

УДК 7.025'174

DOI <https://doi.org/10.32782/uad.2025.2.3>**Калашнікова Ольга Леонідівна,**

доктор філологічних наук, професор,

завідувачка кафедри експертизи культурних цінностей та дизайну

Університету митної справи та фінансів

ORCID ID: 0000-0003-3584-1427

Scopus ID: 58507761500

vassiliska@ua.fm

Прокопович-Ткаченко Дмитро Ігорович,

кандидат технічних наук, доцент,

завідувач кафедри кібербезпеки та інформаційних технологій

Університету митної справи та фінансів

ORCID ID: 0000-0002-6590-3898

omega2417@gmail.com

ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖ ДЛЯ АТРИБУЦІЇ КУЛЬТУРНИХ ЦІННОСТЕЙ: МЕТОДОЛОГІЯ, РЕЗУЛЬТАТИ ТА ПЕРСПЕКТИВИ

Мета статті: позначити можливості та перспективи використання нейронних мереж, зокрема глибоких моделей, для атрибуції культурних цінностей і творів мистецтва. Робота зосереджена на проблемі використання нейромереж для розпізнавання стилю, школи, періоду та авторства художніх творів, а також для розрізнення оригіналів і підробок. Нейронні мережі здатні виявляти малопомітні візуальні патерни та кореляції між складовими зображення, що дає змогу суттєво підвищити точність атрибуції порівняно з традиційними методами. Розглянуто сучасні архітектури, такі як згорткові нейронні мережі та трансформерні підходи (Vision Transformers, CLIP), які доповнюють дослідженням контекстну складову аналізу. Окремо висвітлено питання формування та збагачення баз даних оцифрованих зображень, оскільки якість і репрезентативність навчальних вибірок безпосередньо впливають на результати моделювання. У статті розглянуто проблему стилізації, адже впливи митців один на одного та культурні інтерференції можуть ускладнювати розпізнавання стилістики. Позначено етичні аспекти та наслідки неправильних атрибуцій, які можуть істотно впливати на мистецький ринок та історико-культурні дослідження. Представлено результати експериментальних оцінок точності атрибуції та запропоновано рекомендації щодо застосування напрацювань у музейній справі й наукових дослідженнях. Зроблено висновок, що попри високий потенціал нейронних мереж, участь експертів-мистецтвознавців в процесі атрибуції культурних цінностей залишається надзвичайно важливою. Отримані результати можуть слугувати підґрунтям для подальшого розвитку методів комп'ютерного аналізу в культурології та мистецтвознавстві, а також стимулювати появу нових міждисциплінарних досліджень у сфері цифрової гуманітаристики.

Ключові слова: культурні цінності, атрибуція, нейронні мережі, цифрова гуманітаристика, культурологія, мистецтвознавство.

Kalashnikova Olha, Prokopovych-Tkachenko Dmytro. APPLICATION OF NEURAL NETWORKS FOR ATTRIBUTION OF CULTURAL VALUES: METHODOLOGY, RESULTS AND PROSPECTS

The aim of the article is to identify the possibilities and prospects of using neural networks, in particular deep models, for the attribution of cultural values and works of art. The work focuses on the problem of using neural networks to recognize the style, school, period, and authorship of works of art, as well as to distinguish between originals from fakes. Neural networks are able to detect subtle visual patterns and correlations between image components, which makes it possible to significantly increase the accuracy of attribution compared to traditional methods. Modern architectures, such as convolutional neural networks and transformer approaches (Vision Transformers, CLIP), which complement the contextual component of the analysis with research. The issue of forming and enriching databases of digitized images is separately highlighted, since the quality and representativeness of training samples directly affect the results of modeling. The article considers the problem of stylization, since influences between artists and cultural interference can complicate the recognition of stylistics.

The ethical aspects and consequences of incorrect attributions, which can significantly affect the art market and historical and cultural research, are indicated. The results of experimental assessments of attribution accuracy are presented and recommendations are offered for the application of developments in museum work and scientific research. It is concluded that despite the high potential of neural networks, the participation of art experts in the process of attribution of cultural values remains extremely important. The results obtained can serve as a basis for the further development of computer analysis methods in cultural studies and art history, as well as stimulate the emergence of new interdisciplinary research in the field of digital humanities.

Key words: cultural values, attribution, neural networks, digital humanities, cultural studies, art history.

Вступ. За останні десятиліття розвиток обчислювальних потужностей і методів штучного інтелекту істотно розширив можливості дослідження та аналізу культурних цінностей, зокрема, творів образотворчого мистецтва, археологічних знахідок, історичних документів і т. ін. Використання нейронних мереж дозволяє автоматизувати складні процедури атрибуції, раніше доступні лише професійним мистецтвознавцям та історикам культури. Атрибуція культурних пам'яток включає визначення автора, періоду, школи чи художнього напрямку, техніки виконання, автентичності, що має виняткове значення як у музейній, так і в ринковій сфері.

У контексті мистецтвознавства атрибуція завжди була складним завданням, оскільки вона потребує врахування численних факторів: стилевих особливостей авторів різних періодів; еволюцію технік та методик виготовлення творів живопису чи скульптури; взаємодію митців, шкіл та культур; історичний, політичний та релігійний контексти формування художніх традицій; стан збереженості матеріалів і можливі реставраційні втручання, наявність провенансу.

Традиційний підхід, заснований переважно на кваліфікованих візуальних спостереженнях експертів, ретельному аналізі каталогів та архівних записів, часто потребує додаткових експертиз (хімічний аналіз пігментів, радіовуглецеве датування, історичний пошук тощо) і містить суб'єктивний чинник. Сучасні ж методи глибокого навчання дають змогу опрацювати великі масиви даних про зображення, текстові матеріали та метадані, систематизувавши їх на високому рівні деталізації [1; 2].

Актуальність цієї теми обумовлена не лише загальним трендом цифровізації гуманітарної сфери, а й можливістю прискорити процес наукової атрибуції артефактів; підвищити

достовірність і точність оцінювання за рахунок кількісних підходів; уніфікувати методи аналізу та формування баз знань про пам'ятки мистецтва; знайти нові закономірності або взаємозв'язки в межах великих масивів культурно-історичних даних.

Практична й наукова цінність досліджень у цій галузі полягає, з одного боку, у збереженні світової культурної спадщини, а з іншого – у якісному формуванні світового ринку мистецтва, де вартість окремих творів може сягати мільйонів доларів, адже навіть невеликі неточності в атрибуції можуть призвести до значних фінансових втрат чи спотворення історико-культурної картини певного періоду.

Метою даної статті є систематизація основних підходів до побудови та навчання нейронних мереж, застосованих для завдання атрибуції творів мистецтва; демонстрація практичної методики збору та підготовки даних (зокрема, оцифрованих зображень і метаданих) для вдосконалення точності атрибуції; експериментальна перевірка ефективності різних архітектур (згорткові нейронні мережі, трансформерні моделі); окреслення перспектив і обмежень використання даних методів, а також визначення подальших напрямів дослідження.

Матеріали та метод. Методологія атрибуції культурних цінностей за допомогою нейронних мереж охоплює кілька послідовних етапів: (1) формування вибірки даних, (2) передобробка та аугментація даних, (3) проєктування та тренування моделі, (4) валідація та тестування, (5) оцінювання ефективності та інтерпретація результатів.

Формування вибірки даних

Для здійснення якісного моделювання необхідно мати достатньо велику та різноманітну вибірку зображень мистецьких творів.

У межах нашого дослідження ми використали такі джерела: відкриті бази зображень картин і скульптур, надані музеями та науковими бібліотеками; приватні колекції, що погодилися надати фото оригіналів і підробок; оцифровані каталоги аукціонів, де збережено опис, фото та метадані (дата створення, автор, техніка).

Для кожного зображення збиралися такі поля: унікальний ідентифікатор, автор, рік створення (або період), художня школа, матеріали (полотно, пігмент), розміри, музей (галерея) зберігання, а також посилання на оригінальний файл високої роздільної здатності.

Першочергово було сформовано базовий датасет у кількості близько 18000 зображень із підтвердженою атрибуцією, які поділялися за жанрами (портрет, пейзаж, історична картина тощо) і школами (наприклад, італійська ренесансна, нідерландська, іспанська, українська барокова школа тощо).

Передобробка й аугментація даних

Отримані зображення стандартизувалися за кольоровою глибиною (RGB 8 біт), просторовою роздільною здатністю (наприклад, 512×512 пікселів), і нормалізувалися за статистичними параметрами середнього та стандартного відхилення.

Застосовувалися методи аугментації для підвищення стійкості моделі до різноманітних змін: випадкове обертання зображень на кут у межах 15–30 градусів; горизонтальне та вертикальне віддзеркалення; зміна яскравості й контрастності в невеликому діапазоні; додавання слабких гаусових шумів (Gaussian Noise).

Такі операції дозволяють суттєво розширити ефективний обсяг вибірки та забезпечити кращу генералізацію моделі, особливо в умовах обмеженої кількості оригінальних зразків [3; 4].

Проектування та тренування моделі

У ролі моделей було обрано: глибокі згортові нейронні мережі (Convolutional Neural Networks, CNN), такі як ResNet, EfficientNet, VGG; трансформерні архітектури, включаючи Vision Transformers (ViT) та CLIP.

Першочергово моделі ініціалізувалися попередньо натренованими ваговими коефіцієнтами, отриманими на загальних наборах зображень (наприклад, ImageNet). На

наступному етапі проводилося додаткове перенавчання (fine-tuning) на зібраній вибірці артефактів.

Загальна схема навчання

Нехай $X = \{x_1, x_2, \dots, x_N\}$ – множина зображень (векторів або тензорів), а $Y = \{y_1, y_2, \dots, y_N\}$ – відповідні мітки (атрибуції), що можуть бути як *автор* (для задачі ідентифікації автора), так і *школа*, *період* чи інша категоріальна ознака.

Модель нейронної мережі f_θ з параметрами θ приймає на вхід x_i і повертає вектор ймовірностей $\hat{y}_i = f_\theta(x_i)$. Завдання навчання полягає в мінімізації функції втрат $\mathcal{L}(\theta)$, зазвичай крос-ентропії для багатокласової класифікації:

$$\mathcal{L}(\theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{i,k} \log \hat{y}_{i,k} \quad (1)$$

де K – кількість класів (наприклад, число можливих авторів), а $y_{i,k}$ – бінарний індикатор, що дорівнює 1, якщо зображення x_i належить до класу k , і 0 – інше. Вихід мережі $\hat{y}_{i,k}$ – це ймовірність того, що x_i належить до класу k .

Для оптимізації використовувався стохастичний градієнтний спуск (SGD) або його модифікації (Adam, RMSProp) із різними значеннями швидкості навчання (learning rate). Навчання проходило в декілька епох, після кожної епохи виконувалася валідація на відкладеній вибірці.

Інтеграція текстової інформації

У випадках, коли для кожного зразка доступні текстові метадані (опис артефакту, історична довідка, ключові слова тощо), застосовується мультимодальна модель, де вхідний вектор складається з компонентів, що відповідають візуальній та текстовій ознаковій репрезентації. У такому разі можна використати підхід на основі трансформерів, що виконує паралельне навчання зображень та тексту:

$$Z = \text{Fusion}(\text{Encoder}_{\text{image}}(x_i), \text{Encoder}_{\text{text}}(t_i)), \quad (2)$$

де t_i – текстова інформація для зображення x_i , а Z – об'єднаний вектор ознак, що далі подається на класифікатор.

Валідація, тестування та оцінювання ефективності

Для перевірки та порівняння моделей використовувалися стандартні метрики: точність (Accuracy); повнота (Recall); точність у вузькому сенсі (Precision); F1-міра.

Також проводився перехресний аналіз (Cross-validation) з різними частинами вибірки для оцінки стійкості та узагальнення підходу.

Таблиця 1

Параметри дослідження

Параметр	Значення
Обсяг базового датасету	18000 зображень
Просторова роздільна здатність	512 × 512 пікселів
Аугментація	Поворот (до 30) віддзеркалення, зміна яскравості/контрасту, додавання шумів
Моделі	CNN (ResNet, VGG, EfficientNet), ViT, CLIP
Оптимізатор	SGD, Adam
Розмір батча	32-64
Кількість епох	50 (середній показник)
Кількість класів	Від 5 (базові школи) до 50+ (автори)

Важливою частиною дослідження був аналіз того, як якість і обсяг навчальної вибірки впливають на точність. Це перевірялося шляхом поступового збільшення кількості зображень і вимірювання зміни метрик класифікації.

Інтерпретація результатів

Окрім власне значення точності, в цій сфері важливо проаналізувати, які саме особливості зображення використовує нейромережа. Для візуалізації було застосовано методи CAM (Class Activation Map), що дозволяють виділити зони, на які модель найсильніше реагує під час прийняття рішення. Таким чином, експерт-мистецтвознавець може корелювати «активні зони» із стилістичними чи матеріальними особливостями твору.

Отже, сукупність описаних методів забезпечує комплексний підхід до атрибуції об'єктів мистецтва за допомогою нейронних мереж.

Результати. Особливу увагу приділено порівнянню різних архітектур нейронних мереж і визначенню впливу обсягу та якості даних на кінцеву точність атрибуції. Наведені

також візуалізації, що ілюструють процес і результати моделювання.

Порівняння моделей

Під час експериментів було випробувано кілька популярних архітектур CNN (ResNet-50, VGG16, EfficientNet-B4) та дві трансформерні моделі (Vision Transformer, CLIP). Деякі узагальнені показники точності (Accuracy) для завдання класифікації за автором (50 можливих авторів) наведено нижче:

ResNet-50: 84.2%

VGG16: 81.5%

EfficientNet-B4: 86.7%

Vision Transformer (ViT): 88.9%

CLIP (мультимодальний підхід): 90.3%

Отримані результати показують, що використання трансформерних підходів, зокрема мультимодальної архітектури CLIP, дало змогу отримати вищу точність порівняно з класичними CNN-моделями. Класифікація за художньою школою (5 шкіл) показала вищу середню точність (понад 95%), що очікувано, адже поділ на меншу кількість грубих категорій є простішим завданням.

Вплив обсягу навчальних даних

Дослідження впливу обсягу навчальної вибірки свідчить, що модель EfficientNet-B4 помітно збільшує точність із ростом кількості зображень, а трансформерні моделі (ViT, CLIP) стають більш стійкими вже при середніх обсягах даних (близько 10000 зразків). На вибірці менше 2000 зображень нейронні мережі демонструють низький рівень узагальнення, оскільки складні патерни не можуть бути коректно ідентифіковані.

Приклад візуалізації результатів

На Рис. 1 показано візуалізацію Class Activation Maps (CAM), що є важливим методом у дослідженні та поясненні роботи глибоких нейромереж у задачах атрибуції артефактів. Однією з ключових проблем застосування нейромереж у мистецтвознавстві є складність пояснення отриманих результатів, оскільки рішення моделі можуть бути нечіткими або важко інтерпретованими людиною. Використання CAM дозволяє побачити, які області зображення найбільш впливають на визначення стилю, школи або авторства твору мистецтва. У процесі атрибуції мистецьких

артефактів штучний інтелект аналізує зображення, знаходячи візуальні патерни, притаманні певному художнику або мистецькому напрямку. Це можуть бути характерні мазки пензля, композиційні рішення, кольорові гами та структурні особливості полотна. Проблема автоматизованої атрибуції полягає в тому, що неймережі можуть використовувати для класифікації неочевидні особливості, які не завжди відповідають мистецтвознавчим критеріям. Тому важливо зрозуміти, які саме зони зображення впливають на рішення моделі. Для цього застосовують візуалізацію SAM, яка надає теплові карти активацій, що показують рівень впливу різних частин зображення на кінцевий результат класифікації.

Class Activation Maps (CAM) for Impressionist Artwork




Рис. 1. Приклад карти активацій (CAM) для класифікації за автором

У даній роботі реалізована візуалізація SAM для імітації аналізу твору мистецтва, зокрема картини в стилі імпресіонізму. Для цього було створено тестове зображення, що імітує художню композицію, з додаванням кольорових областей, які нагадують мазки пензля. Це дозволяє відтворити умови, за яких модель аналізує картину, розпізнаючи характерні особливості стилю. Для генерації SAM використовується випадкова матриця, що імітує реальну теплову карту, яку могла б створити неймережа під час роботи з реальними творами мистецтва.

Накладання SAM-карти на тестове зображення дозволяє побачити зони, що мають найбільше значення для аналізу. Темно-червоні області відображають зони найвищої активації, тобто ті частини зображення, які найбільш впливають на рішення моделі. Жовті, сині та менш насичені кольори показують зони зі слабшою активацією, які відіграють меншу роль у процесі класифікації. Це допомагає оцінити, наскільки модель орієнтується на художні особливості твору, чи, можливо, звертає увагу на непринципові деталі, такі як текстура полотна або фон.

Для аналізу використано чотири різні кольорові схеми, кожна з яких дозволяє підкреслити певні аспекти активацій. Колірна схема *jet* представляє плавний перехід від синього до червоного, що дозволяє легко сприймати розподіл уваги моделі. Палітра *hot* містить відтінки чорного, червоного, жовтого та білого, що допомагає чітко виділяти гарячі області з високою активацією. Колірна схема *parula* забезпечує більш природний перехід між кольорами, роблячи візуалізацію м'якшою. Палітра *turbo* надає більш насичені кольори, що покращує контрастність активацій та робить їх більш помітними.

Очікуваний результат візуалізації дозволяє побачити, як модель розподіляє увагу під час аналізу зображення. Важливі області картини будуть виділені більш насиченими кольорами, тоді як менш значущі зони залишаться у холодних відтінках. Це може допомогти мистецтвознавцям і дослідникам штучного інтелекту оцінити, чи правильно модель використовує характерні риси твору для класифікації, чи, можливо, орієнтується на випадкові візуальні патерни. Такий підхід може стати важливим кроком у створенні пояснюваних неймереж у галузі мистецтвознавства, де розуміння контексту та художніх традицій відіграє вирішальну роль. Методика застосування SAM може бути використана для перевірки атрибуції творів мистецтва у музейних колекціях та на арт-ринку. Вона допомагає автоматизувати процеси аналізу великих масивів мистецьких даних, знаходити нові зв'язки між художниками та школами, а також виявляти потенційні підробки, спираючись

на стилістичні особливості. Незважаючи на високий потенціал автоматизації, людський фактор залишається важливим, оскільки мистецтвознавці повинні аналізувати отримані візуалізації та перевіряти їх на відповідність історичним і художнім критеріям.

Порівняльна характеристика результатів

На основі зведених даних про точність (Accuracy), F1-міру та час навчання сформовано Таблицю 2, яка відображає основні підсумкові показники.

Як видно з Таблиці 2, CLIP демонструє найвищі значення точності та F1-міри, однак час навчання моделі був найбільшим і вимагав спеціалізованих обчислювальних ресурсів (потужні GPU). Vision Transformer (ViT) також показує високий результат, наближаючись до CLIP, але без мультимодальної складової.

Таким чином, результати підтвердили попереднє припущення про перевагу сучасних трансформерних архітектур, особливо якщо є достатній обсяг даних або можливість підкріплення їх текстовими метаданими.

На основі отриманих результатів можна зробити кілька важливих висновків, що стосуються як наукової, так і практичної складової завдання атрибуції творів мистецтва за допомогою нейронних мереж.

Віповідно до висунутої в цій роботі гіпотези, застосування сучасних глибинних нейронних мереж, зокрема трансформерних моделей, здатне суттєво підвищити точність атрибуції у порівнянні з традиційними підходами та навіть із «класичними» CNN-мережами. Результати дослідження підтвердили цю тезу, особливо завдяки введенню мультимодальної компоненти (CLIP), яка

дозволяє доповнити візуальну інформацію текстовим описом.

Отримані показники точності та узагальнюючої здатності корелюються з результатами, наведеними в інших подібних роботах [5; 6].

Можливі обмеження дослідження

Обмеження розміру та репрезентативності датасету: хоча 18000 зображень здаються значним масивом, для задачі, що охоплює сотні авторів і різноманітні школи, це може бути недостатньо. Якість оцифрованих зображень: різні умови сканування або фотографування можуть вносити додаткові спотворення (бліки, тіні, нерівномірне освітлення). Текстові дані можуть бути неповними або містити неточності в описах, що впливає на мультимодальні підходи. Етичні аспекти: автоматизована атрибуція може бути використана несумлінними учасниками ринку мистецтва, що загрожує поширенням фальсифікацій.

Перспективні напрями майбутніх досліджень

– Розвиток більш складних мультимодальних архітектур, що включають не лише текст та зображення, а й метадані про склад пігментів, результати спектроскопії тощо.

– Створення великомасштабних баз даних зі стандартизованою системою тегів і метаданих, уніфікованих у глобальному масштабі.

– Застосування методів інтерпретованого штучного інтелекту (Explainable AI), що дозволять краще розуміти, як і чому мережа дійшла певних рішень.

– Розширення аналізу на тривимірні об'єкти культури (скульптури, архітектурні елементи), де можуть використовуватися алгоритми 3D-розпізнавання.

Таблиця 2

Основні результати порівняння моделей

Модель	Accuracy	F1-міра	Час навчання (год)	Переваги / Недоліки
ResNet-50	84.2%	0.82	6	Надійна, поширена, але обмежена масштабованість
VGG16	81.5%	0.80	5	Проста в налаштуванні, висока вимога до пам'яті
EfficientNet-B4	86.7%	0.85	8	Оптимальне співвідношення швидкості та точності
ViT	88.9%	0.87	12	Висока точність, але потребує великого датасету
CLIP	90.3%	0.89	15	Найкраща точність, мультимодальність, складніше навчання

Таким чином, попри досягнуті високі показники точності, модель потребує подальшого вдосконалення й масштабування, а повна автоматизація процесу навряд чи замінить експертну думку фахового мистецтвознавця. Однак як інструмент підтримки експерта нейромережі перспективні та вже доводять свою ефективність у реальних дослідницьких і музеологічних умовах.

Висновки. У даній роботі було представлено результати дослідження можливостей застосування нейронних мереж різної архітектури для автоматизованої атрибуції культурних цінностей, зокрема живопису. Отримані дані свідчать про високу ефективність як традиційних CNN-рішень, так і новітніх трансформерних підходів, особливо мультимодальної архітектури CLIP.

– Згорткові мережі (ResNet, VGG, EfficientNet) демонструють солідний базовий рівень точності, придатний для багатьох практичних застосувань.

– Трансформери (ViT) та мультимодальні підходи (CLIP) істотно підвищують точність класифікації, особливо якщо кількість зображень досить велика та доступні якісні текстові описи.

– Аугментація даних (повороти, шум, віддзеркалення) та попереднє тренування (pretraining) є важливими складовими успішного навчання глибоких моделей на відносно невеликих датасетах.

– Обсяг і якість вибірки мають критичне значення для досягнення високої точності. Також значну роль відіграє збалансованість класів (шкіл чи авторів).

– Інтерпретованість результатів через візуальні методи (CAM, Grad-CAM) дає змогу експертам-мистецтвознавцям ліпше розуміти рішення, ухвалені нейромережею, що посилює довіру до таких алгоритмів.

Практичні рекомендації щодо застосування

Музеї та науково-дослідні установи можуть створювати системи попереднього

аналізу нових надходжень, аби швидко визначити гіпотетичного автора або період і таким чином спростити роботу експерта.

На арт-ринку (аукціони, приватні колекції) глибинні мережі здатні виявляти потенційні підробки або сумнівні атрибуції на ранній стадії, знижуючи ризик шахрайства.

Розширене документування та зберігання оцифрованих зображень разом зі стандартизованими описами дозволить у майбутньому вдосконалювати алгоритми та обмінюватися релевантними даними між установами.

Використання методів Explainable AI дасть змогу зменшити недовіру фахівців через «непрозорість» нейромереж і наблизити результати моделювання до рівня експертного аналізу.

Інтеграція нейромереж у широкі платформи цифрової гуманітаристики допоможе об'єднати в єдиному середовищі дані з різних джерел (архівні матеріали, тексти, іконографічні довідники).

Важливим напрямом має стати розробка доменних моделей, спеціально налаштованих на певні культурно-історичні періоди, школи чи технології.

У перспективі можливо використовувати методики в аналізі скульптури, археологічних та етнографічних об'єктів, що потребують більш складних методів обробки даних (3D-сканування, багатоспектральні зображення).

Використання нейромереж стане у пригоді і для дослідження взаємодії між культурами: динамічні моделі, що відстежують розвиток стилю протягом певного хронологічного періоду.

Таким чином, людський фактор залишиться важливою складовою мистецтвознавчого аналізу. Проте нейронні мережі слугуватимуть потужним допоміжним інструментом, який може спростити та пришвидшити процес атрибуції, а також відкрити нові перспективи для досліджень у галузі культурології та мистецтвознавства.

Література:

1. Trigka M. 1, Elias Dritsas E. Comprehensive Survey of Deep Learning for Image Restoration. *Sensors*. 2025. Vol. 25, no. 2. P. 531. URL: <https://www.mdpi.com/1424-8220/25/2/531> (date of access: 20.04.2025)

2. Baltrušaitis T., Ahuja C., Morency L.-P. Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2019. Vol. 41, no. 2. P. 423–443. URL: <https://dl.acm.org/doi/10.1109/tpami.2018.2798607> (date of access: 20.02.2025)
3. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*. 2012. Vol. 25. P. 1097–1105. URL: <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>. (date of access: 20.04.2025)
4. Zhou B., Khosla A., Lapedriza A., Oliva A., Torralba A. Learning Deep Features for Discriminative Localization. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27 2016 to June 30 2016. / Las Vegas, Nevada, USA, 2016. P. 2921–2929. URL: <https://www.computer.org/csdl/proceedings-article/cvpr/2016/8851c921/12OmNqIhFR6> (date of access: 01.05.2025)
5. Radford A., Kim J.W., Hallacy C., et al. Learning Transferable Visual Models From Natural Language Supervision. *arXiv:2103.00020v1 [cs.CV]*. Cornell University, 2021. P. 8748–8763. URL: <https://doi.org/10.48550/arXiv.2103.00020> (date of access: 24.03.2025)
6. Vinayavekhin Ph., Khomkham B., et al. Identifying Relationships and Classifying Western-style Paintings: Machine Learning Approaches for Artworks by Western Artists and Meiji-era Japanese Artists. *ACM Journal on Computing and Cultural Heritage*. Vol. 17, Issue 1. Article no.: 6, 2024. P. 1–18. URL: <https://doi.org/10.1145/3631136> (date of access: 20.02.2025)

References:

1. Trigka, M., & Elias Dritsas, E. (2025). Comprehensive Survey of Deep Learning for Image Restoration. *Sensors*. Vol. 25, no. 2. P. 531. Retrieved from: <https://www.mdpi.com/1424-8220/25/2/531>.
2. Baltrušaitis, T., Ahuja C., & Morency, L.-P. (2019). Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. Vol. 41, no. 2. P. 423–443. Retrieved from: <https://dl.acm.org/doi/10.1109/tpami.2018.2798607>.
3. Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*. Vol. 25. P. 1097–1105. Retrieved from: <https://proceedings.neurips.cc/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf>.
4. Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., & Torralba, A. (2016). A. Learning Deep Features for Discriminative Localization. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. June 27 2016 to June 30 2016 / Las Vegas, Nevada, USA. P. 2921–2929. Retrieved from: <https://www.computer.org/csdl/proceedings-article/cvpr/2016/8851c921/12OmNqIhFR6>.
5. Radford, A., Kim, J.W., Hallacy, C., et al. (2021). Learning Transferable Visual Models From Natural Language Supervision. *arXiv:2103.00020v1 [cs.CV]*. Cornell University. P. 8748–8763.
6. Vinayavekhin, Ph., Khomkham, B., et al. (2024). Identifying Relationships and Classifying Western-style Paintings: Machine Learning Approaches for Artworks by Western Artists and Meiji-era Japanese Artists. *ACM Journal on Computing and Cultural Heritage*. Vol. 17. Issue 1. Article no. 6. P. 1 – 18. Retrieved from: <https://doi.org/10.1145/3631136>