

До проблеми активних методів детекції та верифікації ШІ-генерованого контенту: метадані провенансу C2PA

Ігор Римар

кандидат історичних наук, завідувач відділу дослідження звуко- та відеозапису, лабораторія досліджень у сфері інформаційних технологій, Київський науково-дослідний експертно-криміналістичний центр Міністерства внутрішніх справ України, м. Київ, Україна, ORCID: <https://orcid.org/0000-0001-6153-0900>, e-mail: igor.rymar@outlook.com

Ганна Тулайдан

старший судовий експерт, відділ фототехнічних та портретних досліджень, лабораторія досліджень у сфері інформаційних технологій, Київський науково-дослідний експертно-криміналістичний центр Міністерства внутрішніх справ України, м. Київ, Україна, ORCID: <https://orcid.org/0009-0003-1192-5981>, e-mail: annatulaydan@gmail.com

Докладно розглянуто стандарт C2PA та інструментарій c2patool, виявлено основні обмеження стандарту. Обґрунтовано необхідність гібридного підходу для аналізу ШІ-генерованого контенту та сформульовано рекомендації щодо практики документально орієнтованого обміну цифровими доказами в діяльності слідчих та оперативних співробітників.

Ключові слова: C2PA; c2patool; штучний інтелект; SynthID.

On the Issue of Active Detection and Verification Methods for AI-Generated Content: C2PA Provenance Metadata

Ihor Rymar, Anna Tulaydan

The paper provides a detailed examination of the C2PA standard and the c2patool utility, identifying the key limitations of the standard. It justifies the necessity of a hybrid approach to analyzing AI-generated content and formulates recommendations for document-oriented digital evidence exchange in the activities of investigators and operational officers.

Keywords: C2PA, c2patool; artificial intelligence; SynthID.

Стрімкий розвиток генеративних моделей штучного інтелекту (далі — ШІ), зокрема дифузійних мереж, великих мовних моделей і відеогенераторів спричинив якісний зсув у характері цифрових загроз: синтетичний контент набув масштабу, доступності та фотореалістичності, що внеможливило його візуальну ідентифікацію без застосування спеціальних знань і ставить під сумнів доказову силу цифрових матеріалів у судових провадженнях. Глобальний звіт про ризики Всесвітнього економічного форуму (2024) назвав дезінформацію та маніпуляцію з медіаконтентом найбільшими глобальними ризиками найближчих років [1]. Для судово-експертної спільноти це означає нагальну необхідність формування верифікованих методологічних підходів до виявлення, ідентифікації та оцінки допустимості як доказу ШІ-

генерованого контенту в умовах відсутності усталених галузевих стандартів і методик.

Продовжуючи дослідження проблеми детекції медіаконтенту, створеного генеративним ШІ [2], звернімося до активних методів виявлення: до C2PA.

C2PA (Coalition for Content Provenance and Authenticity) є відкритим технічним стандартом, розробленим у 2021 році консорціумом Adobe, Microsoft, BBC, Intel, Truepic, Arm та інших організацій під егідою Joint Development Foundation. Поточна версія специфікації (C2PA 2.2, травень 2025 р. [3]) визначає формат *маніфесту провенансу*, що вбудовується безпосередньо у файл цифрового контенту (зображення, відео, аудіо, документ). Маніфест провенансу є своєрідним «ланцюжком зберігання доказів» (*chain of custody*) у цифровому форматі та містить основні компоненти, зазначені у табл. 1.



Таблиця 1

Компоненти маніфесту провенансу C2PA [4; 3]

Компонент	Визначення
Claim	Центральний підписаний об’єкт, що підтверджує сукупність <i>assertions</i> контенту
Assertions	Структуровані записи про дії над контентом (створення, редагування, публікація), використані інструменти, час, геолокацію, ідентифікатор моделі ШІ
Claim Signature	Цифровий підпис <i>PKI (X.509)</i> , що прив’язує <i>claim</i> до конкретного актора
Ingredient Hashes	Хеші (<i>SHA-256/SHA-512</i>) вхідних матеріалів для верифікації цілісності
Hard Bindings	Хеші самого файлу, що унеможливлюють підміну контенту без інвалідації підпису

Маніфест зберігається у форматі *JUMBF (ISO 19566-5)* і вбудовується у відповідний контейнер: *JPEG* (маркер *APP11*), *PNG* (власний *chunk*), *MP4/MOV (uuid box)*, *WebP*, *HEIC*, *PDF* тощо [3]. Стандарт забезпечує верифіковану (а не декларативну) прозорість: факт користування ШІ підтверджено криптографічним підписом виробника інструмента, а не самодекларацією автора. Відкрита специфікація, активна екосистема та поступова інтеграція у соціальні мережі (*LinkedIn*, *TikTok*), упровадження підтримки на рівні апаратного забезпечення провідними виробниками (*Sony*, *Leica*, *Nikon*) формують реальну індустріальну базу стандарту [5]. Національний інститут стандартів і технологій США (*NIST*) схарактеризував *C2PA* як «оптимальний стандарт» для масштабованої прозорості цифрового контенту [5]. Водночас важливо розуміти, що *C2PA* не призначений для автоматичної верифікації достовірності інформації. Він підтверджує лише походження та ланцюжок змін контенту [6].

Офіційною реферативною реалізацією стандарту з відкритим вихідним кодом (*Rust*, ліцензія *Apache 2.0/MIT*), який підтримують *Adobe* і спільнота *C2PA*, є пакет *c2patool*, що забезпечує: читання та відображення мані-

фесту; створення та підписання нового маніфесту із застосуванням сертифікатів *X.509*; перевірку валідності підпису та цілісності хешів; підтримку широкої номенклатури форматів (*JPEG*, *PNG*, *MP4*, *WebP*, *HEIC*, *TIFF* та ін.); *CLI*-інтерфейс та бібліотечний *API*.

Незважаючи на переваги, фундаментальним недоліком є добровільний (*opt-in*) характер стандарту: відсутність маніфесту не є доказом автентичності [6]. *C2PA* не вирішує проблеми «першого підпису» (*first-mile problem*): якщо зловмисник підписує синтетичний контент як автентичний, криптографія підтверджує лише факт підпису, а не відповідність дійсності, що є суттєвим обмеженням у контексті судово-експертної діяльності. Окрім того, офіційна документація стандарту фіксує можливість обходу захисних механізмів через підробку провенансних метаданих та імітацію цифрових відбитків [7]. Інфраструктура відкритих ключів (*PKI*) також потребує верифікованих центрів сертифікації, що залишається невирішеним на рівні глобальної довіри. Основною операційною проблемою *C2PA* в реальних умовах обігу контенту є систематичне знищення маніфестів під час передавання через популярні платформи, що відображено у табл. 2 [5; 8—11].

Таблиця 2

Збереження метаданих провенансу під час передавання через популярні платформи

Платформа / месенджер	Перекодування (стандартний режим)	EXIF / XMP	C2PA	Режим «документ / файл»	Деталізація збереження C2PA (результати експерименту)
WhatsApp	JPEG (40–80%); H.264 (відео); Opus (аудіо)	Ні	Ні	Так (зберігає оригінал для зображень, відео й аудіо)	Перетягування (стандартний): .wav → Так; .jpeg/.jpg, .mp4 (Якість: HD/SD) → Ні; Файлом: .wav/.jpg/.png/.mp4 → Так

Завершення таблиці 2

Платформа / месенджер	Перекодування (стандартний режим)	EXIF / XMP	C2PA	Режим «документ / файл»	Деталізація збереження C2PA (результати експерименту)
Telegram	JPEG (стандартний режим); H.264/H.265 (відео); OGG Opus (аудіо)	Hi	Умовно ¹	Так («без стиснення» / «файлом») — зберігає оригінал і метадані	Без стиснення (стандартний): .wav/.jpg/.png/.mp4 → Так; Файлом: .wav/.jpg/.png/.mp4 → Так; Швидко (стандартний): .mp4 → Так; .jpeg/.jpg → Hi
Viber	JPEG («миттєво»); H.264 (≤720p)	Hi	Умовно ²	Так (зберігає оригінал зображень, відео й аудіо)	Миттєво (стандартний): macOS 26.4.1: .jpg/.png → Так; Android 16: .jpg → Hi; Оригінал: .jpg/.png → Так; Перетягуванням: .wav/.mp4 → Так; Файлом: .wav/.jpg/.png/.mp4 → Так
Facebook	JPEG/WebP; H.264	Hi	Hi	Недоступний	Повідомленням/Публікація: .jpg/.jpeg/.mp4/.webp → Hi ³
Instagram	JPEG/WebP; H.264	Hi	Hi	Недоступний	Публікація (yt-dlp ⁴ /gallery-dl ⁵)/ Повідомленням: .jpg/.mp4 → Hi
Twitter / X	JPEG/WebP; H.264	Hi	Hi	Недоступний	Публікація (yt-dlp): .jpg/.mp4 → Hi
TikTok	H.264/H.265 (обов'язкове)	Hi	Hi	Недоступний	Публікація: .mp4 → Hi
LinkedIn	Помірне JPEG	Hi ⁶	Hi ⁶	—	Повідомленням (зображенням, файлом): .jpeg/.jpg/.png → Hi; Публікація: macOS 26.4.1: .jpeg → Hi; Windows 11 (Chrome DevTools ⁷): .mp4 → Hi
YouTube	VP9/AV1/H.264	Умовно	Hi	—	Публікація: .mp4 → Hi

Примітка. «Так» — метадані збережені в усіх перевірених сценаріях; «Умовно» — часткове збереження або залежить від режиму передавання / операційної системи; «Hi» — метадані не збережені в жодному зі стандартних сценаріїв. Результати експерименту (квітень 2026 р.) є попередніми, потребують підтвердження / уточнення / корегування із застосуванням більшого масиву експериментальних даних (фото / відео / аудіо) і платформ / месенджерів.

¹ Telegram / C2PA: у стандартному режимі («швидко») C2PA не зберігається для зображень. Режими «без стиснення» і «файлом» забезпечують збереження C2PA для всіх форматів (.wav, .jpg, .png, .mp4) на macOS 26.4.1 та Android 16. У режимі «швидко» відеофайли (.mp4) зберігають C2PA, зображення (.jpeg/.jpg) — ні.

² Viber / C2PA: у стандартному режимі «миттєво» C2PA зберігається на macOS 26.4.1 (.jpg, .png), але не зберігається на Android 16 (.jpg). Режими «оригінал», «перетягуванням» і «файлом» забезпечують збереження C2PA на обох платформах. Режим «файлом» підтримує всі формати (.wav, .jpg, .png, .mp4).

³ У деяких файлах частково збережено ter DigitalSourceType (MediaInfo, v. 26.01), що фіксує «Created using Generative AI». C2PA-маніфест відсутній.

⁴ yt-dlp — багатофункціональний завантажувач аудіо / відео командного рядка з підтримкою тисяч сайтів. Проект є форком youtube-dl, заснованим на нині неактивному youtube-dlc.

⁵ gallery-dl — кросплатформний інструмент з багатьма параметрами командного рядка й налаштування, а також потужними можливостями іменування файлів.

⁶ LinkedIn / C2PA та EXIF/XMP: експеримент не виявив збереження C2PA-маніфесту в жодному із перевірених сценаріїв завантаження (macOS 26.4.1, Android 16 і Windows 11), підтримка Content Credentials стосується лише відображення інформації платформою для завантажених матеріалів, але не гарантує збереження C2PA у файлах під час завантаження.

⁷ Chrome DevTools — набір інструментів веброзробника, убудованих безпосередньо в браузер Google Chrome (та ін. на базі Chromium). Вони дають змогу редагувати сторінки в реальному часі, діагностувати проблеми, налагоджувати HTML, CSS і JavaScript, аналізувати продуктивність сайту й мережевий трафік.



Отже, поведінка платформ є свідомим архітектурним рішенням, спрямованим на забезпечення стандартизації, конфіденційності й оптимізації трафіку [12; 10], а не наслідком компресії даних. За стандартної передачі медіаконтенту через соціальні мережі та месенджери маніфести C2PA майже гарантовано знищуються, що внеможливорює верифікацію походження ШІ-генерованого контенту на стороні отримувача. Критичним чинником для відео- (MP4/MOV) та аудіофайлів (MP3, WAV) є процедура транскодування: навіть за збереження вихідного контейнера, будь-яке перекодування потоку в стрімінгові формати (такі як Opus, AAC або

VP9) призводить до незворотного видалення службових блоків метаданих (*uuid box* у відеофайлах, *ID3v2*, *RIFF-INFO* в аудіофайлах), що узгоджується з попередніми спостереженнями щодо проблематики збереження метаданих у цифрових розслідуваннях [12]. Тож для потреб судової експертизи єдиним надійним методом передачі медіаданих працівниками слідчих та оперативних підрозділів, що забезпечує цілісність метаданих провенансу, залишається режим «документ / файл».

Наявні сьогодні шляхи розв'язання проблеми метаданих провенансу наведено у схемі далі.




Схема «Шляхи збереження метаданих провенансу»

Отже, незважаючи на те, що метадані провенансу C2PA є найбільш технічно зрілими і криптографічно обґрунтованими з-поміж наявних активних механізмів маркування ШІ-генерованого контенту [4; 3] і вирішують проблему *верифікованої атрибуції*, вони мають низку суттєвих обмежень, що стосуються проблем *обов'язкового маркування* [15], крихкості маніфестів — це суттєво обмежує практичну придатність C2PA в контексті криміналістичного дослідження [7; 6; 10] — і потребують гібридного підходу (аналіз C2PA-маніфесту (за наявності) + верифікація через хмарне сховище *Content Credentials* + аналіз перцептивно-стійкого водяного маркування

(наприклад, *SynthID*) + пасивні методи дослідження) для аналізу ШІ-генерованого контенту. Подальший розвиток стандарту C2PA покликаний виробити дійсно корисний і потужний інструмент, який у поєднанні з аналітичними методами дасть змогу з великою часткою ймовірності досліджувати й ідентифікувати контент, генерований ШІ.

Перелік джерел посилання

1. World Economic Forum. Global Risks Report 2024. Geneva : WEF, 2024. URL: <https://www.weforum.org/reports/global-risks-report-2024> (дата звернення: 12.04.2026).

2. Рymar I., Тулайдан Г. До проблеми методів детекції медіаконтенту, створеного за допомогою генеративного штучного інтелекту, під час проведення судової експертизи. *Актуальні питання експертного забезпечення правосуддя у справах адміністративної юрисдикції: сучасний стан та перспективи розвитку* : зб. мат-лів Міжнар. наук.-практ. конф. (Харків — Київ, 25.02.2026). Харків, 2026. С. 360—363. URL: <https://res2.weblum.site/res/64e5d4a1196a4b000eb26345/69ae823c2235cac5e127d5c7> (дата звернення: 12.04.2026).
3. Coalition for Content Provenance and Authenticity (C2PA). *C2PA Technical Specification v2.2. Joint Development Foundation*. 2025. URL: <https://surl.li/isnmvk> (дата звернення: 12.04.2026).
4. Coalition for Content Provenance and Authenticity (C2PA). *C2PA Technical Specification v2.1. Joint Development Foundation*. 2024. URL: <https://surl.li/yfhfrt> (дата звернення: 12.04.2026).
5. Coalition for Content Provenance and Authenticity (C2PA). *Response to NIST AI 100-4: Reducing Risks Posed by Synthetic Content*. 2024. URL: <https://surl.li/tlckhd> (дата звернення: 12.04.2026).
6. Kaye K., Dixon P. Privacy, Identity and Trust in C2PA: A Technical Review and Analysis of the C2PA Digital Media Provenance Framework. *World Privacy Forum*. 2025. URL: <https://world-privacyforum.org/posts/privacy-identity-and-trust-in-c2pa/> (дата звернення: 12.04.2026).
7. Coalition for Content Provenance and Authenticity (C2PA). *Security Considerations. Joint Development Foundation*. 2024. URL: <https://surl.li/dfjlww> (дата звернення: 12.04.2026).
8. Arshad M., Ahmad A., Onn C. W., Sam E. A. Investigating methods for forensic analysis of social media data to support criminal investigations. *Frontiers in Computer Science*. 2025. Vol. 7. Art. 1566513. DOI: 10.3389/fcomp.2025.1566513 (дата звернення: 12.04.2026).
9. Content Credentials: Strengthening Multimedia Integrity in the Generative AI Era. *U. S. National Security Agency. Cybersecurity Information Sheet*. 2025. URL: <https://surl.li/bjpths> (дата звернення: 12.04.2026).
10. Soni N. Forensic Value of Exif Data: An Analytical Evaluation of Metadata Integrity across Image Transfer Methods. *Perspectives in Legal and Forensic Sciences. SCIEPublish*. 2025. Vol. 2. Is. 2. DOI: 10.70322/plfs.2025.10006 (дата звернення: 12.04.2026).
11. The Promise and Risk of Digital Content Provenance. *Center for Democracy and Technology (CDT)*. 2025. URL: <https://surl.lu/wwjqyn> (дата звернення: 12.04.2026).
12. Marin M. Sending Encrypted Photos While Preserving Metadata. *Citizen Evidence Lab*. 2020. URL: <https://surl.li/woxkqm> (дата звернення: 12.04.2026).
13. Watermarking AI-Generated Text and Video with SynthID. *Google DeepMind*. 2024. URL: <https://deepmind.google/blog/watermarking-ai-generated-text-and-video-with-synthid/> (дата звернення: 12.04.2026).
14. Dathathri S., See A., et al. Scalable watermarking for identifying large language model outputs. *Nature*. 2024. Vol. 634. P. 818–823. DOI: <https://doi.org/10.1038/s41586-024-08025-4> (дата звернення: 12.04.2026).
15. Code of Practice on Marking and Labelling of AI-generated Content (second draft). *European Commission*. March 2026. URL: <https://surl.li/fovlkv> (дата звернення: 12.04.2026).