

Харківський національний університет імені В. Н. Каразіна

Факультет математики і інформатики
Кафедра прикладної математики

Кваліфікаційна робота

бакалавра

на тему *«Розпізнавання художника за допомогою згорткових нейронних мереж»*

Виконав:

студент групи МП41, 4 курсу
спеціальність 113 – прикладна математика
освітньо-професійна програма «Прикладна математика»

Рябов О.О.

Науковий керівник:

викладач кафедри прикладної математики

Карєва В.В.

Рецензент:

доцент кафедри фізики НТУ «ХП», к. ф.-м.н.

Ольга Водоріз

Харків – 2025 рік

Анотації

Рябов Олег Олексійович. Розпізнавання художника за допомогою згорткових нейронних мереж

У роботі досліджено задачу автоматичної ідентифікації художника за зображенням живописного твору за допомогою згорткових нейронних мереж. Розглянуто застосування моделей VGG16, ResNet50, InceptionV3, EfficientNetB0 та EfficientNetB1 у поєднанні з техніками трансферного навчання, аугментації та тонкого донавчання. Проведено експериментальне порівняння моделей на основі точності класифікації, що показало перевагу EfficientNetB0 в умовах обмеженого набору даних. Отримані результати демонструють ефективність глибокого навчання для задач стилістичної атрибуції творів мистецтва.

Ключові слова: розпізнавання художника, згорткові нейронні мережі, трансферне навчання, атрибуція.

Riabov Oleh Oleksiiovych. Artist Identification Using Convolutional Neural Networks

This work explores the task of automatic artist identification based on images of paintings using convolutional neural networks. The study evaluates the performance of several architectures – VGG16, ResNet50, InceptionV3, EfficientNetB0, and EfficientNetB1 – combined with transfer learning, data augmentation, and fine-tuning techniques. An experimental comparison of the models based on classification accuracy reveals that EfficientNetB0 performs best under limited data conditions. The results demonstrate the effectiveness of deep learning approaches for

the stylistic attribution of artworks.

Keywords: artist identification, convolutional neural networks, transfer learning, attribution.

Зміст

Вступ	6
1. Теоретичні основи комп'ютерного зору та згорткових нейронних мереж	8
1.1. Основи глибокого навчання	8
1.2. Принцип роботи згорткових нейронних мереж	8
1.3. Типова архітектура CNN	9
1.4. Переваги та обмеження CNN у задачах комп'ютерного зору . .	10
1.5. Застосування CNN у класифікації зображень мистецтва	11
2. Огляд архітектур згорткових нейронних мереж	12
2.1. Архітектура VGG16	12
2.2. Архітектура ResNet50	13
2.3. Архітектура InceptionV3	13
2.4. Архітектури EfficientNetB0 та EfficientNetB1	15
2.5. Порівняння архітектур	16
3. Обробка даних та покращення якості моделей	17
3.1. Аугментація даних	17
3.2. Трансферне навчання	18
3.3. Тонке донавчання (Fine-Tuning)	19
3.4. Синергія методів для підвищення якості класифікації	20
4. Практична реалізація системи ідентифікації художника	21
4.1. Опис датасету та параметри навчання	21

	5
4.2. Побудова моделей на основі попередньо навчених CNN	22
4.3. Аугментація та попередня обробка даних	22
4.4. Навчання та оцінювання моделей	23
4.5. Підхід до порівняння моделей	23
4.6. Результати та порівняння моделей	24
4.7. Аналіз динаміки навчання	24
Висновки	26
Список використаних джерел	28

Вступ

У сучасному світі глибоке навчання стало невіддільною складовою розвитку штучного інтелекту, зокрема в галузі комп'ютерного зору. Одним із найперспективніших напрямів є автоматичне розпізнавання та класифікація зображень, що знаходить широке застосування в медицині, промисловості, безпеці, а також у сфері мистецтва. Ідентифікація художника за його творами є складною задачею, яка потребує врахування візуального стилю, кольористики, композиційних особливостей, техніки написання та інших неформалізованих ознак. Традиційні алгоритмічні методи опрацювання зображень виявляються малоефективними в умовах такої складності. Саме тому використання згорткових нейронних мереж (CNN), здатних самостійно навчатися витягувати релевантні ознаки із зображень, є доцільним та актуальним підходом до розв'язання поставленого завдання.

Метою цієї роботи є дослідження можливостей згорткових нейронних мереж для класифікації живопису з метою визначення авторства художніх творів. Особливу увагу зосереджено на аналізі ефективності різних архітектур CNN, таких як VGG16, ResNet50, InceptionV3, EfficientNetB0 та EfficientNetB1. У ході дослідження було також застосовано техніки попередньої обробки даних, зокрема аугментацію, а також методи трансферного навчання і fine-tuning для підвищення якості класифікації при обмеженій кількості доступних зображень.

Завдання ідентифікації художника на основі цифрових зображень картин є багатогранною проблемою, оскільки вимагає від моделі розпізнавання нюансів індивідуального стилю, який може змінюватися з часом або в залежності від жанру. Крім того, в роботі враховано питання узагальнення моделей на но-

ві, раніше не бачені твори, що є ключовим аспектом при створенні практично корисних систем класифікації.

Практична частина дослідження базується на експериментах із використанням відомих архітектур глибоких нейронних мереж, їх порівнянні за точністю, швидкістю навчання, обсягом параметрів та здатністю узагальнювати. Усі моделі навчалися на одному датасеті картин з використанням єдиного пайплайну обробки даних для забезпечення об'єктивності результатів. Отримані результати можуть мати застосування як у цифровій атрибуції мистецтва, так і в створенні рекомендаційних систем, архівуванні або автоматичному описі творів.

Таким чином, ця робота поєднує теоретичне обґрунтування доцільності застосування CNN у задачах мистецтвознавчої класифікації з практичним дослідженням, що має на меті визначити найбільш ефективні архітектури для задачі ідентифікації художника.

Розділ 1

Теоретичні основи комп'ютерного зору та згорткових нейронних мереж

1.1. Основи глибокого навчання

Глибоке навчання є підгалуззю машинного навчання, що використовує штучні нейронні мережі з великою кількістю шарів для обробки ієрархічних структур даних. Завдяки здатності автоматично витягувати ознаки з необроблених даних, глибокі моделі значно перевершують традиційні методи у задачах класифікації, детекції та сегментації зображень [1].

Основною одиницею побудови є штучний нейрон, який виконує зважену суму вхідних сигналів та передає результат через функцію активації. Формально, вихід нейрона y обчислюється за формулою:

$$y = \phi \left(\sum_{i=1}^n w_i x_i + b \right),$$

де x_i – вхідні значення, w_i – вагові коефіцієнти, b – зсув, а ϕ – нелінійна функція активації (наприклад, ReLU або сигмоїда).

1.2. Принцип роботи згорткових нейронних мереж

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) спеціалізовані для аналізу даних у вигляді сітки, таких як зображення. Основна ідея полягає у використанні операції згортки, яка дозволяє виявляти локальні




Рис. 1.1: Схема згортки

патерни (лінії, кути, текстури) незалежно від їхнього розташування на зображенні.

Згортка між зображенням I та ядром (фільтром) K визначається як:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n) \cdot K(m, n),$$

де S – вихідне зображення (feature map).

Завдяки використанню спільних ваг у фільтрах, згорткові шари значно зменшують кількість параметрів у порівнянні з повнозв'язними шарами. Зазвичай згортковий шар супроводжується операцією підвибірки (pooling), яка зменшує розмірність карти ознак і допомагає моделі узагальнювати.

1.3. Типова архітектура CNN

Типова архітектура згорткової нейронної мережі містить послідовність згорткових шарів, операцій pooling, функцій активації та, зрештою, повнозв'язні (fully connected) шари. Найчастіше використовуваною функцією




Рис. 1.2: Схема архітектури CNN

активації є ReLU (Rectified Linear Unit), яка визначається як:

$$\text{ReLU}(x) = \max(0, x).$$

В останніх шарах мережі зазвичай використовується softmax-функція для багатокласової класифікації:

$$\text{softmax}(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}},$$

де K – кількість класів.

1.4. Переваги та обмеження CNN у задачах комп'ютерного зору

Основними перевагами згорткових нейронних мереж є здатність автоматично витягувати ознаки без ручного втручання, інваріантність до трансляцій та масштабів об'єктів на зображенні, а також хороша узагальнююча здатність при достатньому обсязі даних.

Втім, CNN мають і низку обмежень. Зокрема, вони є обчислювально дорогими при великій кількості параметрів, чутливими до перекривання класів або стилістичної подібності у вхідних даних. Крім того, їхня ефективність знижу-

ється при перенавченні, що вимагає застосування регуляризації, аугментації та трансферного навчання [2].

1.5. Застосування CNN у класифікації зображень мистецтва

Застосування згорткових мереж до аналізу картин художників базується на припущенні, що стиль автора виявляється у візуальних патернах, які можуть бути розпізнані автоматичною системою. CNN здатні вивчати стильові елементи, характерні для конкретного автора – такі як мазки пензля, кольорові палітри, композиційні особливості. Це відкриває можливість автоматизованої атрибуції творів мистецтва, що є актуальним завданням у цифровому мистецтвознавстві [3].

Однак така задача є нетривіальною через високу міжкласову подібність і внутрішньокласову варіативність, особливо коли автор працював у різних жанрах або техніках. У зв'язку з цим доцільним є використання попередньо навчених моделей та адаптація їх під специфіку мистецьких зображень.

Розділ 2

Огляд архітектур згорткових нейронних мереж

У сучасному комп'ютерному зорі велика кількість завдань розв'язується за допомогою заздалегідь навчених глибоких згорткових нейронних мереж. Вибір архітектури суттєво впливає на якість класифікації, швидкість навчання, обсяг необхідних обчислювальних ресурсів та здатність моделі узагальнювати. У цьому розділі розглянуто п'ять популярних архітектур: VGG16, ResNet50, InceptionV3, EfficientNetB0 та EfficientNetB1. Кожна з них має власні конструктивні особливості та переваги.

2.1. Архітектура VGG16

Мережа VGG16, запропонована дослідниками з Оксфордського університету [2], є класичним прикладом глибокої CNN з послідовним застосуванням згорткових шарів. Архітектура складається з 13 згорткових шарів і 3 повнозв'язних шарів. Всі згортки використовують ядра розміру 3×3 , що забезпечує локальне захоплення контексту зображення.

Ключова ідея VGG – простота: моделі з однаковими фільтрами впродовж кількох рівнів, а також регулярне використання MaxPooling після кожного блоку.

Перевагами VGG16 є інтуїтивна структура та стабільність навчання, проте значним недоліком є велика кількість параметрів (понад 138 мільйонів), що призводить до високих вимог до пам'яті.




Рис. 2.1: Схема архітектури VGG16

2.2. Архітектура ResNet50

Модель ResNet [4] представила концепцію залишкових з'єднань (skip connections), які дозволяють мережі ефективно навчатися навіть на великій глибині. Залишковий блок має вигляд:

$$y = \mathcal{F}(x, \{W_i\}) + x,$$

де $\mathcal{F}$ – функція, яка описує обчислення в середині шару, а x – вхід до блоку. Таким чином, мережа не просто вивчає нові представлення, а вчиться наближення до залишку (residual), що суттєво покращує зворотне поширення похибки (backpropagation).

ResNet50 має 50 шарів і вважається однією з найбільш збалансованих моделей щодо точності та ефективності.

2.3. Архітектура InceptionV3

Модель InceptionV3 [5] базується на ідеї обчислення згорток з різними розмірами фільтрів паралельно. Це дозволяє мережі одночасно вивчати ознаки різного масштабу. Структурно модель складається з так званих Inception-




Рис. 2.2: Залишковий блок ResNet




Рис. 2.3: Архітектура Resnet50




Рис. 2.4: Архітектура InceptionV3

блоків, які об'єднують згортки 1×1 , 3×3 та 5×5 , а також pooling.

З метою зменшення обчислювальної складності застосовуються згортки 1×1 для попереднього зменшення кількості каналів (bottleneck layers).

InceptionV3 демонструє дуже високу точність при відносно помірних обчислювальних витратах, що робить її ефективною в умовах обмежених ресурсів.

2.4. Архітектури EfficientNetB0 та EfficientNetB1

EfficientNet [6] є сімейством моделей, які масштабуються збалансовано за трьома параметрами: глибина (d), ширина (w), і роздільна здатність зображення (r). Основна ідея полягає у використанні координаційного коефіцієнта ϕ :

$$\text{depth} = \alpha^\phi, \quad \text{width} = \beta^\phi, \quad \text{resolution} = \gamma^\phi,$$

де α , β , γ – коефіцієнти масштабування, які підбираються експериментально.

EfficientNetB0 – базова модель, а EfficientNetB1 є масштабованою версією з більшими ресурсами. Незважаючи на компактність, ці моделі досягають надзвичайно високої точності при меншій кількості параметрів і FLOPs у порівнянні з іншими глибокими CNN.




Рис. 2.5: Архітектура EfficientNet

2.5. Порівняння архітектур

Для візуального порівняння характеристик моделей наведено узагальнену таблицю, що ілюструє кількість параметрів, обчислювальну складність і типові показники точності (на ImageNet або аналогічному наборі).

Модель	Кількість параметрів	FLOPs (млрд)	Топ-1 точність
VGG16	138M	15.5	~71.5%
ResNet50	25.6M	3.8	~76.0%
InceptionV3	23.8M	5.7	~77.9%
EfficientNetB0	5.3M	0.39	~77.1%
EfficientNetB1	7.8M	0.7	~79.1%

Табл. 2.1: Порівняння згорткових архітектур

Як видно з таблиці, моделі EfficientNet забезпечують найкраще співвідношення точності до обчислювальних витрат. Це робить їх особливо придатними для задач, де ресурси є обмеженими, або при потребі у швидкій інференції.

Розділ 3

Обробка даних та покращення якості моделей

Глибокі згорткові нейронні мережі є потужним інструментом для класифікації зображень, проте ефективність їхнього застосування у реальних умовах значною мірою залежить від обсягу та якості даних, а також від використання сучасних методів підвищення продуктивності. У цьому розділі розглянуто теоретичні засади трьох ключових підходів: аугментації даних, трансферного навчання та тонкого донавчання (fine-tuning).

3.1. Аугментація даних

Аугментація (data augmentation) – це метод розширення навчальної вибірки шляхом генерації нових прикладів на основі наявних. Основна мета аугментації – підвищення узагальнюючої здатності моделі шляхом забезпечення більшої варіативності вхідних даних, не змінюючи їхню смислову сутність.

Найчастіше використовуються такі типи трансформацій:

- геометричні (обертання, масштабування, дзеркальне відображення);
- колористичні (зміна яскравості, контрасту, насиченості);
- просторові (зсув, обрізка, шум).

З математичної точки зору, аугментація створює нову вибірку X^* з оригінальної X за допомогою функцій T_i , де T_i – набір стохастичних або детермі-



Рис. 3.1: Приклад аугментації одного зображенн

нованих перетворень:

$$X^* = \{T_i(x) \mid x \in X, i = 1 \dots N\}.$$

Ефективність аугментації підтверджена численними дослідженнями, зокрема для задач із недостатньою кількістю розмічених даних [7]. Застосування аугментації дозволяє не лише знизити ризик перенавчання, але й зробити модель стійкішою до випадкових варіацій у реальних даних.

3.2. Трансферне навчання

Трансферне навчання (transfer learning) – це підхід, при якому знання, набуті моделлю в одній задачі, використовуються для розв’язання іншої, але пов’язаної задачі. У контексті комп’ютерного зору це зазвичай означає використання нейронної мережі, попередньо навченої на великому датасеті, наприклад ImageNet, для обробки нових зображень, що походять з іншої області.

Переваги трансферного навчання:

- Зменшення часу навчання, оскільки більшість параметрів вже налаштовані.

- Покращення точності при обмеженому обсязі нових даних.
- Можливість використовувати складні архітектури без потреби у значних обчислювальних ресурсах.

Формально, модель f_θ з параметрами θ спочатку навчається на задачі T_{source} , після чого використовується в задачі T_{target} з можливим адаптуванням параметрів:

$$f_{\theta^*}(x) \longrightarrow f_{\theta'}(x), \quad \text{де } \theta' = \text{адаптовані параметри.}$$

Цей підхід особливо корисний у задачах, де структура вхідних даних подібна, але кінцеві цілі відрізняються – наприклад, при переході від класифікації побутових об’єктів до класифікації картин художників.

3.3. Тонке донавчання (Fine-Tuning)

Тонке донавчання є розширенням і конкретизацією трансферного навчання. Його суть полягає в поступовому оновленні частини або всіх параметрів попередньо навченої моделі для кращої адаптації до нової задачі. Найчастіше fine-tuning застосовується після того, як нові класифікаційні шари вже навчено, і модель демонструє базовий рівень точності.

Основний виклик при застосуванні fine-tuning – уникнення перенавчання. Тому, як правило, навчаються лише верхні шари мережі, які відповідають за високорівневі ознаки. Базові шари, що виявляють прості патерни, як правило, залишаються замороженими.

Рекомендовано поєднувати fine-tuning зі зменшеною швидкістю навчання (learning rate), що дозволяє уникнути руйнування вже навченої структури ознак:

$$\eta_{fine_tune} \ll \eta_{initial}$$

Також важливо відслідковувати метрики продуктивності на валідаційному наборі для запобігання деградації результатів при надмірному донавчанні.

3.4. Синергія методів для підвищення якості класифікації

У реальних задачах, особливо у випадках, коли доступні лише обмежені датасети, поєднання аугментації, трансферного навчання та тонкого донавчання дозволяє досягти значного покращення результатів. Аугментація збільшує різноманітність даних, трансферне навчання дає сильну стартову точку, а fine-tuning адаптує модель до специфіки предметної області.

Ці три стратегії створюють комплексний підхід, який дозволяє ефективно вирішувати задачі класифікації навіть у випадках, коли повноцінне навчання "з нуля" було б надто ресурсомістким або неефективним.

Розділ 4

Практична реалізація системи ідентифікації художника

У цьому розділі описано реалізацію та налаштування системи глибокого навчання для задачі класифікації художників на основі їхніх живописних творів. Робота охоплює процес підготовки даних, вибору моделей, налаштування гіперпараметрів та застосування методів покращення продуктивності, таких як аугментація та тонке донавчання (fine-tuning). Усі експерименти були виконані у середовищі Kaggle Notebooks з використанням графічного прискорювача NVIDIA T4 (2 шт.).

4.1. Опис датасету та параметри навчання

Для експериментів використано відкритий датасет “Best Artworks of All Time”, що містить зображення живописних робіт понад 50 художників. З метою забезпечення статистичної стабільності та балансованості класів було обрано лише ті категорії, які містили щонайменше 200 зображень. У підсумку навчання здійснювалось на підмножині, що охоплює понад 20 000 зображень, розподілених між 10+ художниками.

Зображення були автоматично масштабовані до фіксованого розміру — 224×224 пікселів. Дані були поділені на навчальний та валідаційний набори у співвідношенні 80:20 з фіксацією генератора для забезпечення відтворюваності. Також було збережено пропорційне представлення кожного класу.

4.2. Побудова моделей на основі попередньо навчених CNN

Для реалізації класифікатора було обрано п'ять архітектур глибоких згорткових нейронних мереж: VGG16, ResNet50, InceptionV3, EfficientNetB0 та EfficientNetB1. Усі моделі були попередньо навчені на ImageNet і використовувались у режимі трансферного навчання.

Базова частина кожної моделі (feature extractor) була розширена класифікаційним шаром, адаптованим до кількості класів. На першому етапі навчався лише цей шар при замороженій основі. Потім здійснювався етап тонкого донавчання з розморожуванням старших згорткових шарів, що дало змогу краще адаптувати модель до художньої стилістики.

4.3. Аугментація та попередня обробка даних

Для покращення здатності моделі до узагальнення при обмеженому обсязі даних застосовано просту, але ефективну аугментацію зображень. Використано наступні трансформації:

- горизонтальне віддзеркалення (`RandomFlip("horizontal")`);
- вертикальне віддзеркалення (`RandomFlip("vertical")`).

Ці методи не змінюють семантику зображень, але збільшують варіативність вхідних даних.

Окрім цього, кожна архітектура використовувала відповідну функцію попередньої обробки (наприклад, `resnet50.preprocess_input` чи `efficientnet.preprocess_input`), що дозволяло подавати дані у форматі, очікуваному конкретною моделлю.

4.4. Навчання та оцінювання моделей

Навчання здійснювалося у два етапи: початкове навчання класифікатора та подальше тонке донавчання з адаптацією базових шарів. В якості оптимізатора використовувався Adam із початковим кроком навчання $1 \cdot 10^{-3}$ (або $1 \cdot 10^{-4}$ у фазі fine-tuning). Для контролю перенавчання застосовувались:

- EarlyStopping за валідаційною точністю;
- динамічне зменшення learning rate;
- збереження найкращої моделі.

4.5. Підхід до порівняння моделей

Усі моделі тренувались за єдиною методологією: однаковий розмір вхідного зображення (за винятком архітектурних обмежень), кількість епох, параметри генерації вибірок та метрики. Єдиною варіативністю були наявність/відсутність аугментації та fine-tuning, що дозволило об'єктивно оцінити їхній вплив.

4.6. Результати та порівняння моделей

Після завершення експериментів отримано такі результати (табл. 4.1):

Модель	Точність (val_acc)	Втрати (val_loss)
EfficientNetB0 (fine-tune + aug)	0.899	0.343
EfficientNetB1 (fine-tune + aug)	0.894	0.342
ResNet50 (fine-tune + aug)	0.885	0.443
ResNet50 (fine-tune only)	0.867	0.522
ResNet50 (aug only)	0.840	0.597
ResNet50 (без fine-tune, без aug)	0.834	0.559
InceptionV3 (fine-tune + aug)	0.834	0.602
VGG16 (fine-tune + aug)	0.830	0.584

Табл. 4.1: Порівняння моделей за точністю та функцією втрат

Найкращу точність (89.9%) показала EfficientNetB0 з активованим тонким донавчанням і аугментацією. Це підтверджує ефективність цієї архітектури у поєднанні з адаптаційними техніками.

4.7. Аналіз динаміки навчання

На графіку (рис. 4.1) представлена динаміка навчання моделі EfficientNetB0.




Рис. 4.1: Графік навчання EfficientNetB0: точність і функція втрат на train/val наборах

Помітно стабільне зростання точності та зменшення втрат без ознак перенавчання, що свідчить про вдало підбрану архітектуру, регуляризацію та налаштування навчання.

Отримані результати підтверджують, що навіть за умов обмеженого датасету можливо досягти високої точності класифікації авторства за допомогою сучасних архітектур і відповідної технічної стратегії.

Висновки

У даній роботі було досліджено можливість застосування згорткових нейронних мереж для автоматичної ідентифікації художника за його живописними творами. Розв’язання цієї задачі є складним через значну варіативність художніх стилів, технік виконання та високий рівень міжкласової подібності між творами різних авторів. Проте згорткові моделі завдяки своїй здатності до автоматичного витягання ознак із візуальних даних продемонстрували високу ефективність у цьому контексті.

Теоретична частина роботи охопила основи побудови згорткових нейронних мереж, їхні ключові компоненти, а також порівняння поширених архітектур – VGG16, ResNet50, InceptionV3, EfficientNetB0 та EfficientNetB1. Окрема увага була приділена теоретичним аспектам аугментації даних, трансферного навчання та тонкого донавчання, які дозволяють суттєво покращити результати моделей у випадках обмеженого обсягу навчальних даних.

У практичній частині було реалізовано класифікатор, заснований на згорткових мережах, та проведено серію експериментів із використанням вищезгаданих архітектур. Порівняння продуктивності моделей продемонструвало, що найвищу точність – 89.9% на валідаційному наборі – показала модель EfficientNetB0 з активованими аугментацією та fine-tuning. Інші моделі також дали конкурентні результати, але поступилися за точністю або ефективністю використання обчислювальних ресурсів.

У підсумку можна зробити висновок, що застосування попередньо навчених згорткових мереж у поєднанні з адаптаційними техніками є перспективним підходом до класифікації творів мистецтва за авторством. Найкращі результати досягаються при поєднанні кількох стратегій: аугментації даних,

часткового донавчання моделі та коректного налаштування гіперпараметрів. Отримані результати можуть бути використані в подальших дослідженнях у сфері цифрової гуманітаристики, зокрема для автоматизованої атрибуції творів, візуального аналізу мистецької спадщини або побудови систем підтримки прийняття рішень у музеях та галереях.

Подальші дослідження можуть бути спрямовані на використання гібридних або ансамблевих методів, інтеграцію інформації про композицію та кольорову палітру, а також застосування підходів пояснюваного штучного інтелекту для кращого розуміння того, на які візуальні елементи орієнтується модель при прийнятті рішень.

Список використаних джерел

- [1] Goodfellow I., Bengio Y., Courville A. Deep Learning. MIT Press, 2016.
- [2] Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556, 2014.
- [3] Elgammal A., Liu B., Elhoseiny M., Mazzone M. CAN: Creative Adversarial Networks, Generating Art by Learning About Styles and Deviating from Style Norms. IJCAI, 2017.
- [4] He K., Zhang X., Ren S., Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, 2016.
- [5] Szegedy C., Vanhoucke V., Ioffe S., Shlens J., Wojna Z. Rethinking the inception architecture for computer vision. *Proceedings of the IEEE conference on computer vision and pattern recognition (CVPR)*, 2016.
- [6] Tan M., Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks. *Proceedings of the 36th International Conference on Machine Learning (ICML)*, 2019.
- [7] Shorten C., Khoshgoftaar T.M. A survey on image data augmentation for deep learning. *Journal of Big Data*, 6, 60 (2019).