

DOI: 10.34185/1991-7848.2023.01.8

УДК 004.942:681.3.068

К.Ю. Островська, В.Ф. Балакін, С.С. Черський

ВИКОРИСТАННЯ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ ДЛЯ ВИРІШЕННЯ ЗАДАЧІ КЛАСИФІКАЦІЇ ДЕФЕКТІВ МЕТАЛОПРОКАТУ

***Анотація.** Основною метою роботи є створення програмної системи, що виконує класифікацію дефектів поверхні металопрокату з високою точністю (понад 90%) та високою швидкістю (не більше 1 секунди на 1 зображення) за рахунок використання штучних нейронних мереж. Для досягнення мети необхідно виконати такі завдання: 1) виконати дослідження предметної галузі, визначити можливість використання нейронних мереж для вирішення задачі класифікації дефектів металопрокату; 2) побудувати модель нейронної мережі, придатну на вирішення завдання класифікації видимих дефектів металопрокату; 3) виконати генерацію навчальної, тестової та валідаційної вибірок на основі бази даних дефектів поверхні гарячого металопрокату, наданої Північно-східним університетом (NEU); зробити аугментацію згенерованих вибірок; 4) спроектувати та реалізувати систему класифікації дефектів; 5) провести тестування та обчислювальні експерименти. В результаті роботи було розроблено програмну систему для класифікації дефектів металопрокату на базі нейромережових технологій, яка здатна менш ніж за 1с часу виконувати класифікацію дефекту на зображенні з точністю не менше 90%.*

***Ключові слова:** Нейромережа, програмна система, класифікація, дефект, металопрокат, аугментація, API, web-інтерфейс, REST, MobileNet, InceptionV3, Python, Django web/rest framework, JavaScript, Bootstrap, набір даних, датасет.*

Вступ

Контроль якості продукції є важливим етапом на металургійних заводах, адже гарантія якості означає відповідність механічних та інших властивостей певним значенням. Але коли метал перебуває у прокаті, стан його поверхні чи покриття створює окремий важливий чинник якості, який також необхідно контролювати [6].

Контроль поверхні зазвичай здійснюється візуально (людиною) на кінцевих етапах виробництва. Однак навіть тут швидкість прокату металу дуже висока і на проведення контролю є дуже мало часу. По закінченню процесу метал, що прокочується, згортається в рулон, після чого виявити дефект стає ще важче. Нерідко це призводить до відвантаження споживачеві неякісного металу, що надалі тягне за собою значні фінансові втрати для виробника.

Таким чином, очевидно, що потреба металургійних підприємств у системах автоматизації виявлення та класифікації поверхневих дефектів є дуже високою. Але незважаючи на цю високу потребу, розробників подібних систем на сьогоднішній день досить мало. Найбільш відомі: ISRA Parsytec, Codnex, Matra, EES, Siemens-VAI, Sipar та ін) [1]. При цьому існуючі системи добре виконують виявлення дефектів, але досі мають складнощі з їхньою класифікацією. Складність обумовлена тим, що поверхні сталей, що прокочуються на різних агрегатах навіть одного і того ж заводу, часто різняться на вигляд, а це призводить до ускладнення алгоритмів виявлення та класифікації дефектів поверхні [2, 5, 9]. З іншого боку, будь-яку універсальну частину системи доводиться адаптувати під конкретну виробничу лінію [7]. Крім цього, складність обумовлена великою кількістю різновидів поверхневих дефектів [4].

Характеристики та класифікація дефектів варіюються для кожного конкретного виробництва та агрегату та не регулюються загальноприйнятим стандартом. Навіть невеликі зміни у виробничому процесі можуть спричинити появу нових видів дефектів [10].

Архітектура та докладні характеристики комерційних систем автоматичного виявлення дефектів не поширюються у відкритому доступі. Однак є науково-дослідні проекти на цю тему.

Наприклад, у роботах [3, 8] описаний приклад з використанням алгоритму виділення ознак, створеного без використання машинного навчання в комбінації з нейронною мережею для класифікації.

Варто окремо відзначити, що висока точність класифікації дефектів створить можливість заздалегідь узгоджувати якість металопркату зі

споживачем – підприємство може піти на певні поступки замість повної заміни та подальшого надвиробництва продукції.

Таким чином, розробка аналогічної системи з використанням штучних нейронних мереж для досягнення високої точності класифікації є дуже актуальним завданням.

Мета роботи

Основною метою даної роботи є створення програмної системи, що виконує класифікацію дефектів поверхні металопрокату з високою точністю (понад 90%) та високою швидкістю (не більше 1 секунди на 1 зображення) за рахунок використання штучних нейронних мереж.

Існуючі моделі нейронних мереж для класифікації дефектів металопрокату з заявленою точністю класифікації представлено в таблиці 1.

Таблиця 1

Моделі нейронних мереж для класифікації дефектів металопрокату

Модель	Заявлена точність класифікації, %	Час класифікації 1-го зображення, с
SVM	93.27	1.133
HSVM-МС	95.18	1.104
HCGA	95.04	0.158
5HL-MPCNN	89.01	0.113
7HL-MPCNN	93.03	0.062
Improved YOLO	97.55	0.012

Проектування програмної системи

У процесі проектування системи розроблено архітектура класів, представлена на рис. 1.

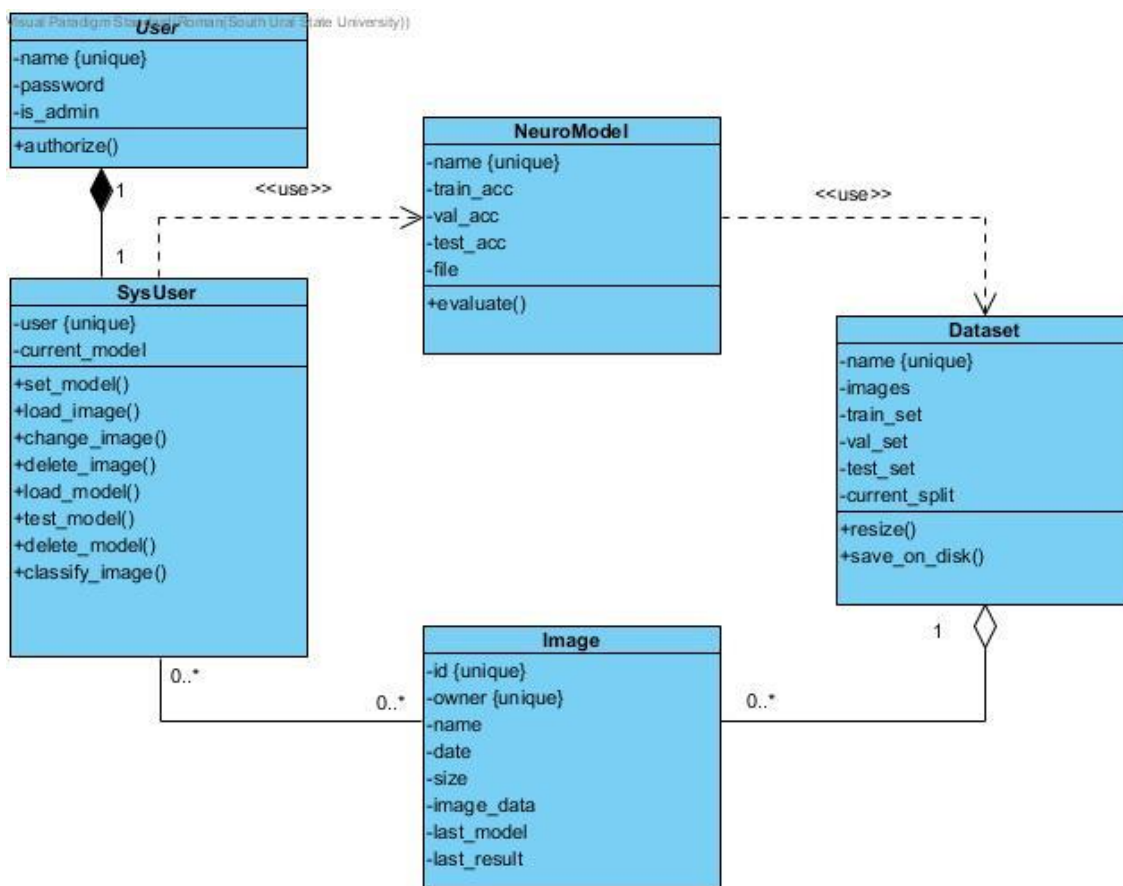


Рисунок 1 - Діаграма класів системи

Основними класами у системі є:

- User, SystemUser, Image, Dataset, NeuroModel – описуються далі.
- Клас User: стандартна модель користувача у django.
- Клас SystemUser: описує користувачів, які працюють із системою.
- Клас Image: описує зображення, що зберігається в системі
- Клас Dataset: визначає набір зображень, на основі яких формуються вибірки для роботи з моделями ШНМ.
- Клас NeuroModel: описує наявні в системі моделі ШНМ.

Для взаємодії із системою було реалізовано 2 інтерфейси: програмний та графічний.

Процес виконання запиту до API наведено на діаграмі діяльності на рисунку 2, а приклад його реального виконання з авторизацією – на рисунку 3.

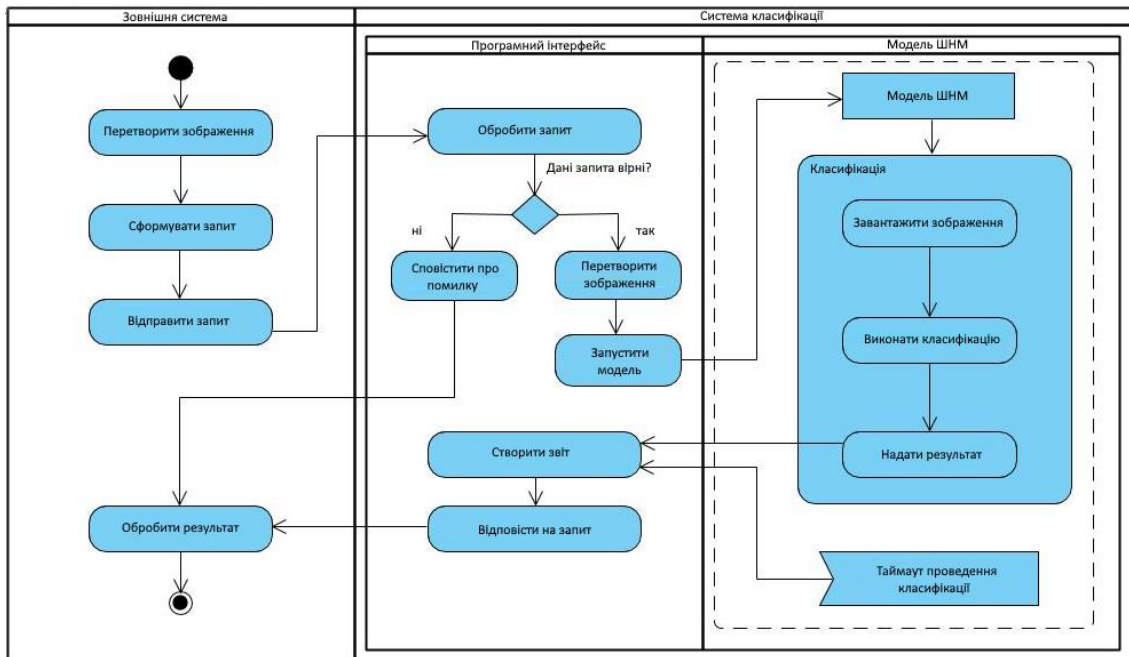


Рисунок 2 - Діаграма діяльності щодо виконання запиту до системи

```

>>> import requests, base64
>>> login, password = "██████", "██████"
>>> auth_string = ("{login}:{password}".format(login=login, password=password)).encode()
>>> auth_key = base64.b64encode(bytes(auth_string)).decode()
>>> headers = {'Authorization': 'Basic %s' % auth_key}
>>> data = requests.get("http://127.0.0.1:8000/api/neuromodel", headers=headers).json()
>>> print (data)
{'name': 'AFDC_BC_AUG_TEST', 'train_acc': 0.88, 'validation_acc': 0.74, 'accuracy': 0.71}
    
```

Рисунок 3 - Приклад виконання запиту до API

Для зручності використання інтерфейсу зовнішніми системами його архітектура спроектована за правилами REST (Representational state transfer.

Базові правила REST визначаються на основних типах HTTP запитів і описуються так:

- тип запиту GET – отримати інформацію;
- тип запиту POST – редагувати інформацію;
- тип запиту PUT – додати інформацію;
- тип запиту DELETE – видалити інформацію.

Таким чином, в рамках спроектованого API було виділено 3 основні URL для виконання запитів до системи:

- для отримання інформації про поточну модель класифікації та вибору іншої моделі;

- для керування зображеннями;
- щодо класифікації.

Взаємодія користувача з цим інтерфейсом представлено на рисунку 4, а скріншот самого інтерфейсу – на рисунку 6 та таблиця 2.

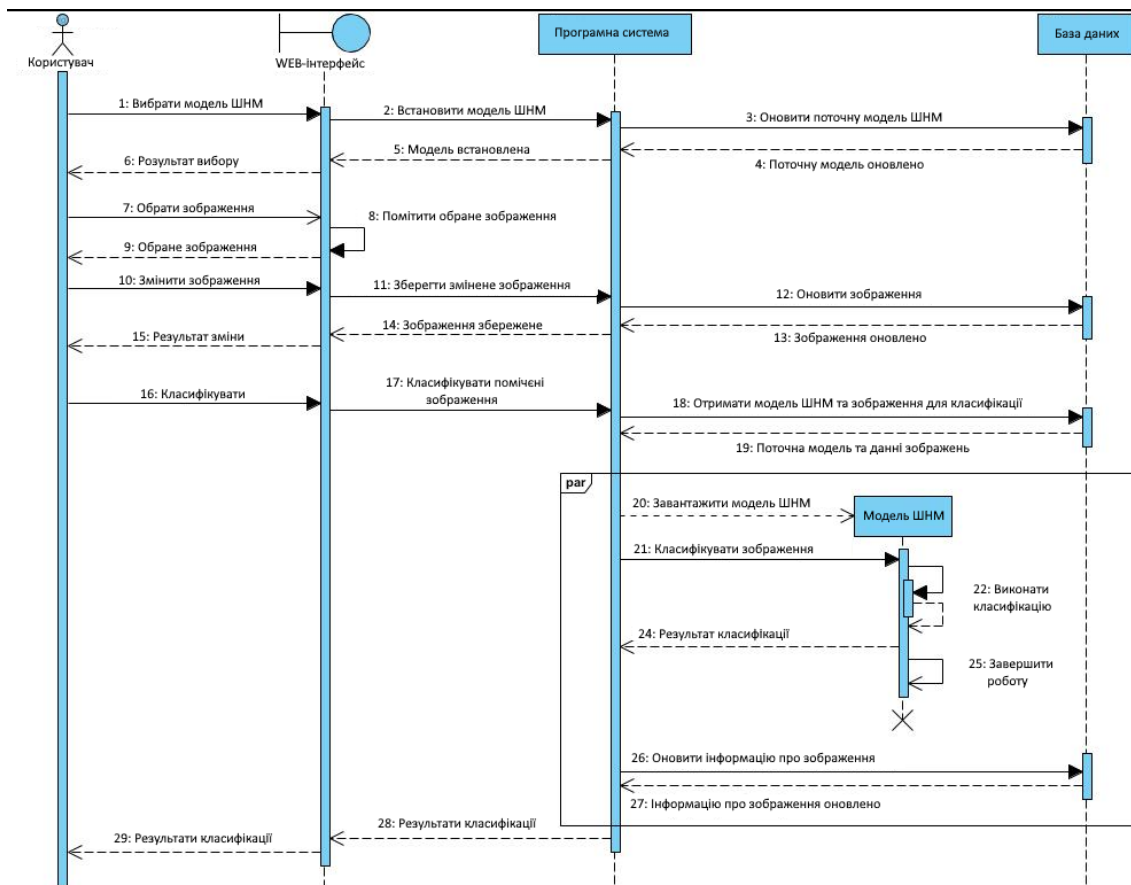


Рисунок 4 - Діаграма послідовності виконання класифікації

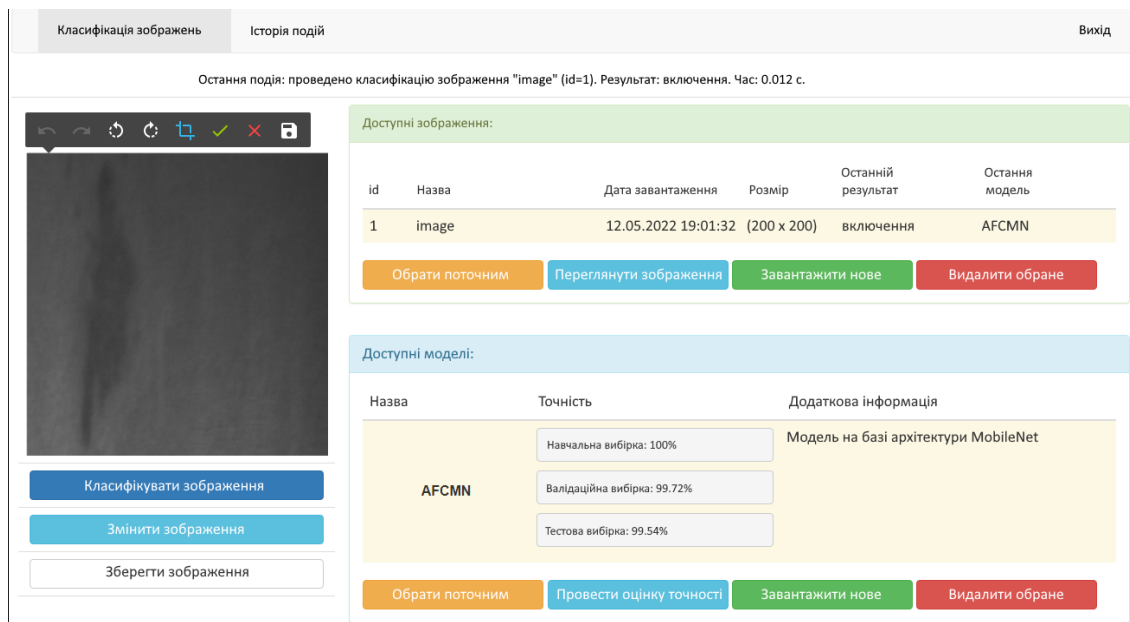


Рисунок 5 - WEB-інтерфейс системи

Таблиця 2

WEB-інтерфейс системи

Компонент	Опис та функціонал
кнопка завантаження зображень	надає можливість вибору та завантаження зображення з локального комп'ютера
список із завантаженими зображеннями	дозволяє вибрати зображення для подальшої зміни або класифікації
список з моделями ШНМ у системі	дозволяє вибрати одну з існуючих в системі моделей ШНМ для процесу класифікації
інтерактивний модуль зміни зображення	дозволяє змінити вибране зображення шляхом повороту або масштабування
кнопка запуску класифікації	дозволяє виконати класифікацію вибраного зображення
текстове поле	відображає результати операцій користувача в системі
кнопка завантаження моделі ШНМ	надає можливість вибору та завантаження навченої моделі ШНМ з локального комп'ютера доступно тільки адміністратору системи примітка: доступно тільки адміністратору
кнопка проведення оцінки точності для моделі ШНМ	дозволяє провести тестування точності класифікації для обраної моделі ШНМ на внутрішньому датасеті системи примітка: доступне тільки адміністратору

**Дослідження нейромережевих технологій
для вирішення задачі класифікації дефектів металопрокату**

Для проведення експериментів та створення нових архітектур було відібрано 3 базові моделі ШНМ: InceptionV3, MobileNet, MobileNetV2.

Модель AFDC_BC. Кількість параметрів моделі склало: 13130694, з яких 13130694 тренуваних та 0 не тренуваних.

InceptionV3 - Ця архітектура була відібрана для проведення досліджень, оскільки основна мета її розробників – ефективність обчислень та кількості параметрів для реальних додатків. Кількість параметрів моделі склало: 22854950, з яких 22820518 тренуваних та 34432 не тренуваних.

MobileNet - Відібрано для проведення досліджень, оскільки вихідна модель дуже компактна і вимагає значно менше обчислювальних ресурсів, чим багато інших нейронних мереж. MobileNet – одна з найпопулярніших мобільних технологій глибокого навчання, яка не тільки мала за розміром та ефективна в обчислювальному відношенні, але й забезпечує високу продуктивність (щодо точності). Кількість параметрів моделі склало: 3756742, з яких 3734854 тренуваних та 21888 не тренуваних.

Модель на базі MobileNetV2 - Кількість параметрів моделі становило: 2916934, з яких 2882822 тренуваних та 34112 не тренуваних.

Слід зазначити той факт, що найменша кількість параметрів з усіх моделей має AFDC_MNV2, а значить, вона є легковажною.

Реалізація. Генерація вихідних даних.

В якості вхідних даних виступає датасет дефектів гарячого металопрокату, що надається Північно-східним університетом США (NEU) спеціально для наукових досліджень, який і використовується як базовий набір даних для виконання даної роботи.

У датасеті представлено 6 різних типів дефектів, кожен із яких є по 300 різних зображень. Таким чином, датасет складається з 1800 зображень. Типи поданих дефектів такі: 1) crazing - волосовина, 2) inclusion – включення; 3) patches – плями; 4) pitted surface – горобина; 5) rolled-in-scale – вкатана окалина; Приклад зображень дефектів з датасета наведено на рисунку 6.




Рисунок 6 - Зображення 6 різних дефектів металопрокату

Приклад зображення, отриманого в ході аугментації наведено на рисунку 7.




Рисунок 7- Приклад зображення, отриманого в ході аугментації

Крім аугментації, необхідно було також розподілити дата сет на навчальну, валідаційну та тестову вибірки. Тому всі отримані зображення були розподілені на зазначені вибірки у наступному відповідної пропорції – 75/15/15 % кожного типу дефектів.

Обчислювальні експерименти.

У процесі проведення експериментів змінювалися різні параметри моделей, зокрема параметри, що впливають аугментацію даних. Крім того, важливим параметром був розмір батча - розмір підмножини об'єктів вибірок, що вибираються для оптимізації моделі в процесі навчання, який також впливає на швидкість навчання: чим більший розмір батча, тим швидше нейронна мережа навчається, але при цьому може втрачатися точність моделі цієї мережі. У цьому роботі застосовувалися розміри: 1, 8, 16 і 32.

Для опису результатів наводяться графіки точності моделей у процесі навчання на тренувальній та валідаційній вибірках, а також функція втрат цих моделей.

Функція втрат – це функція, яка мінімізується у процесі навчання (підгонки) моделі. Вона представляє обрану міру незгоди даних і даних, що «спостерігаються», «передбачуваних» підігнаною функцією. Іншими словами - відмінність отриманого результату від дійсного. Відповідно, що менше значення функції втрат, то краще модель дає результати.

Для наочності, на графіках представлено 2 лінії: дійсна функція (прозора лінія) і згладжена версія цієї функції з коефіцієнтом згладжування (factor) рівним 0.6 (не прозора лінія). Функція згладжування є лінійною функцією, реалізованою в TensorBoard [11]:

$$smoothed(y_i) = \begin{cases} y_i & \text{if } i = 0 \\ y_{i-1} * factor + (1 - factor) * y_i & \text{if } i > 0, i = [0, n). \end{cases} \quad (1)$$

Оскільки рання зупинка процесу навчання не розглядалася, через наявність необхідних обчислювальних ресурсів, всі моделі навчалися протягом 500 епох, основні результати наводяться за 100 епох.

На рисунку 8 наведено графіки процесу навчання: для моделі AFDC_BC графіки зліва та для моделі AFDC_IV3 – справа. Верхній графік показує точність

моделей на навчальній вибірці, середній – функцію втрат та нижній – точність класифікації за валідаційною вибіркою. За графіками видно, що модель на базі InceptionV3 мала значну різницю точно на валідаційній вибірці залежно від епохи навчання та ця точність досягала пороги понад 90%. Якщо говорити про модель на базі простої згорткової мережі, то тут процес навчання йшов гладкіше - точність на вибірці валідації не мала особливих стрибків. Однак, ця модель не зуміла переступити поріг у необхідні 90%.

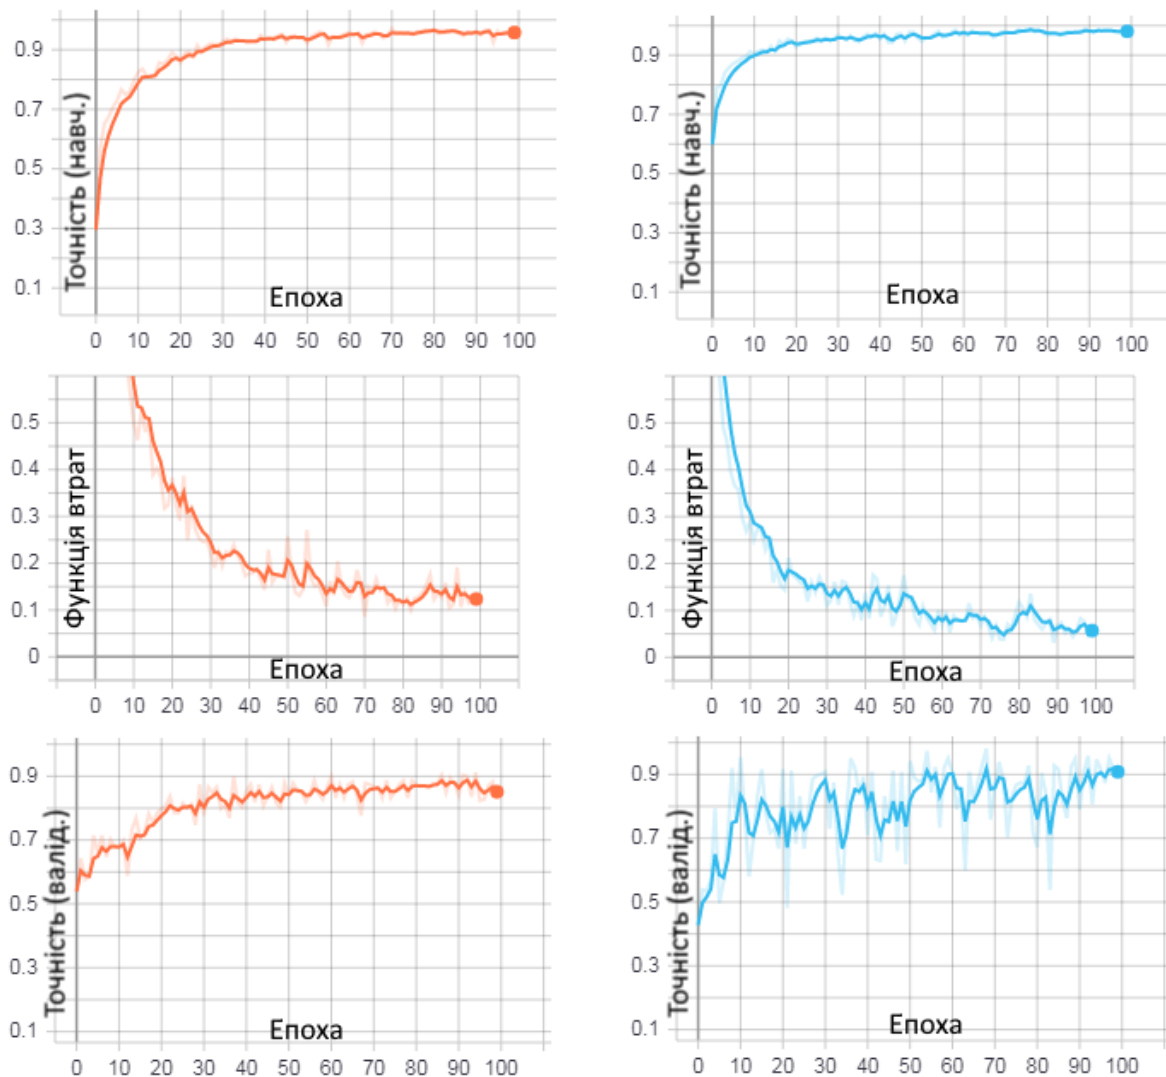


Рисунок 8 - Графіки процесу навчання моделей:
ліворуч – AFDC_BC, праворуч – AFDC_IV3

Слід зазначити, що зміна значень функції втрат цих моделей загалом відповідає оцінці точності на валідаційній вибірці.

На рисунку 9 наводяться графіки, аналогічні описаним раніше, але для моделей AFDC_MN – ліворуч і AFDC_MNV2 – праворуч. За даними графіками можна зробити описані далі висновки.

1. Модель на базі MobileNet мала відмінну точність на валідаційній вибірці на всіх епохах навчання, періодично досягаючи максимуму 100%;

2. Модель на базі MobileNetV2 мала значні коливання в процесі навчання, але все ж таки не раз досягла точності в 99%.

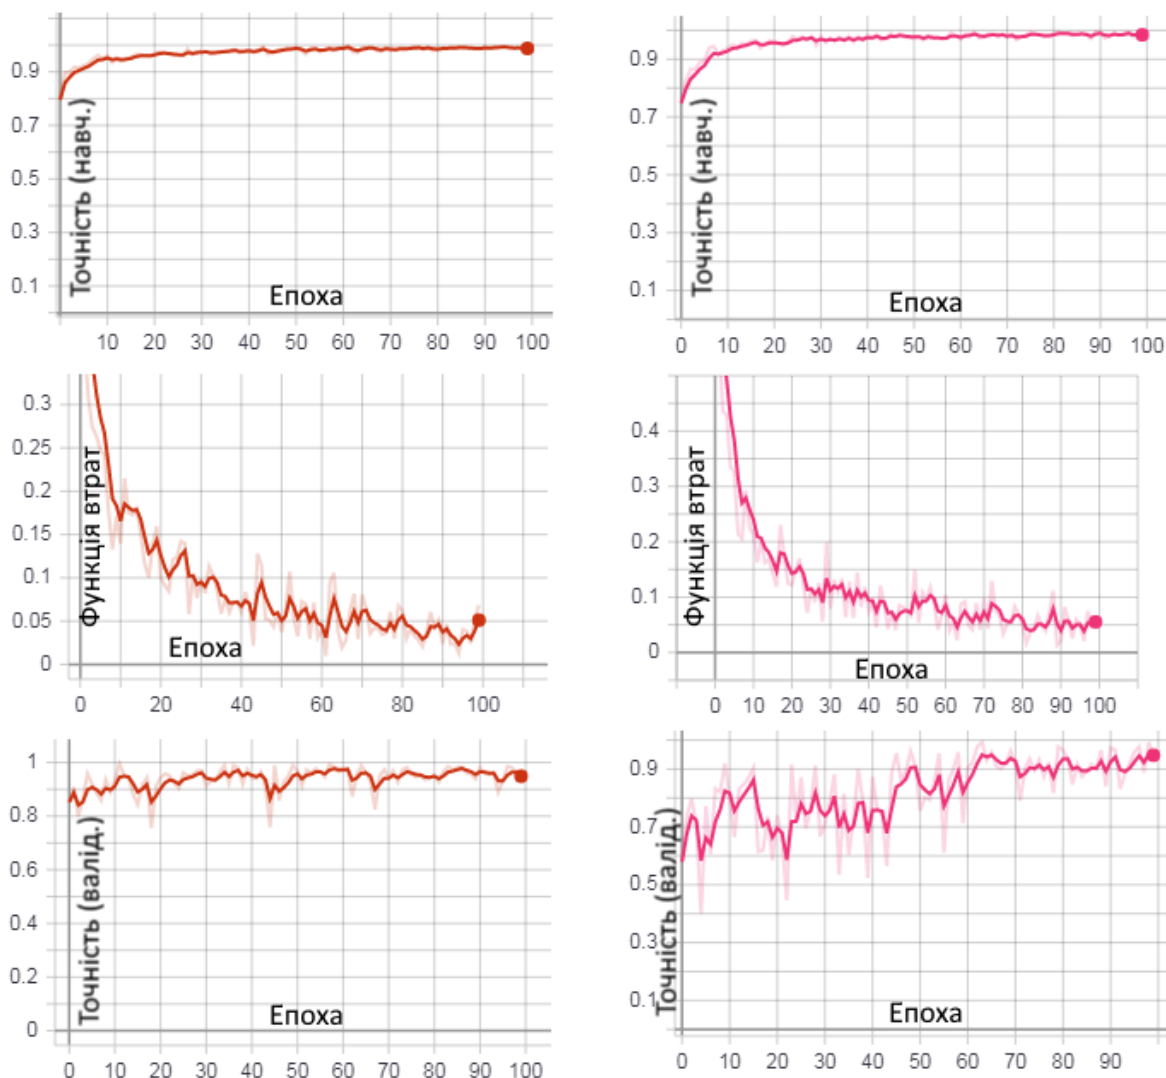


Рисунок 9 - Графіки процесу навчання моделей: ліворуч – AFDC_MN, праворуч – AFDCMN_V2

Таким чином, завдання отримання моделі класифікації дефектів з точністю вище 90% успішно виконано.

Висновки

Мета полягала у розробці програмної системи для класифікації дефектів металопрокату на базі нейромережових технологій, здатну менш ніж за 1 з часу виконувати класифікацію дефекту на зображенні з точністю не менше 90%. Для досягнення мети в рамках даної роботи було виконано такі завдання:

1) виконано дослідження предметної галузі, визначено можливість використання нейронних мереж для вирішення задачі класифікації дефектів металопрокату;

2) побудовано модель нейронної мережі, що підходить для вирішення задачі класифікації видимих дефектів металопрокату;

3) виконано генерацію навчальної, тестової та валідаційної вибірок на основі бази даних дефектів поверхні гарячого металопрокату, наданої Північно-східним університетом (NEU), здійснено аугментацію згенерованих вибірок;

4) спроектована та реалізована система класифікації дефектів;

5) проведено обчислювальні експерименти.

ЛІТЕРАТУРА / REFERENCES

1. Alkapov R.R. Automatic Visible Defect Detection and Classification System Prototype Development for Iron-and-Steel Works. / Alkapov R.R., Konyshev A.A., Vetoshkin N.A., Valkevich N.V., Kostenetskiy P.S. // 2018 Global Smart Industry Conference (GloSIC). Chelyabinsk, November 13-15, 2018, IEEE, 2018. – P. 1-8.
2. Baidorf I. Optimizatsiya protsessa i kachestva korrozionnostoykoy polosy na osnove sistemy kontrolya poverhnostey. / Baidorf I., Anstots T., Eberle A., Ernenpuch L., Holzhauser J. // Chernye Metalli, 2005. – Vol. 3. – P. 45-56.
3. Caleb P., Steuer M. Classification of surface defects on hot rolled steel using adaptive learning methods. // Proceedings of the Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies, August 2000, Brighton, UK. IEEE, 2002. – Vol. 1. – P. 103–108.
4. Guifang W. Design of online surface inspection system of hot rolled strips. / Guifang W., Kwak H., Jang S., Xu K., Xu J. // 2008 IEEE International Conference on Automation and Logistics, 2008. – P. 2291-2295.
5. Lemon S. Avtomaticheskii osmotr poverhnosty polosy dlya obespecheniya sploshnogo kontrolya kachestva v linii. // Chernye Metalli, 2003. – Vol. 4. – P. 49-54.

6. Mazur I. Quality Control system for a hot-rolled metal surface // *Frattura ed Integrità Strutturale*, 2016. – Vol. 10. – No. 37. – P. 287-296.
7. Neogi N., Mohanta D., Dutta P. Review of vision-based steel surface inspection systems. // *EURASIP Journal on Image and Video Processing*, 2014. – Vol. 2014. – No. 1. – P. 1-50.
8. Popat M., Barai S. Defect detection and classification using machine learning classifier. // *Proceeding of the 16th WCNDT 2004 - World Conference on NDT, 2004.* – P. 788-797.
9. Stolzenberg M. Sistemy osmotra poverhnosty listovoy staly: Rezultaty issledovaniy. / Stolzenberg M., Gruber K., Henkenmayer H., Joncourt K. // *Chernye Metalli*, 2002. – Vol. 12. – P. 40-48.
10. Vetoshkin N., Valkevich N., Kostenetskiy P. Razrabotka polzovatelskogo interfeysa dlya sistemy avtomaticheskogo kontrolya kachestva poverhnosty listovoy staly s pokrytiem. // *Parallel Computational Technologies (PCT'2018)*, 2018. – P. 400-402.
11. TensorBoard: Visualizing Learning [Electronic resource]
URL: https://www.tensorflow.org/guide/summaries_and_tensorboard

Received 06.01.2023.

Accepted 08.02.2023.

UDC 004.942:681.3.068

K. Ostrovska, V. Balakin, S. Cherskyi

THE USE OF NEURAL NETWORK TECHNOLOGIES TO SOLVE THE PROBLEM OF CLASSIFICATION OF ROLLED METAL DEFECTS

The main goal of the work is to create a software system that performs the classification of rolled metal surface defects with high accuracy (over 90%) and high speed (no more than 1 second per 1 image) through the use of artificial neural networks. To achieve the goal, it is necessary to perform the following tasks: 1) perform a study of the subject industry, determine the possibility of using neural networks to solve the problem of classifying rolled metal defects; 2) build a neural network model suitable for solving the problem of classifying visible defects in rolled metal products; 3) generate training, test and validation samples based on the database of hot rolled metal surface defects provided by Northeastern University (NEU); perform augmentation of the generated samples; 4) design and implement a defect classification system; 5) conduct testing and computational experiments. As a result of the work, a software system was developed for the classification of rolled metal defects based on neural network technologies, which is capable of classifying a defect in an image with an accuracy of at least 90% in less than 1 s of time.

Keywords: Neural network, software system, classification, defect, rolled metal, augmentation, API, web interface, REST, MobileNet, InceptionV3, Python, Django web/rest framework, JavaScript, Bootstrap, dataset, dataset.

Островська Катерина Юріївна, кандидат технічних наук, доцент, доцент кафедри Інформаційних технологій і систем НІІ Інститут промислових та бізнес технологій, Українського державного університету науки та технологій.

Балакін Валерій Федорович, доктор технічних наук, професор НІІ Інститут промислових та бізнес технологій, Українського державного університету науки та технологій.

Черський Сергій Сергійович, магістр кафедри Інформаційних технологій і систем НІІ Інститут промислових та бізнес технологій, Українського державного університету науки та технологій.

Ostrovska Kateryna, candidate of technical sciences, associate professor, associate professor of the Department of Information Technologies and Systems of the National Institute of Industrial and Business Technologies, Ukrainian State University of Science and Technology.

Balakin Valerii, doctor of technical sciences, professor Systems of the National Institute of Industrial and Business Technologies, Ukrainian State University of Science and Technology.

Cherskyi Serhii, Master of the Department of Information Technologies and Systems of the National Institute of Industrial and Business Technologies, Ukrainian State University of Science and Technology.