

DOI: 10.53104/xdkxts.2025.01.02.004

推薦系統中演算法強化與使用者偏好共演化機制研究

周波¹

1. 渤海大學，遼寧 錦州，121013

摘要：推薦系統是智慧資訊分發中的關鍵技術，已經成為人們獲取資訊方式中的重要部分。在實際運行中，系統會根據使用者的點擊、流覽和停留等行為反復調整模型參數，這種調整提高了個性化程度和推薦準確性，但同時也在慢慢改變使用者的興趣結構和偏好取向。本文從運行機制出發，討論演算法強化過程與使用者偏好變化之間相互影響、相互塑造的關係，研究首先介紹了推薦系統的基本技術結構和演算法強化的工作方式，指出使用者行為在系統中具有雙重意義，用戶行為直接表達個人興趣和選擇傾向和這些行為會被系統記錄並作為回饋資料重新輸入模型，用來指導下一輪推薦，兩種作用在系統中同時存在，使演算法學習和使用者選擇形成一個持續運轉的反饋回路。文章從機制層面分析了使用者偏好在推薦系統中的變化過程，說明在長期重複的回饋作用下，用戶更容易反復接觸相似內容，興趣逐漸集中在有限的內容類別型上，而其他類型被看到的機會不斷減少，這種偏好收縮和多樣性下降，並不是由個體主觀意願單獨決定的，而是由系統回饋結構本身推動形成的結果。本文提出一個演算法與使用者共同變化的系統模型，將推薦系統理解為一個由演算法學習和人類行為共同驅動的整體系統，這一系統在持續回饋過程中不斷調整自身狀態，表現出明顯的適應性、不均勻變化以及對早期選擇高度依賴的特徵。基於這一認識，文章從工程設計角度討論了強化目標設定、系統穩定性以及內容多樣性等問題，強調在系統設計階段應正視演算法強化對系統長期走向的影響。本文從系統運行和機制結構的角度解釋推薦系統在長期使用中的行為邏輯，為理解演算法強化條件下的人與演算法互動關係提供一種清晰、直接的分析思路。

關鍵字：推薦系統；演算法強化；用戶偏好；反饋回路；共演化機制；系統演化

Research on the Co-Evolution Mechanism of Algorithmic Reinforcement and User Preferences in Recommender Systems

ZHOU Bo¹

1. Bohai University, Jinzhou 121013, P.R.China

Correspondence to: ZHOU Bo; Email: bo.1996.85@outlook.com

Abstract: The recommendation system, as a core technology for intelligent information distribution, has become an important component of the human information interaction structure. With the continuous development of the algorithm reinforcement mechanism, the system continuously optimizes the model performance through user behavior feedback, achieving personalized and high-precision recommendations while gradually influencing and reshaping users' interests and preferences. This paper, from a mechanism perspective, explores the co-evolution

收稿日期：2025-12-10 返修日期：2025-12-30 錄用日期：2026-01-09 出版日期：2026-01-13

通信作者：bo.1996.85@outlook.com

引用格式：周波. 推薦系統中演算法強化與使用者偏好共演化機制研究[J]. 現代科學探索, 2025, 1(2): 37-48.

relationship between algorithm reinforcement and user preferences. The study first analyzes the technical structure of the recommendation system and the logic of algorithm reinforcement, pointing out that user behavior in the system plays a dual role of expressing preferences and generating feedback, thereby forming a continuous reinforcement loop. Subsequently, through mechanism analysis, it reveals the evolution path of user preferences in the recommendation system and demonstrates the internal logic of preference convergence and diversity decline caused by the long-term feedback cycle. Further, this paper proposes a system model of algorithm and user co-evolution, arguing that the recommendation system can be regarded as a self-organizing system driven by both algorithm learning and human behavior. This system exhibits complex characteristics such as adaptability, non-linearity, and path dependence in dynamic feedback. Based on this, this paper conducts mechanism-based reflections on the goal design of reinforcement, system stability, and diversity issues from the engineering perspective, emphasizing that attention should be paid to the shaping effect of algorithm reinforcement on the long-term evolution of the system during the design stage of the recommendation system. The research of this paper does not involve algorithm effect evaluation or empirical verification, but is dedicated to explaining the long-term behavioral logic of the recommendation system from the perspective of system evolution and mechanism, providing theoretical frameworks and engineering inspirations for understanding the human-algorithm interaction relationship under algorithm reinforcement.

Key words: recommender system; algorithmic reinforcement; user preferences; feedback loop; co-evolution mechanism; system evolution

引言

推薦系統已經滲透到人類日常資訊消費的幾乎所有場景。它們在新聞分發、短視頻推薦、社交媒體資訊流、線上教育以及電子商務中承擔著內容篩選與個性化呈現的關鍵角色。面對爆炸式增長的信息量，推薦系統通過演算法自動化決策過程，替代了用戶的自主篩選行為，從而成為數位環境中人機交互的核心機制^[1]。人們在流覽、點擊、評論、分享的過程中不斷生成行為資料，而這些資料又被系統捕獲、分析並用於演算法的持續優化。推薦系統因此不僅僅是資訊分發的工具，也成為塑造資訊接觸結構的重要力量。

在技術邏輯層面，當前主流的推薦演算法大多依賴使用者的歷史行為進行建模。系統通過收集點擊、流覽、停留時間、購買記錄等回饋信號，構建個體化的興趣畫像，並在此基礎上優化模型參數，以實現更高的預測精度。這一機制具有自學習特徵，模型能夠隨著使用者行為的累積而動態更新，從而在不斷的反覆運算中提升匹配度和用戶滿意度。工程實踐中，這種基於回饋的演算法優化被視為智慧化推薦的

核心優勢。

這一過程並非單向的識別與回應關係。演算法在根據使用者行為強化自身性能的同時，也在持續塑造用戶的注意力與偏好。用戶所表現出的興趣往往並非完全獨立的主觀選擇，而是在演算法生成的內容環境中被引導與限定的結果。使用者行為成為演算法學習的輸入，而演算法輸出又反過來影響使用者的行為取向。演算法優化與使用者回應之間形成了一個不斷迴圈的回饋系統，使得個體的興趣軌跡與演算法的演化路徑交織在一起^[2]。

這一迴圈帶來了一個值得深入思考的問題：在演算法的持續強化過程中，用戶的偏好是否仍然可以被視為自主形成的心理結構？或者說，使用者的興趣是否正被演算法所生成的推薦邏輯系統性地重塑？推薦系統的優化目標通常聚焦於提高交互頻率與平臺留存率，用戶偏好的生成則被隱含地嵌入到這一優化框架中。當演算法強化與使用者行為相互作用時，原本應作為系統輸入的使用者偏好，逐漸轉化為演算法輸出的一部分。演算法不再只是識別興趣，而是在重複的回饋迴圈中生產興趣、放大興趣、固化興趣。

在這一意義上，推薦系統已經超越了單純的技術工具屬性，成為一個具有自組織特徵的社會—技術系統。它在運行中不斷學習、調整、適應，而用戶的認知、情感和行為也在系統的動態輸出下逐步演化。演算法強化的技術邏輯與人類心理機制交織，使得個性化推薦演化為一種共生的結構性過程。系統不再是中立的媒介，而是具有方向性的行為塑造力量。

本文正是基於這一現象展開機制層面的探討。研究不討論推薦效果的優劣，也不進行實證驗證，而是聚焦於演算法強化與使用者偏好的互動關係。通過分析推薦系統的結構邏輯與強化機制，揭示演算法在優化過程中如何影響使用者偏好的形成路徑，進而探討人—演算法系統在長期交互中呈現出的共演化特徵。本文試圖從系統演化的視角理解這一機制，為未來關於推薦系統長期行為的研究提供理論基礎。

2 推薦系統與演算法強化的技術基礎

2.1 推薦系統的基本結構

推薦系統是一種通過演算法模型對使用者與內容進行匹配的智慧資訊過濾機制，其目標是在龐大的資訊集合中為特定使用者提供最可能感興趣的項目。在資訊超載的數位環境中，推薦系統通過分析歷史行為資料構建使用者偏好模型，以減少使用者的搜索成本並提升個性化服務品質^[3]。推薦系統的運行依賴於四個基本組成部分：使用者、內容或物品、行為資料與推薦模型。這四個部分構成了一個動態交互的閉環，使系統能夠在不斷地資料流程動中實現自學習與性能優化。

使用者是推薦系統的起點與核心。系統需要在大量使用者群體中識別個體特徵，從而生成差異化的推薦結果。使用者在系統中的存在並不僅僅是被動的接收者，他們通過點擊、流覽、收藏、評論、購買等行為不斷提供資訊信號，這些信號成為演算法優化的直接依據^[4]。使用者的行為構成了推薦系統的感知層，決定了系統能夠捕捉到怎樣的興趣輪廓與偏好趨勢。

內容或物品是推薦系統的另一端。系統需

要對內容資源進行結構化處理與特徵表示，使其可以被演算法識別與計算。在實際系統中，無論是視頻、文章還是商品，系統通常會通過特徵提取技術將其轉化為向量化的資料結構，以便與使用者興趣空間進行匹配。推薦系統不僅處理內容的顯性資訊，還通過隱語義建模方式捕捉潛在屬性，從而發現抽象層面的偏好模式^[3]。

行為資料在系統中承擔橋樑作用。它連接使用者與內容，是系統學習與回饋的基礎。資料的收集通常通過埋點、日誌記錄和使用者交互介面完成。點擊、停留時間、跳出率、點贊次數等指標構成了系統的輸入信號。資料經過清洗、預處理與建模後進入推薦模型的訓練階段，成為演算法優化的核心資源。資料品質直接影響模型性能，而模型對資料的依賴也導致推薦系統具有明顯的歷史依賴特徵^[4]。

推薦模型是整個系統的智慧中樞，其核心任務是從資料中學習模式與規律，形成可泛化的預測能力。早期推薦系統主要基於協同過濾思想，即通過比較用戶或物品之間的相似性實現推薦。隨著機器學習技術的發展，基於矩陣分解、深度神經網路等方法逐漸成為主流^[3]。這些模型能夠從大規模行為資料中提取高維特徵，並在非線性空間中進行匹配預測，從而提高推薦效果。

推薦系統的運行邏輯可以概括為一個動態的閉環。使用者的行為首先被採集並轉化為結構化資料，系統利用這些資料訓練模型，模型生成新的推薦結果，用戶在接收推薦後再次產生新的行為，而這些新的行為又被系統採集進入下一輪學習。這種迴圈形成了自我調整的資料流程動機制，系統性能的提升依賴於回饋品質，而回饋品質又受到系統輸出的影響^{[3][5]}。用戶的每一次點擊都可能在無形中影響模型的未來更新方向，使演算法在演化過程中不斷重構用戶興趣空間。

在實際應用中，推薦系統常常面臨多目標優化問題。平臺可能同時關注點擊率、轉化率、停留時間與用戶滿意度等指標。不同目標之間存在潛在的張力，系統需要在短期收益與長期用戶體驗之間取得平衡。演算法在此過程中會形成複雜的優化路徑，這種多維度的學習與調

節進一步加深了推薦系統的動態複雜性^[6]。

2.2 演算法強化的基本邏輯

演算法強化指系統在運行過程中通過回饋信號實現性能的自我改進。這一概念源自強化學習的思想，即智慧體在環境中通過行動與回饋不斷學習最優策略。在推薦系統中，演算法強化表現為模型利用使用者的行為回饋來調整推薦策略，使得系統在連續交互中逐漸趨向於最能引發積極反應的推薦模式^[7]。

推薦系統的回饋信號通常以點擊、停留時長、轉化行為或互動頻率等形式存在。這些回饋被視為系統對某一推薦結果的回報評估。演算法的優化目標通常是最化某種回報函數，代表系統希望達到的行為效果。例如在短視頻平臺中，演算法可能以使用者的觀看時長作為主要回報信號，在電商平臺中則可能以購買轉化率為主要優化指標。回報函數的設定直接決定了演算法強化的方向，也隱含地規定了系統的演化軌跡^[7]。

演算法強化過程可以理解為一個持續的決策鏈條。每一次推薦都是演算法在當前狀態下對未來行為的一種預測與嘗試。系統根據使用者的即時回饋調整模型參數，使後續推薦更符合預期。強化學習在此過程中提供了一種動態平衡機制，使系統能夠在探索新內容與利用已有規律之間尋找最佳策略^[8]。

強化過程具有顯著的路徑依賴性。推薦系統初期的行為資料往往在演算法中佔據不成比例的權重，這些早期資料構成了系統的“經驗基礎”。模型在訓練中會逐漸偏向于這些早期形成的偏好模式，導致演算法在後續階段更傾向於重複強化既有的興趣結構。這種依賴性使系統在長期運行中可能出現興趣收斂與推薦趨同的現象^{[5][7]}。

演算法強化不僅是一種技術過程，也是一種認知生成過程。使用者行為既是演算法學習的依據，也是被演算法塑造的產物。使用者在演算法推薦的內容中進行選擇，這些選擇又反過來驗證演算法的判斷。演算法因此獲得“正回饋”，進一步強化相似的內容分發模式。推薦系統逐步形成自迴圈的結構，使演算法強化與使用者回應之間呈現相互放大的趨勢^{[2][5][8]}。

在工程實踐中，演算法強化通常通過線上學習機制實現。系統會在每一次使用者交互後即時更新部分模型參數，使得推薦策略能夠適應環境變化。這種更新方式使系統具備高度靈活性，但也帶來動態不穩定的風險。當系統對短期回饋過度敏感時，演算法可能出現頻繁的策略波動，導致推薦品質下降或用戶體驗斷裂。為緩解這種問題，部分系統會引入延遲回饋建模機制，通過時間視窗平滑參數更新，降低短期雜訊的影響^{[6][7]}。

從系統演化的角度看，演算法強化構成了推薦系統的內在驅動力。系統通過強化機制不斷優化自身行為模式，實現自組織與適應性演化。每一次回饋更新都意味著系統的內部狀態發生微小調整，積累到宏觀層面便可能引發系統結構的整體偏移。演算法因此不再是被動響應機制，而是具有主動演化特徵的適應性實體^[8]。

3 演算法強化驅動的使用者偏好演化機制

推薦系統的運行不僅是演算法對資料的計算過程，也是一種社會—技術層面的交互過程。演算法強化使得推薦系統在技術上實現自我優化的同時，在內容分發過程中參與了用戶注意力與偏好的塑造。這種交互表明用戶興趣、認知與選擇習慣並非孤立存在，而是在演算法模型與回饋迴圈中持續演化，這與“使用者與演算法共演化”的結構性機制一致^{[9][10]}。

3.1 使用者行為作為強化信號的機制分析

在推薦系統中，使用者行為資料被視為演算法優化的核心資源。點擊、收藏、停留時長、點贊、評論等行為都被設計為回饋信號，直接影響模型的更新方向。系統在獲取這些信號時往往假定它們真實反映了用戶偏好。然而，從系統機制角度看，使用者行為不是完全獨立的心理意圖表達，而是在演算法推薦環境中產生的反應結果。推薦系統通過反復展示演算法認為高價值的內容，使使用者在有限的內容集合中做出選擇，這一過程引發了回饋信號的“約束性表達”^{[9][10]}。

這種限定性表達構成了使用者偏好的半結構化資料空間。演算法在這一空間中學習興趣分佈，但這種興趣空間本身已受到既有推薦策略的影響。當使用者行為被用作訓練信號時，系統在優化模型的同時也在強化自身對這一行為空間的依賴，從而使行為資料既是輸入又是約束機制^{[10][11]}。這種編碼與過濾作用在機器學習中常見於對輸入特徵的精煉，在推薦系統中體現為對“強信號”和“弱信號”的不同解讀與放大。

推薦系統的回饋邏輯改變了傳統資訊選擇的路徑，使“被動暴露”逐漸替代了“主動搜索”。推薦演算法根據使用者與候選內容的歷史行為分配注意力，而使用者在演算法分配的注意力空間中做出的每一次點擊，都被量化為回饋信號^{[10][12]}。隨著時間累積，這種迴圈不斷削弱了使用者在資訊選擇中的自主性，使得使用者偏好受到演算法結構的強約束。

從心理機制層面分析，用戶行為本身帶有情緒與動機成分。演算法推薦常常通過介面設計、排序策略等方式放大內容的情緒吸引力，使用戶在愉悅或好奇等心理狀態下產生更多高回饋行為。系統捕捉到這些信號後進一步放大同類內容，使使用者形成習慣性偏好^{[9][10]}。這種情感驅動的行為強化與演算法參數更新同步進行，構成了技術層面與心理層面的共振。

行為信號的可計算性使演算法能夠對使用者偏好進行有效估計，但這種簡化也伴隨資訊損失。複雜的心理興趣被折疊成可統計指標，在高維空間中被模型平滑為穩定趨勢^{[10][11]}。這種模型追求穩定性的策略往往優先強化重複性行為，而忽視偏好本身的流動特性，在長期演化中可能造成興趣結構的漸進固化。

3.2 強化反饋回路的形成過程

推薦系統的回饋結構可抽象為一個閉環過程：初始偏好 → 推薦內容 → 使用者回應 → 模型強化 → 下一輪推薦。這一迴圈不僅是技術流程，也是動態認知生成機制。系統在每一輪迴圈中吸收使用者回饋信號，調整內部權重，生成更新的推薦內容；使用者在新環境中反應再次形成資料登錄^{[10][11]}。

初始偏好通常來自用戶顯性輸入或冷開機

特徵，如註冊興趣標籤或早期行為歷史。基於此資訊，系統生成第一輪推薦。使用者對推薦內容的回應成為演算法學習的第一批回饋資料，而這些資料在初期階段對模型方向具有顯著影響，因為初期資料量少但權重往往較大^{[9][10]}。這種早期效應常常導致參數空間快速收斂到特定模式。

隨著系統運行，推薦內容逐步趨向高回饋區域。演算法通過點擊率等指標判定哪些內容能獲得更高使用者回應，並提高其曝光優先順序^[14]。這種機制在理論上能夠快速提升短期回饋指標，但長期來看卻可能壓縮用戶的探索空間，使推薦策略陷入“高回饋區域迴圈”。

用戶回應是閉環中的關鍵節點。演算法將使用者行為視為環境回饋，而模型通過梯度調整等機制更新參數。這種基於統計規律的強化方式無法區分使用者的真實興趣和環境誘導行為^{[10][11]}。由於演算法並不理解使用者內在心理意圖，其“學習”實際上是對行為模式的概率化估計，這種估計在長期迴圈中可能產生系統性偏移。

在進入下一輪推薦後，新策略往往更偏向歷史高回饋區域，使得使用者接收到的內容結構更加集中，從而引發行為模式趨同^{[10][12]}。短期內這似乎提高了預測準確度，長期則會使系統多樣性下降、興趣空間壓縮。這種結構化反饋回路與認知層面的習慣形成高度耦合，使推薦系統具有自組織特性。

介面設計與交互機制在強化回路中起到輔助作用。推薦系統通過視覺佈局、推薦頻率等方式控制使用者注意力路徑，從而在行為層面引導用戶選擇^{[10][12]}。使用者對內容的回應因此並非完全自主，而是在演算法與介面共同塑造的結構性行為空間中發生。

從系統演化角度看，強化反饋回路是一種自組織過程。演算法通過局部回饋優化實現全域結構穩定，使用者行為在多輪交互中形成規律性分佈^{[9][10]}。這種動態平衡不依賴外部控制，而是由回饋機制驅動維持，使推薦系統表現出複雜適應系統的特徵。

3.3 用戶偏好收斂與演化趨勢

長期運行的推薦系統往往呈現出使用者偏

好收斂的趨勢。演算法在強化過程中放大高回饋行為模式，使使用者接觸的資訊類型逐漸集中。這一收斂趨勢在多個研究中被觀察到，被認為是“回音室”（echo chamber）或“過濾氣泡”（filter bubble）現象的一種演算法性呈現^{[10][13]}。

偏好收斂首先表現為內容多樣性的下降。推薦演算法在優化回饋信號時，會優先選擇產生最大即時回報的內容類別型，而對低回饋內容的機會減少^[14]。高回饋區域獲得更多曝光，而長尾內容或低回饋類型被邊緣化，導致內容聚集效應增強。隨著時間推移，使用者興趣空間不斷壓縮在演算法偏好的核心區間。

偏好收斂的第二層面體現在使用者心理結構的變化。使用者在長期交互中對推薦系統產生信任感與依賴，演算法逐漸成為預設的資訊選擇代理，使用者的探索性逐漸減少^{[9][10]}。這一趨勢與認知科學中的“確認偏誤”效應一致，即人們傾向於接受與自身既有興趣一致的資訊，強化回饋機制加劇了這一心理傾向。

偏好收斂還具有社會擴散效應。當大量使用者在同一演算法邏輯下互動時，個體偏好收斂過程可能在群體層面放大^{[10][14]}。推薦系統通過共用模型參數影響整體使用者行為模式，使群體行為趨同成為全域性現象。平臺生態中出現內容同質化、新穎內容難獲得曝光等現象，反映了強化機制在社會層面的累積效應。

從機制角度看，偏好收斂並非演算法失效，而是強化過程的自然結果。在高回饋區域達到收益最大化時，演算法會壓縮探索空間，使系統在局部最優狀態保持收斂^{[10][14]}。除非引入外部擾動或不同目標函數，否則系統難以自發打破收斂趨勢。這一結構性特徵說明推薦系統的多樣性衰減並非偶然，而是強化機制的內在邏輯。

4 演算法強化與使用者偏好的共演化模型

推薦系統在長期運行過程中逐漸形成一種動態複雜的交互結構。演算法與使用者並非簡單的因果關係，而是在持續的回饋迴圈中相互影響、相互適應、共同演化。演算法通過強化機

制不斷學習使用者的行為模式，使用者在演算法生成的內容環境中改變自身的興趣、注意力與選擇習慣。二者之間的關係既不是單向控制，也不是完全獨立，而是一種持續耦合的動態系統。這種現象可以用“共演化”來描述^{[9][10]}。

4.1 共演化的概念界定

“共演化”一詞最早源於生物生態學，指不同物種在競爭、合作等互動中共同演化的過程。在複雜系統科學中，該概念被擴展為兩個或多個子系統在長期交互中通過回饋調整模式與狀態，實現相互塑造和動態演化^[9]。在推薦系統語境下，這種動態過程體現為演算法與使用者之間的交互通訊迴圈。

在推薦系統中，演算法根據行為資料生成推薦結果，使用者對推薦內容的選擇、點擊、停留和忽略等行為又成為新一輪訓練資料。這些信號推動模型參數更新，導致系統輸出狀態發生變化，從而影響用戶下一輪的行為環境。隨著這一過程的反覆運算，演算法與使用者的狀態不斷調整，形成長期自我調整互動^[10]。演算法在優化過程中不斷調整參數，而使用者在資訊暴露與心理反應中不斷重塑興趣結構，二者共同構成一個自組織的演化系統^[9]。

共演化的關鍵特徵是相互依賴與回饋放大。演算法需要使用者行為作為學習素材，而使用者的行為模式又在演算法輸出下發生變化，這種迴圈體現出非靜態平衡的動態調整特性^[9]。演算法不是簡單地適應使用者，使用者也不是被動接受演算法，而是在多輪交互中共同決定系統演化方向。共演化體現了人機之間的共構關係，演算法強化與人類認知行為在同一回饋網路中進行共同演進。

在這一結構中，推薦系統不再是外部為使用者服務的工具，而成為人類行為的一部分。使用者興趣不再是獨立生成的心理狀態，而是演算法結構中不斷被重塑的變數^[10]。演算法的學習規則與使用者行為策略交織成一個複雜的共演過程，系統穩定性、偏好分佈以及資訊生態特徵都源自這一起演化機制。

共演化的另一核心維度是自我調整性。演算法與使用者在互動過程中不斷調整自身行為規則以適應對方變化。演算法通過強化學習或

深度學習機制更新推薦策略，而用戶在推薦流中形成對演算法輸出的心理預期，並據此調整自身反應。系統內部每一方通過經驗積累實現適應性演化。演算法優化速度與使用者行為變化頻率共同決定系統動態平衡狀態，當兩者適應節奏同步時，系統趨向穩定；當變化速度不匹配時，系統可能出現震盪或模式漂移。

共演化不僅是一種關係描述，也是一種生成機制。它揭示了推薦系統如何通過長期交互形成複雜行為結構。演算法強化的技術邏輯與使用者的心理反應共同構成系統演化動力，理解共演化核心在於識別回饋路徑與適應過程之間的非線性關聯^[10]。

4.2 人 - 演算法系統的動態耦合機制

推薦系統中的人 - 演算法關係可以被視作一種動態耦合結構。演算法是通過數學模型實現的自學習系統，使用者是具有情感、認知與動機的行為體。兩者的互動不是線性的輸入一輸出關係，而是一種相互影響、相互重塑的動態過程^[12]。演算法的更新規則決定了使用者在平臺中的可行行為空間，用戶行為變化又反過來影響演算法參數，使模型對特定特徵的回應敏感性不斷調整。

這種動態耦合體現於多個層面。第一層是結構耦合。推薦系統通過介面與交互設計將演算法輸出嵌入使用者體驗中，用戶在操作過程中無意識適應系統邏輯。演算法的內容佈局、推薦節奏與呈現方式構成行為場景，使用者反應被收集為資料回饋^[10]。

第二層是認知耦合。使用者的注意力、興趣與判斷在演算法推薦引導下形成新的感知模式。演算法決定資訊呈現順序，從而塑造使用者心理預期。使用者選擇行為並非完全自主，而是在演算法生成的注意力環境中發生。演算法持續調整推薦權重，使使用者認知傾向逐漸與系統輸出相一致。使用者通過習慣與學習形成對演算法的適應性反應，演算法也在使用者聚合行為中學習回饋規律。這種認知層面雙向適應使系統呈現複雜的心理動力特徵。

第三層是演化耦合。演算法強化過程中通過優化目標函數更新模型參數，使用者在內容消費中形成新的行為模式。隨著交互累積，演

算法與使用者狀態變數在高維空間形成相互依賴軌跡。演算法強化速度與使用者行為變化率共同決定系統演化方向。當演算法過度敏感時，系統可能陷入短期回饋迴圈；當使用者行為變化太慢時，演算法可能失去適應性，導致推薦品質下降^[12]。系統演化路徑因此呈現多重非線性動態。

動態耦合機制使推薦系統具備自組織特徵。系統整體狀態不是外部控制的結果，而是演算法與使用者相互作用的產物。微小演算法調整可能引發大規模行為偏移，個體用戶反應聚合又可能反向影響模型參數分佈^{[9][12]}。這種非線性互動構成系統複雜性根源，長期演化過程難以完全預測。

從資訊理論視角看，動態耦合可以視為資訊熵的雙向傳遞過程。演算法從使用者行為中獲取資訊以降低預測不確定性；使用者從演算法推薦中獲取內容以提升認知確定性。隨著回饋迴圈持續，系統總體熵值趨向穩定，表現為推薦準確度提升與用戶行為慣性化^[10]。系統熵平衡狀態代表共演化階段性穩定，但這種穩定是暫時的，任何新的演算法策略或使用者群體變化都可能打破平衡，引發系統重構。

耦合機制還具有社會性特徵。使用者並非孤立個體，而是處在社交與行為網路中。演算法對個體行為的回應通過群體聚合效應影響整體行為分佈，群體行為變化又反向調節演算法更新。這種社會層面耦合使推薦系統演化具備集體動力^[14]。演算法在優化個體體驗的同時，也在無意中調整群體資訊流結構，使共演化不僅發生於個人一系統層面，也在技術系統與社會系統之間展開。

4.3 共演化機制的工程特徵

從工程角度看，演算法與使用者的共演化過程表現出三個顯著特徵：自我調整性、非線性與難以逆轉性，這些特徵使推薦系統的演化不同于傳統線性優化結構，而呈現複雜自組織系統模式^{[9][10]}。

自我調整性表現為系統根據環境與使用者行為變化調整內部狀態的能力。演算法強化學習中不斷調整策略優化長期回饋，用戶在推薦流中通過習慣形成、興趣更新或選擇遷移來適

應系統輸出。雙向調整形成動態平衡，使推薦系統能夠在不斷變化的內容與需求環境中保持有效性。

非線性體現為系統對微小輸入變化的放大反應。一方面，演算法的微小參數調整可能引起大規模行為偏移；另一方面，使用者群體行為的變化通過資料回饋誘發模型結構改變^{[12][14]}。這種非線性源於回饋機制的多層嵌套，即系統不僅回應個體使用者行為，還回應群體資料分佈。延遲回饋進一步加劇動態反應滯後性。

難以逆轉性表現為系統狀態的路徑依賴。一旦演算法強化形成特定參數結構或偏好模式，系統難以通過局部調整回到初始狀態；長期交互中使用者形成的行為慣性使系統對規則變化的回應具有遲鈍性^[14]。這種路徑依賴使推薦系統在長期演化中形成穩定但封閉的狀態空間。

共演化機制具有分層結構性。在個體層面，演算法與單個使用者之間回饋構成微觀共演；在群體層面，使用者行為聚合與演算法全域參數調整構成宏觀共演。局部行為模式與全域系統結構之間存在跨層回饋，個體行為影響演算法方向，而演算法更新又通過策略影響個體行為。

工程意義上，這種共演化機制解釋了推薦系統的自組織與複雜性來源。演算法強化不僅是優化工具，更是系統內部演化動力。使用者偏好不是靜態變數，而是在演算法學習過程中不斷重構的動態要素。推薦系統的穩定性、偏好收斂與多樣性衰減都可以從共演化視角理解。演算法與使用者共同構成具有自我調節能力的適應系統，其行為由內部機制驅動而非外部干預。

這種共演化機制在大規模平臺上尤為顯著。當使用者數量與內容規模超過一定閾值時，系統的回饋網路呈現高維複雜性。演算法優化的每一次反覆運算都在重塑資訊流結構，使用者行為聚合反過來驅動演算法演化。長期運行中形成宏觀模式，如內容集中化、興趣分層與注意力極化^[14]。

從長期演化視角看，共演化機制意味著推薦系統處於持續未完成狀態。演算法與使用者

的互動持續生成新平衡點，在穩定與擾動之間迴圈。任何外部干預如演算法規則調整或介面設計變動都可能引發新的演化方向。推薦系統因此具有演化開放性，其結構在不斷自我調整中維持生命力^{[9][10]}。

理解演算法強化與使用者偏好的共演化機制，有助於從根本上認識推薦系統的長期動態。本章揭示了技術系統與人類行為之間的深層耦合關係，說明推薦演算法不只是資訊工具，而是認知環境的一部分；演算法強化塑造了使用者偏好結構，而使用者偏好又通過行為回饋塑造演算法邏輯，共演化過程在雙向塑造中持續展開。

5 機制分析的工程啟示與系統思考

推薦系統的長期運行結果往往超出了工程設計的初始預期。演算法在不斷強化的過程中不僅優化了性能指標，也改變了系統的整體演化方向。機制分析揭示出，推薦系統的行為是目標函數、資料結構、回饋信號與使用者反應之間的複雜互動產物。理解這一互動機制的工程啟示有助於從系統層面反思演算法設計的邊界與潛在後果。推薦系統不再是單純追求效率的計算模型，而是一種具有演化屬性的動態系統，其行為應當從長期結構和演化趨勢角度進行分析。

5.1 強化目標與系統行為之間的關係

推薦系統的長期運行結果往往超出了工程設計的初始預期。演算法在不斷強化的過程中不僅優化了性能指標，也改變了系統的整體演化方向。機制分析揭示出，推薦系統的行為是目標函數、資料結構、回饋信號與使用者反應之間複雜互動的產物。理解這一互動機制的工程啟示，有助於從系統層面反思演算法設計的邊界與潛在後果。推薦系統不再是單純追求效率的計算模型，而是一種具有演化屬性的動態系統，其行為應從長期結構和演化趨勢角度進行分析^[6]。

目標函數與系統行為之間並非線性映射，而是複雜的回饋系統。演算法的優化過程反向影響使用者行為模式，使用者行為再通過回饋信號影響模型更新。目標函數的定義實際上決

定了演算法對環境的敏感區域，也決定了系統的長期演化方向。例如，當推薦系統目標是最大化點擊率時，演算法傾向推送高吸引力內容，使用者逐漸適應這種刺激結構，形成短時偏好，系統整體逐漸偏離對真實興趣的刻畫。

目標函數的設計不僅影響系統性能，也影響其社會與心理效應。點擊率或停留時間等指標雖易量化，卻無法代表用戶長期滿意度或認知收益。演算法通過強化機制優化這些指標，實質上是在優化用戶即時反應，而非資訊品質。隨著時間推移，系統在高回饋區域內收斂，形成封閉的偏好迴圈。使用者行為在演算法引導下逐漸同質化，系統失去了對多樣化興趣的敏感性。

目標函數的單一化是強化機制偏移的根源。當系統忽視多目標平衡時，演算法行為方向被短期信號主導，表現出路徑依賴性。模型參數在特定優化區域內不斷強化，形成長期結構偏移。工程實踐表明，目標函數的微小調整往往引發系統級行為變動，這種非線性關係說明演算法優化與系統行為之間存在深層耦合。

一個更系統的工程視角應將目標函數視為系統演化的控制變數。其設計需考慮強化機制的動態特徵，包括回饋延遲、使用者慣性和系統自組織趨勢。演算法優化的真正目標應從性能提升轉向系統穩定性與長期演化方向的調控。

5.2 推薦系統穩定性與多樣性問題的機制解釋

推薦系統在長期運行中普遍出現多樣性下降、內容集中和興趣趨同等問題。這一現象表面上似乎是演算法偏差或資料不均衡造成的，但從機制角度看，是強化回饋自然演化的結果。演算法在強化學習過程中聚焦高回報區域，模型的注意力被限制在回饋最強部分，系統因而逐漸喪失探索能力。

推薦系統的核心矛盾在於探索與利用的平衡。演算法需在已知高回饋內容與潛在未知內容之間分配資源。強化學習傾向於利用歷史經驗，減少不確定性，而這一傾向在長期中會抑制探索性。系統在短期收益驅動下形成自我驗證的偏好回路，探索空間被壓縮，多樣性下降並非設計缺陷，而是反饋回路內生結果。

系統穩定性與多樣性之間存在天然張力。強化機制通過優化回饋信號實現穩定收斂，但穩定往往以犧牲多樣性為代價。收斂速度越快，內容覆蓋面越窄，使用者行為模式越單一。演算法在追求性能中形成穩態結構，這種穩態雖提升了預測精度，卻削弱了系統的動態適應性。當外部環境或興趣發生變化時，系統調整遲滯、回應慣性增強。

多樣性問題不僅存在於內容層面，也反映在行為結構中。長期交互使用戶對推薦結果的依賴增強，探索意願下降。演算法強化使用者對特定類型內容的偏好，使用者行為反過來驗證演算法判斷，系統陷入偏好收斂的迴圈。多樣性下降因此是演算法與使用者共同作用的產物，系統在回饋放大中自發生成行為同質化結構。

工程上，穩定性與多樣性的平衡應在模型設計階段考慮。單一優化目標易導致系統收斂至局部最優。引入多目標優化、探索性策略或矯正則化機制可緩解問題。系統需在局部回饋最大化與全域結構平衡間維持動態協調，從而保持長期健康性與多樣性。

推薦系統的穩定性還受回饋時延影響。行為回饋具有時間滯後，模型更新使用的信號往往落後於真實興趣變化。短期內演算法可能過度響應舊資料，導致學習振盪。理解並建模回饋時延，有助於提高演算法自我調整能力，使系統在不犧牲多樣性的前提下維持穩定運行。

5.3 對推薦系統設計的機制層面啟示

從機制角度看，推薦系統的設計應當超越性能導向的短期思維，轉向對系統演化規律的整體理解。演算法強化並非僅僅是模型優化的過程，而是系統在使用者行為環境中不斷調整自身結構的演化機制。強化過程本身應被視為關鍵變數，其設計需要考慮對系統長期行為的塑形作用。

工程設計的第一層啟示是目標多樣化的重要性。推薦系統不應僅以點擊率或停留時間作為優化目標，而應引入反映用戶長期滿意度與多樣性維持的指標。多目標優化可以使演算法在短期收益與長期結構之間建立平衡。系統設計者需要明確不同目標之間的權重關係，使演

算法能夠在強化學習過程中保留探索能力。

第二層啟示是回饋結構的可控性。推薦系統的回饋機制決定了演算法與使用者之間的資訊流動路徑。系統設計應避免形成完全閉合的強化回路，需要通過外部擾動或引入隨機探索信號打破自我驗證結構。例如可以通過引入冷開機機制或動態重置策略，讓演算法定期重新採樣使用者興趣空間，從而恢復多樣性與適應性。

第三層啟示是系統時間尺度的設計。推薦演算法的學習週期、更新頻率與使用者回饋節奏之間需要建立協調關係。過度敏感的演算法容易陷入短期波動，過於遲鈍的演算法又難以回應環境變化。合理的時間尺度設計可以防止系統陷入非平衡狀態，使強化過程在長期內保持可控的演化路徑。

第四層啟示是結構透明性。隨著推薦系統的複雜化，演算法內部的強化路徑和行為邏輯逐漸難以解釋。建立可解釋的模型結構有助於工程師識別強化機制的偏移風險，從而在早期階段進行調整。系統的透明性不僅提高工程可控性，也有助於在社會層面增強用戶信任。

推薦系統的設計應當以系統演化的可持續性為核心。演算法強化機制在優化局部性能的同時可能削弱系統的長期生命力。工程思維需要從靜態的性能追求轉向動態的系統調控，強調對演化趨勢的監測與調節。推薦系統的設計不應只關注模型在當前環境下的最優性，而應考慮其在未來環境中的適應性。

機制分析提供了一種新的工程視角。它將推薦系統視為複雜的演化體，而非孤立的演算法集合。理解演算法強化與使用者偏好共演化的機制，有助於構建更具穩態性與多樣性的系統結構。推薦系統的設計應當在優化與演化之間尋求平衡，使技術發展與用戶行為共處於可持續的動態平衡之中。

6 結論

推薦系統的演化已經超越了傳統的演算法優化范式，成為一種人機共生的動態系統。演算法的強化學習機制在長期運行中不只是提升了預測精度和個性化水準，也在不斷重塑使用

者的興趣結構與行為模式。本文通過對演算法強化與使用者偏好互動機制的分析，揭示了推薦系統在運行過程中所呈現出的共演化特徵。演算法與使用者在回饋迴圈中相互依賴、相互塑造，共同構成了系統演化的核心動力。

本文首先從系統結構層面對推薦系統進行了分析。推薦系統由使用者、內容、資料與模型構成的閉環結構，使其具備自學習特徵。演算法以使用者行為為輸入，通過回饋信號實現自我強化。這一過程的本質是一種持續的交互學習。用戶的每一次行為既是個體偏好的表達，也成為演算法更新的依據。系統通過對回饋信號的回應不斷調整推薦策略，使用戶體驗趨向個性化，而使用者的行為又因演算法輸出而發生變化。

機制分析表明，演算法強化與使用者偏好之間存在結構性的共振關係。演算法的優化目標決定了系統的學習方向，而用戶行為在回饋中起到調節作用。系統在高回饋區域不斷強化，形成了興趣收斂的趨勢。這種趨勢不僅表現為內容多樣性的下降，也體現在使用者心理結構的變化。使用者逐漸在演算法生成的內容環境中形成新的興趣模式，探索性行為被削弱，注意力資源集中於演算法偏好的區域。演算法與使用者在多輪交互中形成穩定的回饋路徑，構成共演化的動力結構。

共演化機制使推薦系統呈現出非線性、自我調整與難以逆轉的特徵。演算法的每一次更新都在改變用戶的認知環境，而用戶行為的微小變化又可能引起演算法參數的系統性偏移。系統在這種迴圈中實現自組織和平衡，但這種平衡往往是局部的、暫時的。當外部條件或目標函數發生改變時，系統會重新尋找新的平衡點。推薦系統因此不是靜態優化器，而是不斷重塑自身與使用者關係的演化系統。

從工程視角來看，理解共演化機制的意義在於重新定義演算法優化的目標。推薦系統的長期行為不應被簡單視為性能指標的延伸，而應被理解為演算法與使用者共同適應的結果。單一的目標函數往往導致系統演化方向過於集中，使使用者偏好結構固化。多目標優化、動態回饋調節與探索機制的引入，有助於打破這種收斂趨勢，使系統在長期運行中保持多樣性與

穩定性。演算法的強化過程應被納入系統設計的整體框架中，作為影響系統演化方向的核心變數。

本文的理論貢獻在於提出一種機制性解釋框架，用以理解推薦系統的長期行為特徵。該框架揭示了推薦系統中的優化過程與人類行為之間的深層耦合關係，說明演算法的技術演化與使用者的心理演化是同步發生的。演算法通過對行為資料的強化學習生成推薦模式，使用者在這一模式中形成興趣偏好，系統的長期輸出即是二者共演化的結果。這一視角有助於突破傳統以演算法性能為中心的研究範式，使推薦系統的研究回歸到系統性與動態性的層面。

未來研究可以在此基礎上展開更細緻的建模與實證工作。一方面，可以從系統動力學角

度建立演算法強化與使用者偏好共演化的數理模型，以刻畫回饋放大、偏好收斂與多樣性演化的規律。另一方面，可以通過長期行為資料驗證共演化過程的動態路徑，為演算法調控提供經驗支援。共演化機制的深入理解將為推薦系統的可持續發展提供理論基礎，也為未來人機協同系統的設計提供新的思路。

推薦系統的演化並非線性增長的技術進步，而是一種複雜的社會技術過程。演算法強化機制在優化資訊流的同時，也在重塑認知空間。人類的興趣、選擇與價值感知在演算法回饋中不斷被重新定義。理解這一過程，有助於認識技術系統與人類行為之間的共生關係，也為資訊社會的長期結構性演變提供了新的理論視角。

參考文獻：

- [1] Adomavicius G, Tuzhilin A. Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(6): 734-749.
- [2] Mansouri M, Abdollahpouri H, Pechenizkiy M, Mobasher B, Burke R. Feedback Loop and Bias Amplification in Recommender Systems [EB/OL]. arXiv preprint arXiv:2007.13019, 2020. Available at: <https://arxiv.org/abs/2007.13019>
- [3] 曹俊偉, 李軍祥, 李玉璐. 電子商務推薦系統研究綜述[J]. 電子商務評論, 2025, 14(12): 3087-3097.
- [4] 胡琪, 朱定局, 吳惠聰, 巫麗紅. 智慧推薦系統研究綜述[J]. 電腦系統應用, 2022, 31(4): 47-58.
- [5] Jiang R, Chiappa S, Lattimore T, György A, Kohli P. Degenerate Feedback Loops in Recommender Systems[EB/OL]. arXiv preprint arXiv:1902.10730, 2019. Available at: <https://arxiv.org/abs/1902.10730>
- [6] 張浪朗. 基於多目標優化及偏好策略的推薦演算法研究[D]. 東華大學, 2022.
- [7] 周銘. 智慧資訊系統中的強化學習演算法在推薦系統中的應用[J]. 資訊系統工程, 2024, (08): 52-55.
- [8] Zhang S, Yao L, Sun A, Tay Y. Deep Learning Based Recommender System: A Survey and New Perspectives[J]. ACM Computing Surveys, 2019, 52(1): 1-38.
- [9] Pedreschi D, et al. Human-AI coevolution: Feedback loops and societal impact [J]. Artificial Intelligence, 2025, 339: 104244.
- [10] Krauth K, Wang Y, Jordan M I. Breaking Feedback Loops in Recommender Systems with Causal Inference [EB/OL]. arXiv preprint, 2022. Available at: <https://arxiv.org/abs/2207.01616>
- [11] Mollabagher A, Naghizadeh P. The Feedback Loop Between Recommendation Systems and Reactive Users [EB/OL]. arXiv preprint, 2025. Available at: <https://arxiv.org/abs/2504.07105>
- [12] Barlacchi G, Lalli M, Ferragina E, Giannotti F, Pappalardo L. A Simulation Framework for Studying Systemic Effects of Feedback Loops in Recommender Systems [EB/OL]. arXiv preprint, 2025. Available at: <https://arxiv.org/html/2510.14857v1>

- [13] Jiang R. Degenerate Feedback Loops in Recommender Systems [C]. AAAI/ACM Conference on AI, Ethics, and Society, 2019. Available at: https://www.aies-conference.com/2019/wp-content/papers/main/AIES-19_paper_187.pdf
- [14] Klimashevskaya, A., Jannach, D., Elahi, M. et al. A survey on popularity bias in recommender systems [J]. User Model User-Adap Inter, 2024, 34, 1777-1834.

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。