

УДК 7.025'174

DOI <https://doi.org/10.24919/2308-4863/74-2-16>

**Євген САННИКОВ,**

*orcid.org/0009-0008-9917-8461*

*аспірант кафедри теорії та історії мистецтва*

*Національної академії образотворчого мистецтва та архітектури*

*(Київ, Україна) yevhen.sannikov@naoma.edu.ua*

**Олена ГОМИРЕВА,**

*orcid.org/0000-0002-9808-7997*

*кандидат мистецтвознавства,*

*старший викладач кафедри теорії та історії мистецтва*

*Національної академії образотворчого мистецтва та архітектури*

*(Київ, Україна) olena.gomyreva@naoma.edu.ua*

## **ПРАКТИЧНЕ ЗАСТОСУВАННЯ АЛГОРИТМІВ НЕЙРОННИХ МЕРЕЖ ДЛЯ АНАЛІЗУ ВІЗУАЛЬНОГО МИСТЕЦТВА**

*Актуальність проблеми обумовлена стрімким розвитком технологій штучного інтелекту, зокрема нейронних мереж, що відкриває нові можливості для автоматизованого аналізу візуальних даних та ставить питання про ефективність алгоритмів машинного навчання у вирішенні завдань, які досі вважалися прерогативою експертів-людей. Мета дослідження – проаналізувати можливості та практичне застосування алгоритмів нейронних мереж для дослідження та аналізу творів візуального мистецтва. У статті розглянуто ключові концепції та архітектури нейромереж, що використовуються для обробки зображень, і на конкретних прикладах показано, як ці методи можуть бути застосовані для вирішення таких мистецтвознавчих задач, як розпізнавання стилів та авторства, пошук схожих робіт у великих базах даних, виявлення характерних патернів у композиції та колористиці робіт певних художників. Методологія дослідження включає методи аналітичного огляду та порівняння кейсів використання різних архітектур нейронних мереж, зокрема згорткових нейронних мереж (CNN), генеративно-змагальних мереж (GAN), трансформерів зі зсувом вікна (SWIN) та дифузійних моделей. Проаналізовано низку досліджень та проєктів, що демонструють ефективність цих алгоритмів для автоматизованого аналізу великих масивів візуальних даних у сфері мистецтва. Наукова новизна визначається комплексним розглядом можливостей та обмежень різних архітектур нейромереж у контексті мистецтвознавчих задач, а також аналізом викликів, пов'язаних з інтеграцією цих технологій у мистецтвознавчу практику. Висновки. Обговорено питання інтерпретації результатів та підкреслено потреби в експертній оцінці. Показано, що найбільш перспективним є підхід, який поєднує обчислювальну потужність алгоритмів з експертними знаннями мистецтвознавців, дозволяючи генерувати нові гіпотези та глибше розуміти закономірності розвитку мистецтва*

***Ключові слова:** нейронні мережі, візуальне мистецтво, аналіз зображень, атрибуція, пошук подібності, глибинне навчання, мистецтвознавство.*

**Yevhen SANNIKOV,**

*orcid.org/0009-0008-9917-8461*

*PhD student at the Department of Art Theory and History*

*National Academy of Fine Arts and Architecture*

*(Kyiv, Ukraine) yevhen.sannikov@naoma.edu.ua*

**Olena HOMOYREVA,**

*orcid.org/0000-0002-9808-7997*

*Candidate of Theory and History of Art,*

*Senior Lecturer at the Department of Art Theory and History*

*National Academy of Fine Arts and Architecture*

*(Kyiv, Ukraine) olena.gomyreva@naoma.edu.ua*

## **PRACTICAL APPLICATION OF NEURAL NETWORK ALGORITHMS FOR VISUAL ART ANALYSIS**

*The relevance of the problem is determined by the rapid development of artificial intelligence technologies, particularly neural networks, which opens up new possibilities for automated analysis of visual data and raises questions about the*

effectiveness of machine learning algorithms in solving tasks that were previously considered the prerogative of human experts. **The purpose of the study** is to analyze the possibilities and practical applications of neural network algorithms for research and analysis of visual art works. The article considers the key concepts and architectures of neural networks used for image processing and shows, using specific examples, how these methods can be applied to solve such art history problems as style and authorship recognition, search for similar works in large databases, and identification of characteristic patterns in composition and coloristics of works by certain artists. **The research methodology** includes methods of analytical review and comparison of cases of using different neural network architectures, such as convolutional neural networks (CNN), generative adversarial networks (GAN), shifted window transformers (SWIN), and diffusion models. A number of studies and projects are analyzed that demonstrate the effectiveness of these algorithms for automated analysis of large amounts of visual data in the field of art. **The scientific novelty** is determined by a comprehensive consideration of the possibilities and limitations of applying various neural network architectures in the context of art history tasks, as well as an analysis of the challenges associated with the integration of these technologies into art history practice. **Conclusions.** In particular, the issues of interpreting the results and the need for expert evaluation are discussed. It is shown that the most promising approach is one that combines the computational power of algorithms with the expert knowledge of art historians, allowing for the generation of new hypotheses and a deeper understanding of the patterns of art development.

**Key words:** neural networks, visual art, image analysis, attribution, similarity search, deep learning, art history.

**Постановка проблеми.** Традиційний мистецтвознавчий аналіз спирається на експертні знання, однак розвиток технологій штучного інтелекту, зокрема нейронних мереж, відкриває нові можливості для автоматизованого аналізу візуальних даних. Постає питання ефективності та достовірності роботи алгоритмів машинного навчання у вирішенні завдань, які досі вважалися прерогативою експертів – розпізнавання стилів, авторства, пошук схожих робіт, виявлення прихованих закономірностей. Дослідження в цьому напрямі важливі не лише для галузі комп'ютерних наук, але й для мистецтвознавства, оскільки пропонують нові інструменти аналізу творів мистецтва.

**Аналіз досліджень.** Застосування методів машинного навчання в сфері мистецтва привертає дедалі більшу увагу дослідників. Піонерська робота Девіда Г. Сторка продемонструвала можливість використання згорткових нейронних мереж для атрибуції портретів, створених майстернею Рембрандта (Stork, 2009). Бабак Салех і Ахмед Елгаммал запропонували метод пошуку візуально схожих картин на основі виділення високорівневих характеристик зображень (Saleh & Elgammal, 2016). Група дослідників на чолі з Сергієм Караєвим дослідила можливість автоматичного розпізнавання стилю в живописі (Karaev et al., 2014). Інша група науковців використала глибинне навчання для класифікації картин за стилями (Lescoutre et al., 2017). Крістіан Сандовал та його колеги запропонували двоетапний підхід до класифікації живопису на основі глибинного навчання (Sandoval et al., 2019). Єва Цетініч зі співавторами показали, як точне налаштування згорткових нейромереж покращує результати класифікації (Cetinic et al., 2018). Попри значний прогрес у цій галузі, більшість існуючих досліджень зосереджені на вирішенні окремих задач і часто

обмежуються невеликими датасетами. Бракує комплексного розгляду можливостей та обмежень різних архітектур нейромереж у контексті мистецтвознавчих задач.

**Мета статті.** Метою цієї статті є аналіз можливостей та практичного застосування алгоритмів нейронних мереж для дослідження та аналізу творів візуального мистецтва. Ми розглянемо ключові концепції та архітектури нейромереж, що використовуються для обробки зображень, і на конкретних прикладах покажемо, як ці методи можуть бути застосовані для вирішення таких мистецтвознавчих задач, як розпізнавання стилів та авторства, пошук схожих робіт у великих базах даних, виявлення характерних патернів у композиції та колористиці робіт певних художників. Також ми обговоримо обмеження та виклики, пов'язані з інтеграцією цих технологій у мистецтвознавчу практику.

**Виклад основного матеріалу.** Перед тим як перейти до розгляду практичних прикладів використання штучного інтелекту в аналізі мистецтва, важливо познайомитися з ключовими концепціями та типами нейронних мереж, що лежать в основі цих підходів.

*Нейронні мережі* – це математичні моделі, які за принципом роботи нагадують людський мозок. Вони складаються з великої кількості простих обчислювальних елементів, які називають нейронами за аналогією з клітинами мозку. Ці штучні нейрони з'єднані між собою у складну мережу. Кожен такий нейрон у мережі виконує прості операції: отримує сигнали від інших нейронів, обробляє ці сигнали за певними правилами і передає результат далі по мережі. Хоча кожен нейрон виконує лише прості обчислення, вся мережа в цілому здатна вирішувати складні задачі, такі як розпізнавання образів чи прогнозування. Щоб нейро-

мережа змогла розв'язувати певну задачу (наприклад, розпізнавати стиль картини), її потрібно навчити на прикладах. Цей процес називається «тренуванням» моделі, для чого потрібен датасет – великий набір даних із правильними відповідями. Для аналізу творів візуального мистецтва, датасет зазвичай містить тисячі зображень картин з анотаціями про автора, назву, рік, стиль, жанр тощо, причому анотації роблять експерти вручну або напівавтоматично. Тому, «правильність» у цьому випадку гарантується фаховістю експерта, залученого до створення анотацій. Під час тренування нейромережа «бачить» приклади картин з датасету і коригує свої параметри так, щоб її прогнози стилю чи автора збігалися з анотаціями людини. Цикл повторюється знову і знову, поки модель не почне давати точні відповіді на більшості аналізованих зображень. Після цього вона готова аналізувати нові картини, яких не бачила раніше. Саме здатність виявляти складні закономірності в даних і навчатися на власному досвіді робить нейронні мережі потужним інструментом для вирішення багатьох задач, від генерації зображень та відео до аналізу візуального мистецтва.

Одним з найефективніших типів нейромереж для аналізу зображень є *згорткові нейронні мережі* (Convolutional Neural Networks, CNN). Їх особливість полягає в здатності автоматично розпізнавати візуальні елементи різної складності – від простих ліній до цілісних об'єктів. CNN досягають цього, поступово скануючи зображення та виявляючи характерні візуальні патерни. Цей процес нагадує роботу мистецтвознавця, який послідовно вивчає картину, звертаючи увагу на окремі деталі: мазки, кольори, форми, композицію, а потім синтезує ці спостереження в цілісну інтерпретацію. Так само, як мистецтвознавець з роками, набуваючи досвіду, навчається розпізнавати стиль художника, аналізуючи багато його робіт, CNN навчається розпізнавати візуальні особливості на великій кількості прикладів (Li, 2017).

Інший важливий тип нейромереж – *генеративно-змагальні мережі* (Generative Adversarial Networks, GAN). Вони складаються з двох частин: генератора і дискримінатора. Обидві частини тренуються одночасно, змушуючи одна одну вдосконалюватися. Результатом є вже навчаний генератор, здатний створювати реалістичні зображення, які важко відрізнити від створених людиною. Генератор – це нейромережа, яка навчається створювати нові зображення, схожі на ті, приклади яких були їй «показані». Наприклад, якщо генератор навчався на картинах певного художника, він намагатиметься створювати нові зображення, які

виглядають так, ніби вони були намальовані цим художником. Дискримінатор – це інша нейромережа, яка навчається відрізнити справжні зображення (вона вже «бачила» їх у окремому істинному наборі) від синтезованих зображень, створених генератором. Її задача – виявити підробки, створені генератором. Під час навчання GAN генератор і дискримінатор змагаються один з одним. Генератор намагається створити зображення, які дискримінатор буде визнавати справжніми, а дискримінатор намагається не дати себе «обдурити». Це змушує обидві частини постійно вдосконалюватися, і, у результаті, після багатьох ітерацій навчання, генератор навчається створювати зображення, які дуже складно відрізнити від справжніх (Schmidhuber, 2015).

Серед новітніх архітектур нейромереж для обробки зображень – трансформери зі зсувом вікна (Shifted Window Transformers, SWIN). На відміну від згорткових нейромереж (CNN), які обробляють зображення цілісно, SWIN розбивають його на перекриваючі фрагменти і обробляють кожен з урахуванням контексту сусідніх. SWIN можна уявити як команду мистецтвознавців, які працюють над аналізом картини, розбиваючи її на фрагменти. Кожен «експерт» зосереджується на своїй ділянці, ретельно вивчаючи деталі, але постійно обмінюється спостереженнями із сусідами, щоб зберегти бачення цілого. Такий підхід дозволяє виявляти тонкі нюанси стилю та техніки художника, які можуть губитися при розгляді картини в цілому (Wang, 2022).

Варто також згадати *дифузійні моделі* (Diffusion Models) – клас генеративних нейромереж, що створюють зображення, послідовно додаючи деталі до початкового шуму. Цей процес нагадує роботу художника, який поступово проявляє зображення з хаосу мазків та кольорових плям. Дифузійні моделі дозволяють керувати генеруванням зображення, задаючи бажаний стиль чи сюжет на старті (OpenAI, 2016).

Отже, нейронні мережі – це потужний інструмент для аналізу творів мистецтва. Різні архітектури, від вже класичних CNN до новітніх трансформерів та дифузійних моделей, дозволяють вирішувати широкий спектр задач: розпізнавання стилів і авторства, пошук схожих робіт, виявлення прихованих паттернів та навіть генерацію нових зображень. Але щоб розкрити цей потенціал, нейромережі потребують якісних даних для навчання та інтерпретації результатів експертами. У наступному розділі ми розглянемо конкретні приклади того, як ці технології вже застосовуються в мистецтвознавчих дослідженнях та які нові можливості це відкриває.



**Приклади практичного застосування алгоритмів нейронних мереж для аналізу візуального мистецтва.** У статті «Visual Patterns Discovery in Large Databases of Paintings» пропонується метод пошуку візуально схожих картин у великій базі з 39000 цифрових зображень живопису. Проект Replica – це співпраця між дослідниками з Федеральної політехнічної школи Лозанни (EPFL) та Фондом Чіні у Венеції. Цей проект поєднує в собі два паралельні напрямки: оцифрування бібліотеки Фонду Чіні та створення спеціалізованої пошукової системи для виявлення візуальних патернів у цій базі даних. Бібліотека Фонду Чіні – це унікальна колекція, що містить близько мільйона фотографій картин, гравюр, скульптур та архітектури, датованих періодом від 1300 до 1900 року. Оцифрування такої масштабної колекції відкриває нові можливості для дослідників мистецтва, адже вони отримують доступ не лише до добре відомих шедеврів, але й до величезного масиву робіт художників, які раніше були малодоступні для аналізу. Однак сам по собі доступ до оцифрованої колекції не розкриває весь потенціал цього ресурсу. Тому другою складовою проекту Replica стала розробка спеціалізованої пошукової системи, здатної знаходити схожі картини не лише за текстовими описами, але й безпосередньо за їх візуальним змістом (di Lenardo et al., 2016).

Дослідження творчості художника без усвідомлення зв'язків цієї творчості з контекстом епохи, тенденціями того часу, творчістю інших художників не є продуктивним, тому дослідники вивчають зв'язки, творчі й особисті контакти, впливи. Очевидним рішенням є проведення порівняльного аналізу з творами митців, з якими даний художник точно мав творчі контакти, що підтверджується біографічними відомостями. Але розширивши за рахунок нейронних мереж можливості пошуку візуальних схожостей між картинами досліджуваного митця і картинами численних митців того часу можна виявити неочікувані паралелі, які, не маючи історичного підтвердження про пряме знайомство художника з цими творами, дадуть дослідникам ширше поле для подальшого аналізу. Зокрема, ці паралелі можуть поглибити висновки щодо географічної розповсюдженості стилістичних рис, притаманних певній школі чи осередку; щодо сталості художніх рішень, притаманних певному напрямку чи епосі; ці паралелі можуть спровокувати глибше занурення в біографічні подробиці для пошуку «ниточок» зв'язку через творчі контакти, спадковість майстерності між митцями, в творах яких виявлено відчутну схожість. Спектр висновків і нових відкриттів, на які може вплинути цей аспект, є дуже широким.

Уявіть, що ви – мистецтвознавець, який досліджує еволюцію певного іконографічного мотиву, скажімо, натюрморту з квітами. Традиційно вам довелося б переглядати сотні й тисячі картин, покладаючись на власну зорову пам'ять та інтуїцію, щоб віднайти схожі роботи. Але що, якби ви могли просто завантажити зображення одного натюрморту в пошукову систему і миттєво отримати десятки схожих картин, причому не лише за сюжетом, але й за композицією, колоритом, стилістикою? Саме таку можливість і надає пошукова система, розроблена в рамках вищезгаданого проекту Replica. Її «серцем» є згортовка нейронна мережа (CNN) – алгоритм глибокого навчання, який виділяє з кожної картини набір високорівневих характеристик, так званих дескрипторів. Дескриптори – це компактне числове представлення візуального змісту картини, а процес отримання дескриптора можна уявити як «стиснення» картини від мільйонів пікселів до набору з, наприклад, 1000 чисел. Кожне число в цьому наборі відповідає певній високорівневій візуальній ознаці, такій як наявність певних об'єктів, текстур, колірних сполучень тощо. Для ілюстрації цього принципу, розглянемо спрощений гіпотетичний приклад. Припустимо, що наша нейромережа використовує лише 5 візуальних ознак. Тоді дескриптори для двох картин можуть виглядати так:

Картина 1: [0.8 (присутність архітектури), 0.2 (присутність пейзажу), 0.9 (теплі кольори), 0.1 (холодні кольори), 0.6 (зображення людей)]

Картина 2: [0.7 (присутність архітектури), 0.3 (присутність пейзажу), 0.8 (теплі кольори), 0.2 (холодні кольори), 0.5 (зображення людей)]

У цьому прикладі обидві картини мають подібні значення для більшості ознак, що вказує на їх візуальну схожість з точки зору нейромережі, навіть якщо вони зображують різні сюжети. У реальних застосуваннях дескриптори зазвичай містять сотні або тисячі чисел, і точний семантичний зміст кожного числа може бути незрозумілим для людини. Однак математично ці числа представляють суттєві характеристики картини з точки зору нейромережі. Ця стислість дозволяє ефективно порівнювати дескриптори різних картин для пошуку схожих робіт у великих базах даних. Чим ближче дескриптори двох картин у цьому багатомірному просторі ознак, тим більше схожих візуальних елементів містять ці картини з точки зору нейромережі. Але найцікавіше починається, коли користувач починає комбінувати ці дескриптори за допомогою спеціальної алгебраїчної мови запитів. Наприклад, ви можете «взяти» картину з натюрмортом, «відняти» від неї картину з фігурами

людей і отримати в результаті ще точніший пошук: лише натюрморти, без жанрових сцен. Або ж ви можете «скласти» дескриптори двох картин, щоб знайти інші роботи, які поєднують риси їх обох. Такий інтерактивний пошук дозволяє дослідникам поступово звужувати чи розширювати критерії подібності, крок за кроком наближаючись до потрібного результату. Дослідники можуть знаходити не лише очевидні іконографічні паралелі, але й несподівані структурні аналогії між картинами різних епох і жанрів. Звичайно, такий наддетальний пошук стає можливим лише за наявності достатньо великої бази даних оцифрованих зображень. Саме тому роль Фонду Чіні як партнера, що надає доступ до своєї унікальної колекції, є ключовою для проєкту. На момент написання статті в експериментах використовувалася підмножина з 39 000 картин, що вже є значним обсягом даних. Однак справжній потенціал цього підходу розкриється з розширенням оцифрованої колекції до сотень тисяч і мільйонів зображень. Такий масштаб даних відкриє нові горизонти для мистецтвознавчих відкриттів, дозволяючи виявляти раніше непомітні закономірності та зв'язки в історії мистецтва. Підсумовуючи, проєкт Replica – це приклад плідної взаємодії між двома сферами знань: мистецтвознавством з його багатим евристичним досвідом та комп'ютерними науками з їх потужним аналітичним апаратом. Система дозволяє вченим віднаходити неочевидні зв'язки та закономірності в океані візуальних даних, і зрештою, по-новому поглянути на еволюцію форм і смислів у мистецтві.

Дослідження «Analysis of Dutch Master Paintings with Convolutional Neural Networks» проведено Стівеном Дж. Франком та Андреа М. Франк (Frank, Frank, 2020). Автори застосували згорткові нейронні мережі (CNN) для аналізу творів двох видатних голландських художників – Рембрандта ван Рейна (1606–1669) та Вінсента ван Гога (1853–1890). Вибір цих митців та жанрів (портрет для Рембрандта, пейзаж для ван Гога) дозволив протестувати універсальність запропонованого підходу. Ключовою особливістю методу є розбиття зображень високої роздільної здатності на клаптики (тайли) та відбір для аналізу лише тих тайлів, що мають високу ентропію, тобто візуальну різноманітність. Це дозволяє обійти обчислювальні обмеження CNN щодо розміру зображень, зберігаючи важливі деталі. Навіть з невеликої кількості картин можна отримати тисячі інформативних тайлів для навчання моделі. Не менш важливим є ретельний підбір навчальної вибірки. Окрім робіт самого

художника, вона включає картини схожого стилю інших митців – від дуже близьких наслідувачів, до тих, чия манера помітно відрізняється. Це вчить нейромережу розрізняти тонкі нюанси авторського стилю та узагальнювати отримані знання на нові твори. Навчена таким чином модель CNN здатна з високою точністю відрізнити картини Рембрандта від робіт його учнів та послідовників. При цьому оптимальний розмір тайлу для аналізу портретів Рембрандта приблизно відповідає розміру обличчя, що вказує на важливість відносно великих візуальних структур для його стилю. Це узгоджується з висновками традиційних мистецтвознавчих досліджень про активне залучення майстром учнів та асистентів, особливо для другорядних елементів композиції. Для візуалізації результатів аналізу автори створюють карти ймовірностей, які кольоровим кодом показують ймовірність того, що окремі ділянки картини належать пензлю самого художника. Ці карти можуть виявляти області, потенційно написані учнями, помічниками або пізніше змінені реставраторами. Наприклад, аналіз портрета Йоханнеса Втенбогарта (1633) підтверджує гіпотезу провідного експерта з Рембрандта Ернста ван де Ветерінга про те, що руки моделі, ймовірно, були виконані асистентом (E. van de Wetering, 2014).



**Рис. 1. Рембрандт ван Рейн  
«Портрет Йоханнеса Втенбогайта»  
Карта ймовірностей**

У випадку з пейзажами ван Гога, навпаки, найвища точність розпізнавання досягається при менших розмірах тайлів – приблизно на рівні окремих мазків. Це вказує на те, що унікальність стилю ван Гога найбільше проявляється саме на рівні пензлевої техніки, тоді як композиційні особливості його робіт можуть успішно імітуватися іншими художниками. Такий результат добре узгоджується з фактом, що ван Гог працював самостійно, без учнів чи асистентів.




**Рис. 2. Вінсент ван Гог  
«Зелене пшеничне поле з кипарисом»  
Карта ймовірностей**

Автори також протестували свою модель на кількох картинах ван Гога, атрибуція яких викликала суперечки серед експертів, а також на одній навмисній імітації його стилю, виконаній сучасним художником. У всіх випадках класифікація CNN збіглася з поточним консенсусом мистецтвознавців, що свідчить про надійність методу. Водночас, дослідники застерігають від надмірного захоплення висновками, які можуть виникати при інтерпретації карт ймовірностей. Вони наголошують, що будь-яка гіпотеза щодо авторства картини повинна спиратися не лише на результати комп'ютерного аналізу, а й на традиційні мистецтвознавчі та науково-технічні методи експертизи. Автори вбачають основну цінність свого методу не в остаточному розв'язанні атрибуційних питань, а в генеруванні нових гіпотез та напрямків для подальшого дослідження.

Дослідження «Inferring compositional style in the neo-plastic paintings of Piet Mondrian by machine learning» аналізувало цифрові зображення 45 картин Мондріана у його класичному неопластичному стилі – з характерними горизонтальними та вертикальними чорними лініями, кольоровими прямокутниками (червоними, жовтими, синіми, чорними) на білому тлі. Крім того, дослідники мали доступ до зображень проміжних версій 11 картин, отриманих за допомогою рентгеновської та інфрачервоної зйомки. Ці ранні стани картин дозволяють прослідкувати еволюцію композиції і дають цінну інформацію про творчий метод художника. Їх включення до аналізу допомагає моделям машинного навчання краще «розуміти» стиль Мондріана. Щоб адаптувати зображення картин для аналізу нейромережами, їх було переведено у векторний формат. Кожна картина представлялася як набір координат ліній та кольорових прямокутників. Таке представлення дозволяє зосередитися на композиційній структурі, відкинувши несуттєві деталі.

Дослідники поставили собі за мету кількісно оцінити інтуїтивне відчуття візуальної ваги кож-



**Рис. 3. Набір векторних репрезентацій «ранніх станів» робіт Мондріана**

ного кольору. Вони припустили, що Мондріан інтуїтивно чи свідомо розподіляв кольорові елементи так, щоб зрівноважити композицію відносно центру картини. Отримані значення ваг (чорний – 0.392, червоний – 0.237, синій – 0.227, жовтий – 0.143) дають кількісне уявлення про те, як Мондріан використовував колір для балансування композицій. Чорний колір має найбільшу візуальну вагу, він найсильніше впливає на сприйняття композиції. Жовтий, навпаки, має найменшу вагу. Червоний і синій – десь посередині.

Ці ваги можуть бути корисні для мистецтвознавців, які вивчають творчість Мондріана та інших абстракціоністів, а також для створення комп'ютерних моделей, здатних імітувати стиль художника. Візуальна «вага» кольорів дає можливість розглянути її в світлі філософських та естетичних ідей неопластичизму, базованих на динамічній рівновазі, пошуку гармонійної онтологічної схеми в мистецтві. Дане дослідження показало, що в цій концепції Мондріана є чітка кольорова «рецептура» (розподілення тих елементів світу, які символізувалися через ці кольори). Крім того, запрошується паралель з пропонуваним в теорії Йоханнеса Іттена розподілом кольорів за кількістю, де жовтий займав найменшу площу (Itten, 1970).

Автори визнають і обмеження свого підходу. Зокрема, вони зазначають, що їхні моделі не враховують деякі тонкі нюанси, такі як фактура мазків чи ледь помітні варіації кольору. Включення цих аспектів могло б додати моделям точності і наблизити їх до справжнього «розуміння» стилю Мондріана. Попри ці обмеження, дослідження демонструє потужний потенціал методів машинного навчання як інструменту для аналізу мистецтва. І хоча ці методи навряд чи зможуть повністю замінити традиційну мистецтвознавчу експертизу, вони, безумовно, можуть стати ефективним доповненням до неї.



**Висновки.** Підсумовуючи зазначене вище, можемо констатувати, що алгоритми нейронних мереж відкривають нові можливості для дослідження та аналізу творів візуального мистецтва. Вони дозволяють автоматизувати рутинні задачі, такі як класифікація за стилями та авторством, пошук схожих робіт у великих базах даних, та виявляти неочевидні закономірності в композиції та колористиці художніх творів. Різні архітектури нейромереж демонструють вражаючу ефективність у вирішенні цих задач, часто перевершуючи

можливості експертів за швидкістю та масштабом обробки даних. Водночас, інтеграція цих технологій у мистецтвознавчу практику пов'язана з низкою викликів, зокрема потребою в експертній інтерпретації результатів та врахуванні потенційних упереджень моделей машинного навчання. Найбільш перспективним є підхід, який поєднує обчислювальну потужність алгоритмів з експертними знаннями мистецтвознавців, дозволяючи генерувати нові гіпотези та глибше розуміти закономірності розвитку мистецтва.

### СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. David G. Stork. Computer vision and computer graphics analysis of paintings and drawings: an introduction to the literature. *Computer analysis of images and patterns, 13th international conference*, Münster, 2 September 2009. PP. 9–24.
2. Saleh B., Elgammal A. Large-scale classification of fine-art paintings: learning the right metric on the right feature. *International journal for digital art history*. 2006. No. 2. URL: <https://doi.org/10.11588/dah.2016.2.23376> (date of access: 29.04.2024).
3. Karaev S., Hertzmann A., Winnemoeller H. Recognizing image style. *ArXiv preprint arxiv:1311.3715*. 2013. URL: <https://doi.org/10.48550/arXiv.1311.3715> (date of access: 29.04.2024).
4. Lecoutre A., Negrevergne B., Yger F. Recognizing art style automatically in painting with deep learning. *Proceedings of the ninth asian conference on machine learning*. 2017. No. 77. P. 327–342. URL: <https://hal.science/hal-02004781> (date of access: 29.04.2024).
5. Sandoval C., Pirogova E., Lech M. Two-Stage deep learning approach to the classification of fine-art paintings. *IEEE access*. 2019. Vol. 7. P. 41770–41781. URL: <https://doi.org/10.1109/access.2019.2907986> (date of access: 29.04.2024).
6. Cetinic E., Lipic T., Grgic S. Fine-tuning convolutional neural networks for fine art classification. *Expert systems with applications*. 2018. Vol. 114. P. 107–118. URL: <https://doi.org/10.1016/j.eswa.2018.07.026> (date of access: 29.04.2024).
7. Li B., Venkatesan R. Convolutional neural networks in visual computing: a concise guide. Taylor & Francis Group, 2017. 168 p.
8. Schmidhuber J. Deep learning in neural networks: an overview. *Neural networks*. 2015. Vol. 61. P. 85–117. URL: <https://doi.org/10.1016/j.neunet.2014.09.003> (date of access: 29.04.2024).
9. Wang S., Gao Z., Liu D. Swin-GAN: generative adversarial network based on shifted windows transformer architecture for image generation. *The visual computer*. 2022. URL: <https://doi.org/10.1007/s00371-022-02714-9> (date of access: 29.04.2024).
10. Generative models. *OpenAI*. URL: <https://openai.com/research/generative-models> (date of access: 29.04.2024).
11. di Lenardo I., Seguin B., Kaplan F. Visual patterns discovery in large databases of paintings. *Digital humanities, Krakow, Poland*. 2016.
12. Wetering E. V. D. A corpus of rembrandt paintings VI: rembrandt's paintings revisited - A complete survey. Springer, 2014. 736 p.
13. Frank S. J., Frank A. M. Analysis of dutch master paintings with convolutional neural networks. 2020. URL: <https://doi.org/10.48550/arXiv.2002.05107> (date of access: 29.04.2024).
14. Inferring compositional style in the neoplastic paintings of Piet Mondrian by machine learning / D. Andrzejewski et al. *Proceedings of SPIE - the international society for optical engineering*. 2010. Vol. 7531. URL: <https://doi.org/10.1117/12.840558> (date of access: 29.04.2024).
15. Itten J. Elements of color. Wiley & Sons, Incorporated, 2009.

### REFERENCES

1. David G. Stork. (2009). Computer vision and computer graphics analysis of paintings and drawings: An introduction to the literature. *Computer analysis of images and patterns, 13th international conference*.
2. Saleh, B., & Elgammal, A. (2006). Large-scale classification of fine-art paintings: Learning the right metric on the right feature. *International Journal for Digital Art History*, (2). <https://doi.org/10.11588/dah.2016.2.23376>
3. Karaev, S., Hertzmann, A., & Winnemoeller, H. (2013). Recognizing image style. *ArXiv preprint arxiv:1311.3715*. <https://doi.org/10.48550/arXiv.1311.3715>
4. Lecoutre, A., Negrevergne, B., & Yger, F. (2017). Recognizing art style automatically in painting with deep learning. *Proceedings of the Ninth Asian Conference on Machine Learning*, (77), 327–342. <https://hal.science/hal-02004781>
5. Sandoval, C., Pirogova, E., & Lech, M. (2019). Two-Stage deep learning approach to the classification of fine-art paintings. *IEEE Access*, 7, 41770–41781. <https://doi.org/10.1109/access.2019.2907986>
6. Cetinic, E., Lipic, T., & Grgic, S. (2018). Fine-tuning convolutional neural networks for fine art classification. *Expert Systems With Applications*, 114, 107–118. <https://doi.org/10.1016/j.eswa.2018.07.026>
7. Li, B., & Venkatesan, R. (2017). *Convolutional neural networks in visual computing: A concise guide*. Taylor & Francis Group.

- 
8. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
  9. Wang, S., Gao, Z., & Liu, D. (2022). Swin-GAN: Generative adversarial network based on shifted windows transformer architecture for image generation. *The Visual Computer*. <https://doi.org/10.1007/s00371-022-02714-9>
  10. *Generative models*. OpenAI. <https://openai.com/research/generative-models>
  11. di Lenardo, I., Seguin, B., & Kaplan, F. (2016). Visual patterns discovery in large databases of paintings. *Digital Humanities, Krakow, Poland*.
  12. Wetering, E. V. D. (2014). *A corpus of Rembrandt paintings VI: Rembrandt's paintings revisited - A complete survey*. Springer.
  13. Frank, S. J., & Frank, A. M. (2020). Analysis of dutch master paintings with convolutional neural networks. <https://doi.org/10.48550/arXiv.2002.05107>
  14. Andrzejewski, D., Stork, D. G., Zhu, X., & Spronk, R. (2010). Inferring compositional style in the neoplastic paintings of Piet Mondrian by machine learning. *Proceedings of SPIE - The International Society for Optical Engineering*, 7531. <https://doi.org/10.1117/12.840558>
  15. Itten, J. (2009). *Elements of color*. Wiley & Sons, Incorporated.