

DOI: 10.53104/xdkxsts.2025.01.02.002

# AIGC 生成內容的權威性與品質控制科學知識生成中的驗證與評價 機制探討

陳明<sup>1</sup>

1. 南京師範大學，江蘇 南京，210023

**摘要：**人工智慧生成內容（AIGC）技術持續高速演進推動知識生產與傳播模式發生深度轉型，AIGC 在文本創制、圖像生成、資料解析與科研協助等多領域落地大幅提升資訊處理效能與知識創造速率，AIGC 在內容品質與權威特質方面的潛在隱患逐步顯現，科學知識生產與公共傳播領域中其內容真實屬性、可靠特質與可驗證屬性等問題亟需回應。本文系統梳理 AIGC 的技術發展背景與應用現狀從內容品質管控、權威特質驗證與評價機制構建三個維度解析其核心技術邏輯與制度約束條件，研究表明當前 AIGC 內容在真實屬性評估、倫理責任界定與標準化治理方面仍存在明顯缺口集中表現為事實核驗機制不足、演算法偏見積澱與統一品質評估架構缺失。文章進一步探析 AIGC 內容權威性的社會認知基礎與科學驗證機制的結構性難題提出通過搭建可解釋性演算法體系、健全多層次驗證機制、建立跨行業品質基準與倫理治理架構優化 AIGC 知識生成的可信程度，本文認為 AIGC 的未來發展取向應聚焦“科學驗證 — 品質評估 — 社會信任”三維聯動推動人工智慧從“資訊生成”邁向“知識生產”實現技術創新與認知可靠屬性的動態平衡。

**關鍵字：**人工智慧生成內容；權威性；品質控制；驗證機制；知識生成；可信 AI

## Exploring the Authority and Quality Control of AIGC Generated Content in the Verification and Evaluation Mechanisms of Scientific Knowledge Production

CHEN Ming<sup>1</sup>

1. Nanjing Normal University, Nanjing 210023, P.R.China

Correspondence to: CHEN Ming; Email: chen\_ming74@hotmail.com

**Abstract:** The rapid evolution of Artificial Intelligence Generated Content (AIGC) technology has profoundly transformed the modes of knowledge production and dissemination. The application of AIGC across multiple domains—including text creation, image generation, data analysis, and scientific research assistance—has greatly enhanced the efficiency of information processing and the speed of knowledge generation. However, potential risks concerning content quality and authority have gradually emerged, particularly in the fields of scientific knowledge production and public communication, where issues such as factual authenticity, reliability,

收稿日期：2025-11-19 返修日期：2025-12-16 錄用日期：2025-12-22 出版日期：2025-12-31

通信作者：chen\_ming74@hotmail.com

引用格式：陳明. AIGC 生成內容的權威性與品質控制科學知識生成中的驗證與評價機制探討[J]. 現代科學探索, 2025, 1(2): 12-29.

and verifiability of AIGC-generated content demand urgent attention. This paper systematically reviews the technological background and application status of AIGC, analyzing its core technical logic and institutional constraints from three dimensions: content quality control, authority verification, and evaluation mechanism construction. The study finds that current AIGC content still faces significant deficiencies in factual verification, ethical accountability, and standardized governance—mainly reflected in insufficient fact-checking systems, accumulated algorithmic bias, and the lack of unified quality assessment frameworks. Furthermore, the paper explores the social cognitive foundations of AIGC authority and the structural challenges of scientific validation mechanisms. It proposes the construction of explainable algorithmic systems, multi-layered verification frameworks, and cross-industry ethical governance standards to enhance the credibility of AI-generated knowledge. The study concludes that future development of AIGC should focus on a triadic linkage among “scientific validation – quality assessment – social trust,” promoting a transition of artificial intelligence from “information generation” to “knowledge production,” thereby achieving a dynamic balance between technological innovation and epistemic reliability.

**Key words:** Artificial Intelligence Generated Content (AIGC); authority; quality control; validation mechanism; knowledge generation; trustworthy AI

## 引言

人工智慧技術高速發展讓生成式人工智慧內容 (AIGC, AI-Generated Content) 成為當下社會及各行業的重要組成部分，這項融合深度學習、自然語言處理、電腦視覺等技術的內容生成方式能自主產出文章、新聞稿件、廣告構想、學術論著、圖像、音訊及視頻等多種形式成果，為各行各業提供極大便利的同時提升生產效能、降低人力成本，在個性化推薦、內容創作等領域已成為核心驅動力量。

AIGC 技術應用不斷深入使其生成內容的品質與權威性受到廣泛關注，依賴海量歷史資料訓練的 AIGC 模型因資料品質與來源難以完全可靠，導致生成內容在精準度、權威性、客觀性等方面存在潛在風險，且這類內容會受演算法模型自身局限性、輸入資料品質、模型偏差及外部環境變動等多重因素影響，保障 AIGC 內容生成效率的同時確保其品質與可信度成為技術界、學術界及行業發展的重大難題。

AIGC 生成內容的權威性問題尤為突出，資訊傳播節奏加快的當下網路資訊的真實性與精準度面臨前所未有的檢驗，缺乏有效品質管控與驗證機制的 AIGC 內容可能成為誤導公眾、傳播不實資訊的工具並影響社會決策、輿

論走向及公眾信任，而 AIGC 生成內容的評價標準與方法仍處於探索階段，現有品質評判體系與驗證機制未能完全適配這一快速發展的技術領域，建立健全 AIGC 內容品質管控與驗證體系成為保障其各領域健康發展、避免技術濫用引發社會問題的迫切需求。

本文基於 AIGC 生成內容的技術背景與應用現狀，探討其品質管控與驗證機制的現有狀況及面臨的挑戰，具體將圍繞以下方面展開：回顧 AIGC 技術的起源與發展歷程，分析其核心技術架構與工作機理，探究當前 AIGC 技術在各行各業的應用趨勢及主要挑戰；剖析 AIGC 生成內容的品質管控機制，探討現有品質評判標準與管控手段，指出當前品質管控體系的薄弱環節並提出未來優化方向；重點解析 AIGC 生成內容的權威性與可信度，明確二者定義，探究影響 AIGC 內容權威性的各類因素並提出提升內容可信度的策略與實踐路徑；詳細探討 AIGC 內容的驗證與評價機制，分析現有技術與方法的挑戰及創新方向，探究現有驗證體系的優化路徑；總結當前研究成果並提出相關政策建議，對 AIGC 技術未來發展方向進行展望。

AIGC 的快速發展帶來極大便利的同時伴隨不可忽視的風險，全球資訊化進程持續提速背景下有效保障 AIGC 生成內容的品質、權威

性及社會價值成為技術發展無法回避的重要課題，本文旨在為這一課題的解決提供理論支撐與實踐框架，推動 AIGC 相關領域的深入研究与技術創新，為政策制定者提供參考以助力 AIGC 技術健康發展。

本研究期望為完善 AIGC 生成內容的品質管控與驗證機制提供有力支撐，增進社會對 AIGC 技術的正確認知與合理運用，確保其在更健康、更可控的環境中發揮更大社會效益。

## 1 AIGC 生成內容的技術背景與現狀

### 1.1 AIGC 技術的起源與發展

AIGC（人工智慧生成內容）作為新興技術領域依託人工智慧技術演進形成，深度學習、自然語言處理與電腦視覺的快速發展為其提供核心支撐，通過演算法模型自主產出與人類創作成果相近的文本、圖像、視頻等內容，脫離傳統人工創作流程的約束，背後基礎理論與實踐應用已通過長期反覆運算實現逐步完善<sup>[1]</sup>。

AIGC 技術的雛形源自人工智慧早期探索階段，20 世紀 50 至 80 年代 AI 領域研究集中於邏輯推演與符號運算，這一時期的電腦程式僅用於執行特定規則與任務不具備創意發揮或內容生成能力，90 年代機器學習技術興起讓 AI 逐步獲得學習與資料處理能力進入“弱人工智慧”階段，得以在特定領域內完成指定工作。

21 世紀人工神經網路與深度學習的崛起為 AIGC 技術發展奠定堅實基礎，卷積神經網路（CNN）、遞迴神經網路（RNN）及生成對抗網路（GAN）等深度學習模型實現 AIGC 技術的革命性突破，電腦借助深度神經網路從海量資料中捕捉複雜模式並開展自我訓練，最終具備自主生成內容的能力。

2014 年 Ian Goodfellow 團隊提出的生成對抗網路（GAN）成為 AIGC 技術發展的關鍵節點，該模型通過對抗性訓練模式讓生成模型更精準類比真實資料的分佈特徵，使其在圖像、視頻及文本生成等領域展現出前所未有的能力，既能產出高度逼真的圖片也能依據少量輸

入創作富有創意的藝術作品、廣告文案等內容。

GAN 的成功推動圖像生成領域進步的同時激發文本生成領域的研究熱潮，基於 Transformer 架構的生成模型（如生成預訓練 Transformer GPT）實現自然語言處理技術的重大突破，GPT 系列模型通過預訓練與微調的結合生成語法規範、語義豐富的自然語言文本，確立在文本生成領域的標杆地位<sup>[2]</sup>。

OpenAI 推出的 GPT-1、GPT-2 及 GPT-3 系列生成預訓練語言模型在自然語言生成任務中表現卓越，其中 GPT-3 以 1750 億參數規模引發學術界與工業界廣泛關注，可完成文本創作、代碼編寫、對話生成、詩歌創作等多項任務，既提升 AIGC 在文本內容生成領域的品質水準也拓展其應用邊界。

GPT-3 的普及應用讓 AIGC 技術影響力快速滲透至教育、醫療、金融、媒體、娛樂等多個行業，在自動寫作、智慧客服、情感分析、文本摘要等場景得到實際應用，圖像生成領域通過 DALL·E 等模型實現文本到圖像的順暢轉換，有效推動 AIGC 技術在實際場景中的落地實施。

深度學習與多工學習的發展讓 AIGC 應用突破單一資料類型限制，多模態生成技術成為 AIGC 領域的研究前沿，這類技術整合圖像、視頻、文本等多種資料形態實現跨模態資訊的生成與轉化，OpenAI 的 DALL·E 模型可依據文本描述創作高度擬真且富有創意的視覺作品，CLIP 模型實現視覺資訊與語言資訊的融合推動圖像理解與生成的跨領域協同。

多模態生成技術拓展 AIGC 在藝術創作、品牌行銷、娛樂內容製作等領域的應用範圍，技術升級帶來深度學習模型泛化能力的持續提升，AIGC 已能依據用戶輸入的少量提示或指令生成具備高度定制化與創新性的內容，使用者通過與 AI 的交互可快速獲取符合自身需求的創意成果顯著提升創作效率。

未來 AIGC 技術將朝著生成品質更優、應用場景更廣、個性化程度更高的方向持續演進，計算能力的提升與演算法的優化將推動 AIGC 在生成速度、內容多樣性與創意性方面實現更大突破，自然語言處理、電腦視覺與語音生成



等領域的融合應用將使其在更多新興行業中發揮重要作用。

AIGC 技術的普及應用讓保障生成內容的品質、準確性與可信度成為日益關鍵的議題，技術的快速發展既需要技術層面的持續革新也需要完善相應的品質控制、驗證機制及倫理法規，技術、標準與監管的協同發力才能推動 AIGC 走向成熟，為各行業創新發展提供堅實支撐。

AIGC 技術的起源與發展歷程映射人工智慧領域的迅猛進步，從早期簡單自動化任務到如今高複雜度內容生成，AIGC 已成為推動社會變革與行業發展的重要力量，技術的持續突破與應用場景的不斷拓展將讓其在未來內容生產與創作領域發揮愈發重要的作用。

## 1.2 AIGC 的核心技術架構與原理

AIGC（人工智慧生成內容）的核心技術架構與原理以多種前沿人工智慧方法及深度學習模型為支撐，生成對抗網路（GAN）、自回歸模型（如 GPT）、變分自編碼器（VAE）及多模態學習構成核心支撐體系，這些技術共同實現對人類創作類內容的理解與學習並生成形態相似的文本、圖像、音訊、視頻等，以下詳細拆解其核心技術架構與運作機理。

### 生成對抗網路（GAN）

生成對抗網路（GAN）是 AIGC 領域的核心技術支柱，2014 年由 Ian Goodfellow 提出，其結構包含生成器（Generator）與判別器（Discriminator）兩個核心神經網路，二者通過對抗性訓練形成博弈關係，生成器以產出與真實資料高度相似的內容為核心使命，判別器專注辨別生成內容與真實資料的差異。生成器通過持續學習資料分佈特徵從隨機雜訊中衍生圖像、文本等新的資料形態，判別器以區分資料真偽為目標判斷輸入樣本屬性，兩者在競爭中不斷優化生成器持續調整輸出形態直至判別器無法分辨其與真實內容的區別，這種機制讓 GAN 能夠生成高度逼真的各類內容並廣泛應用於圖像生成、文本創作及多模態內容生成等場景。

### 自回歸模型（如 GPT）

自回歸模型是 AIGC 技術體系中的重要架構，在自然語言處理（NLP）領域應用尤為廣泛，OpenAI 推出的 GPT 系列（Generative Pretrained Transformer）是該類模型中最具代表性的範例，其基於 Transformer 架構採用自回歸生成模式通過逐一生成詞彙或符號並借助已生成內容片段推測後續詞彙。GPT 模型先在海量的無標籤資料中完成預訓練掌握語言的統計特徵與上下文關聯，在無監督環境中積累廣泛語言知識後通過微調（Fine-tuning）適配文本生成、對話交互、情感研判等特定任務需求，依託對海量資料的學習積累 GPT 能夠生成連貫規範、語義豐富的自然語言文本並勝任文章創作、代碼編寫、語言翻譯等複雜語言類任務。

### 變分自編碼器（VAE）

變分自編碼器（VAE）是生成模型領域的常用技術，植根於概率圖模型的生成類框架，核心目標是通過學習資料潛在分佈特徵生成全新資料，其核心邏輯是編碼器將輸入資料轉換至潛在空間（Latent Space）維度解碼器再從這一空間還原原始資料特徵，訓練過程中 VAE 持續優化潛在空間分佈讓生成資料不斷逼近真實資料形態。與傳統自編碼器相比 VAE 引入概率模型設計通過變分推斷方式逼近真實資料分佈，進而產出更具真實性的資料樣本，在 AIGC 應用場景中 VAE 常被用於圖像生成、語音合成等領域且尤其適配需要多樣化內容輸出的使用場景。

### Transformer 架構與多頭注意力機制

Transformer 架構在 AIGC 技術中具有不可替代的關鍵作用，處理文本、語音、時間序列等序列資料時優勢尤為突出，不同於傳統遞迴神經網路（RNN）與長短時記憶網路（LSTM），Transformer 借助“自注意力機制”（Self-Attention）並行處理序列中的全部元素顯著提升計算效率與模型表達能力。自注意力機制通過計算序列中每個元素與其他所有元素的關聯程度捕捉長距離依賴關係，彌補傳統 RNN 與 LSTM 處理長序列時的資訊損耗缺陷，Transformer 架構中的多頭注意力機制允許模型在同一層級並行關注輸入序列的多個子空間進一步強化模型表現力。在 AIGC 領域 Transformer 廣泛應用於文本生成、機器翻譯、

語音合成等任務，成為 GPT、BERT、T5 等大規模預訓練模型的核心基礎，其強大的處理能力支撐 AIGC 生成高品質文本內容並在多模態生成任務中發揮關鍵賦能作用。

#### 多模態學習與生成

AI 技術的持續演進讓 AIGC 應用場景突破單一資料模態限制，多模態學習 (Multimodal Learning) 已成為當前 AIGC 領域的重點研究方向，這類學習模式指 AI 系統能夠同步解讀處理文本、圖像、音訊、視頻等多種不同模態的資料資訊並實現跨模態的資訊轉換及內容生成。OpenAI 的 DALL·E 模型可依據文本描述生成對應圖像，CLIP 模型則融合圖像與文本資訊完成圖像理解與搜索任務，多模態生成技術充分利用不同模態間的共性特徵與互補優勢，讓 AIGC 在廣告創意自動生成、視頻內容製作、跨語言翻譯等更多場景中實現高效創作與生產。

#### AIGC 的生成原理與演算法

AIGC 的生成過程可簡要歸納為模型通過訓練從海量真實資料中掌握資料的分佈特徵與規律再依託演算法完成內容生成，文本、圖像、音訊等各類生成任務的核心原理均為通過訓練讓模型在輸入文本、關鍵字、圖像描述等給定條件下產出滿足需求的目標內容。生成內容的品質與創意表現通常與訓練資料的品質及多樣性密切相關，通過持續優化訓練流程 AIGC 能夠生成具備高度創新性與複雜結構的內容，部分場景中 AIGC 還可借助生成對抗機制、強化學習等方式進一步提升生成內容的品質與多樣性水準。

#### AIGC 技術架構的整合

當前 AIGC 技術架構愈發重視模組化設計與跨領域融合，多個生成模型、學習演算法及資料來源可協同運作提升生成內容的品質與適用範圍，文本與圖像生成任務中，文本生成模型先輸出基礎文本內容再與圖像生成模型配合，通過 DALL·E 等技術生成契合文本描述的圖像，多模態 AI 平臺將各類技術整合銜接形成更為完整強大的 AIGC 技術架構體系，適配更廣泛的應用需求<sup>[1]</sup>。

### 1.3 當前 AIGC 應用的行業趨勢與挑戰

人工智慧技術持續演進推動 AIGC (人工智慧生成內容) 在媒體、廣告、教育、醫療等多個行業深度落地，各領域均在主動探尋 AIGC 催生的行業變革，這類技術落地既提升生產運轉效率也給內容創作賦予更多創新方向與實現可能，AIGC 在實際場景應用中仍面臨不少現實難題，內容品質管控、倫理規範約束、版權歸屬界定等層面問題尤為突出，下文從行業應用趨勢與核心挑戰兩大維度展開深入剖析。

#### 1.3.1 行業趨勢

##### 內容創作領域的創新引領

AIGC 在內容創作領域滲透最為深入，新聞傳播、文學創作、廣告策劃等行業均有廣泛應用，GPT 系列、BERT 等自回歸模型已能自主完成新聞稿件撰寫、小說詩歌創作甚至科學研究論文框架草擬。廣告行業中 AIGC 被用於快速產出廣告文案、產品推介內容及行銷推廣方案，既提升創意從業者工作效能也有效控制人力投入成本。依託 GAN 技術的圖像生成平臺 (如 OpenAI 的 DALL·E) 可依據使用者文字描述產出高品質圖像，Deepfake 技術在影視製作、娛樂產業及虛擬實境 (VR) 領域獲得較多運用，借助 AIGC 相關技術打造虛擬角色與場景環境，技術持續升級將進一步推動個性化內容創作發展，更好滿足使用者對定制化內容的實際需求。

##### 教育領域的智慧化革新

AIGC 在教育行業發展空間十分可觀，能為學習者提供定制化學習素材並自主生成練習題目、解題思路及學習評價，通過對話交互系統協助學生解決學習過程中各類問題，語言習得與程式設計教學場景中 AIGC 相關技術已能為學習者打造多樣化練習資源，助力學生依照自身學習節奏與個性化需求開展自主學習。AIGC 還被用於教育資源智慧化產出，自動構建線上課程體系、編制教學講義及製作教學視頻等，這種智慧化內容生產模式既提升教育資源可獲取程度也有效降低教師教學壓力，推動教育事業朝著普及化與智慧化方向穩步發展。

##### 金融領域的智慧分析與報告編制

金融行業中 AIGC 核心應用集中在資料解讀、報告編制與智慧客戶服務等場景，能自

動生成財務分析報表、市場動態研判報告及投資參考建議，幫助金融從業者高效解析海量資料資源並為客戶提供貼合個人需求的投資規劃方案。AIGC 可借助自然語言生成技術（NLG）搭建智慧問答平臺，優化客戶服務回應速度並減輕人工客服工作負荷。

#### 醫療行業的輔助診斷與健康養護

醫療領域中 AIGC 應用重點集中在醫學影像解讀、病歷概要撰寫、健康管理及定制化醫療服務等方面，通過大規模醫療資料訓練學習 AIGC 相關技術能夠協助醫生生成病例分析報告，為快速確診病症提供輔助支援，醫學影像領域 AIGC 已廣泛用於病灶識別、圖像標記及報告自動生成等工作，大幅提升醫學影像分析效率與精準度。AIGC 在健康管理領域也發揮重要作用，通過生成定制化健康指導方案與飲食搭配建議為用戶提供專屬健康養護規劃，AI 技術不斷進步讓 AIGC 在醫療行業應用前景更為廣闊，人口老齡化社會背景下其技術優勢將得到更為充分的展現。

#### 1.3.2 面臨的挑戰

##### 內容品質管控與偏見規避難題

AIGC 在內容創作方面展現突出應用價值但生成內容的品質水準與精準程度仍存在較高不確定性，部分文本生成模型因訓練資料存在偏向性，產出內容可能包含錯誤資訊、歧視性表述、片面觀點或資訊失實等問題，部分 AI 寫作工具生成的文章可能出現誇大其詞或虛假表述的情況，涉及敏感議題時極易引發倫理層面爭議。解決這一問題需進一步優化 AIGC 模型訓練資料資源，保障資料多元性與公正性，建立健全品質管控機制與驗證流程，確保 AIGC 生成內容符合真實客觀基本準則。

##### 倫理規範與法律界定問題

AIGC 技術落地應用伴隨諸多倫理與法律層面挑戰，生成內容的版權所屬問題已成為行業內熱議焦點，這類內容版權究竟歸屬於誰、內容創作者與 AI 技術開發者之間版權劃分如何界定，目前尚未形成統一界定標準。Deepfake 等技術的不當使用還引發涉及個人隱私、虛假資訊擴散及肖像權侵害等方面的法律與倫理爭議，解決這些問題需要制定針對性法律法規條

文，強化對 AIGC 生成內容的監管力度，將 AIGC 生成內容的來源追溯、責任認定及隱私保護等事項納入法律約束框架，推動行業朝著合規化方向發展<sup>[4]</sup>。

##### 技術模型的可靠性能與透明程度

當前 AIGC 技術雖實現長足發展但多數模型的透明程度與可解釋性均顯不足，用戶難以清晰知曉 AIGC 生成內容的決策邏輯與過程，進而影響 AIGC 應用的可信度與市場接受度，醫療、金融等高風險行業中 AIGC 的“黑箱”特性可能引發決策失誤並造成嚴重不良後果。提升 AIGC 技術可靠性能與透明程度需要未來更加注重模型可解釋性研發，打造能夠向使用者呈現內容生成過程與決策依據的相關工具，同時增強演算法穩定性能避免生成錯誤或有害的內容資訊。

##### 計算資源佔用與能源消耗問題

AIGC 相關技術尤其是基於深度學習的生成模型（如 GPT-3、DALL·E）的訓練與推理過程需耗費海量計算資源，這類大規模模型訓練通常需要高端計算硬體支援且消耗大量能源，帶來沉重的生態負擔與經濟開銷，保障技術性能前提下減少計算資源佔用成為 AIGC 技術發展過程中面臨的重要難題。技術創新可改良模型結構設計提升計算處理效能，推進綠色算力技術發展降低 AIGC 應用對環境造成的影響，這也是行業當前亟待解決的問題。

## 2 AIGC 生成內容的品質控制機制

本章聚焦 AIGC 生成內容在技術與流程維度的品質管控議題，重點探討優質內容的界定標準及現有系統在實際運作中通過哪些技術與管理路徑維繫內容的穩定性與可信度。本章關注的核心是模型輸出在形式與內容層面的可用價值，不涉及權威性、治理屬性或社會信任等宏觀議題，此類內容將在後續章節單獨展開探討。

### 2.1 AIGC 內容品質的界定與評估標準

#### 2.1.1 內容品質的核心要義

AIGC 應用場景下內容品質不再局限于語句通順程度，而是由多個維度共同構成的綜合



屬性集合。首要維度是資訊精準度，涉及事實類資訊的文本必須在資料參數、時間節點、專有名詞及邏輯推演上與可核驗的客觀事實相符，尤其在新聞編撰、政策解讀、醫療科普及科技知識傳播等領域資訊偏差會直接削弱整個系統的實用價值與風險管控能力。任務適配性與語境契合度是另一重要維度，同一內容在不同任務場景中或許會獲得截然不同的評判，技術說明文檔需保證概念界定清晰、操作步驟完整，面向公眾的科普文本則更強調層次清晰、通俗易懂且規避過度專業化表述，生成內容能否匹配具體任務需求與目標受眾的理解水準本身就是品質評判的關鍵維度。

內容的結構編排與語言表達同樣是品質的核心構成，AIGC 生成結果若要真正被使用者接納通常需要在段落組織、論述節奏、句法規範及專業術語運用上達到基礎標準，結構鬆散或內容冗餘堆砌會導致讀者難以捕捉文本核心脈絡，即便資訊本身無誤也會降低實際可讀性與使用意願。創意呈現與非機械複刻也不可忽視，在廣告文案創作、敘事文本撰寫、課程內容設計等場景中生成內容過度依賴範本或固定句式將難以滿足用戶對差異化與新鮮感的需求，適度的表達變異、情境化描述及風格辨識度都是評估 AIGC 內容品質的重要依據。合規性與風險可控性是品質範疇的基礎要求，主要指向內容層面的底線準則如規避仇恨言論、歧視性表述、直白暴力內容或明顯侵權資訊等，責任劃分與監管機制等規範性議題將在後文從制度維度另行探討。

綜合上述維度可知 AIGC 內容品質本質上是多維度權衡的結果，不同應用場景會在精準度、可讀性、創造性與風險管控之間形成不同的組合側重。品質評估的首要工作是明確特定場景下哪些指標被列為優先考量項，哪些是可在合理範圍內調整讓步的次要指標。

### 2.1.2 品質評估的核心標準具體實施層面

AIGC 內容品質的評估通常採用量化指標與質性判斷雙路徑結合的方式。系統會借助一系列可量化的技術指標捕捉語言與結構層面的特徵，例如利用困惑度評估模型對後續詞彙的預測穩定性，借助 BLEU、ROUGE 等指標判定生成文本與參考文本的相似性及覆蓋範圍，或

通過詞彙豐富度與句式變化程度判斷文本是否存在過度範本化問題；對於包含事實陳述的內容部分系統還會設計與外部資料庫或知識庫的比對流程，將關鍵表述與已知權威資料進行匹配進而構建一套近似準確率與可驗證性的量化評估機制。

諸多與創造性、專業性及語境適配性相關的特徵仍需依託人工判斷來精準把握，編輯、審稿人員或專業評審會從結構明晰度、論證完備性、風格統一性及語用恰當性等角度對生成結果展開細緻審查；在醫療、法律、金融等高風險領域專業人員還會核查術語運用是否精準、推理鏈條是否存在斷裂、結論是否超出資料支撐範圍。實際操作中單一指標往往難以覆蓋全部需求，較為常見的做法是將自動化評估作為前置篩選工具再輔以抽樣式或重點式人工評估，兩者互補形成兼具效率與嚴謹性的品質評判體系。

## 2.2 AIGC 品質管控的主要技術與路徑

厘清合格內容界定標準後品質管控核心聚焦於通過系統設計與工作流程規劃讓生成結果穩定貼近既定標準。當前實踐中品質管控呈現多層次疊加格局，自動化檢測、人工審核、資料驅動調整與風險敏感領域強化管控相互協同，構成從前端生成到後端修正的完整管控鏈條<sup>[5]</sup>。

模型輸出文本後系統即刻開展語法與拼寫校驗，標記明顯錯誤或不合語法規範的片段，同時借助語義相似度計算與文本匹配技術核查生成內容與訓練資料或外部語料在短語層面的重合程度，借此管控抄襲隱患與過度複刻問題。部分場景設定敏感詞庫與結構化準則，對涉及特定人群、議題或表述形式的內容實施預警與攔截。這一層級檢測主要針對形式特徵與顯性問題，優勢體現在成本低廉且回應迅捷。

人工審核與專業評估構成品質把關的二次屏障。普通內容由編輯或審核人員集中評估文本是否契合預設用途、語氣是否妥當、是否存在機器難以識別的語義模糊與價值偏差；高風險或高度專業化內容需引入醫師、律師、教師或領域研究者等專業群體，就生成結果中的專業表述與推理邏輯給出具體修改建議。這類人工介入雖無法覆蓋全部輸出，但可針對性聚焦

代表性樣本與關鍵節點，在資源有限前提下最大化提升整體品質與安全閾值。

越來越多系統依託使用者行為資料與主觀回饋優化生成策略，點擊率、停留時長、完讀率及退回刪除操作等均作為反映內容實際使用情況的間接指標。通過 A/B 測試對比不同風格、長度或結構的生成版本系統逐步鎖定特定場景下更易被接納的呈現形式；搭配簡易評分或標注機制讓使用者直接標記“有說明”“資訊失准”“表述晦澀”等問題類型，可在不顯著增加用戶負擔的前提下為後續模型微調與資料清理提供細緻指引。

面向醫療、金融、未成年人相關內容等敏感領域實踐中額外搭建風險強化型審查流程。這類流程通常對輸出內容施加更嚴格的結構與語用約束，例如限制模型出具具體診斷或投資建議轉而採用一般性資訊與風險提示的呈現形式，或明確涉及關鍵決策建議的文本必須經人工或專家覆核後方可對外發佈。同時針對這些領域單獨開展模型微調，使其表達更傾向於保留不確定性與條件限制，減少過度肯定式表述。從品質管控視角看這本質上是依據不同場景的風險承受能力設計匹配的內容生成與審查深度。

### 2.3 現有品質管控機制的技術瓶頸

技術實現與流程設計層面的多層次防護大幅增強 AIGC 內容的穩定度與實用價值，當前階段品質管控仍受限於若干無法規避的技術桎梏。最核心桎梏源自生成機制本身的概率屬性，大型語言模型依託條件概率分佈推演後續詞彙，輸入提示與參數配置完全一致依舊可能輸出差異明顯的結果。這種內在隨機性決定品質波動無法徹底消除，僅能通過反復參數調試與後期修正降低錯誤發生頻率卻難以將風險歸零。

當前自動化評估工具大多局限於淺層特徵識別，對句法失誤、基礎語義矛盾與明顯重複內容的辨識效果較佳，面對論證完備性、推理邏輯性、例證合適性等深層次內容判斷演算法至今仍難以輸出穩定可信的評估結果。這使得高階品質管控在較長週期內不得不持續依託人工審查，人工資源在規模化內容流通場景中必

然面臨成本與效率的雙重制約。

訓練資料的偏差對輸出內容品質形成深遠影響，即便管控環節著重強調資訊準確、內容多元與風險防範，模型訓練階段仍可能從失衡或帶有偏向性的語料中習得特定的敘事範式、視角取向或評價體系。這類偏向未必以顯性錯誤形態呈現，更多表現為風格固化、範式複製與視野局限等問題進而增加後期人工修正與二次編輯的工作量。

人工審核體系自身存在可持續運行與標準統一的難題，當內容生成效率遠超審核承載能力時即便實施抽樣審核與分級把關策略依舊難以杜絕部分問題內容的疏漏。不同審核人員在專業背景、價值取向與風格偏好上的差異會導致對同一文本做出截然不同的評判，進而影響系統長期優化的方向與穩定性。這些技術局限與人力約束共同構成當前 AIGC 內容品質管控無法回避的結構性瓶頸。

### 2.4 未來 AIGC 品質管控機制的優化路徑

立足上述技術與流程約束未來 AIGC 品質管控的發展走向更傾向於從「外掛式核驗流程」轉型為「深度嵌入模型架構與生產流程的全週期管控體系」。一個關鍵發展維度是在模型底層架構中植入更完善的事實核驗與知識約束模組，讓內容生成過程天然整合對外部權威知識庫的實時調取與資訊比對功能。包含專業知識的輸出內容生成過程中模型可同步調取結構化資料或權威資料庫核驗核心表述，視實際需求優化措辭表達或添加不確定性提示語，有效降低「文本流暢度達標但事實性存在偏差」的問題發生率。

另一核心升級路徑是把品質導向的各類回饋信號更體系化地融入模型訓練與參數微調全流程。綜合運用人類標注的偏好序列、任務達成度指標與長期使用者回饋資料，模型能夠在掌握語言生成規律的過程中逐步構建內部的「高品質內容判定體系」，進而在生成階段自主優化輸出風格與資訊密度配置。同期推進品質管控架構的分層化與協同化升級明確機器預審核、人工覆核與專家抽檢的職能邊界，讓各層級管控環節專注於適配自身的問題類型，實現成本可控前提下關鍵內容深度審查的持續落



地。

第三大核心方向是推動使用者回饋的系統化整合與高效應用使其在未來品質管控體系中佔據更關鍵的地位。通過搭建簡潔直觀的回饋入口持續歸集資訊錯誤、表達晦澀與風格失配等實際問題案例，系統可在反覆運算運算與參數更新中不斷校正模型固有偏向，推動品質管控從靜態的「標準條目集合」升級為與使用場景同步演進的動態適配機制。從長遠發展視角分析只有當品質管控邏輯真正深度融入模型架構設計、資料治理體系與全流程生產環節，AIGC 內容生產才能在保留創新活力的基礎上持續維持行業所需的穩定性與結果可預期性<sup>[6]</sup>。

### 3 AIGC 生成內容的權威性與可信度分析

#### 3.1 AIGC 權威性與可信度的概念界定

AIGC 深度融入知識生產與資訊流通場景中“權威性”與“可信度”不再局限於內容屬性範疇，而是演變為使用者在具體情境中完成的判斷過程。權威性核心指向知識是否被認可為“合規”“專業”“可信賴”，可信度更多體現為個人獲取資訊時形成的主觀確信度。兩者不存在簡單對等關係，部分內容可能在形式層面具備高度權威性卻未必獲得使用者的實質信賴，一些來源不明的生成內容也可能在具體場景下被認定為“足夠可信”<sup>[7]</sup>。

AIGC 區別於傳統知識生產體系不依賴清晰的作者標識或機構擔保，其權威性難以通過“來源可查證”的方式予以確認。這一前提下使用者對內容的判斷不再以作者或機構為核心依據，更多依賴內容本身的呈現形態、語言範式與邏輯框架。AIGC 的權威性並非外部賦予而是在資訊接收過程中持續建構而成，這一建構過程並非單次完成而是融入個人的使用體驗、媒介認知能力以及已有知識體系之中。

可信度的生成同樣具備鮮明的主體性特質。使用者判斷 AIGC 內容可信度時通常不會開展嚴謹的事實核驗，而是依據內容的連貫性、表達的篤定程度以及與自身經驗的匹配度快速形成判斷。這一判斷模式並非“非理智”，而

是在資訊高度飽和環境中形成的實際適應策略。日常應用場景下可信度更多體現為“可接納性”，即內容是否能夠納入個人的理解框架進而用於指導行動或決策。

#### 3.2 AIGC 權威性的主體內化路徑

AIGC 生成內容可在缺失明確知識溯源依據的前提下建立權威屬性，核心邏輯在於其權威屬性並非由外部賦予而是經由使用者的持續應用與心理內化過程逐步構建。使用者多次接觸生成內容過程中會逐步形成對其語言範式與接聽模式的熟悉度，這種熟悉度本身即構成信任的底層基礎。生成內容在各類場景中呈現“邏輯自洽”“回應適宜”特徵時其權威屬性便無需額外的外部佐證。

這一過程中主體並非被動接收資訊而是在持續優化自身的判斷維度與標準，原本需要依託權威來源進行核驗的內容逐步被替換為對“表述是否周全”“邏輯是否貫通”的直觀評估。長此以往權威的內涵便從“來源具備可信度”轉變為“回應契合預期設想”，這種認知轉變並非由平臺強制引導而是在個體層面潛移默化地發生，屬於典型的自我調適機制。

這種權威內化過程並不代表主體徹底喪失獨立判斷的能力，大量使用者在實踐過程中構建起一套“經驗導向的篩選體系”，例如針對涉及專業風險的問題保持審慎態度對日常資訊則給予相對較高的信任權重。這種差異化的判斷模式表明 AIGC 權威屬性的形成並非單向線性過程，而是與具體使用場景及個體經驗儲備存在緊密關聯。

#### 3.3 可信度判斷中的自我治理邏輯

相較於權威屬性可信度更直觀地呈現為主體層面的自我治理行為，缺失明確外部規範約束的前提下使用者需要獨立承擔判斷內容真偽與潛在風險的責任。這種責任並未以制度化的形式予以明確而是以內在化的方式滲透到日常使用行為當中，個體在使用 AIGC 的過程中往往會持續進行自我提示如“不可全盤採信”“需自主再次判斷”，這類自我提示本身就是一種治理機制的具體表現。

實際應用過程中可信度的判斷並非通過系統性的核查流程完成，而是借助對內容“是否

具備合理性”的快速評估來實現。使用者並非追求內容的絕對正確性而是尋求一種具備可操作性的確定感，這種確定感並非源自外部權威的背書而是來自主體對自身判斷能力的內在信任。本質而言可信度的維繫依賴於主體持續確認“自身具備判斷能力”的主觀感知，而非內容本身所具備的客觀真實性。

這種自我治理邏輯在一定範圍內緩解了資訊不確定性引發的焦慮情緒，同時也可能掩蓋潛藏的各類風險。主體過度依賴自身經驗開展判斷時錯誤資訊並不會被及時識別，反而可能在多次使用過程中被逐漸合理化。由此可見可信度並非一種穩定不變的狀態，而是一個持續被協商、被調整修正的動態過程<sup>[8]</sup>。

## 4 AIGC 內容的驗證與評價機制

### 4.1 AIGC 內容驗證的現有技術與實現路徑

AIGC 生成內容的驗證環節是保障其真實屬性與可信特質的核心支撐，人工智慧在內容創作與傳播領域的應用場景持續拓展，通過技術手段實現 AI 生成資訊的識別核驗與溯源已成為學術研究與產業實踐領域的共同聚焦方向。當前 AIGC 內容驗證主要依託多層級技術路徑與演算法架構，涵蓋文本一致性檢測、事實核查演算法、模型特徵識別及多源交叉驗證等實施模式。

文本一致性與語義匹配檢測屬於基礎層級的驗證手段，這類方法通過比對生成內容與權威資料庫或既有文獻資源的語義相似程度評估其是否與客觀現實事實保持一致。部分自然語言處理系統運用語義匹配演算法或上下文相似度計算（如余弦相似度演算法）對 AI 生成文本開展事實一致性校驗，該方式廣泛應用於新聞生成與科學文本審查場景能夠有效識別模型輸出中的“偽事實陳述”與邏輯矛盾，卻仍受限於資料覆蓋範圍與演算法識別精度。

事實核查演算法在 AIGC 驗證體系中佔據核心地位，這類技術主要依託知識圖譜、關係抽取與實體連結等手段將生成內容中的核心資訊要素（如時間座標、事件脈絡、人物資訊、數值參數）與權威知識庫進行匹配校驗。學術文本或政策分析生成場景中可通過知識圖譜比

對機制判斷文本引用資料的真實屬性，近年來部分 AI 實驗室已開發自動事實核查系統（如穀歌事實核查工具）能夠對生成文本中的關鍵陳述進行自動標注與證據檢索提升驗證流程效率，該技術仍存在語境依賴難題針對隱含性推理或複雜敘事場景的核驗能力相對不足。

模型特徵識別與生成軌跡溯源是區分 AI 生成內容與人工創作成果的重要手段，AIGC 生成內容往往具備獨特的語言分佈特徵、句式結構與概率模型可通過統計學習演算法識別其中的“模型特徵標識”。OpenAI 與斯坦福大學聯合研發的“AI 文本浮水印技術”通過在生成語料中植入特定統計特徵實現後期演算法檢測識別，這類方法為 AI 內容的可追溯性提供技術支撐卻同時面臨反向規避與模型模仿攻擊的實際挑戰。

多源交叉驗證機制在高可信度需求場景中的受關注程度持續提升，該方法通過整合多管道資訊來源（如資料庫資源、新聞機構素材與人工審核結論）對 AI 生成內容開展綜合驗證。科學研究與政策諮詢領域中多源交叉驗證常與人工評估相結合構建“人機協同”的驗證體系，確保內容既在資料層面準確無誤又在邏輯層面保持連貫自治。

人工參與及專家評估機制仍是 AIGC 驗證體系中不可或缺的構成部分，針對複雜模糊或高風險內容（如醫學診斷報告、學術論著、法律文書）單純依靠演算法驗證難以保障精準程度需引入人工評估流程結合專家專業知識開展事實核驗。專家審查在 AI 新聞編輯、科技報告撰寫與學術出版場景中應用廣泛，是提升 AI 生成內容權威屬性的關鍵補充手段<sup>[9]</sup>。

### 4.2 AIGC 生成內容的評價體系與核心標準

AIGC 生成內容的評價體系與核心準則是衡量其品質等級、可信屬性與社會影響邊界的核心依據，區別於傳統人工創作模式 AIGC 內容生產依靠演算法邏輯與資料訓練構建，評價過程需同步考量技術性能表現、內容核心屬性與倫理規範要求三個維度。當前 AIGC 評價體系正逐步從單一技術評估轉向綜合性標準框架，形成以內容品質等級、事實精準度、可解釋屬性與社會責任履行度為核心的多層級評價架



構。

內容品質評價是 AIGC 評估的核心基礎維度，主要聚焦生成內容的語言表達流暢度、邏輯連貫度與語義合理性，常用自動化指標包括困惑度、BLEU 評分（用於文本生成精準度評估）及 ROUGE 指標（用於摘要撰寫與文本相似性判斷）。實際應用場景中研究機構通常結合機器評估與人工打分，通過設立“內容流暢度”“結構連貫性”“語義完整性”等評價維度構建綜合計分框架，新聞媒體的 AI 寫作系統會依據語義連貫度與讀者回饋資訊綜合判定內容品質等級進而優化模型輸出策略。

事實精準度與知識可靠性評價是保障 AIGC 內容可信屬性的核心支撐，該維度側重驗證生成資訊是否與客觀事實相符、是否存在虛假表述偏差內容或未經證實的資訊點。典型評價方法包括基於知識圖譜的事實比對機制、事實覆蓋比例與錯誤發生率指標，部分 AI 平臺近年引入“可信來源占比”指標用於評估生成內容中引用來源的權威屬性，這一方法已應用於科學論文自動撰寫與政策報告生成系統用以確保模型輸出契合學術規範與政策要求。

模型可解釋屬性與透明特質評價逐步成為 AIGC 標準體系的核心構成要素，AI 生成內容的可解釋程度直接影響用戶信任度與社會接納度需建立模型透明化評估機制。評價指標通常涵蓋生成依據可追溯性、演算法決策透明度與內容標識機制，部分 AI 平臺要求在生成內容中自動添加“AI 產出標識”明確其非人工創作來源以保障資訊傳遞的透明程度。

倫理與社會責任準則為 AIGC 評價提供規範支撐基礎，該維度強調生成內容是否契合社會價值導向與倫理底線要求、是否存在歧視性表述誤導性資訊或侵犯隱私的潛在風險。國際上較為成熟的框架包括歐盟提出的《可信 AI 倫理準則》突出公平屬性、問責機制與可審查特質；中國相關研究機構正探索 AI 內容倫理評估指標如“社會風險評估指數”“文化適配度評分”等用以衡量生成內容的社會接納程度。

綜合評價框架的形成標誌著 AIGC 標準體系的系統化發展趨勢，當前多個國家和機構

已提出多維度綜合評價模型例如 IEEE 的《AI 系統品質評估標準》（P7000 系列）與中國信通院的《人工智慧內容品質評估指南（2024）》等。這些標準普遍採用“技術層面—內容層面—倫理層面”三維度架構強調品質與責任兼顧的評價原則。

#### 4.3 驗證機制的現實難題與創新趨向

AIGC 內容驗證機制的發展雖已實現顯著進展但技術落地、標準規範與社會治理等維度仍存在多重困境。這些困境既會影響 AI 生成內容的可信屬性也決定人工智慧能否真正融入科學知識生產與公共傳播體系，技術與治理機制的創新探索持續推進驅動驗證機制向體系化、多層級與智慧協同方向穩步發展。

事實驗證的複雜屬性仍較為突出，AIGC 生成內容常整合多領域知識邏輯關聯緊密且語義層次豐富，傳統事實核查演算法難以精準辨識語境關聯的虛假資訊。模型應答科學或醫學類問題時可能生成表面合理但事實存在偏差的內容，這類“偽事實表述”比顯性虛假資訊更難甄別。當前驗證模式主要依託知識庫匹配與語義比對，生成內容涉及隱含推理或跨學科知識時其正確性難以通過自動演算法全面核實。

多模態內容驗證尚未建立統一規範，AIGC 在圖像、語音、視頻等領域的應用持續拓展內容驗證的複雜程度不斷攀升。文本驗證依託語義比對邏輯，圖像與音訊內容則需通過特徵識別、中繼資料追蹤等方式實施驗證，目前尚未構建跨模態統一驗證框架，文字說明與配圖間的事實偏差往往無法通過單一演算法檢測致使多模態生成內容的真實屬性驗證仍處於起步階段。

演算法的不透明屬性削弱驗證體系效能，多數 AIGC 系統屬於商業閉源架構外部機構難以知曉其訓練語料、參數配置及生成邏輯，致使驗證機構無法追溯內容生成路徑。生成內容出現偏差時即便發現問題也難以明確責任主體或定位錯誤環節，這種“黑箱化”困境在學術內容與政策解讀等高風險領域表現尤為顯著加大內容監管的制度實施難度。

倫理與法律規範的缺失加劇驗證困境，AI



生成內容涉及誤導性資訊、隱私洩露或價值偏向時現行監管體系缺乏明確法律約束。部分平臺以“技術創新”為藉口規避內容審核致使 AI 生成內容在社會傳播中難以追究責任；驗證機制在倫理判斷層面存在“機器無法界定價值取向”的困境，演算法可判別資訊真偽卻難以判斷內容是否“適宜生成傳播”。

面對上述現實困境 AIGC 內容驗證機制正呈現多重創新方向。新一代生成模型逐步嵌入“事實比對”與“內部回饋迴圈”功能，在生成過程中自動調取外部資料庫實施即時驗證，模型發現輸出與既有知識不一致時可實現自我修正從源頭減少錯誤資訊傳播。基於區塊鏈技術的內容溯源系統持續完善，通過為 AI 生成內容分配唯一數位簽章與時序標識構建完整的“生成—傳播—驗證”鏈路，確保每段內容均可被追蹤與審計，該機制在學術出版、政策檔與媒體新聞領域適用性尤為顯著。人機協同驗證機制逐步落地，高風險或高專業度領域中引入人工專家與演算法系統協同審查，AI 負責初步篩查與一致性檢測專家承擔語義與事實覆核工作，實現驗證效率與精確度的動態平衡。社會化驗證模式持續探索，部分科研機構與媒體平臺嘗試搭建“開放驗證平臺”允許公眾、研究者與協力廠商機構參與 AI 內容評估與監督，形成動態回饋機制提升社會信任水準。

#### 4.4 未來驗證與評價機制的發展展望

AIGC 技術持續快速反覆運算其生成內容的驗證與評價機制正經歷從“事後核驗”到“全流程管控”的轉型歷程。未來驗證與評價體系不再局限於輸出結果的核驗工作而是延伸至演算法架構設計、資料來源頭篩選、生成邏輯推演及社會影響評估等多個維度，實現動態化、透明化與多維度的品質管控訴求。

驗證機制將呈現“模組內嵌”與“流程前置”的發展態勢，以往驗證多依託人工或獨立系統實施事後檢測，未來 AIGC 系統將依託模型內嵌的驗證模組在生成流程中即時監測事實匹配度、來源可信度與邏輯連貫性，實現“生成即驗證”的核心訴求。這一發展方向已在部分科研類 AIGC 平臺落地實踐，比如通過語義匹配與知識圖譜比對即時識別潛在偏差在

生成階段降低虛假資訊傳播概率。

驗證機制將與評價體系深度融合構建“技術—倫理—社會”三位一體的綜合標準體系。未來 AIGC 評價體系既關注生成內容的語言水準與事實精確度也會評估其社會職責、倫理風險與文化適配性。科學知識生成領域中 AI 產出的論文或技術報告需通過多維指標體系，涵蓋學術引用有效性、資料可追溯性、演算法透明度與倫理合規性等保障契合科研規範與公共信任訴求。

評價機制將更多依託開放協同的治理架構，政府監管部門、科研機構、企業平臺與公眾使用者將共同參與 AIGC 內容的監督與回饋工作搭建“多主體共治”的社會化評價網路。這一機制可借助開放資料庫、可追蹤報告及跨平臺審計實現持續動態監管，降低 AI 濫用與內容失真風險。

技術創新將成為驗證與評價機制演進的核心動力支撐，區塊鏈溯源技術、聯邦學習演算法與可解釋性模型等將助力構建去中心化驗證體系實現內容來源可查、修改軌跡可溯、相關責任可究。未來 AIGC 系統有望具備“自我驗證”與“自我評估”功能通過內部演算法自檢持續優化生成品質，依據外部回饋動態調整模型參數。

總體來看 AIGC 驗證與評價機制的未來發展方向將是標準體系化、技術智慧化與治理協同化的三位一體。唯有構建從演算法層面到社會層面的全鏈路可信體系才能保障人工智慧在知識生成與公共傳播領域既具備創新活力又擁有權威屬性與可控特質<sup>[10]</sup>。

## 5 AIGC 生成內容的評價體系與標準

### 5.1 AIGC 內容的評價標準與核心框架

AIGC 生成內容的評價標準與核心框架是保障人工智慧在科學知識生產與社會傳播中具備權威特質與可信屬性的關鍵支撐，不同於傳統人工創作模式 AIGC 的生成邏輯由演算法主導，其內容品質既依賴語言表達效果與邏輯連貫程度更取決於演算法架構設計、資料來源頭選擇與生成流程的透明屬性，建立科學系統可衡量的評價標準對保障 AI 生成內容的真實

特質、可追溯屬性與社會責任具有重要意義，當前 AIGC 內容的評價標準主要包含四個核心維度即事實精準度、邏輯連貫特質、倫理合規屬性與公共可信程度，這些指標共同構成 AIGC 內容品質的多層級評價架構。

事實精準度是 AIGC 內容評價的首要基準，AI 生成系統通常依託大規模訓練語料開展知識提取與語言生成工作，模型存在事實偏差、資訊滯後或語義謬誤的潛在風險，事實精準度要求 AI 輸出內容與現實世界資訊保持契合，可通過多源驗證機制實現例如與權威知識圖譜比對、事實資料庫交叉核驗或參考文獻檢索等方式，科研領域中 AI 生成的論文摘要應準確反映原始研究的資料結論與研究方法，不得出現偽造引用或編造資料的情況，事實核驗機制的引入既是技術層面的保障更是 AI 生成內容獲得社會信任的根本前提。

邏輯連貫特質是 AIGC 內容品質的內在基準，聚焦生成內容內部結構是否合理、推理過程是否自治、論述表達是否連貫，邏輯謬誤常出現在多步推理、知識遷移或概念整合過程中，尤其 AIGC 生成科學性內容時邏輯連貫特質直接影響知識的科學屬性與可解釋程度，可採用語義鏈分析、推理路徑視覺化等方法檢測模型生成過程中的邏輯連貫程度，進而識別潛在的推理漏洞或資料雜訊引發的邏輯斷裂。

倫理合規屬性是 AIGC 評價體系中的社會規範維度，AI 生成內容時必須遵守法律法規與社會倫理準則，避免傳播虛假資訊、歧視性表述、偏見觀點或侵犯隱私的內容，倫理評價應覆蓋三個層面即演算法偏見檢測、生成內容核查與責任歸屬界定，例如 AI 生成的科學報導應避免強化性別偏見、科研國家主義或學科歧視等隱性傾向，實踐過程中可通過引入倫理約束演算法、價值敏感設計（VSD）原則與人工覆核機制，保障 AIGC 在知識生產中的社會責任與道德合法性。

公共可信程度是評價 AIGC 生成內容能否被公眾與學術界廣泛接納的重要指標，可信程度既源於事實與邏輯的精確屬性也取決於內容來源的透明程度與模型輸出的可解釋性，AI 系統能夠明確標注資料來源、模型版本與訓練範圍時使用者對內容的信任度會顯著提升，未

來 AIGC 的可信程度評估應結合用戶行為分析、社會回饋機制與協力廠商審查制度，通過持續性評價構建動態信任體系。

整體來看 AIGC 生成內容的評價框架可分為三個層面，第一層為技術層面即模型內部的自動化自檢機制對生成內容開展即時監測與修正，第二層為平臺層面包含企業或科研機構的多重審查機制負責技術核查、倫理監督與內容覆核，第三層為社會層面即由公眾、學術團體與監管機構共同參與的外部評估體系，保障 AI 內容符合公共利益與科學規範。

這一三層結構的框架既實現了從“演算法生成”到“社會認定”的完整閉環也為 AIGC 在科學知識生產中的標準化與制度化提供了基礎路徑，未來隨著國際 AI 治理體系的發展中國應結合自身科研與文化語境，建立具有本土特色的 AIGC 內容評價體系實現科學屬性、規範特質與社會價值的統一。

## 5.2 評價指標的設計與落地實施

AIGC 生成內容的評價指標設計與落地實施是將抽象品質標準轉化為可落地可衡量評估架構的核心支撐，AIGC 生成內容在科學知識傳播、媒體資訊發佈與教育場景應用等不同領域呈現多樣化特徵，其評價指標體系需兼顧通用屬性、層級特質與動態適配能力，整體劃分為技術層指標、內容層指標與社會層指標三大類別構建層級遞進的綜合評估結構。

技術層評價聚焦模型性能表現與生成流程的可控屬性，核心指標包含①事實契合率測算生成內容與權威資料及知識庫的契合水準；②邏輯連貫水準借助語言模型的語義相關度評分與推理鏈解析判斷內容邏輯自治屬性；③可解釋性分值評估模型生成過程中對資訊源頭、推理依據的披露程度；④可追溯性係數通過記錄資料來源與生成路徑保障結果可複查特質，這些指標設計使 AI 系統輸出內容時實現“自我驗證”有效降低錯誤傳播風險。

內容層評價指標圍繞 AIGC 生成文本或圖像的品質核心展開，涵蓋①資訊精準程度依託事實核驗與資料比對作為核心方式；②語言合規程度考察生成內容在語法規範、結構架構、語義表達層面的精準屬性與流暢特質；③原創



屬性與創新特質通過相似度檢測與語義重構解析研判內容是否具備獨立表達與知識增值效果；④倫理合規屬性識別內容中是否存在歧視傾向、偏見表述、隱私侵犯或倫理隱患，科學知識生成領域中原創屬性與倫理屬性是保障內容學術合法特質的重要指標。

社會層評價指標聚焦公眾信任程度與社會影響範圍，包括①可信程度分值結合用戶信任回饋、專家覆核建議與社會平臺聲譽研判 AI 生成內容的整體可靠水準；②社會影響係數通過輿情監測與資訊擴散模型研判內容傳播的正負向效應；③透明程度指數測算 AIGC 在資訊來源、演算法邏輯與責任歸屬方面的公開程度，這類指標落地體現“技術—倫理—社會”一體化治理思路實現 AI 品質管控與社會責任的同步推進。

落地實施階段 AIGC 評價指標採用多主體協同與分階段推進的機制，系統內部自動化評估先行 AI 模型通過演算法自檢輸出初步品質分值，平臺與專家評估系統後續覆核針對科研資料、醫療建議等高風險內容開展人工審查，社會化回饋機制同步引入結合用戶舉報、媒體核查與監管機構評估形成動態更新，各階段回饋資料反向訓練模型持續優化生成策略與判斷邏輯。

指標權重設置需根據不同應用場景靈活適配，科研文本應強化“事實契合率”與“原創屬性”的權重占比，面向公眾的資訊傳播內容需提高“倫理合規屬性”與“社會可信程度”的比重分配，此外指標體系需具備動態適配特質隨技術演進與社會規範更新持續優化，未來結合大資料監測與人工智慧評估將構建自動化 AIGC 內容評分系統，實現從靜態核查到動態品質管控的轉型為 AIGC 在科學研究與社會應用領域的可信落地提供堅實支撐。

### 5.3 評價體系的優化路徑與技術難題

AIGC 技術持續演進現有評價體系面臨多重挑戰尤其體現在內容品質與可信程度的評估維度，提升 AIGC 生成內容的精確特質、可靠屬性與社會適配能力評價體系的優化是核心關鍵環節，優化過程並非簡單指標調整而是涉及技術難題、倫理研判與實施層面的複雜問題。

自動化評估的精確程度是評價體系優化中尤為顯著的技術難題，AIGC 生成內容具備較強動態特質與多樣屬性其品質評估難以單純依託固定規則或單一模型，現有自然語言處理（NLP）與電腦視覺（CV）技術在精確屬性與流暢特質上已有明顯突破卻仍難以全面應對語境解讀、隱含語義及文化背景差異等複雜情形，AIGC 生成內容可能語法層面無明顯疏漏但其中隱性偏見、誤導性表述或倫理失當傾向仍難以通過單一技術指標甄別，評價體系優化過程中需結合多種技術手段開展交叉驗證提升 AI 模型在複雜場景中的判斷能力這是當前需解決的核心問題。

模型可解釋屬性與透明特質是評價體系技術優化的核心方向，AIGC 生成流程的黑箱特質使其產出內容缺乏透明推理脈絡使用者難以明晰 AI 得出結論的具體路徑，這既影響內容的權威特質與可信屬性也給後期品質管控帶來極大困難，優化過程中如何讓模型生成內容時提供可解釋的推理流程如何搭建基於模型透明特質的評價標準已成為當前技術研究的熱點，這要求設計評價體系時採用更先進的演算法與技術推動 AIGC 模型向更“可解釋”方向發展進而增強其輸出內容的透明程度與信任水準。

倫理問題的多維度研判亦是技術優化中的重要難題，AIGC 生成內容的倫理合規屬性在醫學、教育、法律等敏感領域中尤為關鍵，現有評價體系檢測內容倫理問題時過於依賴人工標注造成效率偏低且易出現偏差，有效解決這一問題需在評價體系中引入更多倫理評估標準通過深度學習與語義解析等技術提升模型對倫理合規問題的敏感程度，AI 可通過自動化識別內容中潛在偏見、歧視性表述加以規避但這要求評價體系能對不同文化背景與社會環境中的倫理標準進行靈活適配。

跨領域協同與資料共用在優化評價體系過程中面臨一定技術阻礙，AIGC 應用場景持續拓展使得內容評價標準與技術手段需跨越傳統領域界限開展跨行業、跨學科的整合，不同領域對 AIGC 生成內容的需求與標準差異明顯保持行業標準獨特性的同時搭建統一評價體系與評估框架依賴多方技術協作與資料共用，此



過程中如何保障資料隱私、安全屬性及模型適配能力將成為亟待解決的技術難題。

實際實施層面評價體系的實操屬性亦是需優化的重要維度，部分現有評價標準實操性偏弱難以在實際應用中精準落地，生成內容評分系統中如何對長文本、圖片或音訊等不同形式內容進行統一合理的評分仍是技術性難題，不同評價標準對結果的評分權重分配不均且難以量化進一步加劇評價體系的複雜程度，未來優化工作應從簡化操作流程、提升自動化水準與豐富評估方法等角度出發確保評價體系的易用屬性與實施效果。

#### 5.4 國際與國內 AIGC 評價標準的比較分析

全球範圍內 AIGC 生成內容的評價體系仍處於構建階段不同國家及地區在技術基準、倫理準則與治理架構上表現出明顯不同，整體來看歐美國家的 AIGC 評價體系更側重透明特質、可解釋屬性與責任可追溯屬性中國的評價標準則更強調內容安全屬性、倫理合規要求與社會影響管控，這種差異體現各國在技術治理理念、社會文化背景及政策導向層面的不同取向。

國際層面歐盟與美國在 AIGC 評價標準制定上處於領先地位，歐盟於 2023 年正式頒佈《人工智慧法案》(AI Act) 首次依據風險等級對 AI 系統實施分級管控，其中對 AIGC 類生成模型提出明確的透明特質與可追溯屬性要求，該法案明確生成式 AI 需標注內容源頭、說明是否為 AI 生成保障模型訓練資料的合法屬性與可審計特質，歐洲標準化委員會 (CEN) 與國際電子電機委員會 (IEC) 聯合發佈的 AI 內容評估框架強調技術中立屬性與資料可解釋特質，將事實契合程度、偏差甄別能力和倫理自我核驗列為核心評估維度，美國以市場機制為核心導向由產業聯盟與大型科技企業牽頭標準構建，美國國家標準與技術研究院 (NIST) 發佈的《人工智慧風險管理框架》(AI RMF 1.0) 提出從模型開發、內容生成到結果驗證的全過程評估原則，重點關注演算法偏差管控、內容真實屬性評估與責任歸屬界定機制，OpenAI、Google DeepMind 等機構已搭建內部 AIGC 品質管控體系通過多層人工審查、事實交叉核驗及偏差檢測工具保障生成內容的可靠屬性與安

全特質。

中國的 AIGC 內容評價體系更具政策導向與社會治理特徵，2023 年發佈的《生成式人工智慧服務管理暫行辦法》明確 AIGC 服務提供者須對生成內容承擔責任，確保輸出契合社會主義核心價值觀與公共秩序要求禁止生成虛假資訊、有害內容或侵犯隱私的內容，評價體系建設方面中國標準化研究院正在推進《人工智慧生成內容安全標準體系框架》的制定，核心涵蓋事實精準程度、內容安全屬性、模型可控特質和倫理合規要求四大指標，中國在 AIGC 監管中引入事前報備、事中監控、事後問責的分層管理機制與西方的行業自我約束 + 外部監管模式形成區別，百度、阿裡巴巴、智譜 AI 等企業已搭建內部多維內容審查系統結合語義識別技術、人工覆核流程與黑名單機制，實現 AIGC 輸出的自動篩查與風險分級管控。

國際與國內標準的核心差異體現在三個維度，治理邏輯存在差異歐美強調透明屬性與問責機制注重技術過程與結果的可解釋特質中國強調可控特質與合規要求更注重生成內容的社會影響與政治倫理安全，評估重點有所不同歐美的 AIGC 評價標準偏向技術導向關注演算法偏差、模型透明程度與資料來源合法屬性中國的評價體系以社會導向為核心重視內容是否符合法律法規、倫理道德與社會穩定要求，實施機制存在區別西方主要依靠行業自我約束與社會監督力量中國採用政府監管與企業自主核查相融合的管理模式形成更具集中性的管控體系。

儘管存在差異國際與國內在 AIGC 評價體系建設上呈現趨同態勢，均逐步重視生成內容的真實屬性與可追溯特質均在探索搭建跨學科倫理評估框架均強調模型透明程度與可解釋屬性的重要價值，未來中國可在借鑒國際經驗的基礎上搭建具有中國特色的 AIGC 評價架構，在保障內容安全與倫理合法的前提下加強對技術透明程度、資料合規要求與社會信任構建的平衡推動 AIGC 品質治理標準的國際化與科學化演進。

## 6 結論與展望

## 6.1 AIGC 內容的權威特質與品質管控現狀總結

近年 AIGC(人工智慧生成內容)技術持續高速發展帶動知識生產與資訊傳播模式發生深度變革,其在科研寫作、新聞採編、教育資源創制及輿情研判等領域展現出顯著應用潛力,伴隨技術應用範圍拓展 AIGC 內容的權威特質與品質管控問題逐漸成為影響其社會信任水準與學術價值的核心議題,當前 AIGC 內容品質管控體系尚未完全成熟在技術、制度與倫理維度均面臨多重挑戰。

技術維度上 AIGC 生成內容的精准屬性與連貫特質仍有明顯差距,模型訓練依託大規模互聯網資料資訊源頭存在真實程度不一、更新遲緩與偏見積澱等情況,導致 AI 輸出內容可能出現事實謬誤、邏輯斷層與語義偏差,尤其科研知識生成與政策分析等高精度領域 AI 生成內容若缺乏嚴格驗證機制極易造成偽知識或誤導性結論擴散,近年雖引入知識圖譜對應、事實核驗演算法與模型溯源技術但當前自動化品質檢測仍以語義流暢度為主,難以全面評估內容真實屬性與專業深度。

制度與治理維度 AIGC 內容的監管架構正在逐步構建但仍呈零散狀態,國際層面主要採用“行業自我約束 + 政府監督管理”的融合模式,中國則在政策層面搭建了更為嚴格的內容審查與報備機制,如《生成式人工智慧服務管理暫行辦法》明確了 AI 內容的安全邊界與主體責任,這些管理舉措在執行過程中仍面臨標準不統一、評價指標缺乏實操屬性等問題,不同平臺、行業間的品質標準存在明顯差異導致 AIGC 的可信程度難以實現跨平臺統一。

倫理與社會維度 AIGC 的權威特質受到演算法偏見與責任界定模糊的雙重作用,AIGC 生成內容常被視作“客觀產出”實則體現訓練資料與演算法架構中蘊含的人類偏見與價值傾向,知識傳播領域中這種“偽中立屬性”可能掩蓋不平等敘事或強化既有權力結構,削弱內容的科學公正特質同時 AIGC 的責任歸屬問題尚未明確,當生成內容引發倫理爭議或造成社會誤導時責任主體的界定仍存在模糊空間。

當前 AIGC 內容品質管控已呈現積極發展態勢,大模型企業與科研院所正在推行多層級驗證機制包括事實比對、專家覆核與社會回饋系統以提升內容可信程度,部分平臺已開始探索自動化倫理審查與語義安全評估架構通過演算法識別潛在風險並在生成階段進行即時修正,越來越多跨學科研究正嘗試構建“科學—倫理—社會”三維評價架構在技術進步與公共利益之間尋求平衡。

## 6.2 政策建議與行業發展導向

應對 AIGC 內容權威特質與品質管控相關挑戰中國及全球的政策制定與行業演進需從技術治理、制度構建與社會協同三個維度系統推進,AIGC 作為知識生產的核心工具其健康演進既依賴演算法與模型的優化更取決於法律法規的健全、行業標準的規範落地以及倫理與社會監督的有效參與。

政策維度應加快搭建國家級 AIGC 內容品質管制與評估架構,制定統一的《AIGC 內容品質與安全基準》明確事實核驗、資料合規要求、倫理核查與可解釋屬性等基本準則形成跨行業跨平臺的品質管控標準體系,推動“生成式人工智慧透明化條例”落地實施要求 AIGC 產品明確標注內容生成源頭、演算法版本及資料訓練範圍保障公眾知情權與可追溯特質,政府建立 AI 生成內容報備制度與演算法安全評估機制確保 AIGC 模型上線前通過倫理核查與安全測試從源頭防範錯誤資訊與偏見傳播。

行業發展維度企業與科研院所需主動肩負 AIGC 品質治理的主體責任,建立企業內部“內容核查與倫理治理委員會”以專家參與模式對 AI 輸出內容開展定期抽查與風險評估,行業聯盟共同推動“AI 內容自主約束公約”在競爭中形成合規共識與共用責任,推動 AIGC 平臺間的資料共用與模型互認機制促進標準的互聯互通,科研院所強化 AIGC 模型的學術核查制度確保 AI 生成科研文本、技術報告等內容的可驗證屬性與可複現特質防範“AI 學術造假”現象蔓延。

社會治理維度需搭建多元主體參與的協同監督機制,政府監管部門通過智慧化手段(如

語義識別與演算法審計)實現對 AIGC 內容的動態監管,公眾與媒體納入社會監督體系通過舉報、回饋與輿論評估參與 AIGC 治理,積極推動公眾 AI 認知素養培育使社會具備識別與評估 AI 內容的能力形成“技術透明—公眾參與—責任共擔”的良性治理生態。

未來發展導向中 AIGC 行業應以可信 AI 為核心發展導向,加快推進可解釋人工智慧(XAI)技術研發使模型生成知識的同時提供邏輯依據與資料來源頭提升內容的可驗證特質,推動 AI 與區塊鏈技術融合構建基於溯源機制的內容認證體系實現從資料登錄到結果輸出的全過程追蹤,引導 AIGC 應用向高價值領域延伸(如科學研究、教育創新、公共服務等)在規範化基礎上實現社會效益最大化。

AIGC 的政策與行業發展需在“技術創新”與“社會信任”之間尋求平衡通過法制化、標準化與智慧化的協同路徑搭建開放安全負責任的 AI 內容生態系統,使 AIGC 真正成為推動知識增長與社會進步的核心力量。

### 6.3 未來研究的方向與潛在可能

AIGC 內容的權威特質與品質管控是動態發展的研究範疇,其發展取向既取決於人工智慧技術的突破也依託於社會治理理念、倫理規範與跨學科研究的推進,未來研究將聚焦多方面實現 AIGC 從“智慧生成”到“可信知識創造”的轉型。

搭建可解釋屬性與透明特質的知識生成機制是核心研究議題,目前多數 AIGC 模型生成內容時缺少明確推理脈絡與溯源記載,導致知識源頭不可追蹤、邏輯過程不可驗證,未來研究應聚焦“生成可解釋性”通過語義鏈視覺化、因果關係建模與資料來源映射,使 AI 生成的知識具備可追蹤、可驗證、可審計的特徵增強內容的科學屬性與可信程度。

倫理與價值融入機制需深入探析,AIGC 在跨文化跨領域應用中遭遇複雜價值判斷情形,模型訓練階段融入倫理約束與文化多樣認知直接決定其輸出的社會適配能力,未來研究

可從演算法倫理學、社會技術系統(STS)和人機協同治理等角度探索 AI 系統生成知識時的價值平衡機制,規避技術理性對社會多元價值的消解。

多模態內容品質管控與跨領域標準化評估架構是 AIGC 治理的關鍵取向,當前研究多聚焦文本生成範疇 AIGC 在圖像、視頻、音訊及科學類比資料等領域應用持續拓展,未來需建立統一品質評估架構涵蓋語義精確度、資料真實屬性、感知一致特質和倫理安全等維度推動多模態 AIGC 內容的協同治理,不同行業應聯合搭建跨領域品質基準與審查架構形成可比屬性與互認機制。

人機協同創作與智慧核查的聯動機制是未來研究新趨向,AIGC 持續參與科研寫作、政策起草與新聞編輯等高風險範疇單純依託演算法自動生成與核查難以滿足可信程度要求,未來研究應探索“人機混合決策模型”通過人工專家與 AI 系統的聯動學習實現對生成內容的雙重核驗與動態修正,在保障效率的同時提升內容品質與責任歸屬的明確程度。

AIGC 社會影響的長期評估與政策回饋機制是亟需關注的新範疇,AIGC 既是技術現象也是社會變遷的驅動力量未來研究應跨越技術邊界,關注其在公共輿論形成、知識權力結構、勞動市場與文化生態中的深層影響,通過搭建長期追蹤與政策回饋架構研究者可為 AIGC 的社會治理提供持續的理論支撐與實證基礎。

整體來看未來 AIGC 研究方向將從單一的“內容生成與品質核查”轉向綜合性的“知識治理與社會信任構建”,這不僅是技術優化問題更是融合人工智慧倫理、資訊科學、社會學與哲學的系統性研究議題,隨著 AI 能力的持續演進 AIGC 研究將逐步從“工具視角”邁向“認知共同體視角”,推動人類社會進入更具智慧特質、透明屬性與可信特質的知識生產新時代。

### 參考文獻：

- [1] 人工智慧生成內容(AIGC)白皮書編寫組. 人工智慧生成內容(AIGC)白皮書[M]. 北京:中國資訊



通信研究院, 2022.

[2] Cao Yihan, Li Siyu, Liu Yixin, Yan Zhiling, Dai Yutong, Yu Philip S., Sun Lichao. A comprehensive survey of AI-generated content (AIGC): A history of generative AI from GAN to ChatGPT[EB/OL]. arXiv, 2023, arXiv:2303.04226. <https://arxiv.org/abs/2303.04226>.

[3] Wang Yuntao, Pan Yanghe, Yan Miao, Su Zhou, Luan Tom H. A survey on ChatGPT: AI-Generated contents, challenges, and solutions[EB/OL]. arXiv, 2023, arXiv:2305.18339. <https://arxiv.org/abs/2305.18339>.

[4] 證券研究報告編寫組. 人工智慧系列深度報告：AIGC 行業綜述篇——開啟 AI 新篇章[R/OL]. 證券研究報告, 2023-03-20.

[5] 錢亮帆, 劉立翔. 高校 AIGC 檢測標準的反思：人工智慧與人的主體性讓渡[J]. 中國現代教育學報, 2025, 1(1): 25-31. DOI: 10.70693/jyxb.v1i1.9.

[6] Papagiannidis E, Alamanos E. Responsible artificial intelligence governance: a review and research agenda[J]. Technological Forecasting and Social Change, 2025, 196: 122727. DOI: 10.1016/j.techfore.2024.122727.

[7] Lu Y. Reforming copyright law for AI-generated content[J]. TechReg, 2025, (2): 39-58.

[8] Huschens M, Briesch M, Sobania D, Rothlauf F. Do you trust ChatGPT? Perceived credibility of human and AI-generated content[EB/OL]. arXiv, 2023, arXiv:2309.02524.

[9] Elkhataf A. M., Elsaid K., Almeier S. Evaluating the efficacy of AI content detection tools in differentiating between human and AI-generated text[J]. International Journal for Educational Integrity, 2023, 19: 17. DOI: 10.1007/s40979-023-00140-5.

[10] Taeihagh A. Governance of Generative AI[J]. Policy and Society, 2025, 44(1): 1-23.

## 版權聲明

© 2025 作者版權所有。本文依據“知識共用署名 4.0 國際授權合約”（CC BY 4.0）以開放獲取方式發佈。該許可允許使用者在任何媒介中自由使用、複製、傳播與改編文章（含商業用途），惟須明確署名原作者及出處，並注明所作修改（如有）。完整協議詳見：<https://creativecommons.org/licenses/by/4.0/deed.zh-hans>

## 出版聲明

所有出版物中的陳述、觀點及資料僅代表作者及供稿者個人立場，與 Brilliance Publishing Limited 及/或編輯人員無關。Brilliance Publishing Limited 及/或編輯人員對因內容所提及的任何理念、方法、說明或產品所導致的人身或財產損害概不負責。