss: 0.0849 - acc: 0.9665
Epoch 13/25
82/82 ----- 126s 2s/step - loss: 0.0687 - acc: 0.9767
Epoch 14/25
82/82 ----- 122s 1s/step - loss: 0.0704 - acc: 0.9748
Epoch 15/25
82/82 ----- 121s 1s/step - loss: 0.0756 - acc: 0.9783
Epoch 16/25
82/82 ----- 126s 2s/step - loss: 0.0581 - acc: 0.9832
Epoch 17/25
82/82 ----- 131s 2s/step - loss: 0.0616 - acc: 0.9802
Epoch 18/25
82/82 ----- 129s 2s/step - loss: 0.0539 - acc: 0.9844
Epoch 19/25
82/82 ----- 141s 2s/step - loss: 0.0552 - acc: 0.9855
Epoch 20/25
82/82 ----- 131s 2s/step - loss: 0.0444 - acc: 0.9878
Epoch 21/25
82/82 ----- 148s 2s/step - loss: 0.0506 - acc: 0.9870
Epoch 22/25
82/82 ----- 160s 2s/step - loss: 0.0561 - acc: 0.9859
Epoch 23/25
82/82 ----- 160s 2s/step - loss: 0.0425 - acc: 0.9897
Epoch 24/25
82/82 ----- 157s 2s/step - loss: 0.0420 - acc: 0.9916
Epoch 25/25
82/82 ----- 130s 2s/step - loss: 0.0406 - acc: 0.9916

```

Рис. 3. Результати навчання CNN-2 з використанням Image-Dataset-L1




Рис. 4. Сума помилок для кожної епохи навчання з використанням Image-Dataset-L1




Рис. 5. Точність розпізнавання заданого об'єкта для кожної епохи з використанням Image-Dataset-L1

Навчання CNN-2 з використанням множини Image-Dataset-L2 пройшло з гіршими результатами за навчання з використанням множини Image-Dataset-L1, що видно з графіків на рис. 6 та рис. 7. Точність розпізнавання склала 71.39 % проти 99.16% у першому випадку.




Рис. 6. Сума помилок для кожної епохи навчання з використанням Image-Dataset-L2




Рис. 7. Точність розпізнавання заданого об'єкта для кожної епохи з використанням Image-Dataset-L2

Тестування на адекватність роботи CNN-2 за допомогою Image-Dataset-T.

Заключним етапом дослідження було тестування навченої CNN-2 для випадків Image-Dataset-L1 та Image-Dataset-L2 за допомогою єдиного

для обох випадків Image-Dataset-T. Для випадку Image-Dataset-L1 навчена CNN-2 показала наступний результат:

```
File name: 2.jpg. Result: Chair
File name: s19UJnvW0xj9VJG8kqIz3Q.png. Result: Chair
File name: tryumo-1-everest.jpg. Result: Chair
File name: 3.jpeg. Result: Chair
File name: shkaf-3-h-dvernij-nensi-roza.jpg. Result: Chair
File name: dakas-trymo-viktoriya_1-640x480.jpg. Result: Chair
File name: фв.jpg. Result: Chair
File name: 4.JPG. Result: Chair
Count chairs: 8
Count not chairs: 92
```

Тобто, CNN-2 визначила вірні п'ять зображень завданого елемента, проте зображення ще на трьох фото також класифікувала, як завданий елемент.

Для випадку Image-Dataset-L2 навчена CNN-2 показала наступний тестовий результат:

```
True elements: 44
False elements: 56
```

Незважаючи на те, що через надмірну кількість змінних параметрів мережі не можливо побачити внутрішній процес отримання остаточного результату, варто зазначити, що значний вплив на похибки справив невеликий обсяг Image-Dataset.

Висновки. У результаті проведених експериментів в рамках заявленої тематики було доведено, що CNN-1 є більш ефективною для пошуку великого спектру об'єктів на зображеннях, CNN-2 є ефективною для вузько направлених надточних пошуків завданих об'єктів. При подальшій розробці варто перевірити, які тестові результати видасть CNN-2, навчена з використанням Image-Dataset з великим об'ємом, а також спробувати синхронно навчити CNN-3, CNN-4 etc. за іншими не тотожними параметрами.

Список літератури:

1. *Raghava Sh.* Neural Network / *Sh. Raghava*, Amazon Digital Services LLC, 2016. – 105 p.
2. *Aggarwal, C.C.* Neural Networks and Deep Learning / *C.C. Aggarwal*. – Springer International Publishing, 2018. – 512 p.
3. *He K.* Deep residual learning for image recognition / *K. He, X. Zhang, S. Ren, J. Sun* // Proc. of IEEE Conf. on Computer Vision and Pattern Recognition, 2016. – P. 770-778.
4. *Keinert J.* Design of Image Processing Embedded Systems Using Multidimensional Data Flow / *J. Keinert, J. Teich*, Springer, 2011. – 337 p.

5. *Fukuda T.* Efficient Knowledge Distillation from an Ensemble of Teachers / *T. Fukuda, M. Suzuki, G. Kurata, S. Thomas, J. Cui, B. Ramabhadran* // Proc. Interspeech 2017, August 20–24, Stockholm, Sweden, 2017. – P. 3697–3701.
6. *Aghdam H.H.* Guide to Convolutional Neural Networks: A Practical Application to Traffic-Sign Detection and Classification / *H.H. Aghdam, E.J. Heravi*, New York: Springer, USA, 2017. – 299 p.
7. *Madasamy B.* Improving classification Accuracy of Neural Network through Clustering Algorithms / *B. Madasamy, J. Tamilselvi* // International Journal of Computer Trends and Technology (IJCTT). – 2013. – Vol. 4, Issue 9. – Режим доступу: [www. URL: http://www.ijcttjournal.org/Volume4/issue-9/IJCTT-V4I9P151.pdf](http://www.ijcttjournal.org/Volume4/issue-9/IJCTT-V4I9P151.pdf), (accessed 15.10.2018).
8. *Advances in Image and Video Segmentation* / Zhang, Y.-J. (Ed.), IRM Press, 2006. – 473 p.
9. *Ngan K.N.* Video Segmentation and Its Applications / *K.N. Ngan, H. Li* (Eds.), Springer, 2011. – 179 p.
10. *Howard A.G.* Mobilenets: Efficient convolutional neural networks for mobile vision applications / *A.G. Howard, M. Zhu, Bo Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam* // arXiv: 1704.04861, 2017, (accessed 15.12.2018).
11. *Geras K.J.* Blending LSTMs into CNNs / *K.J. Geras, A.-R. Mohamed, R. Caruana*, et al // ICLR Workshop, 2016.
12. *Li J.* Learning small-size DNN with output-distribution-based criteria / *J. Li, R. Zhao, J.-T. Huang, and Y. Gong* // Proc. Interspeech. – 2014. – P. 1910–1914.
13. *Wong J.H.M.* Sequence student-teacher training of deep neural networks / *J.H.M Wong and M.J.F. Gales* // Proc. Interspeech. – 2016. – P. 2761–2765.
14. *Zhang C.* Understanding deep learning requires rethinking generalization / *C. Zhang, S. Bengio, M. Hardt, B. Recht and O. Vinyals* // Proc. of International Conference on Learning Representations. – 2017.
15. *Sewak M.* Practical Convolutional Neural Networks / *M. Sewak, K. Rezaul and P. Pujari*, Packt Publishing, 2018. – 218 p.
16. Keras Documentation [Електронний ресурс] – Режим доступу: [www. URL: https://keras.io/preprocessing/image/](http://www.keras.io/preprocessing/image/), accessed 21.09.2018, (accessed 21.09.2018).
17. Opensv [Електронний ресурс] – Режим доступу: URL: <https://github.com/opencv/opencv/tree/master/samples/dnn>, (accessed 21.09.2018).
18. MobileNet SSD [Електронний ресурс] – Режим доступу: [www. URL: https://github.com/chuanqi305/MobileNet-SSD](https://github.com/chuanqi305/MobileNet-SSD), (accessed 15.10.2018).
19. Python Script to download hundreds of images from 'Google Images' [Електронний ресурс] – Режим доступу: [www. URL: https://github.com/hardikvasa/google-images-download](https://github.com/hardikvasa/google-images-download), (accessed 21.09.2018).
20. *Калинин С.* Сверточная сеть на Python [Електронний ресурс] / *С. Калинин*. – Режим доступу: [www. URL: https://habr.com/company/ods/blog/344008/](http://www.habr.com/company/ods/blog/344008/), (accessed 21.09.2018).
21. *Advances in Image Segmentation* / P.-G.P. Ho (Ed.), InTech. – 2012. – 126 p.
22. *Changhau I.* Loss Functions in Neural Networks [Електронний ресурс] / *I. Changhau* – Режим доступу: [www. URL: https://isaacchanghau.github.io/post/loss_functions/](https://isaacchanghau.github.io/post/loss_functions/), (accessed 21.09.2018).

References:

1. Raghava, Sh. (2016), *Neural Network*, Amazon Digital Services LLC, 105 p.
2. Aggarwal, C.C. (2018), *Neural Networks and Deep Learning*, Springer International Publishing, 512 p.
3. He, K., Zhang, X., Ren, S. and Sun J. (2016), "Deep residual learning for image recognition", *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, P. 770-778.

4. Keinert, J., and Teich, J. (2011), *Design of Image Processing Embedded Systems Using Multidimensional Data Flow*, Springer, 337 p.
5. Fukuda, T., Suzuki, M., Kurata, G., Thomas, S., Cui, J. and Ramabhadran, B. (2017), "Efficient Knowledge Distillation from an Ensemble of Teachers", *Proc. Interspeech 2017*, August 20–24, Stockholm, Sweden, pp. 3697-3701.
6. Aghdam, H.H., and Heravi, E.J. (2017), *Guide to Convolutional Neural Networks: A Practical Application to Traffic-Sign Detection and Classification*, Springer, New York, USA, 299 p.
7. Madasamy, B., and Tamilselvi, J. (2013), "Improving classification Accuracy of Neural Network through Clustering Algorithms", *International Journal of Computer Trends and Technology (IJCTT)*, Vol. 4, Issue 9, available at: <http://www.ijcttjournal.org/Volume4/issue-9/IJCTT-V4I9P151.pdf>, (accessed 15 Oct 2018).
8. Zhang, Y.-J. (Ed.) (2006), *Advances in Image and Video Segmentation*, IRM Press, 473 p.
9. Ngan K.N., Li H. (Eds.) (2011), *Video Segmentation and Its Applications*, Springer, 179 p.
10. Howard, A.G., Zhu, M., Chen, Bo, Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam H. (2017), "Mobilenets: Efficient convolutional neural networks for mobile vision applications" *arXiv: 1704.04861*, (accessed 15 Oct 2018).
11. Geras, K.J., Mohamed, A.-R., Caruana, R., Urban, G., Wang, S., Aslan, O., Philipose, M., Richardson, M. and Sutton, C. (2016), "Blending LSTMs into CNNs", *ICLR Workshop*.
12. Li, J., Zhao, R., Huang, J.-T. and Gong, Y. (2014), "Learning small-size DNN with output-distribution-based criteria", *Proc. Interspeech 2014*, September, pp. 1910-1914.
13. Wong, J.H.M and Gales, M.J.F. (2016), "Sequence student-teacher training of deep neural networks", *Proc. Interspeech*, pp. 2761-2765.
14. Zhang, C., Bengio, S., Hardt, M., Recht, B. and Vinyals O. (2017), "Understanding deep learning requires rethinking generalization", *Proc. of International Conference on Learning Representations*.
15. Sewak, M., Rezaul, K. and Pujari, P. (2018), *Practical Convolutional Neural Networks*. Packt Publishing, 218 p.
16. Keras Documentation (2018), available at: <https://keras.io/preprocessing/image/>, (accessed 21 Oct 2018).
17. Opensv (2018), available at: <https://github.com/opencv/opencv/tree/master/samples/dnn>, (accessed 21 Sept 2018).
18. MobileNet SSD (2018), available at: <https://github.com/chuanqi305/MobileNet-SSD>, (Accessed 15 Oct 2018).
19. Python Script to download hundreds of images from 'Google Images' (2018), available at: <https://github.com/hardikvasa/google-images-download>, (accessed 21. Sept 2018).
20. Kalinin S. Svertochnaya set' na Python, available at: <https://habr.com/company/ods/blog/344008/> (accessed 21 Sept 2018).
21. Ho, P.-G.P. (Ed.) (2012), *Advances in Image Segmentation*, InTech, 126 p.
22. Changhau, I. (2017), "Loss Functions in Neural Networks", available at: https://isaacchanghau.github.io/post/loss_functions/ (accessed 21 Sept 2018).

Статтю представив д.т.н., проф. Національного технічного університету "Харківський політехнічний інститут" О.П. Арсенева.

Надійшла (received) 16.11.2018

Zubarev Dmytro, master

Volodymyr Dahl East Ukrainian National University

59-a Central avenue, Severodonetsk, Luhansk region, Ukraine, 93400

tel./phone: (064) 522-89-97, e-mail: dmytrozubarev@gmail.com

ORCID ID: 0000-0003-2933-9457

Skarga-Bandurova Inna, Dr. Sci. Tech., Professor

Volodymyr Dahl East Ukrainian National University

59-a Central avenue, Severodonetsk, Luhansk region, Ukraine, 93400

tel./phone: (064) 522-89-97, e-mail: skarga_bandurova@ukr.net

ORCID ID: 0000-0003-3458-8730

УДК 004.932.1

Аналіз ефективності навчання CNN за принципом "вчитель-учень" з використанням непідготовленого Image-Dataset / Зубарев Д.О., Скарга-Бандурова І.С. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2018. – № 42 (1318). – С. 188 – 201.

Штучні нейронні мережі з кожним роком розширюють спектр існуючих та потенційних сфер використання. Якість навчання штучних нейронних мереж є основою якості їх подальшого функціонування. Стаття присвячена аналізу ефективності навчання штучних нейронних мереж класу CNN для розпізнавання непідготовленого набору зображень (Image-Dataset) за принципом "вчитель-учень", де у ролі вчителя виступає попередньо навчена діюча штучна нейронна мережа CNN-1, що завдає алгоритм навчання, а учнем є непідготовлена штучна нейронна система CNN-2. Доведено, що CNN-1 є більш ефективною для пошуку великого спектра об'єктів на зображеннях, а CNN-2 найкраще працює для вузько направлених надточних пошуків заданих об'єктів. Іл.: 7. Бібліогр.: 22 назв.

Ключові слова: штучна нейронна мережа; CNN; зображення; Image-Dataset.

УДК 004.932.1

Анализ эффективности обучения CNN по принципу "учитель-ученик" с использованием неподготовленных Image-Dataset / Зубарев Д.А., Скарга-Бандурова И.С. // Вестник НТУ "ХПИ". Серія: Інформатика и моделирование. – Харьков: НТУ "ХПИ". – 2018. – № 42 (1318). – С. 188 – 201.

Искусственные нейронные сети с каждым годом расширяют спектр существующих и потенциальных сфер использования. Качество обучения искусственных нейронных сетей является основой качества их дальнейшего функционирования. Статья посвящена анализу эффективности обучения искусственных нейронных сетей класса CNN для распознавания неподготовленного набора изображений (Image-Dataset) по принципу "учитель-ученик", где в роли учителя выступает предварительно обученная искусственная нейронная сеть CNN-1, которая задает алгоритм обучения, а учеником является неподготовленная искусственная нейронная система CNN-2. Доказано, что CNN-1 является более эффективной для поиска большего спектра объектов на изображениях, а CNN-2 лучше всего работает для узко направленных сверхточных поисков заданных объектов. Ил.: 7. Библиогр.: 22 назв.

Ключевые слова: искусственная нейронная сеть; CNN; изображения; Image-Dataset.

UDC 004.932.1

Analysis of the Efficiency of CNN Learning Based on Teacher-Student Training with Untrained Image Dataset / Zubarev D.O., Skarga-Bandurova I.S. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2018. – № 42 (1318). – P. 188 – 201.

Artificial neural networks expand the range of existing and potential spheres of use each year. The quality of training artificial neural networks is the basis of the quality of their further functioning. The article is devoted to the analysis of the effectiveness of the training of CNN class artificial neural networks for the recognition of an unprepared set of images (Image-Dataset) based on the principle of "teacher-student", in which the acting teacher of artificial neural network CNN-1 pre-trained, which causes the learning algorithm, and the pupil An untrained artificial neural system CNN-2. It is proved that CNN-1 is more effective to search for a large spectrum of objects in images, and CNN-2 works best for narrowly focused precise searches of objects. Figs.: 7. Refs.: 22 titles.

Keywords: artificial neural network; CNN; image; Image-Dataset.