

УДК 004.93'1=161.2

DOI: 10.31673/2412-9070.2023.013237

Є. А. ЧИЧКАРЬОВ, доктор техн. наук, професор;

О. В. ЗІНЧЕНКО, доктор техн. наук, доцент;

М. М. ЛИСЕНКО, здобувач,

Державний університет телекомунікацій, Київ

## ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ РОЗПІЗНАВАННЯ РУКОПИСНИХ УКРАЇНСЬКИХ ЛІТЕР ТА ЦИФР ІЗ ВИКОРИСТАННЯМ СИНТЕТИЧНИХ НАБОРІВ ДАНИХ

*Розглянуто кілька варіантів архітектури згорткових нейронних мереж для розпізнавання ізольованих рукописних українських символів та цифр, які було навчено з використанням синтетичного набору даних, побудованого на базі датасету CoMNIST і додатково згенерованих зображень літер із застосуванням набору рукописних шрифтів та друкованих курсивних шрифтів. Найкращі результати розпізнавання набору тестових зображень із літерами та цифрами забезпечили моделі сімейства DenseNet. Крім того, на результати розпізнавання, яких було досягнуто, помітно впливає обсяг навчальної вибірки.*

**Ключові слова:** розпізнавання рукописного тексту; розпізнавання українських символів; згорткові нейронні мережі (CNN); розпізнавання цифр; глибоке навчання; оброблення зображень.

### ВСТУП

Оптичне розпізнавання символів — технологія, яка сьогодні широко використовується, а системи оптичного розпізнавання символів дають змогу уникнути помилок та заощадити час. Однак розпізнавання рукописних символів є досить складним завданням, і протягом останніх десятиліть дослідники вивчають різні методи та технології вирішення цього питання.

Сучасні системи оптичного розпізнавання здебільшого базуються на нейронних мережах глибокого навчання [1; 2]. Оскільки моделі згорткових нейронних мереж (CNN) добре справляються з такими завданнями комп'ютерного зору, як класифікація зображень, виявлення об'єктів, розпізнавання зображень тощо, то їх широко використовують у моделюванні штучного інтелекту, особливо для створення класифікаторів зображень.

Цю статтю присвячено дослідженню технології розпізнавання рукописних українських літер та цифр із використанням синтетичного набору даних для навчання різних варіантів згорткових нейронних мереж.

**Огляд останніх досліджень і публікацій.** Для досліджень технологій розпізнавання рукописних літер латинського алфавіту фактичним стандартом є набір даних EMNIST [3]. Для класифікації зображень цього набору запропоновано багато різних варіантів архітектур нейронних мереж. Останніми роками увагу почали привертати й інші алфавіти — арабський, казахський тощо [4-7].

Найкращих показників точності та надійності розпізнавання можна досягти за допомогою нейронних мереж досить складної архітектури. Приклад високого показника точності розпізнавання, який отримано для бази даних Letters з EMNIST, становив 95,44% під час об'єднання марковських моделей випадкових полів і згорткових нейронних

мереж. У разі з базою даних Digits (або MNIST) гарних результатів за точністю розпізнавання було здобуто з використанням капсульних шарів після згортки [8; 9].

Прийнятна швидкість навчання зі збільшенням кількості параметрів досягається переважно із застосуванням попередньо тренуваних моделей. Попереднє навчання з використанням ImageNet прискорює збіжність, особливо на початку навчання, але навчання з випадковою ініціалізацією може надолужити втрачене протягом часу, приблизно порівнянню із загальною тривалістю навчання з використанням попереднього навчання [10]. На думку [11], моделі, створені з нуля, зазвичай, дають кращі результати порівняно з попередньо навченими моделями стосовно розпізнавання рукописних символів арабської мови.

У численних дослідженнях, які присвячено розпізнаванню рукописних символів, є досвід використання достатньо складних архітектур нейронних мереж. Наприклад, у статті [12] сучасні попередньо навчені архітектури CNN було використано для класифікації 231 різних рукописних символів Bangla на базі набору даних CMATERdb. Після 50 epoch InceptionResNetV2 було досягнуто найкращої точності (96,99%). DenseNet121 та InceptionNetV3 також продемонстрували чудову точність розпізнавання (відповідно 96,55 та 96,20%). Автори [13] розглянули також комбінацію навчених архітектур InceptionResNetV2, InceptionNetV3 і DenseNet121, що забезпечило ще кращу точність розпізнавання (97,69%) порівняно з іншими окремими архітектурами CNN.

У праці [13] було проведено численні експерименти зі згортковими нейронними мережами, зокрема базовими CNN, VGG-16 та ResNet з використанням регуляризації за допомогою відсіву та аугментації даних. Для архітектури Resnet вдалося досягти найкращого результату з показником

© Є. А. Чичкар'юв, О. В. Зінченко, М. М. Лисенко, 2023

розпізнавання 98,57%, для архітектури VGG-16 — результат 97,14%.

У статтях [14; 15] також здобуто більш високу досягнуту точність розпізнавання в разі використання глибшої архітектури нейронної мережі CNN.

Для розпізнавання кирилических символів такі дослідження досить нечисленні. Є досвід використання архітектури MobileNet [16] для розпізнавання символів казахської мови. Деякі результати розпізнавання кирилических символів подано також у [4; 17]. Щодо набору даних для розпізнавання українських літер, то відомі поодинокі праці в цьому напрямі. На думку [18] під час створення набору даних для навчання моделі потрібно розпізнавати великі і малі літери, а також брати до уваги можливість різного написання однієї і тієї самої літери.

#### **Формулювання задачі та шляхи її розв'язання.**

Цю статтю присвячено дослідженню можливостей розпізнавання українських (із деякими припущеннями — інших кирилических) рукописних літер та цифр із використанням згорткових нейронних мереж та аналізу впливу вибраної архітектури нейронної мережі на точність та надійність розпізнавання. Крім того, було досліджено технологію й особливості генерації повністю або частково синтетичного набору даних з огляду на аугментацію в процесі формування вихідного набору даних, вплив обсягу тренувального набору даних на результати розпізнавання.

Для кирилиці немає наборів даних, подібних до EMNIST. Відомі варіанти зібрань зображень рукописних кирилических літер (наприклад, на Kaggle), а також є деякий досвід використання різних класифікаторів і нейромережних технологій для їх розпізнавання, однак порівняльні дослідження технологій і результатів для них мають фрагментарний характер.

Цілі нашого дослідження:

- проаналізувати вплив архітектури згорткових нейронних мереж на точність розпізнавання рукописних цифр та літер українського алфавіту;
- дослідити раціональну технологію формування повністю або частково синтетичного набору даних літер українського алфавіту або цифр із різними варіантами аугментації навчальної вибірки;
- визначити особливості розпізнавання українських символів за умов навчання згорткових нейронних мереж із використанням згенерованого набору даних.

### **ОСНОВНА ЧАСТИНА**

#### **Методи вирішення поставленого завдання**

#### **Побудова набору даних для навчання моделі.**

Для навчання моделей було використано два набори даних. Перший було згенеровано виключно за допомогою двох зображень із застосуванням від-

повідного шрифту. Кількість згенерованих зображень варіювалася від двох до 48-ми для кожного символу, було взято набір шрифтів з українськими гліфами (48 шрифтів). Наприклад, для 32-х зображень на кожен символ загальний обсяг набору даних становив 116 736 зразків (32 зображення на символ одного шрифту).

Другий варіант набору даних було побудовано з використанням зображень датасета CoMNIST [4], який містить зображення  $278 \times 278$  RGBA літер російського алфавіту. Але цей набір даних досить обмежений, оскільки практично не має маленьких літер, а також не містить українських літер І, Ї, Є, Ї. Крім того, кількість зображень різних літер дещо різниться. До колекції рукописних зображень було додано згенеровані набори великих і малих літер І, Ї, Є, Ї, а також згенеровані набори інших малих літер українського алфавіту та цифр. Усі зображення було перетворено у формат RGB  $32 \times 32$  пікселя. Кількість зображень варіювалася у межах 2, 4, 8 зображень на символ із набору CoMNIST або 2-16 згенерованих зображень/символів. Кількість кожного типу зображень вибиралася у такий спосіб, щоб з огляду на аугментацію набір даних був близьким до збалансованого. Для генерації зображень літер було використано набір з 82-х рукописних або курсивних шрифтів. Загальний обсяг основного варіанта побудованої навчальної вибірки становив 132 248 зображень (із розрахунку чотири зображення на символ), а тестової вибірки — 26436 зображень.

Такий обсяг вибірки цілком можна порівняти з набором даних EMNIST Letters [3], який містить змішані малі та великі літери (26 класів і всього 145 600 зразків).

Для створення або трансформації зображень із літерами чи цифрами було використано бібліотеку Pillow. Тестовий набір даних формувався із застосуванням тих самих шрифтів. Вибір конкретних шрифтів і параметрів доповнення здійснювався випадковим чином. Обсяг тестового набору даних становив майже 15-20% від обсягу навчального.

Для аугментації зображень було використано можливості Image Data Generator із пакета tensorflow (три варіанти трансформації зображень символів: випадкове обертання, трансформація зсуву, трансформація масштабування).

**Попереднє оброблення зображень для розпізнавання.** Для виокремлення ділянок зображень, що містять літери або цифри, які потім розпізнаються, використовувалися інструменти бібліотеки.

Алгоритм попереднього оброблення зображення та виокремлення ділянки, що містить літери або цифри, охоплював етапи:

1. Фільтрація зображення для зниження рівня шуму (використовувався фільтр Гаусса — функція cv2.GaussianBlur).

2. Подальша бінаризація зображення для відсікання шуму (використовувалась функція `cv2.threshold`, її параметри було вибрано для надійного позначення контурів символів).

3. Позначення контурів за допомогою функції `cv2.findContours` та їх сортування, ділянки зі складними літерами (і, і, й) виділялися за допомогою морфологічної трансформації (використовувалося кілька ітерацій).

4. Виокремлення зон розпізнавання як набору прямокутників, що містять контури літер та цифр (використовувалися функції `cv2.boundingRect`).

Безпосередньо для розпізнавання позначені ділянки інтересу вирізалися з первісного зображення, до них знову застосовувалась бінаризація, після чого здобуті зображення окремих символів (без дилатації чи інших спотворень) масштабувалися до розміру  $32 \times 32 \times 3$ .

**Архітектура використаних моделей.** Було розглянуто кілька варіантів досить складних архітектур нейронних мереж. Дослідження проводилися з архітектурами VGG16 і VGG19 [19], ResNet [20] або ResNetV2 [21], MobileNet або MobileNetV2 [22; 23], DenseNet [24].

Кілька варіантів реалізованих архітектур сімейства ResNetV2 зображено на рис. 1.

Було попередньо створено кілька написів, які містили великі і маленькі літери та цифри (безпосередньо рукописні).

Обсяг навчальної вибірки істотно впливає на надійність розпізнавання символів. Генерація 1536 зображень на одну літеру або цифру (32 зображення для кожного символу для 48-ми типів шрифтів) фактично є граничним значенням, що забезпечує прийнятну точність розпізнавання. Зменшення обсягу вибірки спричинює істотне зниження точності розпізнавання (зі 100% точності до 40-60% у разі зменшення обсягу вибірки вчетверо). Збільшення обсягу вибірки призводить до помітного зростання витрат часу на навчання моделі. Варіант побудови набору даних (із використанням CoMNIST або без нього) не вплинув на цей висновок. Порівнявши різні архітектури моделей, можна дійти висновку, що всі розглянуті варіанти показали точність розпізнавання в діапазоні 96-99% під час навчання на наборі даних достатнього обсягу. Збільшення обсягу навчального набору даних для всіх розглянутих архітектур зумовило підвищення точності розпізнавання. Приклад результатів експерименту для моделі з архітектурою MobileNet (повністю згенеровані дані) наведено на рис. 2.

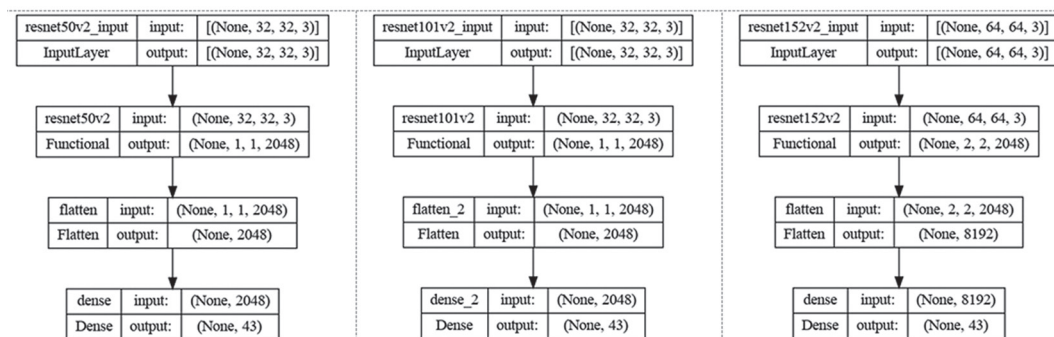


Рис. 1. Приклади реалізації моделей із сімейством архітектур ResNet V2

### Експериментальні результати та їх обговорення

Нейронні мережі для всіх архітектур навчалися за допомогою оптимізатора Adam, швидкість навчання було вибрано такою, що дорівнює 0,0001, кількість епох навчання — 50.

Усі використані архітектури під час навчання на вибірці максимального обсягу забезпечують точність розпізнавання елементів вибірки лише на рівні 95-99%. Збільшення кількості параметрів нейронної мережі внаслідок використання архітектури більшої глибини переважно зумовлює зростання точності розпізнавання.

Однак у разі спроби вирізнити зображення, що не належать до навчальної або тестової вибірки, різко виявилася відмінність досліджених варіантів архітектури щодо можливості розпізнавання символів. Для оцінювання точності розпізнаван-




Рис. 2. Приклад впливу розміру навчального набору даних на досягнуту точність розпізнавання (архітектура MobileNet)

Точність розпізнавання реальних написів на рівні 80-90% було досягнуто, якщо розмір навчальної вибірки не менш як 700, а краще більш ніж 1500 зображень на клас (або не менше чотирьох зображень на символ для набору даних із CoMNIST). Приклад результатів експерименту для моделі з архітектурою MobileNetV2 наведено на рис. 3.

Варіація параметрів трансформацій, які використовувалися для доповнення, також помітно впливає на результати розпізнавання: деформація або поворот зображення більш ніж на 10-15% збільшує частоту помилок.

За даними [25], зростання роздільної здатності зображень навчальних зразків мало вплинуло на результати через насиченість.



Рис. 3. Помилки розпізнавання реальних написів залежно від розміру набору даних навчання (архітектура MobileNetV2, зображення набору даних  $32 \times 32 \times 3$ )

Отже, в процесі використання глибоких нейронних мереж для розпізнавання літер або цифр надійність розпізнавання елементів реальних написів залежала передусім від розміру навчального набору даних. Точність розпізнавання тестового набору даних після навчання всіх варіантів моделей була досить високою — 97-98% і вищою. Однак генерація навчальних наборів даних невеликого розміру (300-500 зображень на клас) практично не забезпечувала надійного розпізнавання.

Загалом, порівнюючи досягнуту точність розпізнавання реальних зображень і швидкість навчання моделі, найкращу продуктивність забезпечили моделі сімейства DenseNet або ResNetV2.

Експерименти зі зміною алгоритму оптимізації порівняно з Adam не дали жодного поліпшення в точності та надійності розпізнавання реальних зразків. Збільшення кількості модельних епох навчання понад позначену також не призвело до зміни результатів.

## ВИСНОВКИ

У статті розглянуто кілька варіантів архітектури згорткових нейронних мереж для розпізнавання ізольованих рукописних цифр та українських літер.

Результати розпізнавання різних зображень, що містять літери та цифри, порівнювали на моделях з різною архітектурою. Показано можливість навчання згорткових нейронних мереж за допомогою синтетичного набору даних, побудованого на основі рукописних або курсивних шрифтів. Розмір навчального набору даних істотно впливає на надійність розпізнавання символів. Набори даних, використані в нашому дослідженні, за обсягом відповідають відомому датасету EMNIST Letters. Нижня межа розміру вибірки, що забезпечує прийнятну точність розпізнавання, становила

майже 1500 символів на клас. Зменшення вибірки завдяки скороченню кількості символів на клас призводить до значного зниження точності розпізнавання (з 90-100% точності розпізнавання елементів реальних написів до 40-60% у разі чотириразового зменшення обсягу вибірки).

Найкращі результати розпізнавання набору тестових зображень з літерами та цифрами забезпечили моделі сімейства DenseNet.

## Список використаної літератури

1. *Image character recognition using deep convolutional neural network learned from different languages* / Bai Jinfeng, Chen Zhineng, Feng, Bailan Xu Bo // 2014 IEEE International Conference on Image Processing, ICIP 2014. 2015. P. 2560–2564. URL: <https://doi.org/10.1109/ICIP.2014.7025518>.
2. *Maitra D. S., Bhattacharya U., Parui S. K. CNN based common approach to handwritten character recognition of multiple scripts* // 3th International Conference on Document Analysis and Recognition (ICDAR). 2015. P. 1021–1025. URL: <https://doi.org/10.1109/ICDAR.2015.7333916>.
3. *EMNIST: Extending MNIST to handwritten letters* / G. Cohen, S. Afshar, J. Tapson, A. Van Schaik // 2017 international joint conference on neural networks (IJCNN). 2017. P. 2921–2926. URL: <https://doi.org/10.48550/arxiv.1702.05373>.
4. *A repository of images of hand-written Cyrillic and Latin alphabet letters for machine learning applications*. URL: <https://github.com/GregVial/CoMNIST>
5. *Bilgin Taşdemir E. F. Online Turkish Handwriting Recognition Using Synthetic Data* // Avrupa Bilim ve Teknoloji Dergisi, Ejosat Special Issue 2021 (RDCONF). 2021. P. 649–656. URL: <https://doi.org/10.31590/ejosat.1039846>.
6. *Handwritten Kazakh and Russian (HKR) database for text recognition* / D. Nurseitov, K. Bostanbekov, D. Kurmankhojayev [et al.] // Multimed Tools Appl. 2021. V. 80. P. 33075–33097. URL: <https://doi.org/10.1007/s11042-021-11399-6>
7. *Ullah Zahid, Jamjoom Mona. An intelligent approach for Arabic handwritten letter recognition using convolutional neural network* // PeerJ Computer Science, 2022. V. 8. P. 995. URL: <https://doi.org/10.7717/peerj.cs.995>.
8. *Baldominos A., Sáez Y., Isasi P. A Survey of Handwritten Character Recognition with MNIST and EMNIST* // Applied Sciences. 2019. V. 3169. URL: <https://doi.org/10.3390/app9153169>.
9. *Handwritten indic character recognition using capsule networks* / B. Mandal, S. Dubey, S. Ghosh [et al.] // 2018 IEEE Applied Signal Processing Conference (ASPCON). 2018. P. 304–308. URL: <https://arxiv.org/abs/1901.00166>.

10. He K., Girshick R., Dollár P. Rethinking imagenet pre-training // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2019. P. 4918–4927. URL: <https://arxiv.org/abs/1811.08883>
11. Albattah Waleed, Albahli Saleh. Intelligent Arabic Handwriting Recognition Using Different Standalone and Hybrid CNN Architectures // *Applied Sciences*. 2022. V. 12. issue 10155. URL: <https://doi.org/10.3390/app121910155>.
12. Performance Analysis of State of the Art Convolutional Neural Network Architectures in Bangla Handwritten Character Recognition / Tapotosh Ghosh, Abedin, MHZ., Al Banna H. [et al.] // *Pattern Recognit. Image Anal.* 2021. V. 31. P. 60–71. URL: <https://doi.org/10.1134/S1054661821010089>.
13. Recognizing Arabic Handwritten Literal Amount Using Convolutional Neural Networks / Aicha Korichi, Slatnia Sihem, Tagougui Najiba [et al.]. 2022. URL: [https://doi.org/10.1007/978-3-030-96311-8\\_15](https://doi.org/10.1007/978-3-030-96311-8_15).
14. A new Arabic handwritten character recognition deep learning system (AHCR-DLS) / Balaha Hossam, Sabry Mohamed, Ali Hesham, Badawy Mahmoud // *Neural Computing and Applications*. 2021. V. 33. URL: <https://doi.org/10.1007/s00521-020-05397-2>.
15. Abo Samra, Gibrael Al Amin, Oqaibi Hadi. An Optimized Deep Residual Network with a Depth Concatenated Block for Handwritten Characters Classification // *Computers, Materials & Continua*. 2021. V. 680. P. 1–28. URL: <https://doi.org/10.32604/cmc.2021.015318>.
16. Classification of handwritten names of cities and handwritten text recognition using various deep learning models / D. Nurseitov, K. Bostanbekov, M. Kanatov [et al.]. 2021. URL: <https://doi.org/10.25046%2Faj0505114>.
17. Vovchuk O., Kyrychenko M. Recognition of Handwritten Cyrillic Letters using PCA. 2019. URL: [https://www.researchgate.net/publication/336987544\\_Recognition\\_of\\_Handwritten\\_Cyrillic\\_Letters\\_using\\_PCA](https://www.researchgate.net/publication/336987544_Recognition_of_Handwritten_Cyrillic_Letters_using_PCA)
18. Economic efficiency of innovative projects of CNN modified architecture application / V. Khavalko, V. Mykhailyshyn, R. Zhelizniak [et al.] // *CEUR Workshop Proceedings*. 2020. Vol. 2654: *Proceedings of the International workshop on cyber hygiene (Cyb-Hyg-2019) co-located with 1st International conference on cyber hygiene and conflict management in global information networks (CyberConf 2019)*. Kyiv, Ukraine; November 30, 2019. P. 182–193. URL: <https://ceur-ws.org/Vol-2654/paper14.pdf>.
19. Simonyan K., Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition // *CoRR abs/1409.1556*. 2014. URL: <https://doi.org/10.48550/arXiv.1409.1556>.
20. Deep Residual Learning for Image Recognition / K. He, X. Zhang, S. Ren, J. Sun // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2015. P. 770–778. URL: <https://doi.org/10.1109/cvpr.2016.90>.
21. Identity Mappings in Deep Residual Networks / K. He, X. Zhang, Shaoqing Ren, Jian Sun // *European Conference on Computer Vision-2016*, Springer. 2016. P. 630–645. URL: [https://doi.org/10.1007/978-3-319-46493-0\\_38](https://doi.org/10.1007/978-3-319-46493-0_38).
22. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications / Andrew G. Howard, Menglong Zhu, Bo Chen [et al.] // *ArXiv abs/1704.04861*. 2017. URL: <https://doi.org/10.48550/arXiv.1704.04861>.
23. MobileNetV2: Inverted Residuals and Linear Bottlenecks / Mark Sandler, Andrew G. Howard, Menglong Zhu [et al.] // *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2018. P. 4510–4520. URL: <https://doi.org/10.1109/CVPR.2018.00474>.
24. Densely Connected Convolutional Networks / G. Huang, Z. Liu, L. Van Der Maaten, K. Q. Weinberger // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA. 2017. P. 2261–2269. URL: <https://doi.org/10.1109/CVPR.2017.243>.
25. Chychkarov Y., Zinchenko O. Handwritten Ukrainian Character Recognition using a Convolutional Neural Networks and Synthetic Dataset // *MoMLeT+DS 2023: 5th International Workshop on Modern Machine Learning Technologies and Data Science*, June 3, 2023, Lviv, Ukraine, 2023. P. 109–121. URL: <https://ceur-ws.org/Vol-3426/paper9.pdf>.

Ye. Chychkarov, O. Zinchenko, M. Lysenko

#### INFORMATION TECHNOLOGY FOR RECOGNITION OF HANDWRITTEN UKRAINIAN LETTERS AND NUMBERS USING SYNTHETIC DATA SETS

The paper considers several variants of the architecture of convolutional neural networks for recognizing isolated handwritten digits and Ukrainian letters.

The results of recognizing different images containing letters and numbers were compared on models with different architectures. Several variants of rather complex architectures of neural networks were considered. Research was conducted with VGG16 and VGG19 architectures, ResNet or ResNetV2, MobileNet or MobileNetV2, DenseNet.

*The possibility of learning convolutional neural networks with the help of a synthetic data set built on the basis of handwritten or cursive fonts is shown. The size of the training data set significantly affects the reliability of character recognition. The data sets used in the work correspond in volume to the well-known EMNIST Letters dataset.*

*The lower limit of the sample size, which provides acceptable recognition accuracy, was about 1500 characters per class. Reducing the sample by reducing the number of symbols per class leads to a significant decrease in recognition accuracy (from 90-100% accuracy of recognizing elements of real inscriptions to 40-60% with a 4-fold reduction in the sample size).*

*Thus, when using deep neural networks to recognize letters or numbers, the reliability of recognizing elements of real inscriptions depended primarily on the size of the training data set. The accuracy of recognition of the test data set after training all variants of the models was quite high - 97-98% and higher. However, the generation of training data sets of small size — 300-500 images per class - practically did not provide reliable recognition.*

*In general, when comparing the achieved recognition accuracy of real images and the model training speed, the best performance was provided by the DenseNet or ResNetV2 family models.*

*Experiments with changing the optimization algorithm compared to Adam did not give any improvement in the accuracy and reliability of recognizing real samples. Increasing the number of model training epochs beyond the specified one also did not change the results.*

**Keywords:** handwriting recognition; recognition of Ukrainian characters; convolutional neural networks (CNN); digit recognition; deep learning; image processing.

