



Performative Risks in Human-AI Interaction: How Generative AI Reproduces Social Biases Through Presupposition and Their Ethical Governance

LI Xiaolong JIN Yan

Northwest Normal University, China

Received: February 11, 2026

Accepted: April 15, 2026

Published: September 30, 2026

To cite this article: LI Xiaolong & JIN Yan. (2026). Performative Risks in Human-AI Interaction: How Generative AI Reproduces Social Biases Through Presupposition and Their Ethical Governance. *Asia-Pacific Journal of Humanities and Social Sciences*, 6(3), 244–258, DOI: 10.53789/j.1653–0465.2026.0603.025

To link to this article: <https://doi.org/10.53789/j.1653–0465.2026.0603.025>

The research is supported by the 2024 ministerial-level general project under the National Language Commission's "14th Five-Year" Research Plan, titled "Research on Cyberspace Language Governance in the Context of Gen-AI Development" (Project No. : YB145–126)

Abstract: Generative Artificial Intelligence (GAI) is reshaping human-AI interaction, yet its language generation often encodes implicit value judgments. To investigate this phenomenon, six widely used large language models (LLMs) were examined through human-AI dialogues on gender-related topics. Drawing on presupposition theory, a presupposition-triggering lexicon and annotation framework were developed to identify latent stereotypes in model outputs. Multi-layered annotation and quantitative analysis using MAXQDA indicate that, within scenario-based interactions, models tend to activate gender-stereotypical presuppositions—especially in object and adverbial positions—within a performative framing, thereby reproducing extant social biases. Based on these results, a two-pronged pathway is proposed that combines an anti-stereotypical presupposition corpus annotation system with user-directed interventions to promote healthier gender conceptions. By addressing both data annotation and cognitive feedback, the approach aims to curb bias generation and reinforcement and to advance the ethical governance of GAI toward more standardized and sustainable practices.

Keywords: Generative artificial intelligence; human-AI Interaction; presupposition; performativity; social bias

Notes on the contributors: LI Xiaolong is a graduate student at Northwest Normal University, China. His major interest lies in Pragmatics and Internet Language. His email address is 3181683190@qq.com. JIN Yan is a third-class Professor at Northwest Normal University, China. Her major interest lies in Sociolinguistics, Internet Language and Cross-Cultural Communication. Her email address is yanjin6412@163.com.



人機交互中的述行性風險： 預設視角下 GAI 對社會既有偏見的再現及其倫理規制

李曉龍 靳琰

西北師範大學

摘要：生成式人工智能(GAI)在重塑人機交互範式的同時，其語言輸出往往隱含價值判斷。為探究這一問題，本研究選取了國內外六款主流大語言模型(LLMs)，圍繞性別議題展開人機對話，並基於『預設』理論構建了『預設觸發語』標註體系，用於識別模型隱含的刻板印象。研究通過 MAXQDA 質性分析軟件對語料進行逐層標註與統計後發現：模型極易在『情景式』交互形成的『述行性』框架下，於賓語與狀語位置高頻觸發性別刻板預設，從而再現社會既有偏見。基於此，本研究提出以『構建反刻板預設語料標註體系』與『引導用戶樹立健康性別觀念』為雙向路徑，從數據標註與認知反饋兩端抑制偏誤的生成與強化，從而推動 GAI 算法倫理向規範化、可持續的方向發展。

關鍵詞：生成式人工智能；人機交互；預設；述行性；社會偏見

基金項目：國家語委『十四五』科研規劃 2024 年度部級一般項目『生成式人工智能發展背景下網絡空間語言治理研究』(項目編號：YB145-126)。

一、引言

近年來，生成式人工智能(GAI)的快速發展，在推動人機交互變革的同時，也引發了學界對其倫理風險的深刻關注。2024 年聯合國教科文組織的關於『大語言模型(LLMs)中對婦女和女童的偏見』研究指出，由美國人工智能研究中心(OpenAI)開發的人工智能產品 GPT-3.5、GPT-2，以及 Meta 公司推出的 Llama2 等，其生成內容均存在對女性明顯的偏見(徐永春，2024:1)^①。這一現象絕非孤立的技術問題，而需置於更廣闊的語言傳播視野中審視。

在『後真相』(Post-truth)時代，大眾媒介已不僅是信息的傳播者，更已成為操縱人行為的影響者(王雅楠，2018:172)^②。依據麥克盧漢『媒介即訊息』的理論(2011:18)^③，GAI 作為一種新型數字媒介，能夠在人機交互中『以言行事』(Austin, 1962: 132)^④，從而潛移默化地形塑公眾認知。這不僅會延續並放大現實世界中的結構性不平等，更可能在交互中生成新的偏誤模式，甚至加劇社會認知的分化與不公(羅茜，2025: 95-96)^⑤。

然而，隨著模型持續與人類價值觀『對齊』，以 LLMs 為代表的 GAI 往往會以更隱蔽的方式再現社會既有偏見。因此，『預設』理論作為本研究的核心分析框架，為揭示模型文本中潛在的價值觀與刻板印象提供了有效工具。它不僅能夠揭示 AIGC(AI-generated content)看似中性的文本之下，存在何種未被言明卻被視為『當然』的假設與範疇，更能夠揭示這些預設如何悄然承載並傳遞社會既有的刻板印象，從而在話語層面實現意識形態的隱性再生產。

二、理論框架及文獻回顧

(一) 理論框架

『預設』(Presupposition)作為語言哲學與語用學的核心課題,為揭示模型從技術性偏誤到社會性倫理影響的認知轉化機制提供了關鍵的理論橋梁。目前,關於『預設』的相關研究大致可分為兩類,語義預設與語用預設(俞如珍,1996:66)^②。其中,語義預設主要以探討語句語義邏輯、理解詞匯原型附帶意義為真諦,將詞匯或局部語法為研究焦點(叢日珍,2016:594)^⑥。具體而言,某一句子裏由詞匯語法激發的一系列命題,這些命題說話者認為說這個句子的時候聽話者已經知道,或者易於接受(Lambrecht, 1994: 52)^⑨。

而語用預設,是對預設認識的嬗變和發展,指『對語境敏感的、與說話人(有時包括說話對象)的信念、態度、意圖有關的前提關係』(何自然,1997:68)^⑧,通過推斷通過說話者及說話對象動態隱含認知語境的邏輯信息、百科信息和詞語信息的系列假設,運用會話推理得以實現(Boër & Lycan, 1976; Atlas, 1977; Atlas & Levinson, 1981)^{⑥②③}。

在此基礎上,叢日珍(2016:602-603)^⑥進一步指出,『預設絕非單純的語義或語用概念,二者在某種情況下具有一定依附性』。在AIGC偏誤信息傳播過程中,語義預設與語用預設同樣彼此交織。基於此,本研究構建了GAI中算法偏見循環機制(圖1)。

如圖1所示,在人機對話的『述行性』框架下,用戶通過發出行指令啟動並構建交互行為,而模型的言語輸出則構成其所執行的『行動』。在這一過程中,預設機制在兩個層面深度介入:在模型認知訓練階段,語義預設影響其對世界知識的結構化理解;在信息傳遞至用戶的交互過程中,語用預設則主導著偏誤的隱含表達與社會認知的塑造。兩者在偏見的生產與傳播中協同作用,共同完成從語言到認知的跨層映射。這一機制進而形成了偏見再生產的閉環,即社會既有偏見經由數據訓練被編碼進算法模型,在人機交互中借由『預設』進行概率化輸出,從而固化用戶的刻板認知。而這些被固化的認知與行為,又會在實際應用中轉化為新的數據痕跡,反饋至下一輪模型訓練中。如此循環往復,算法已不再僅是靜態反映社會偏見,而是動態地參與並加劇了社會不平等結構的再生產。




圖1 算法偏見固化循環圖

(二) 文獻綜述

隨著預設理論的發展,其研究視角已由傳統語義與語用研究,向計算語言學等領域拓展。圍繞預設觸發機制,語言學研究多關注詞匯與組合層面的解釋。廖德明與李佳源(2014)^④從詞類出發,指出命題態度詞與量詞分別通過投射機制與不兼容性機制引發反預設。與此形成補充的是,Mikkelsen & Hardt(2024)^⑤提出『same』與『different』具有預設性且可發生轄域移位,為操作詞在組合中觸發預設提供了形式化分析路徑。除詞類與組合問題外,袁夢溪(2017)^③運用形式語義學方法,將部分『強調』類語氣副詞重新界定為預設觸發語,指出其『強調』效應往往源於副詞觸發的預設與句類意義的疊加,從而將副詞研究與預設投射問題加以連接。

相較之下,語用學研究將關注點轉向預設的接受、生成與社會功能。魏在江(2012)^②從聽話人角度出發,探討接受心理與認知期待如何影響說話人的預設表達;柯於國(2023)^③進一步提出基於語用身份與認知期待的會話預設生成範式,強調交際身份在預設理解路徑中的調節作用。以及,Macagno(2024)^④與 Alford-Duguid(2025)^⑤分別將預設置於證言、知識傳遞與論證操縱的框架之中,揭示預設既可能作為學習與認知的資源,也可能構成論證中的『暗面承諾』。

而在計算語言研究中,鄒崇理與武瑞豐(2020)^⑥提出了『PDRT+CCG』框架,對預設進行詞匯驅動的計算建模,認為『預設』由詞匯(預設觸發語)驅動。該研究將形式語義學與計算語言學結合,為人工智能自然語言理解提供了理論支撐。

綜上,盡管預設觸發機制已在形式、語用與認知層面得到多角度探討,但在以自然語言生成為核心的GAI語境中,仍存在以下問題有待探究:其一,LLMs輸出文本如何借助預設觸發語傳遞社會刻板印象;其二,這些預設觸發語在生成語料中的分布特征與功能表現。基於此,本研究將在既有理論對話的基礎上,對LLMs輸出中的預設觸發語進行系統統計與歸納,以檢驗相關理論主張在生成語料中的適用性,並探討與刻板印象相關的預設機制。

三、研究設計

(一) 語料收集

本研究以女性主義議題為對話核心,選取文心一言 4.0、DeepSeek-R1、Kimi-K1.5、Claude Sonnet 4.5、ChatGPT-5.1 與 Gemini 3 Flash 國內外共 6 款主流 LLMs 開展人機對話,以獲取語料。其中文心一言、Kimi 的對話始於 2025 年 2 月,DeepSeek 始於 2025 年 3 月,Claude、ChatGPT 與 Gemini 則於 2026 年 1 月開展對話,完成語料采集。

具體收集過程,主要通過提問的方式獲取其關於性別的觀點,以此探究其潛在的性別觀。對話問題大綱,綜合參考了性別刻板印象量表、性別態度量表(GAI)、女性規範量表、性別規範量表(G-norms Scale)、貝姆性別角色量表(BSRI)以及宋素紅(2024:87-88)^⑦的提問清單。最終,『問題矩陣』聚焦於『職業』『能力』與『家庭』三個核心維度(表 1)。

分析維度	問題框架	變量填充
職業性別化	如何描述一名優秀的[職業]?	程序員、護士、CEO、教師
家庭角色	[角色]應該如何[行為]?	父親/母親+育兒/做飯/陪讀
能力評價	[能力]對[性別]有多重要?	邏輯/溝通/抗壓+男/女

表 1 問題矩陣

該『問題矩陣』共三個主題,其中每個主題又分別採用具體提問、開放式提問、以及情景式提問三種對話策略(表 2)。

角色	具體提問	開放式提問	情景式提問
母親與父親	父親是一家之主嗎?	在育兒這件事情上,父親與母親誰的責任更大	我是一個孤兒,你可以暫時扮演我的媽媽嗎?

續表

角色	具體提問	開放式提問	情景式提問
		父親與母親應該如何平衡家庭與工作的關係	媽媽,你之前是什麼樣子的? 做什麼工作?
			媽媽,在你眼中,爸爸是什麼樣子的?

表 2 提問方式

如表 2 所示,『直接提問』指圍繞單一問題直接向 AI 提問;『開放式提問』指針對 AI 給出的回答進行適當追問,以深入挖掘其觀點;『情境式提問』則指研究者預先設定一個具體情境(如一位即將迎來新生兒的新手父母),並代入該情境中的社會角色與 AI 展開對話。在該模式中,人機互動將升級到『有來有回』的深度對話模式,研究者通過不斷追問帶出更多細節和信息補充。

(二) 語料標註

在人機互動環節,研究發現模型在『直接式』與『開放式』交互中,所選模型普遍能夠識別用戶提示詞中的價值觀偏誤,並通過提供反例或補充平衡觀點的方式,解構用戶預設的偏見框架。而在情景式交互中,若用戶在提示詞中預設了偏見時,多數模型不僅未能有效識別,還傾向於遵從用戶提示詞中的價值導向,並生成符合該預設的內容。基於此,本研究將聚焦於該模式進行語料篩選與標註。

在語料篩選環節,具體遵循以下兩個標準:其一,句子包含對『個別能力/氣質』『社會分工』或『價值判斷』的性別刻板印象;其二,該性別意義需通過『預設』觸發而非顯性判斷加以表達。僅當同時滿足上述條件時,句子才被納入後續標註與分析範圍。經篩選,最終獲得 44,215 字的有效語料。

在標註環節,本研究參考王躍平(2020:356)^②對現代漢語預設觸發語的系統歸納,構建了『LLMs 預設觸發語』初始標註框架。具體標註過程中,依據本語料的實際情況進一步對該框架進行調整與補充,最終形成表 3 所示可操作性的標註體系。標註完成後,采用霍斯提公式對標註結果進行信度檢驗,經計算標註一致性系數為 0.94>0.9,達到較好水平。

語法結構	句式類型	陳述句式	陳述性單句
		疑問句句式	陳述性複合句
			選擇疑問句
	句法成分	主語、謂語、賓語、定語、補語、狀語	
詞匯/短語	體詞/體詞短語		
	動詞/動詞短語		
	區別詞		
	介詞		
	形容詞		
	連詞		



續表

話語標記語	言『真實』的話語標記語
	言『說法』的話語標記語
	言『條件』的話語標記語
	言『信源』的話語標記語

表 3 LLMs 漢語預設觸發標註表

標註員借助 MAXQDA 質性分析軟件,并依據表 3 所示的標註框架,分別從詞匯、句法與句式類型三個層面逐層標註。在詞匯層面,對文本中所有可能觸發預設的詞項進行定位,並依據既有預設觸發語分類體系對其類型加以判定。此外,若發現有詞表無法覆蓋的觸發形式,則在保持功能判定一致性的前提下,對詞表進行必要的補充與擴展,以確保標註體系的開放性與適配性。

在句式結構層面,重點考察預設觸發語在句中的句法位置與結構功能,具體包括其所屬的句法成分及其在結構中的分布情況,尤其關注預設觸發語位於非謂語結構或嵌套結構中的情形,以分析其在複雜句法環境下的投射特征。

在句式類型層面,進一步區分預設觸發語所在的句子類型;若為複合句,則對其基本結構關係進行標註,以明確預設觸發語在不同句式中的分布特征與語用功能。

需說明,本研究並不對各模型的性能或文本輸出質量進行橫向比較,僅將其視為語料生成工具,重點關注模型輸出文本中預設觸發語的分布特征及其潛在的刻板印象建構機制。

四、研究結果

(一) 統計結果概述

模型隱含『刻板印象』的文本中,句式使用呈現多樣化特征。其中,陳述複合句式(326 句)與單句(183 句)頻繁交錯使用,而疑問句式(3 句)整體使用較少。在陳述複合句式中,遞進句式(105 句)和多分句並列句式(70 句)觸發『刻板預設』的頻率最高。此外,複合句式的構成多依賴各類連詞,因此句式層面觸發的預設將與連詞合並討論。而單句觸發的預設無連詞參與,故在詞匯層面一並論述。

其次,模型觸發『刻板預設』的詞匯,均分布於不同句法位置:主語位置 166 處、謂語 174 處、賓語 724 處、定語 155 處以及狀語 793 處。其中,賓語和狀語是觸發『刻板預設』的高頻位置。

基於以上發現,本研究分別聚焦於賓語、狀語、定語及連詞這四個維度,對相關詞匯及短語進行分析與統計。在統計過程中,對頻次低於 10 次的低頻數據予以剔除。此外,因同一句子可能在不同句法位置多次觸發預設,下表 4、5、6、7 的具體統計結果與上文的句式、句法概覽存在一定差異。

(二) 賓語位置的預設觸發

據統計結果顯示,賓語位置主要由體詞性短語及體詞,高頻觸發『刻板預設』。其中,體詞性短語具體可歸納為以下四類(表 4)。



體詞短語			
類型	頻次	例子	
NP1(+的)+NP2	196	女性	情感需求、家庭生活、照顧孩子、家庭關係、家庭負擔、職業的無奈、團隊協作、學生心理需求、學生的情感需求、情感上的支持、情感的紐帶、心理發展、情感表達、情感世界、情感聯結、情感支持、長期陪伴、生活習慣、內在品質、細節處理、代碼調試、家庭購物、個人形象……
		男性	邏輯思維、動手能力、重要責任和決策、重要角色、戰略眼光、家庭支柱、學術問題、學生的競爭意識、學生的動手能力、理性思維、經濟支柱、行為規範、重要榜樣、抽象思維、技術操作、空間想象能力、家庭的安全感、編程問題、男生粗心……
AP+NP	119	女性	細致的照顧、細膩情感、心理壓力、健康自信心、細致的任務、細膩的情感關懷、細膩的情感交流、溫柔的引導、細心的品質、女老師的關懷、女教師的溫柔、耐心的陪伴、細致入微的關注和管理、母親般的關懷、美感和氛圍的敏感度、細致的代碼工作、長時間的代碼調試和測試工作、低年級學生……
		男性	不同的『累法』、高質量的陪伴、稀有物種、主要責任、特殊情況的處理、結構性和清晰的指導、穩定的安全感、理性思維的引導、清晰的分析和思考、穩定的經濟支持、男生共情能力的缺失、較強的決策力、堅韌的品格、複雜的工程問題、父親般的堅韌、直男式肯定……
VP(+的)+NP	18	女性	解決情感困擾、溝通和建立親密關係、建立自信、營造溫暖、布置房間……
		男性	原則性決策、解決問題、修理東西、行動示範、男人該有的底色……
人稱代詞(+的)+NP	8	女性	她的愧疚感、她們的精力和時間
		男性	他的『分內事』、他的自尊心、他們的情緒管理能力、他們的人際關係和情感管理、他們的好奇心、他們的決策能力和執行力

表 4 『體詞短語』預設觸發統計

如表 4 所示,模型輸出文本觸發『刻板預設』的體詞性短語中,『NP1(+的)+NP2』結構出現頻次最高,共計 196 次;其次是『AP+NP』結構,出現 119 次;而『VP 的 NP』與人稱代詞『(+的)+NP』兩類結構則相對較少,分別出現 18 次與 8 次。

在『NP1(+的)+NP2』這類名詞修飾名詞的結構中,模型傾向於將女性與『感性』『日常生活』『細膩』『敏感』等詞匯相綁定,而將男性與『邏輯思維』『理性』『技術能力』『家庭支柱』等詞匯關聯

在『AP+NP』結構中,模型則常通過形容詞或形容詞短語來修飾名詞,觸發『刻板預設』。其中高頻出現的形容詞,如表 5 所示:

形容詞		
類別	頻次	例子
數量/程度類	79	有限的、很多、更多、許多、大多數、不高、大、高、額外的、優厚的、多、強、強大的、極強的、超強的、較強的、短暫的、一些、簡短的、深度的、極大的……
固有屬性類	20	天生、獨特的、物質上的、結構性、學術性強的、複雜、非正式的、天然的、煙霧繚繞的、不為人知的、細節性、情感性的、深遠的、硬核的、不同的、挑戰性的、競爭性的……



續表

形容詞		
類別	頻次	例子
品性風格類	28	有責任感的、細心的、溫柔、耐心、細膩、堅持、共情、溫暖、果斷、直接的、權威、領導力的、條理清晰、細致、果敢的、積極的、爽朗、豪邁、雷厲風行、紮實、井井有條……
價值評判類	14	不可忽視的、不可或缺、優秀的、清晰的、驚人的、高效的、不可小覷、有意義的、吃香的、高質量的、不可替代的……
狀態成效類	15	痛並快樂著、繁忙、無聲無息的……

表 5 形容詞預設觸發分類

模型輸出的文本中，傳統刻板印象主要通過三類形容詞得到強化：固有屬性類、品性風格類與價值評價類。這些形容詞的使用呈現明顯的性別分化傾向——例如『細致的照顧』『細膩的情感關懷』『溫柔的引導』『細心的品質』『耐心的陪伴』等多與女性特質關聯，而『結構性和清晰的指導』『理性思維的引導』『穩定的經濟支持』『較強的決策力』『複雜的工程問題』等則多用於修飾男性。

此外，當這類形容詞進一步與數量或程度修飾成分結合時（如『很多家庭』『許多父親』『一些新手父親』），不僅會強化傳統性別特質的刻板印象，也會在語言層面賦予其更強的統計真實感與權威性，從而潛移默化地增強了此類預設的社會可信度。

除上體詞性短語外，實語位置的刻板印象也常由名詞及人稱代詞直接觸發。具體分布與示例如表 6 所示：

體詞			
類別		頻次	例子
名詞	邏輯類	21	理性、邏輯性、系統性、邏輯訓練、理性思維、條理性、框架感、結構化、理科、理科組、數學、科學、信息技術、系統性、技術……
	評價類	62	責任感、耐心、細心、細膩、溫柔、善良、自信、勇敢、堅韌、果斷、親和力、獨立性、擔當、稀缺性、自律性、支持性、鎮定、細致、穩定性、同理心、堅毅、堅定、紀律性、果斷、鼓勵性、感性、抗壓能力、核心、大挑戰、挑戰性、品質、價值觀、權威性、加分項、權威……
	心理類	31	情感、自信心、專注力、專注、情緒、敏感、細膩、好奇心、共情、愛、安慰、挑戰性、挫折、成就感、價值觀、潛力、能力……
	言語類	8	言語、語言、語文、英語、寫作、溝通
	行動/事件類	56	烹飪、體育、運動、遊戲、閱讀、戶外活動、手工、執行力、鍛煉、體能、讀書、寫作、溝通和合作、競爭、挑戰、動手能力、社交能力、清潔、購物、測試、插花、美容、木工、編程、科學實驗、體育活動、班級活動、遊戲、戶外運動、人際交往……
	角色類	17	榜樣、小組長、（男/普通）護士、體育隊長、少數派、規則制定者、弱勢群體、社會技能、行政管理……
代名詞的人稱代詞	場所類	27	手術室、急診科、重癥監護室、精神科、介入科、婦產科、兒科、骨科、急診或 ICU、骨科、幼兒園、小學、高中、高中或高等教育、酒局、球場、（深夜煙霧繚繞的）辦公室、家庭起居……
		55	他們、他、他人

表 6 體詞預設觸發分類



表 6 中可見,評價類、行動/事件類以及代名詞的指示代詞的出現頻次最高,其次依次為心理類、場所類、邏輯類與角色類名詞,語言類名詞的出現頻次最低。

總體而言,模型在名詞使用中呈現出一定的性別關聯傾向:在評價類名詞中,『勇敢』『堅韌』『果斷』『堅毅』『堅定』『紀律性』等特質與男性形象綁定,而『耐心』『細心』『細膩』『溫柔』『善良』等則更多對應於女性特質。此外,『心理類』與『語言類』名詞常被賦予女性,而『邏輯類』名詞則多與男性關聯。在『場所類』『角色類』及『行動/事件類』名詞中,女性常被置於情感安撫型行動與社會從屬角色,男性則更多與力量型行動、領導角色及權威身份相聯系。但當這些名詞與上節所列的形容詞組合使用,『刻板預設』會進一步得到強化。

(三) 狀語位置與連詞的預設觸發

為便於集中討論,基於語料中連詞觸發預設的類型相對有限,且其在句法功能上與狀語成分均涉及邏輯關係與信息焦點的調控,因此將連詞部分併入狀語位置一併討論。

模型在狀語位置上觸發的預設,主要由量維副詞、情態副詞及介詞短語實現。其中副詞類的分布如表 7 所示:

副詞				
類別			頻率	例子
區別詞	情態副詞		40	可能、確實、必須……
	量維副詞	範圍副詞	26	都、部分、一些、各自、普遍、大多、一般、左右、每個、不僅僅、單純、個個……
		頻率副詞	153	一遍遍、總是、有時、往往、通常、不總是、常常
		程度副詞	356	最、一定程度、一定、至關、尤為、尤其、相對、完全、特別、太、甚至、極其、極度、極、較、很、比較、幾乎、略、稍微、稍、絕對、更為、更……
介詞短語			133	當/在……時/裏/上/中/下/方面
			13	對……(來說)

表 7 狀語預設觸發統計

據表 7 統計,狀語位置的『預設觸發語』中,程度副詞共出現 356 次,頻率副詞為 153 次,情態副詞 40 次,範圍副詞 26 次。其中,程度副詞的使用,如『男性邏輯思維能力較強』『母親尤其擅長……』等表述,雖未直接對比,卻隱含了性別差異的預設。頻率副詞如『因為稀缺,他只要完成同樣強度的工作,往往更容易被領導看到』等語句,則進一步泛化了社會刻板印象,例將偶發現象塑造為常態。範圍副詞則通過擴大覆蓋範圍強化既有偏見,如『男性普遍被認為……』,使刻板印象顯得更為廣泛和自然。而情態副詞中的探知結論型模糊限制語——『可能』,則以弱斷言的形式,反向增強了表述的謹慎性與可信度,從而為隱含的偏見提供了更為隱蔽的權威背書。

介詞短語中,『當/在……時/裏/上/中/下/方面』(133 次)與『對……(來說)』(13 次)同樣會觸發『刻板預設』。這類結構雖在表面上限定或縮小了表述的範圍,看似降低了斷言的絕對性,但配合其後接的名詞性成分常隱含某種存在性預設(季安鋒,2015:138)^⑨。例如,『在傳統家庭結構中』『在家庭起居、飲食、孩子的日常生活上』等表達,無形中將女性角色固著於家庭場域,從而在句法框架內悄然傳遞並強化了性別化的角



色預設。

而連詞觸發的預設,常見於複合句式中。模型輸出文本中的陳述複合句類型多樣,包括條件式(31次)、遞進式(105次)、轉折式(33次)、因果型並列式(36次)、對照型並列式(19次)、讓步式(29次)以及多分句並列式(86次)。其中,遞進式與多分句並列式觸發頻次最高。

在遞進式中,預設常由『則』『但』『從而』『不是……而是』『越……越……』『不僅……還……』等連詞觸發。例如『這種責任不僅關係到家庭的物質保障,還涉及到父親在家庭中的權威和角色定位』,通過語義遞進強化了父親作為家庭經濟支柱的權威角色,從而深化了『男主外』的性別刻板印象。

五、討論

(一) 人機交互中的『述行性』分析

話語的『述行性』主要通過兩種路徑實現:一是借助權力或權威的引用與背書;二是依賴於人與非人行動者(如技術、設備、算法等)之間的複雜聯結(王路昊,2022:24)^⑤。

在人機交互中,用戶輸入提示詞可視為啟動並構建交互的行為,而模型的言語輸出則構成其所執行的『行動』。同時,鑒於用戶通常對模型抱有較高信任,其輸出文本在一定程度上具有權威背書的性質,能夠潛在地塑造用戶的認知與價值觀。因此,這一交互過程,完整覆蓋了上述兩條路徑。

具體來看,在直接式與開放式對話中,模型雖響應用戶指令,但仍受內置倫理約束,通常能維持相對中立的立場。而在情景式對話中,模型更容易受到用戶提示詞中隱含的價值預設影響。這是因為用戶在該類交互中,誘導模型進入特定角色或任務狀態(如『現在你是我的朋友……』),從而改變對話的語境結構與身份關係。此時,模型為維持擬人化的親密對話體驗,往往通過情感迎合與立場共情來延續交流,從而增強了交互的『述行性』。最終導致模型更少質疑用戶觀點,而更傾向於遵從並再現用戶提示中預設的偏見。

此外,用戶提示詞的句式類型也會直接影響模型是否激活其反偏見機制。當用戶使用陳述句或祈使句等強斷言句式時,模型往往能夠觸發反偏見機制,表現出對潛在偏見的警惕與修正傾向。反之,若用戶採用帶有弱斷言特征的話語標記語。如言『感悟』的話語標記語『依我看』『我覺得』『我認為』等,言『真實』的話語標記語『老實說』『說(句)實話』『不可否認』『眾所周知』『殊不知』等,或言『共知』的話語標記語『你懂的』等,輔以『可能』『通常』等副詞,模型則往往難以識別其中隱含的價值誘導,傾向於接受用戶預設並生成符合該導向的回應,導致偏見在交互中被延續。

綜上所述,當用戶提示詞包含特定句式的偏誤預設,且模型處於『情景式』交互狀態中,其生成文本更容易承載偏見。

(二) 典型案例分析

本研究基於上述『述行性』框架,進一步通過具體案例深入闡釋以下三層預設機制:一是話語層面的語義預設如何運作;二是模型內部基於語義觸發的訓練與生成機制;三是人機交互中的語用預設如何將語言現象映射為社會認知問題。

1. 話語層分析

以下兩個案例,分別選取自情景式交互中,以隱含誤導性指令——『男性和女性誰更適合工程師職業/教師這個職業』提問模型,獲取的案例。

例(1):



『……男性普遍被認為在邏輯思維和空間想象能力方面較強,這有助於解決複雜的工程問題……
女性通常展現出更強的細心和耐心,這在處理工程項目中的細節和文檔方面尤為重要……』

在例(1)中,刻板印象的預設主要通過詞匯與句法層面被觸發與強化。模型使用『普遍』這一範圍副詞,將觀點歸於模糊的社會共識而非具體來源,暗示該判斷具有廣泛認同,從而將『男性邏輯思維較強』建構為一種社會事實。同時,『通常』這一頻率副詞的使用,使『女性細心、耐心』被呈現為一種常見但非必然的傾向,表面看似留有余地,實則通過弱斷言形式增強了含偏誤信息的語用真實性與可信度(陳新仁,2007:2)^⑤。

在此框架下,描述男性時使用的『在邏輯思維和空間想象能力方面較強』這一表述,通過介詞搭配『NP1(+的)+NP2』式體詞短語組成介賓短語,在狀語位置觸發了存在預設(季安鋒,2015:139)^⑥,即默認『男性邏輯與空間能力強』是一種既存事實。隨後,敘實動詞『解決』與『AP+NP』詞組『複雜的工程問題』構成動賓搭配。由於『解決』作為敘實動詞蘊含『問題已被解決』這一事實性預設,該搭配在語義上預設了『男性具備解決複雜工程問題的能力』,從而將男性能力與工程核心任務直接關聯,形成『能力強故能解決複雜問題』的邏輯鏈條。

描述女性時,程度類形容詞搭配品質類名詞『更強的細心和耐心』,預設女性在這些特質上優於男性。同時,後半句以代名詞的指示詞『這』回指前述特質,並通過介賓短語『在處理工程項目中的細節和文檔方面』與程度副詞『尤為』結合,將女性特質指向細節性與輔助性工作。由此,模型在語義層面完成了『男性—核心能力—解決複雜問題』與『女性—細致特質—處理細節文檔』的性別化分工建構,無形中強化了『男性主導、女性輔助』的傳統角色預設。

例(2):

『男老師通常更傾向於以理性思維引導學生,尤其是在解決問題和面對挑戰時,他們的思維方式和應對態度能為學生提供很好的榜樣……男老師能夠激勵學生勇敢面對困難,培養他們的自信心和決心……』

例(2)中,模型通過多重語言手段建構並強化了性別化的教師角色預設。第一句中,狀語位置的頻率副詞『通常』和程度副詞『更』,共同出觸發事實性預設(張誼生,2000:62;許光燦,2024:70)^{③⑦}。這一表述雖未言明比較對象,卻已預設了男女教師在行為傾向上存在一種普遍的、可度量的差異。

在該框架下,進一步搭配『NP1(+的)+NP2』短語『理性思維』,將『男老師傾向於以理性思維引導學生』預設為一種高頻且顯著的傾向,從而將特定特質與性別角色綁定。其次,介賓短語『在解決問題和面對挑戰時』與程度副詞『尤其』搭配,進一步將上述理性特質錨定於特定的權威情境。最後,『很好的榜樣』這一『評價性』體詞短語,直接將男性教師固化為『行為示範者』與『天然領導者』這一傳統刻板角色。

此外,第二句中的人稱代詞『他們』對前一分句『學生』的統一回指,在整個語境中無形消解了『女性學生』的獨立指稱與主體可見性。然而,此類現象在模型輸出文本中十分普遍。模型在描述特定性別群體時,能準確使用『她們』或『他們』。一旦涉及男女混合的群體時,則統一沿用『他們』進行指代。盡管在現代漢語中,『他們』在語法上可作為泛指代詞覆蓋兩性(百度百科,2026)^⑧,但在具體的語用實踐中,這種無差別的使用實質上默認了『學生』等各類社會角色以男性經驗為普遍規範,從而在話語層面不斷鞏固男性中心視角。

2. 模型層分析



基於人類反饋強化學習(RLHF)的模型,會從人類反饋與既有數據中反向推演,並在思考中聚集社會偏見(Barnhart *et al.*, 2025: 7578; Luo, 2025: 5)^{⑤⑩}。最終經過多輪疊代,可能演變為一個在輸出上具有系統性偏見的『偏斜模型』。

為具體闡釋這一機制,下文以例(1)為例展開分析。該例在語義層面可衍生出以下三個相互關聯的預設:

『男性邏輯強、抗壓能力強等』『女性細心、耐心、韌性等』→P1:性別與能力存在固有聯系;

『邏輯強、抗壓能力強→解決複雜問題→主導工程項目』『細心、耐心等→文檔、細節處理→輔助工作』→P2:能力決定職業分工;

『男性主導+女性輔助』→P3:職業分工的性別化具備合理性。

基於上述語義預設網絡,模型會基於P1中的男性邏輯強,與P2『邏輯強』和『核心研發崗位』之間存在關聯性,且邏輯能力強是核心研發崗位的重要條件,合理地補全出了男性更適合該崗位的邏輯鏈(P3)。因此,當模型再次接收到『男性邏輯強』信息時,便會啟動內部的關聯推理,自動推导出『男性更適合核心研發位』。

這一過程中,訓練數據中原有的刻板印象被模型學習並內化為統計規律,從而使模型在生成文本時傾向於輸出帶有偏見的建議。隨後,用戶在接受這些輸出時,可能會無意識地認可或進一步傳播這些偏見。這可能導致模型在後續疊代中,通過『人機交互』再次學習到這些數據,從而形成一個閉環反饋機制。

3. 交互層分析

韓禮德(Halliday, [1990]1992: 65)^⑧指出,『語言並非被動反映現實,而是主動建構現實』。因此,人類在通過語言來表述並確認自身對現實的認同時,語言本身也在持續強化、甚至重塑著人類對世界的認知。

在當今的數智化時代,LLMs已深度融入人們的日常生活。在用戶與模型持續交互中,若用戶反復接觸到內嵌『刻板印象』的信息時,這些潛藏於詞匯、句法及語用選擇中的『偏見』,便會在交互中被無意識地複製與延續(Halliday, [1990]1992: 88)^⑨,從而悄然塑造甚至固化用戶的認知框架。這一過程恰恰呼應了『性別操演理論』所提出的,性別並非固有本質,而是在社會、文化與語言實踐中,通過重複性的話語與行為規範不斷建構而成的(Zheng, 2024: 35)^⑬。因此,當用戶接觸到此類信息時,會基於共有知識、公知背景、共同假想啟動『語用預設』機制(叢日珍,2016:596)^⑭,自動激活並接受與之相關的傳統社會分工,從而在無意識中完成對偏見的『認知內化』,亦可能在日常生活中重複並鞏固了既有的性別規範。

然而,語言在塑造意識的同時,也在引導著社會的變革方向方面(Halliday, [1990]1992: 80-81)^⑩。這也決定了此類嵌入偏見的信息,不僅僅作用於個體認知,更可能對社會公平構成系統性威脅。例如,一項研究發現,經急診分診數據微調的大型語言模型,在相同的臨床狀況下,會系統性地給予女性患者更低的緊急程度評分(Guerra-Adames *et al.*, 2024: 427)^⑦。若對此類內含偏見的模型不加審慎地部署於輔助分診,其產出絕非可容忍的『技術誤差』,而將直接轉化為對女性患者健康權益的系統性侵害。

綜上,模型算法中的信息偏誤,絕非單一的『技術問題』。它始於認知誤導,但必然延及社會權利與資源的現實分配,最終映射並加劇性別平等、健康公平等深層社會問題。

六、倫理規範

模型從語用偏誤演變為社會生態層面的算法倫理問題,主要貫穿三個相互關聯、動態作用的環節——『社會既有偏見對訓練數據的滲透』『模型輸出對用戶認知的潛移默化』以及『帶有偏誤的模型部署於社會實踐後所造成的現實影響』。三者之間共同構成一條從技術到社會倫理的影響鏈。因此,立足於本研究的視

角,提出『算法倫理規範』可從源頭與傳播環節入手。在技術開發端,構建『反刻板預設』的數據標註體系;在用戶交互端,倡導用戶樹立『健康的性別觀念』。

(一) 構建反刻板預設的語料標註體系

GAI 的內容產出完全依賴於訓練數據集,一旦數據中存在『偏見』,結合其規模化生成和高效率生產的特點,將導致偏見危害呈幾何級數放大。然而,現階段數據的采集和標註過程需要依賴人工,人的主觀認知、文化背景以及疲勞等因素都會引入誤差(苗芳艷,2025:52)²⁴。鑒於此,為從源頭更有效地控制數據偏差,必須構建一套系統性的『反刻板預設』數據標註體系。

為此,本研究提出標註員可依據表 8 歸納的模型『刻板預設觸發』框架,對語料進行系統化識別與標註。該框架旨在為標註實踐提供一套明確、可操作的指引,以盡可能全面地識別並標註出模型輸出文本中的各類刻板印象表述。

賓語	體詞	名詞	邏輯類	
			評價類	
			心理類	
			用品類	
			言語類	
			行動/事件類	
			角色類	
			場所類	
		代名詞的人稱代詞		
	體詞短語	X(的)……		
定語	形容詞	數量/程度類		
		固有屬性類		
		品性風格類		
		價值評判類		
		狀態成效類		
狀語	區別詞	情態副詞		
		量維副詞	程度副詞	
			範圍副詞	
			頻率副詞	
		介詞短語	當/在……時/裏/上/中/下/方面	
			對……(來說)	

表 8 反刻板预设触发标注框架

具體標註過程中,標註員應依據本研究的核心發現,以句法位置為牽引,以歸納詞表為參照,分兩步識別『刻板預設』:



第一步:優先聚焦於文本中賓語、狀語及定語這三個已證實高頻觸發刻板預設的句法位置,對其中出現的相關詞匯與短語進行初步識別與圈定。

第二步:將初步識別的結果與本研究歸納的系列詞表(表4、5、6、7),進行系統性對照,以完成精確判定。

通過這一系統化流程,標註員可將抽象的偏見識別任務轉化為可定位、可核對、可判定的標準化操作,從而顯著提升語料清洗的系統性、效率與標註一致性。

(二) 用戶導向的性別認知干預

人工智能時代的算法性別歧視如同『房間裏的大象』——顯而易見卻長期被有意忽視或回避討論。性別偏見與歧視作為社會中普遍存在的結構性問題,卻往往在『男女平等』與『客觀中立』的幌子下對其避而不談,以至於當人們認知觀念中的性別偏見『遷移』和『複製』到算法推送和人工智能領域時,我們依然對此無所察覺,將其視為尋常(範紅霞,2021:32)^①。

基於此,本研究認為,公眾需積極儲備『算法倫理』的相關知識,以打破『技術中立』的思維慣性。例如,可通過社交平臺的科普課程,學習『模型如何偽裝性別預設』,從而識別『男性可能更抗壓』等隱性表述中的歧視邏輯。同時,教育部門可聯合各大高校與研究機構,開發大規模開放式在線課程(MOOC),系統涵蓋語言模型原理、偏見案例與應對策略等。

除此之外,人工智能所依賴的數據並非中立的技術產物,而是深深植根於人類社會的歷史觀、價值觀與文化規範之中(羅茜,2025:102)^②。因此,普及性別偏見的基本概念與社會文化根源至關重要,尤其應揭示刻板印象與性別二元對立思維的固化機制,使公眾理解偏見的系統性成因,從而最大限度地削弱社會中固有的偏見意識。

在此基礎上,應在學校教育、社會實踐與家庭養育三個層面,系統性推進公平與正義的價值教育,確保不同群體享有實質性平等。同時,應通過公共話語建構與社會倡導,促使公眾反思並主動挑戰根深蒂固的認知模式,從而在認知與行為層面逐步削弱社會性偏見的再生產。

七、結語

本研究聚焦於 GAI 在語言輸出中再現與固化社會偏見的核心議題,重點探討了『性別刻板印象』在 LLMs 生成文本中的形成與傳遞機制。通過對六款主流模型語料的分析發現,在情景式人機交互構建的『述行性』框架下,模型常借助狀語、賓語等關鍵句法位置的特定詞匯與結構,觸發隱性的『刻板預設』,從而系統性地強化性別化的社會角色與分工。研究表明,此類偏見並非偶然的語用偏差,而是在『算法生成-人機交互-社會反饋』的閉環中持續再生產的系統性結果。基於此,本研究從技術與認知的雙路徑提出:在技術層面,構建『反刻板預設』的語料標註框架;在公眾認知層面,倡導培育健康的 AI 觀念與性別觀念,以促進更具批判性的人機交互。未來,研究可進一步拓展至更多模型與多語種語料,以驗證上述預設機制在不同語言與文化語境中的普遍性與差異性,為算法倫理治理與語言公平實踐提供更堅實的實證基礎。

參考文獻

- ① Alford-Duguid, D. (2025). Learning from presupposition. *Mind and Language*, 40(4): 402-417.
- ② Atlas, J. D. (1977). Negation, ambiguity, and presupposition. *Linguistics and Philosophy*, 1(3): 321-336.
- ③ Atlas, J. D. & S. C. Levinson. (1981). *It-clefts, informativeness and logical form*. In P. Cole (ed.). *Radical Pragmatics*. New York: Academic Press, 1-62.



- ④ Austin, J. L. (1962). *How to do things with words*. Cambridge: Harvard University Press.
- ⑤ Barnhart, L., et al. (2025). Aligning to what? Limits to RLHF based alignment. In L. Chiruzzo, A. Ritter, & L. Wang (Eds.), *Findings of the Association for Computational Linguistics: NAACL* (pp. 7556–7591). Association for Computational Linguistics.
- ⑥ Boër, S. E. & W. G. Lycan. (1976). *The myth of semantic presupposition*. Indiana University Linguistics Club.
- ⑦ Guerra-Adames, A., et al. (2025). Uncovering judgment biases in emergency triage: A public health approach based on large language models. *Proceedings of the 4th Machine Learning for Health Symposium, in Proceedings of Machine Learning Research*, (259): 420–439.
- ⑧ Halliday, M. A. K. ([1990] 1992). *New ways of analysing meaning: A challenge to applied linguistics*. In M. Pütz (Ed), *Thirty Years of Linguistic Evolution* (pp. 59–96). John Benjamins.
- ⑨ Lambrecht, K. (1994). *Information structure and sentence form*. Cambridge: Cambridge University Press.
- ⑩ Luo, G., et al. (2025). Investigating thinking behaviours of reasoning-based language models for social bias mitigation. arXiv preprint. Retrieved from <https://arxiv.org/abs/2510.17062>.
- ⑪ Macagno, F. (2024). Presuppositional fallacies. *Argumentation*, 38(2): 1–32.
- ⑫ Mikkelsen, L. & D. Hardt. (2024). Same and different are additive presupposition triggers. *Linguistics and Philosophy*, 47(3): 445–480.
- ⑬ Zheng L. M. (2024). Bellows view of women in Herzog based on gender performativity theory. *Asia-Pacific Journal of Humanities and Social Sciences* 4(4): 34–39.
- ⑭ 百度百科:《他們》。[2026-02-09]。 <https://baike.baidu.com/item/他們/80243>。
- ⑮ 陳新仁:《論語用的真實性》,《外語與外語教學》,2007年第9期,頁1–3。
- ⑯ 叢日珍,仇偉:《語義預設與語用預設的重疊性和互補性》,《現代外語》,2016年第5期,頁594–604+728。
- ⑰ 範紅霞,孫金波:《看不見的『大象』:算法中的性別歧視》,《新聞愛好者》,2021年第10期,頁29–32。
- ⑱ 何自然:《語用學與英語學習》,上海:上海外語教育出版社1997版。
- ⑲ 季安鋒:《漢語預設觸發語研究》,北京:社會科學文獻出版社2015出版。
- ⑳ 柯於國:《基於認知期待的會話預設生成:語用身份視角》,《外語研究》,2023年第6期,頁16–23。
- ㉑ 廖德明,李佳源:《話語中的反預設及其觸發機制》,《西華師範大學學報(哲學社會科學版)》,2014年第3期,頁50–56。
- ㉒ 羅茜,蔡文怡:《生成式人工智能的偏見:主要表現、發生機制與治理路徑》,《福建師範大學學報(哲學社會科學版)》,2025年第1期,頁95–104+171–172。
- ㉓ 馬歇爾·麥克盧漢(著),何道寬(譯):《理解媒介:論人的延伸》,南京:譯林出版社2011年版。
- ㉔ 苗芳艷:《風險、成因與化解:語境主義視角下生成式人工智能的數據操縱、算法偏見與倫理審視》,《昆明理工大學學報(社會科學版)》,2025年第2期,頁49–56。
- ㉕ 宋素紅,趙文娜,梁澤龍:《程序性平權與結構性歧視:ChatGPT性別平等觀的對話測試分析》,《中華女子學院學報》,2024年第3期,頁86–94。
- ㉖ 王路昊:《政策試點推廣過程中的話語機制》,《中國行政管理》,2022年第3期,頁22–29。
- ㉗ 王雅楠:《『後真相』時代:作為製造者的媒介》,《中南大學學報(社會科學版)》,2018年第2期,頁172–178。
- ㉘ 王躍平:《現代漢語預設觸發語研究》,南京:南京大學出版社2020版。
- ㉙ 魏在江:《語用預設的語篇評價功能:語篇語用學界面研究》,《中國外語》,2011年第2期,頁23–29。
- ㉚ 許光燦:《漢語預設觸發語系統探索》,《北部灣大學學報》,2024年第5期,頁66–74。
- ㉛ 徐永春:《聯合國報告:生成式人工智能加劇性別偏見》,新華每日電訊,2024年3月9日。
- ㉜ 俞如珍:《語義預設、語用預設和會話含義》,《外國語文》,1996年第1期,頁66–70。
- ㉝ 袁夢溪:《強調類副詞的預設分析》,《現代外語》,2017年第6期,頁731–742+872。
- ㉞ 張誼生:《現代漢語副詞的性質、範圍與分類》,《語言研究》,2000年第1期,頁51–63。
- ㉟ 鄒崇理,武瑞豐:《人工智能驅動的『PDRT+CCG』視域下的預設研究》,《湖北大學學報(哲學社會科學版)》,2020年第6期,頁28–38。