從經濟人到矽基人：
質性數據與 AI 的三重角色

演講者：羅軒濫
陽明交通大學 科技管理博士生

2026/10/02
東華大學



當 AI 越來越強，我該做什麼？

從「工作被取代」的焦慮，到「人該學什麼、做什麼」的提問

在變動的時代
找到更值得成為的自己

模型越來越強
能力不斷突破新高

最新模型在多項測試中，
超越人類表現，推理、生成、
規劃能力持續提升。

工作越來越難找
企業加速導入 AI

多個產業啟動自動化，
初階職缺明顯減少。

軟體工程師首當其衝

AI 已能生成高品質程式碼，
重塑整個開發流程。

大學課程還沒教完
就過時

過時

知識更新速度遠超過，
教育體系，學什麼才不會被淘汰？

AI 都能回答問題
我為什麼還要學？

當然可以，
這是一個關...

還有其他問題嗎？

從寫報告、解題目到專業諮詢，
AI 似乎無所不知。

這樣下去...
我的未來會被取代嗎？

技術在加速，
但人，依然可以選擇
成為更獨特的存在。

當 AI 可以接手
越來越多工作，
我應該做什麼？

學習
持續更新
拓展視野

創造
提出新想法
創造新價值

提問
發現更好的問題

判斷
辨識真偽
做出選擇

整合
連結不同領域
看見全貌

同理
理解人
關心人的需求

合作
與 AI 與他人
共同創造

程式設計
人工智慧
心理學
設計思考
未來工作

AI 會取代我嗎？
我擅長什麼？
未來需要什麼樣的人？
我還能做出什麼價值？

學什麼？
做什麼？
我能貢獻什麼？

更好的
人類
仍然重要

更好的問題
更廣的視野
更深的人性
更有意義的工作

AI 讓一些工作消失，
也讓更多可能性出現。
而我，仍然可以選擇成為什麼樣的人。

從經濟人到矽基人

當大型語言模型成為理解與模擬人類行為的新工具

AI 不是取代人，
而是讓我們更理解人。

理解人
研究人
與 AI 一起
打造更好的社會

PEOPLE
IDEAS
A BRIGHTER
SOCIETY

經濟人（Homo economicus）

理性的個體，追求最大的效用



- 假設人會追求效用最大化
- 偏好相對穩定
- 在資訊與限制下做選擇

傳統社會科學的人性假設

轉變

從理解人，到模擬人，再到與 AI 一起探索人



- 不只研究人
- 也用 AI 模擬人
- 把人類行為帶入可運算模型

從抽象假設 → 可互動模擬

矽基人（Homo silicus）

以語言為介面的新型態行為代理



- LLM 可作為人類判斷的近似模型
- 可設定角色、資訊與偏好
- 可重做經典實驗與情境模擬
- 也能暴露偏誤與新問題

AI 成為社會科學的新實驗夥伴

研究工具　研究對象　模擬代理人

重點：AI 不只是工具，也可能是理解人類決策與行為的新「矽基受試者」。

HUMAN
SOCIETY
TOMORROW

SAME
PEOPLE
BRIGHTER
POSSIBILITIES

為什麼是質性數據？

數字只是冰山露出水面的一角；經濟學頂尖學者，已經開始讀水面下的文字。

80–90%

的資料是文字、影音、照片、社群貼文這類非結構化資料

18%

的組織說自己用得上

MIT Sloan（2021）
Deloitte 調查（2019）

Robert Shiller

2013 諾貝爾獎｜AER 2017

經濟學應該擴大範圍，認真地量化研究不斷變化的大眾敘事。

Gentzkow・Kelly・Taddy

2014 克拉克獎｜JEL 2019

人類的互動、溝通與文化，有越來越高的比例被記錄成數位文字。

Baker・Bloom・Davis

史丹佛等｜QJE 2016

只用報紙報導的頻率，就建出能預示投資與就業下滑的政策不確定性指數。

Stefanie Stantcheva

哈佛｜2025 克拉克獎

選擇題可能誘導答案、漏掉選項；開放題更能問出人們最在意的事。

數字告訴你發生了什麼，文字告訴你為什麼。AI 第一次讓我們能大規模地讀「為什麼」。

已經在發生

質性數據，正在變成主流數據

中央銀行

468 本

聯準會把褐皮書讀成數字

把 1970 年以來褐皮書裡的第一手質性描述，量化成情緒指數，預測景氣衰退。

克里夫蘭聯準會（2024、2025）

經濟學研究

6 個月後

經濟學家讓 AI 當訪談員

AI 訪談比其他大規模質性調查問得更深，還能預測受訪者 6 個月後的行為。

Chopra & Haaland（CESifo 2026）

AI 公司

80,508 人

AI 訪談員，一次訪 8 萬人

159 國、70 種語言，Anthropic 認為是史上最大的質性研究；OpenAI 也與哈佛 Deming 分類 ChatGPT 對話。

Anthropic（2026）；NBER（2025）

共同點：先把文字讀成數字，再問讀得準不準。這就是接下來三個角色要講的事。

學歷與研究方向

從金融問題出發，逐步走向資料、AI、組織韌性、知識管理與人機協作。

From Finance to AI
Different Chapters,
Deeper Me.

持續學習
連結未來
創造更大的可能



2018 — **財務金融**
- 從金融問題出發
- 關注風險與產業



2022–2024 — **資訊管理**
- 資料分析與機器學習
- 文字探勘、社會網絡





2024–2025 — **資財博士**（曾就讀）
- 金融科技與交易策略
- 風險控制、組織韌性





2025–至今 — **科管博士**
- AI × 知識管理
- 人機協作與多代理



同一條研究主線，逐步擴展研究視野。

MORE KNOWLEDGE
A BRIGHTER TOMORROW

競賽與其他經歷

2020/10 「Win the Pride」用指標說故事 **決賽**
國家實驗研究院科技政策研究與資訊中心

2020/11 FinTech金融服務 創意競賽 **第三名**
國立台北商業大學

2022/11 LINE Chatbot 對話機器人設計大賽 **第六名**
LINE Corporation

2022/12 FinTech Taipei 台北金融科技展 **新創廠商**
台北市政府

2023/05 ACT夢想家 ESG影響力計畫_台積電組 **最佳提案團隊**
安通國際股份有限公司

2023/07 「永續金融與淨零創新」影響力提案競賽 **第一名**
金融監督管理委員會

2023/10 「FinTech 數位沙盒」技術實證創新競賽 **第一名 企業獎**
金融科技創新園區





教學與演講

2023/06	**元宇宙與行銷科技** 國立彰化師範大學	專題演講
2023/10	**貨幣銀行學** 世新大學 財務金融學系	受邀講授
2024/01	**大數據與資料視覺化** 新北市崇光高中	多次教學分享
2024/04	**圖論與社會網路分析** 國立聯合大學 在職專班碩士生	多次受邀授課
2025/09	**〈GAI 時代：企劃提案與實戰〉** 世新大學 行政管理學系	業師專題講座
2026/08	**企業內訓（思多葛等）** 數位轉型、AI 導入、數據人物誌；另有大專院校分享	內訓與分享
現任	**陽明交大 課程助教** 人機互動、創新創業、ENPD	助教
2026/10	**從經濟人到矽基人** 國立東華大學 經濟學系	就是今天





財金所 → 科管所

PEOPLE
TECHNOLOGY
ORGANIZATIONS
A BETTER TOMORROW

從金融，走到組織與人機協作：把 AI 本身的判斷與角色，也當成研究問題。



2024	**陽明交大 財務金融研究所博士班** 財務計量、交易風險；企業災防與韌性研究計畫	入學
2025/09	**陽明交大 科技管理研究所** AI × 知識管理、組織韌性、人機協作	重考
2026/04	**Safety Science 期刊論文** 組織韌性測量的範疇回顧	刊登
2026/06	**R&D Management Conference 2026** 半導體人力多樣性與衝擊下的績效穩定	最佳論文獎
2026	**IFKAD 2026 Asia Chapter** AI × 知識管理的書目計量與共詞網絡	發表

From Finance to a More Human-Centered Future



其他研究與投稿

- 《品質月刊》〈四十年來企業韌性發展軌跡探討〉（2025）
- 股票日內交易策略，投稿 International Review of Financial Analysis（2026，已投稿）
- LLM × Photovoice × XR 研究文稿


From Numbers to a More Human World
羅軒澔 個人發展文字雲
FINANCE → AI → HUMAN BEHAVIOR → ORGANIZATIONS
SAME QUESTIONS. DEEPER ANSWERS.
DATA
ALGORITHMS
PEOPLE
ORGANIZATIONS
A MORE HUMAN TOMORROW
MARKETS
PEOPLE
INFORMATION
DECISIONS
A COMPLEX WORLD
+2.14
-0.73
+1.26
-0.91
+3.42
-1.08
Finance
Risk
Information
Fraud
Decision
VOLATILITY
ASSET PRICING
MARKET EFFICIENCY
FINANCIAL NETWORKS
RISK
RETURN
UNCERTAINTY
CAPITAL
ALLOCATION
BEHAVIORAL FINANCE
ESG
SYSTEMIC RISK
DATA
ALGORITHMS
COMPUTATION
LEARNING
GENERATION
INTELLIGENCE
PATTERN
REPRESENTATION
GENERALIZATION
FOUNDATION MODELS
HUMAN-AI ALIGNMENT
Machine Learning
Deep Learning
AI
GAN
LLM
Synthetic Data
NLP
Generative AI
Text Mining
Social Network Analysis
$\min_\theta \mathcal{L}(\theta)$
From Data to Possibilities.
Cognition
Emotion
Social Influence
Mental Models
Bounded Rationality
Human-AI Collaboration
Behavior
Judgment
Decision
Trust
Uncertainty
Simulation
Validation
Prediction ≠ Understanding?
PEOPLE
CONTEXT
MEANING
BEYOND ACCURACY
COLLECTIVE INTELLIGENCE
DYNAMIC CAPABILITIES
ADAPTIVE ORGANIZATIONS
SUSTAINABLE IMPACT
A MORE HUMAN TOMORROW
Knowledge Management
Organizational Resilience
Human-AI Interaction
Persona
AI Consumer
Synthetic Human
Homo Silicus
Multi-Agent
Human-in-the-Loop
Technology Management
PEOPLE + AI
ORGANIZATIONS + PURPOSE
A MORE HUMAN TOMORROW
NUMBERS
ALGORITHMS
HUMAN
ORGANIZATION
RESEARCH
BRIDGES
DISCIPLINES
CREATE
POSSIBILITIES
大學時期
碩士時期
博士時期
Different Lenses
A More Human Tomorrow.
FOR BRIGHTER MINDS
AND A MORE HUMAN WORLD

求學期間的重要人物

從金融、AI，到行為、組織與科技管理的研究關係圖

Better Questions. A More Human Tomorrow

PEOPLE
CONNECT
IDEAS
A MORE HUMAN
TOMORROW

長期合作與方法

從想法到方法，
一起把問題做深



郭迺鋒
長期戰友
金融 → AI → Persona



林宏仁
方法啟蒙
ML / GAN / Synthetic Data

AI METHODS

ALGORITHMS
GENERATIVE AI
SYNTHETIC DATA
HUMAN–AI
INTELLIGENCE
FOR A BETTER TOMORROW

量化與金融研究

從市場數據，
走向更寬廣的世界

FINANCE

MARKETS
RISK
QUANTITATIVE
TRADING
ASSETS
A WIDER WORLD



戴天時
資財博士師長
財務計量 / 量化交易



高竹嵐
量化研究合作
統計推論 / 風險控制



羅軒澔
金融 × AI × 行為 × 組織

連結人
連結知識
走向更有人味的
未來

組織韌性與科技管理

從人與組織出發，
走向永續的影響力



莊秀文
韌性研究轉折
Organizational Resilience / Safety Science



Sirirat Sae Lim 林士平
科管整合 mentor
AI × KM / Human–AI Interaction

ORGANIZATION
MANAGEMENT

PEOPLE
RESILIENCE
KNOWLEDGE
TECHNOLOGY
SUSTAINABILITY
A BETTER SOCIETY

HUMAN BEHAVIOR

COGNITION
DECISION
SOCIAL
TRUST
A MORE HUMAN WORLD

跨域探索與實作

從不同領域相遇，激發更多可能



郭修平
共同探索者
LLM / Photovoice / XR



林立芯
跨域橋樑
社會心理 / 數位行銷 / 跨學科



吳家瑜
實作共創
ESG 系統 / 競賽合作

KNOWLEDGE
PEOPLE
IDEAS

不同人物，串起同一條研究主線：從金融風險、AI 方法，到組織韌性、人機協作與科技管理。

RESEARCH
COLLABORATION
IMPACT

善用 AI，
拓展研究的想像

AI 的三種研究角色

不同的視角
看見不同的可能

角色一：AI 當工具

讓 AI 成為研究路上的得力助手



- 協助蒐集、整理、分析資料
- **重點：AI 是研究輔助工具**

角色二：AI 當受試者

把 AI 放進研究設計中，成為被研究的對象



- 把 AI 視為研究對象
- **重點：觀察 AI 的反應、表現與偏誤**

角色三：AI 當模擬受訪者

用 AI 模擬特定角色，進行訪談或情境對話



- 用 AI 模擬特定角色或受訪者
- **重點：探索可能觀點、情境與回應**

從工具、
到對象、再到對話，
AI 讓研究有更多可能。

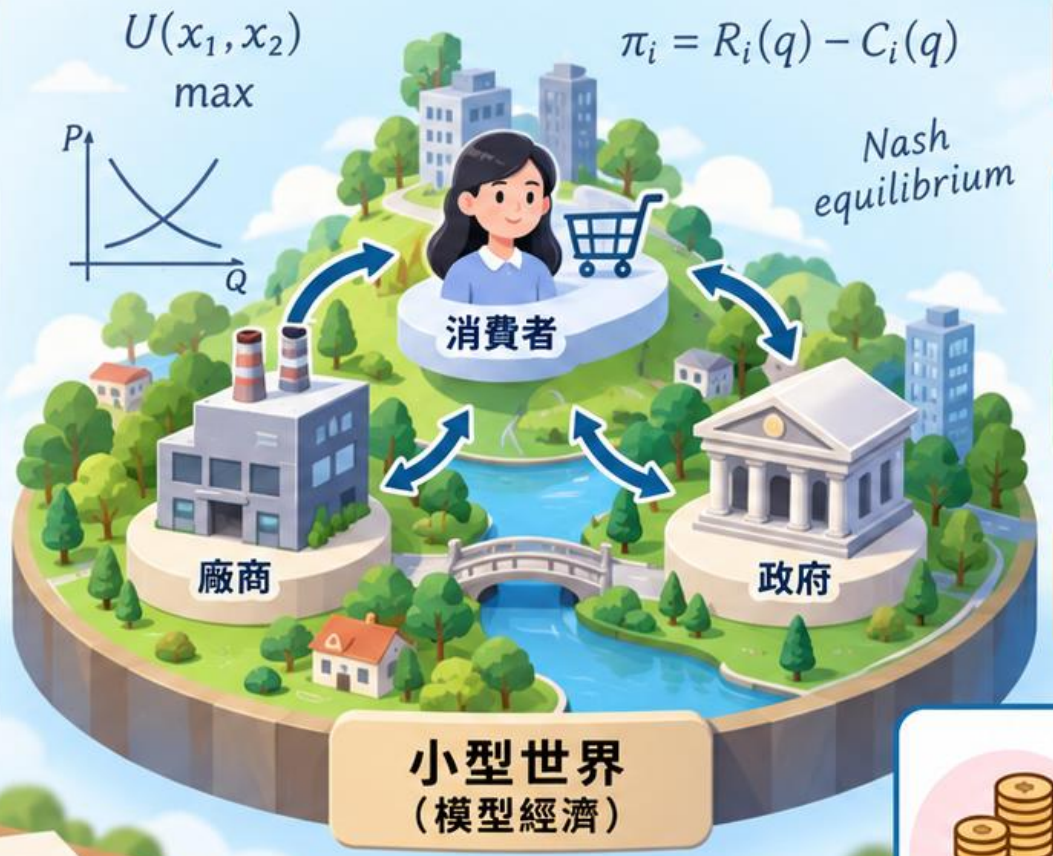
同樣是 AI，研究定位不同，方法與意義也不同。

不同的研究角色，
共同拓展更大的知識地圖

用數學建構一個『小型世界』，然後問：如果每個人都理性做策略選擇，最後會發生什麼？

很像經濟學版的模擬世界，但通常不是 computer simulation，而是 analytical solution。

1. 現實世界的一個問題
2. 把世界簡化成幾個「玩家」
3. 建立數學模型
4. 設定每個玩家的目標函數
5. 假設玩家依序做決策
6. 用賽局理論求均衡
7. 改變參數
8. 看價格、產量、利潤、福利怎麼變



小型世界
（模型經濟）

關注的結果

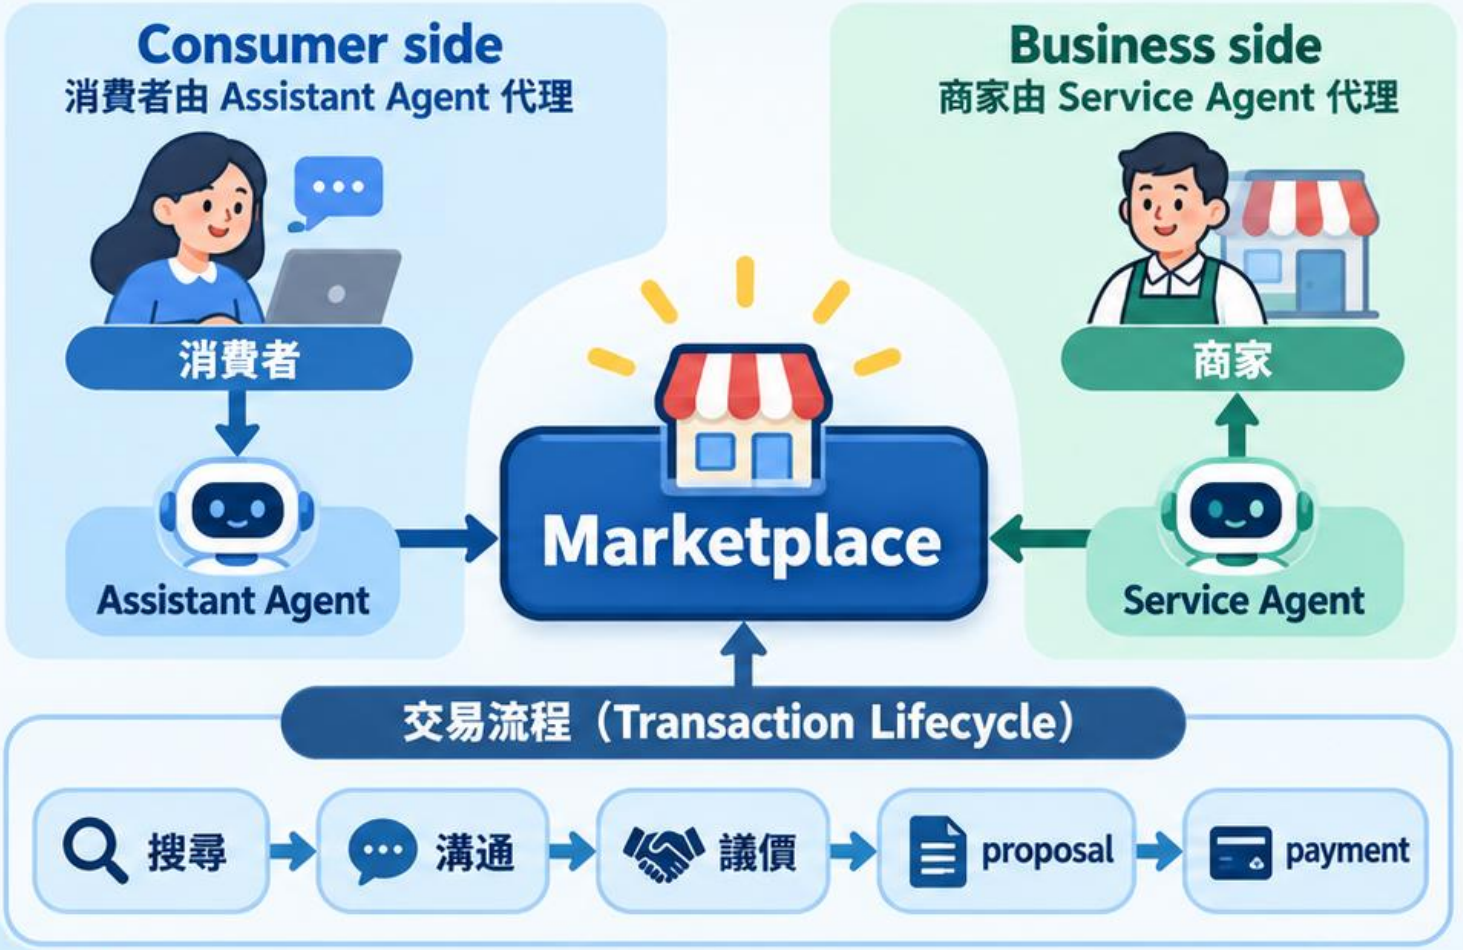
- 價格
- 產量
- 利潤
- 福利





Microsoft 自己就說它研究「雙邊市場」

Magentic Marketplace 目前明確設定成：



Agents Connect People and Businesses

MAGENTIC MARKETPLACE: AN OPEN-SOURCE ENVIRONMENT FOR STUDYING AGENTIC MARKETS

Gagan Bansal, Wenyue Hua, Zezhou Huang, Adam Fourney, Amanda Swearngin,
Will Epperson, Tyler Payne, Jake M. Hofman, Brendan Lucier, Chinmay Singh, Markus Mobius, [1]
Akshay Nambi, Archana Yadav, Kevin Gao, David M. Rothschild,
Aleksandrs Slivkins, Daniel G. Goldstein, Hussein Mozannar, Nicole Immorlica, [2]
Maya Murad, Matthew Vogel,[3] Subbarao Kambhampati,[4,‡] Eric Horvitz,[4] Saleema Amershi [5]

Microsoft ‡Arizona State University
[1] Core Contributors; [2] Contributors; [3] Technical Program Managers; [4] Advisors; [5] Principal Investigator

October 31, 2025

Microsoft 明確稱它為 two-sided agentic marketplace

而且論文自己直接引用：

Rochet & Tirole (2003), Platform Competition in Two-Sided Markets

作為兩邊市場的理論基礎。

Source: arXiv 2510.25779v1

所以真正厲害的研究橋樑出現了

從理論走向真實的世界

傳統經濟模型通常假設：

理論直覺：理性、最適化的代理人

Agent = rational optimizer

「給定所有資訊，企業和消費者會按照效用最大化／利潤最大化行動。」



選擇集合↑ → 更容易找到好商品 → welfare↑

但是 LLM Agent 真的是這樣嗎？



連結理論與真實的 Agent 行為

Microsoft 的結果說：

不一定。😂

實際觀察：更有限的理性、更複雜的行為



選項越多，consumer welfare 有時越低。

Paradox of Choice



有些模型會出現：不會真的把所有選項比較完。



甚至非常容易：接受第一個 proposal。

first-proposal bias

選擇集合↑ → 但有時 → welfare↓

同一個問題，不同時視角，更完整的答案

真實行為
驅動更好的
AI 代理人

1 Persona 已經不是「寫一段 Prompt」而已

從「人工設定 Persona」走向「從真人行為反推出 Persona」

更貼近真實
更智慧的
交通模擬

從真實世界
學習，
創造更好的
未來交通！

論文依據

Contents lists available at ScienceDirect

Transportation Research Part C

journal homepage: www.elsevier.com/locate/trc

Aligning LLM agents with human learning and adjustment behavior: A dual agent approach

Tianming Liu [a], Jirong Yang [b], Yafeng Yin [b], Manzi Li [a], Linghao Wang [c], Zheng Zhu [c,a]

[a] Department of Civil and Environmental Engineering, University of Michigan, Ann Arbor, United States
[b] Department of Electrical Engineering and Computer Science, University of Michigan, Ann Arbor, United States
[c] College of Civil Engineering and Architecture, Zhejiang University, Hangzhou, China

Liu et al. (2026)
Aligning LLM agents with human learning and adjustment behavior: A dual agent approach
Transportation Research Part C，2026 年 10 月

Tianming Liu, Jirong Yang, Yafeng Yin, Manzi Li, Linghao Wang, Zheng Zhu

它已經不是：

人工 Persona／手動寫 Prompt

這樣就夠了嗎？

“你是一個風險厭惡、40 歲的消費者。”

這種方式忽略了真實世界中，人會從經驗中學習與調整的複雜行為。

而是：Behavioral Calibration

真實人類歷史行為
從線上資料中獲取人類的實際出行紀錄

出發地
目的地
出行時間
路線選擇
…

Calibration Agent
利用 LLM 的推理與分析能力來訓練這些代理人的 persona

分析行為
推論特徵
校準 persona

自動推論這個人的 Persona
從行為資料中學習出更貼近真實的 persona

風險偏好？
時間敏感？
對擁塞敏感？
…

Traveler Agent
配備了記憶系統與可學習的 persona，用來模擬真人旅客

評估選項
做出選擇

做下一次選擇
在新的情境下進行路線選擇

這次他真的怎麼選？

看到真人下一次真的怎麼選 再修改 Persona
持續學習、持續更新

持續迭代

越來越貼近真實

理論與貢獻

$$Agent_i = LLM + Persona_i + Memory_i$$

Agent 不是只有模型本身，還包含 persona 與 memory。

$$Persona_{i,t+1} \neq Persona_{i,t}$$

Persona 會學習、會更新。

實證結果

更準確的個人行為預測
更可靠的交通系統分析

- 作者用真實人類的 day-to-day route-choice data 做驗證。
- learnable persona + memory + calibration agent
- 比一般 LLM agent 更能對齊個人行為與整體交通流量。

關鍵啟發

不要由研究者幻想 Persona，
而是從真人行為反推出 Persona。

Behavioral Calibration

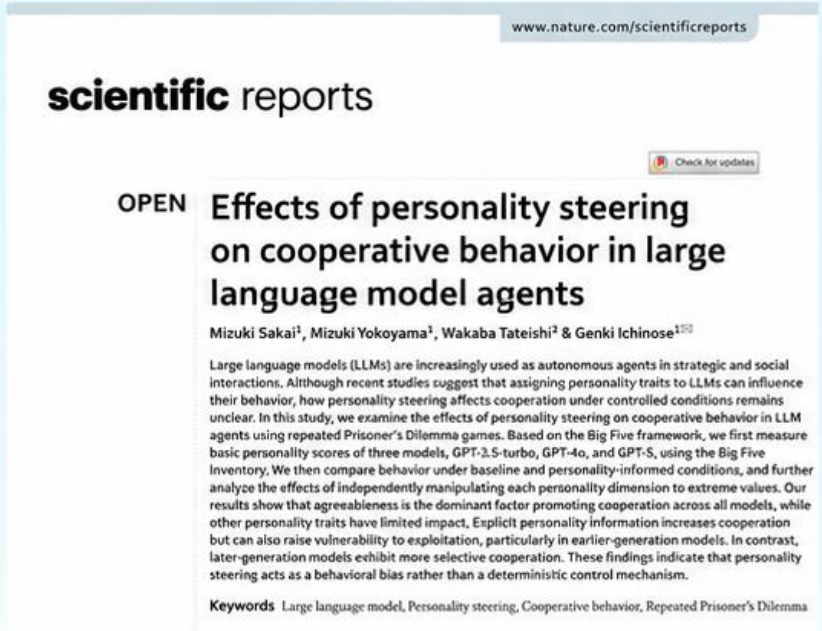
我認為這是下一步的關鍵。

從現實行為出發，
讓 AI 更懂人！

Persona 已經被證明真的會改變「策略行為」

Sakai et al. (2026) | Scientific Reports

研究論文證據



www.nature.com/scientificreports

scientific reports

Check for updates

OPEN

Effects of personality steering on cooperative behavior in large language model agents

Mizuki Sakai[1], Mizuki Yokoyama[1], Wakaba Tateishi[2] & Genki Ichinose[1]✉

Large language models (LLMs) are increasingly used as autonomous agents in strategic and social interactions. Although recent studies suggest that assigning personality traits to LLMs can influence their behavior, how personality steering affects cooperation under controlled conditions remains unclear. In this study, we examine the effects of personality steering on cooperative behavior in LLM agents using repeated Prisoner's Dilemma games. Based on the Big Five framework, we first measure basic personality scores of three models, GPT-3.5-turbo, GPT-4o, and GPT-5, using the Big Five Inventory. We then compare behavior under baseline and personality-informed conditions, and further analyze the effects of independently manipulating each personality dimension to extreme values. Our results show that agreeableness is the dominant factor promoting cooperation across all models, while other personality traits have limited impact. Explicit personality information increases cooperation but can also raise vulnerability to exploitation, particularly in earlier-generation models. In contrast, later-generation models exhibit more selective cooperation. These findings indicate that personality steering acts as a behavioral bias rather than a deterministic control mechanism.

Keywords Large language model, Personality steering, Cooperative behavior, Repeated Prisoner's Dilemma

Sakai et al. (2026)

Effects of personality steering on cooperative behavior in large language model agents

Scientific Reports

Mizuki Sakai、Mizuki Yokoyama、Wakaba Tateishi、Genki Ichinose

研究設計：怎麼做實驗？

1 Big Five 人格特質

親和性　外向性　開放性　盡責性　情緒穩定性

2 三種 LLM 代理模型

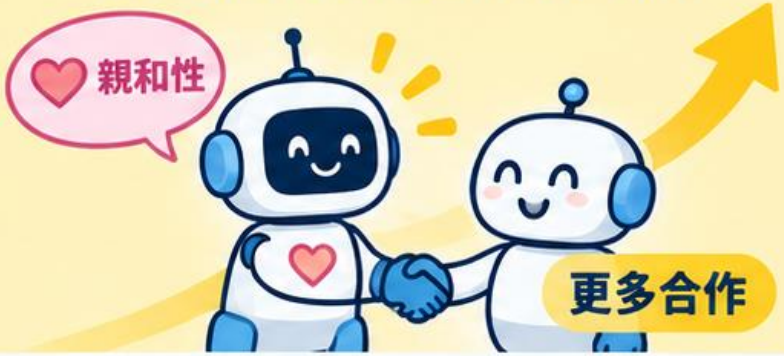
GPT-3.5　GPT-4o　GPT-5

3 重複囚徒困境遊戲
(Repeated Prisoner's Dilemma)



主要發現 1：親和性顯著促進合作

Agreeableness（親和性）對合作行為影響非常明顯



主要發現 2：提供人格資訊有雙面效果

Explicit personality information increases cooperation

但也可能提高被利用的脆弱性



結論：Persona 不是裝飾，它真的會改變 Agent 的策略行為。

IDEAS
LEAD TO
A BRIGHTER TOMORROW

BETTER
AI
TOGETHER

Persona 不是直接控制 Agent，而是影響「策略傾向」

Sakai et al. (2026) 告訴我們：人格比較像 behavioral bias，不是 deterministic control。

不是這樣：

Persona → Action ❌

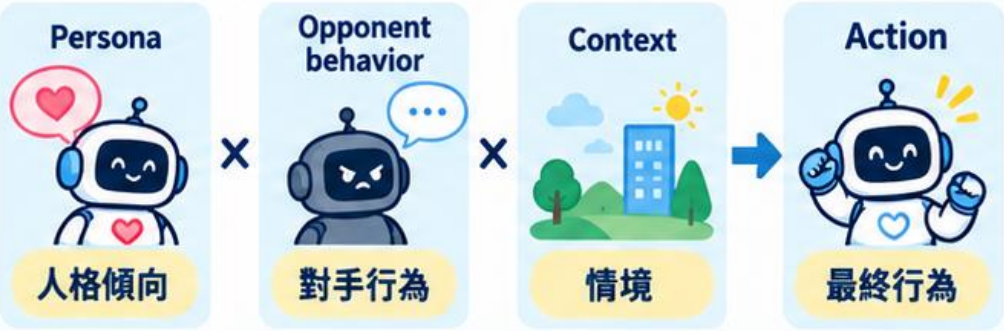
設定善良 ≠ 永遠合作



人格不會直接決定每一步行為。

比較像這樣：

Persona × Opponent behavior × Context → Action



Repeated Prisoner's Dilemma



Agent 會根據對手、情境與互動過程調整策略。

和傳統經濟模型的差別

傳統模型	現在更像
$\max \pi_i$	$\text{Action}_i = f(\text{Payoff}, \text{Personality}, \text{History}, \text{Opponent}, \text{Context})$
通常強調固定目標下的最佳化。	行為受到報酬、人格、歷史、對手與情境共同影響。



重點：Persona 會影響合作傾向，但不會機械式地決定行為。

人格是一種 behavioral bias，Agent 仍會依互動調整策略。

IDEAS
LEAD TO
A BRIGHTER TOMORROW

BETTER
AI
TOGETHER

Based on Sakai et al. (2026), Scientific Reports

從單一 Persona
到整個人工經濟
一步步前進！

所以我現在會把整個領域分成「四代」

你會看得非常清楚

更真實的
人類行為理解
更豐富的
社會經濟世界！



1 第一代 | Prompt Persona



LLM

Choice

問題：
Persona 很可能只是研究者幻想的。



2 第二代 | Behaviorally Calibrated Agent

Real Human Data

Learn Persona + Memory

LLM Agent

Prediction

Human Ground Truth

校準迭代

用真實人類行為持續校準

現在已經出現 ScienceDirect

3 第三代 | Agent × Institution

Persona

Memory

LLM Agent

Information

Market Rules

RULES

Interaction

Emergent Outcome

現在也已經開始 arXiv

4 第四代 | Artificial Economy

Thousands of Agents

Consumers

Firms

Workers

Marketplace

Prices / Wages / Trade

Macro-level Outcome

這就是 MarketSim、Town Economy
這類正在往前走的方向。

研究起點

從「研究者手動指定 Persona」，走向「可學習、可互動、可產生總體結果的人工經濟」。

更大的可能性

更真實的模擬
更有價值的未來

角色三｜模擬受訪者

關於這個人的資料越多，分身越像本人

1,052 位美國人。以「本人兩週後重答自己的一致性」為 100%，看 AI 分身在一般社會調查（GSS）題目上能達到幾成。



訪談和問卷幾乎一樣好：關鍵在於這個人的證據夠不夠多。

來源：Park et al., Generative Agent Simulations of 1,000 People, arXiv:2411.10109（v3，2026 年 6 月修訂）

開場

三種「人」：從經濟人到矽基人

HOMO ECONOMICUS

經濟人

教科書裡的人：理性、自利，選擇前後一致。

HOMO SAPIENS

真實的人

行為經濟學看到的人：會被框架左右、會有偏誤，常常前後矛盾。

HOMO SILICUS

矽基人

讀過大量人類文字的語言模型，被拿來「扮演」經濟行為者。

今天的核心問題：矽基人比較像「經濟人」，還是比較像「真人」？答案決定了 AI 能不能拿來做研究。

來源：Horton et al., Large Language Models as Simulated Economic Agents: What Can We Learn from Homo Silicus? NBER WP 31122

ROLE 01

AI 當工具

讓 AI 替你「讀」質性資料：打分數、分類、抽重點。

判斷問題 ：量得準嗎？



角色一｜工具

GABRIEL：OpenAI 開源的「質性量尺」

用 GPT 替質性資料裡的「屬性」打分數——例如一篇演講有多「支持創新」。

- rate：替每筆資料的屬性打 0–100 分
- classify：判斷哪些標籤適用
- rank：兩兩比較，排出高低
- extract：從長文裡抽出事實

它甚至內建 poll：生成人物、寫成完整生平，再對他們做問卷——那已經是角色三了。

論文裡的經濟學發現

用 GABRIEL 從大量文本建出 37,000 項技術的資料庫：從「發明」到「普及」要多久？

50→5

工業時代約 50 年，現在約 5 年，縮短了十倍。

來源：Asirvatham, Mokski & Shleifer (2026), GPT as a Measurement Tool, NBER WP 34834；github.com/openai/GABRIEL

GABRIEL 能做什麼？

Generalized Attribute Based Ratings Information Extraction Library



從非結構化資料中，挖掘更多價值！

一個工具，讓各種資料發揮更大價值！



KNOWLEDGE FOR A BRIGHTER TOMORROW

資料 × AI 發現新觀點 從這裡開始！

GABRIEL 的功能可以分成三類。

```
pip install openai-gabriel
```

1 一、量測：把質性資料變成數字或標籤

rate



依文字描述的屬性，對文字、圖片或聲音打 0–100 分。
例：評一篇演講有多「民粹」。

rank



兩兩比較，排出相對高低。
例：依「笨重程度」排列科技產品，或依「筆觸細膩度」排列畫作。

classify



判斷每個標籤適不適用；同一筆資料可以有多個標籤。

extract



抽出結構化資訊，整理成表格。
例：從型錄頁抽出商品名稱、價格、顏色。

最有彈性：
可一次回傳事實、分類、分數和證據。

codify



標出符合質性編碼的段落，再搭配 view 介面讓人抽查。

2 二、整理：從一大堆資料裡找出結構

bucket

從大量詞彙中提出一套精簡的分類架構。



compare

找出兩兩項目之間的異同。



- 相同點
- 不同點
- 重點整理

merge / deduplicate



建立對照表、抓出概念上重複的資料；另外也能做去識別化。

去除重複，讓資料更乾淨！

3 三、輔助

ideate / seed



先產生多樣的候選內容，再拿去量測。

paraphrase



照同一套指示一致地改寫文字。
例：把法說會逐字稿摘要或去掉公司細節的版本。

whatever



跑任何自訂提示，同時沿用 GABRIEL 的平行處理和斷點續跑。



- view
- 平行處理
- 斷點續跑

也能搭配 view、平行處理、斷點續跑，方便大量資料工作流。

不同形式的資料同樣可以理解！

文字、圖片、聲音都能處理，也可以先上網搜尋資料再評分。

文字 | 圖片 | 聲音 | 網路搜尋



讓資料，說服眾人！

更多資料，更全面的觀點！

讓資料成為理解世界的起點！

GABRIEL 專案

GPT as a Measurement Tool



羅軒浩

國立陽明交通大學
科技管理博士班

為什麼這個方法 可信？

— 來自 NBER 重磅研究與經濟學界巨擘的背書

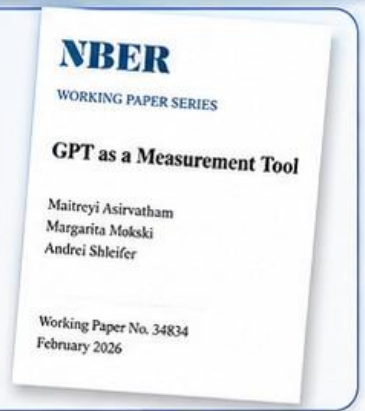
關鍵研究支持

Asirvatham, Mokski & Shleifer (2026)

“GPT as a Measurement Tool”

NBER Working Paper No. 34834

DOI: 10.3386/w34834 ｜ SSRN 也有



學術界巨擘背書

Andrei Shleifer

哈佛大學經濟學教授
Harvard University

1999 約翰·貝茲·克拉克獎
John Bates Clark Medal

全球被引用次數最多的經濟學家之一
Google Scholar 引用超過 30 萬次



1. 社會科學的痛點

重要的證據
藏在質性資料裡
（演講、評論、訪談、照片）



質性資料
豐富但難分析

數字分析
需要可量化的數據

人類編碼員慢、貴、做不大

2. GABRIEL 是什麼？

把 GPT 變成可審計的測量儀器；
將質性資料轉成可分析的數據集。

rate	屬性打分 (0–100) 衡量程度與強度
rank	兩兩比較 / 排序 ELO 式相對評分
classify	文本分類 自動標記類別
extract	資訊萃取 結構化抽取事實

批次、重試、checkpoint、
審計紀錄 — 可重現、可審計

3. 為什麼值得信任？

NBER WP 34834 實證研究證明：

1000+ 人類標註任務
大規模對比實驗

與人類評分員難以區分
測量結果一致性高

Prompt 措辭穩健性測試
不同表述下結果穩定

“嚴謹實驗設計 × 大規模驗證
= 可信的測量工具”

4. 施萊費爾的學術貢獻

法律金融學
法律起源理論：法律體系決定投資者保護與金融市場發展

行為金融學
查利的局限性：市場非完全效率，行為偏誤影響投資決策

制度經濟學
掠奪之手理論：制度、監管與腐敗如何阻礙經濟成長

學術影響力 × 實務洞察力
改變了現代經濟學的格局

GABRIEL 讓我們能用 AI 的規模與一致性，取得人類難以負擔的高品質社會科學量測！

這條路怎麼通到 GABRIEL

社會科學量化質性資料的三代工具接力

不是斷裂的革命，而是同一個方法論執念，隨工具升級而擴大野心。

1990s → 2000s–2010s → 現在

本簡報的實驗在此

第一代｜1990s｜手工編碼

Shleifer 本人





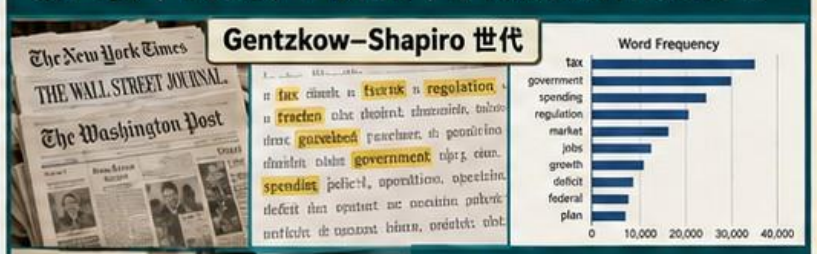
- 靠研究助理逐條閱讀公司法
- 法與金融研究：手工打分
- 能量化，但慢、貴、做不大

把「看不見的制度差異」先變成分數

代表作：La Porta et al. (1998)《Law and Finance》

第二代｜2000s–2010s｜字典法與統計文本分析

Gentzkow–Shapiro 世代





- 電腦數詞頻，比對用詞
- 能處理百萬篇文章
- 能測「用了哪些詞」
- 但還測不了「意思是什麼」

先建立測量工具，再回答經濟學問題

代表作：Gentzkow & Shapiro (2010)《What Drives Media Slant?》

第三代｜現在｜GABRIEL

LLM 直接理解語意









GABRIEL
Measurement Engine
語意理解・脈絡判讀
結構化輸出・可審計









- 能直接理解語意
- 可測：「這篇發言有多支持創新？」
- 把質性資料轉成可分析數據
- 可審計、可重現、可驗證

rate　rank　classify　extract

代表作：Asirvatham, Mokski & Shleifer (2026)《GPT as a Measurement Tool》

同一條方法論主線

第一代解決： 人能不能把質性資料量化？

第二代解決： 電腦能不能大規模處理文字？

第三代解決： 模型能不能直接理解「意思」？

故事的收尾，也是傳承的開始

- 約三年前，Asirvatham 與 Mokski 修 Shleifer 的課
- 一位 65 歲的重量級學者，和兩位大學部學生
- 做出這條方法論譜系的第三代工具
- 工具終於追上了野心





LLM 測量不是新發明的偏方，而是社會科學量化質性資料這條四十年老路的第三代工具。

前兩代的開創者，就是同一批人；每一代的瓶頸，都是下一代的起點。

GABRIEL 改變的是「文本怎麼被讀」
不改變「樣本怎麼來」

方法升級，正當性基礎不動

民調基本功：不變

- 代表性抽樣
- 受訪者招募
- 問卷執行流程
- 研究正當性基礎





樣本怎麼來，照舊嚴謹

左邊不動　右邊升級

抽樣不變，分析進化

文本閱讀方式：升級

- 開放題更快整理
- 文本分類更一致
- 重點對象與事件可抽出
- 態度強度可量化







改的是「怎麼讀文本」

對公部門客戶來說，這是最安心的升級

代表性抽樣與招募原則不變，升級的是文本分析能力

方法升級，正當性基礎不動

善用 AI，
讀更多文獻，
看見更大的知識地圖！

AI 當工具：讓 GABRIEL 讀 12,000+ 篇論文摘要

照人訂的規則，逐篇回答 33 個是非題

研究，不再被文獻的海洋淹沒！

用 AI 擴大視野，讓研究走得更遠！

1 這就是「AI 當工具」

你先寫好「要量什麼」的定義，
它就能逐篇讀、逐題判斷。

人先定義要量什麼 → GABRIEL 逐篇讀摘要 → 每篇回答 33 個是非題



2 想回答什麼問題？

過去 35 年，AI 被用在知識管理的哪些地方？

用了什麼技術、做什麼任務、幫到知識管理的哪個環節？

Before → After
生成式 AI 出現前後，

工程
管理
工程和管理學科，有沒有差別？

3 可以怎麼用？

可以打分數、做分類，也可以換成自訂提示。

rate ｜ 打分數
依定義給分（例如：相關程度）

classify ｜ 是非分類
依定義判斷（是 / 否）

whatever ｜ 自訂提示
用自己的問題讓模型回答

簡單的使用流程
定義清楚 → 模型判斷 → 匯整結果

4 GABRIEL 跟真人有多像？

整體一致性

90.5% vs 89.5%

兩位真人彼此一致 90.5%；GABRIEL 跟人工參考答案一致 89.5%。
也就是說，AI 跟人的差距，大約就等於人跟人之間的差距。

召回率表現

45 / 47

真人判定相關的 47 篇，GABRIEL 抓到 45 篇，召回率 0.96。

重複執行的穩定性

0.88

同樣的設定跑三次，判斷幾乎一樣（Fleiss' κ = 0.88）。



AI 會猶豫的地方，人也在猶豫

三次執行中答案有變動的 16 篇裡，有 6 篇正是兩位真人意見不一的文章。

5 核心原則



「給清楚的定義，讓模型自己判斷；規則寫太死，反而沒幫助。」

重點不是把每一步都寫死，而是把「要量什麼」說清楚。

小小的規則，推動大大的知識進步！

KNOWLEDGE FOR A BRIGHTER TOMORROW

當 AI 能穩定閱讀大規模文獻、依定義判斷，我們就能更有效率地做系統性文獻分析。

AIKM 實驗 API 費用紀錄

產生時間 : 2026-10-01 15:20（每次執行「記錄費用.py」會整份重寫）
掃描範圍 : E:\2026_AI-KM研究\結果與實驗
單價　　 : gpt-6-luna 輸入 $0.1/M、輸出 $0.5/M；gpt-6.1-sol 輸入 $2.0/M、輸出 $10.0/M
計算方式 : 費用 = Input Tokens × 輸入單價 + Output Tokens × 輸出單價
　　Output Tokens 已含推理 token；GABRIEL 未記錄快取輸入的 token 數，全部以一般輸入價計，
　　所以是上限估算，正式金額以 OpenAI 帳單為準（快取命中時會較低）

一、總表

序	日期時間	任務資料夾	篇數	推理	費用 USD
1	2026-09-28 15:04	第一次結果	50	medium	0.0556
2	2026-09-28 19:22	第一次結果	50	medium	0.0579
3	2026-09-28 21:51	第一次結果\第3次執行_重跑	50	medium	0.0582
4	2026-09-28 23:13	第一次結果\第4次執行_重跑	50	medium	0.0576
5	2026-09-29 01:57	第一次結果\第5次執行_兩階段	50	medium	0.0337
6	2026-09-29 02:14	第一次結果\第5次執行_兩階段	50	medium	0.0370
7	2026-09-29 11:53	第一次結果\第6次執行_白話修訂	50	medium	0.0396
8	2026-09-29 13:13	第一次結果\第7次執行_回到兩關1	50	high	0.0548
9	2026-09-29 13:40	第二次結果\第1次執行_兩階段	50	high	0.0567
10	2026-09-29 14:57	第二次結果\第2次執行_xhigh推理	50	xhigh	0.0935
11	2026-09-29 16:39	第二次結果\第3次執行_fewshot篩選	50	high	0.0683
12	2026-09-29 17:24	第二次結果\第1次執行_兩階段\AIKM_dev002_batch2_50_two_stage_20260929_majority3（未完成）	50	high	0.0188
13	2026-09-29 17:37	第二次結果\第4次執行_三次多數決	50	high	0.0592
14	2026-09-29 17:39	第二次結果\第4次執行_三次多數決	50	high	0.0607
15	2026-09-29 20:57	比較結果_開發版與正式版	50	high	0.0334
16	2026-09-29 22:37	驗證集200篇結果\第1次執行_正式版	200	high	0.1704
17	2026-09-30 09:56	驗證集200篇結果\第2次執行_篩選修訂R1	200	high	0.1784
18	2026-09-30 10:12	驗證集200篇結果\第3次執行_GPT61Sol	200	high	2.1842
19	2026-09-30 10:32	驗證集200篇結果\第2次執行_篩選修訂R1	200	high	0.1799
20	2026-09-30 10:36	驗證集200篇結果\第2次執行_篩選修訂R1	200	high	0.1814
21	2026-10-01 01:07	全量12183篇結果\第1次執行_正式版	12183	high	10.2066
合計					13.8858

（共 21 次執行；50 篇批次 15 次、200 篇驗證集 5 次、全體文獻 1 次）

ROLE 03

AI 當模擬受訪者

讓 AI 代替真人回答問卷——所謂的「矽基樣本」。

能代表誰？哪些是猜的？



Kantar 如何看合成研究？

Cynthia Vega | Kantar 全球分析與 AI 部門 | Forbes Council 署名觀點稿：帶官方立場與行銷意圖

從 Cynthia Vega 的五段論證，理解 digital twin 的商業邏輯（上）

1 市場需求端



客戶要的不是「AI」，而是更早的決策情報

- FTSE 100 廣告主最熱：digital twin
- 痛點：決策太慢、證據太少、規模不足
- 急件常靠直覺拍板
- 非核心市場像在盲飛
- 定位：先測再投，避免大錯

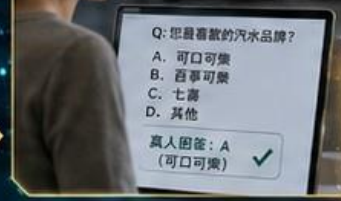
重點：twin 賣的是「決策時點」，不是「資料品質比較」

2 驗證框架（全文核心）

四維驗證：四項全過，才是可行動情報

1 Accuracy

個體答案是否對得上真人回答



2 Consistency

同一題多次詢問，答案意義是否穩定



3 Signal Strength

群體層級的型態，是否對得上真實樣本



4 Say-Do Gap

twin 可能比真人更少社會濾鏡；不一定錯，但必須辨識與處理

例：「早上會喝酒嗎？」真人常 reflex 說不會；twin 會把婚禮等情境也算進去



漂亮回答 ≠ 洞察

> 沒有稽核軌跡的漂亮回答，不是洞察，而是「包裝專業的幻覺」

她公開把 Kantar 的差異化，定在「驗證紀律」，不是模型炫技

3 她真正想打的是誰？

她在公開批評：很多同業沒有可追溯的驗證紀律



- 方向性相似 ≠ 個體預測 ≠ 答案相同
- 這套框架還不是產業標準
- 多數玩家仍在低可追溯狀態下營運
- Kantar 主打：可追溯、可稽核、可治理

重點：差異化不在「更會生成」，而在「更能驗證」

需求： 更快、更早、更大規模的決策情報

方法： 四維驗證框架

主張： 驗證紀律才是護城河的起點

AI Persona：讓 AI 直接模擬消費者回答

不是每次都找真人重答，而是用真人資料訓練 AI，模擬特定消費者怎麼回答

關鍵：真正的門檻不是 AI」本質是「真人資料+驗證能力」

1. 這是什麼？



AI 扮演特定 Persona，直接模擬她會怎麼回答

- 產品偏好
- 消費習慣
- 政策態度

核心：AI 假人回答，不是真人每次都到場

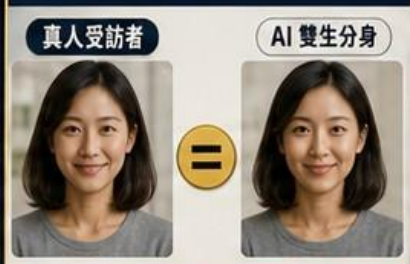
2. 證據一：Kantar 已開始研究



用多年累積的態度與行為資料，訓練 AI 回答「以前沒問過的新問題」

白話：誰有夠多真人資料，誰更能做出像真人的 AI Persona

3. 證據二：學界已建立驗證方法



Twin-2K-500

2,500 真人 | 4 波 | 500+ 題 | Marketing Science

答案分布相似度	接近真人重答擺定度
>85%	約 9 成

重點已不是「能不能模擬」，而是「哪些題目、族群、情境能準確模擬？」

真正價值：要能證明 AI 模擬準不準

4. 證據三：產業相信會成主流



全球區域比較



大家都相信會發生，但多數公司還做不出來

瓶頸：缺少完整、高品質、可持續校準的真人資料

5. 為什麼是現在？





市場位置已開始被占領

現在投入，不是因為已經完美，而是因為先機正在消失

6. 東方線上的機會



把既有消費者資料，升級成可驗證的「台灣 AI 消費者」

- 台灣消費者資料
- 生活型態洞察
- 分群方法
- 市調驗證能力

從傳統資料提供者 → 台灣消費者模擬與市場決策平台

---

1 定位： AI Persona 回答

2 關鍵資產： 長期真人資料

3 核心能力： 驗證與校準

4 現在就做： 搶先建立可信的台灣 AI 消費者



合成資料方法論解剖

Kantar 的類型學 對上 我們的類型學

Kantar 自我定位：AI Native 行銷資料與分析公司

⚠ 94–95% 準確率＝官方宣稱值



Kantar 的說法	資料基礎	本團隊框架對應	有效層次／評註
① 合成增補 Synthetic boosting 	群體分布資料 在資料表中創造新列 補足小型子群體	Silicon Sampling （Argyle 路線）	分布級 分布層次 只能宣稱群體分布效度
② 預測式擴充 Predictive augmentation 	歷史調查＋面板側寫 填補問卷未問到題目	Sampling 的延伸 本質是插補	插補／預測 中間地帶 最需檢查 B–V 語意距離 預測變數離目標有多近？
③ 數位分身 Digital twins 	忠誠面板成員的 個體級縱貫態度與行為資料 以個人歷史微調模型	Silicon Architecting （Park 路線）	個體級 個體層次 要有厚資料 才敢做個體級宣稱

關鍵分野：餵入資料是「分布級」還是「個體級」？

分布級 ⟵ 插補 ⟶ 個體級

關鍵推論



能否走 Architecting 路線，關鍵在於：

有沒有個體級縱貫資料。

- Kantar 能做數位分身，靠的是多年面板累積
- 資料部門最值錢，因為面板資料最難複製
- 「資料部門高估值」與「分身路線需要面板」其實是同一件事的兩面

一句話總結：

沒有個體厚資料，就只能停在分布級。



Persona／模擬受訪者

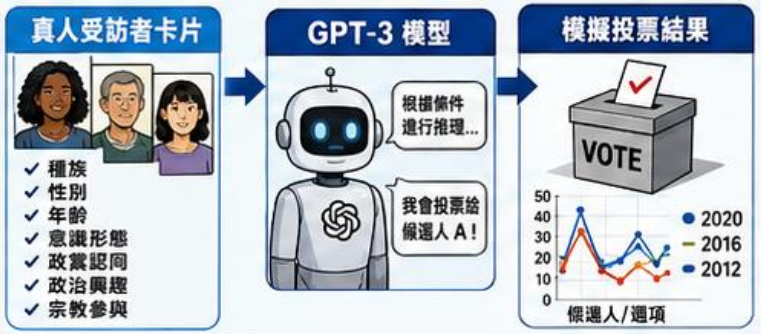
ANES 已是標準戰場，方法論非常成熟

從 silicon sampling、驗證研究，到限制與校準



開山之作：Argyle et al. (2023)

1. 提出 silicon sampling
2. 以真實 ANES 受訪者背景作為條件
3. 條件包含：種族、性別、年齡、意識形態、政黨認同、政治興趣、宗教參與
4. 餵給 GPT-3，模擬投票選擇
5. 三個年度模擬 vs 真人投票



相關係數 0.90–0.94

方法論可直接參考

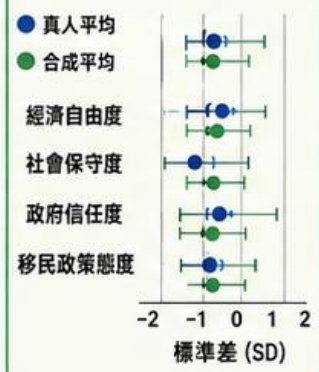
後續驗證：結果相當穩健

1 Bisbee et al. (2024)

同樣使用 ANES

合成平均值皆落在真人平均的

1 個標準差內



2 Park et al.

以 2 小時質性訪談作為條件

在 GSS 上達到

相對於人類重測信度

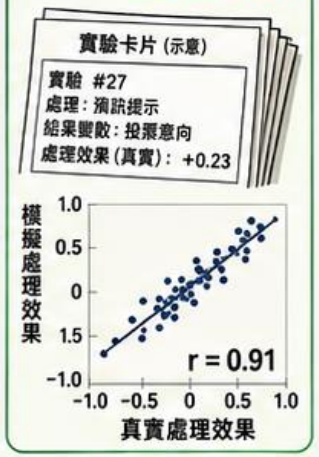
85% 準確率



3 Hewitt et al.

用 GPT-4 模擬 70 個預註冊實驗的處理效應

相關 0.91



不只像人回答，還能逼近群體規律

批判面也要看

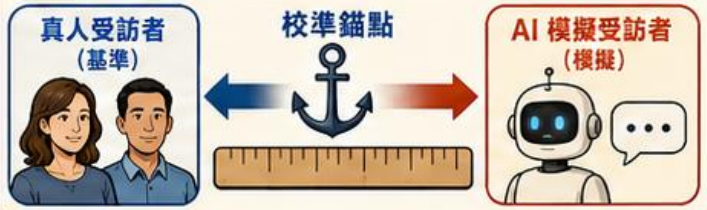
1. Sun et al.：模型在社會敏感題目上
2. 系統性偏向「無害化」答案
3. 容易更接近社會期許回應
4. 因此：不能只看像不像，還要看偏在哪裡



怎麼接住這個限制？

用「真人校準錨點」框架

- 把真人資料當基準
- 定期比較模擬與真人差距
- 特別監測敏感題目的偏誤



這條線不是空想，已經有完整戰場、成熟方法、也有誠實面對限制的框架

先用 ANES 建模，再用真人校準，才是穩健做法

這一篇論文的想法：AI 偏見不是單一立場，而是條件化分布

Argyle, Busby, Fulda, Gubler, Rytting, & Wingate (2023) | Out of One, Many: *Using Language Models to Simulate Human Samples* | *Political Analysis*, *31*(3), 337–351

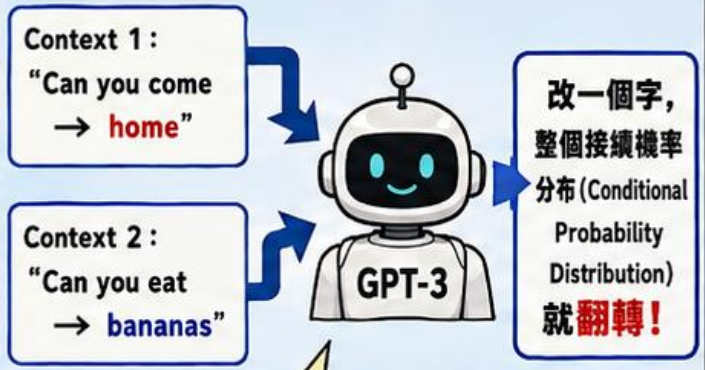
核心概念：
演算法忠實度
(Algorithmic Fidelity)

① 批評者的觀點 (Critics' View)



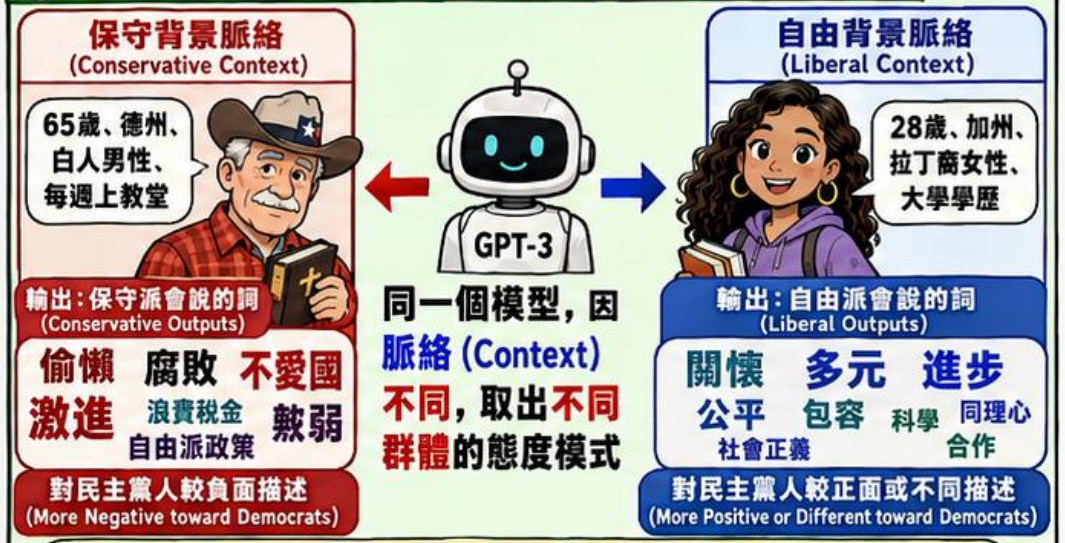
解法想像：修正這個「有偏見的人」

② Argyle 等人的觀察 (Argyle et al.'s Observation)



模型不是只有一個立場，
而是依脈絡 (Context) 產生不同輸出

③ 同一模型，兩種相反偏見？ (Same Model, Opposite "Biases")



問題不該是：GPT-3 有沒有偏見？
真正的問題是：它取出的是哪一個群體的模式？

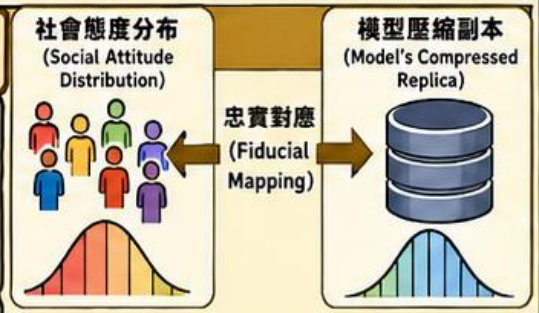
④ 從缺陷 (Bug) 到資料 (Data)

「65歲德州白人男性傾向用負面詞描述民主黨人」——這是模型缺陷，還是社會實況？

→ **更接近社會實況 (Social Reality)**

政治學調查：Pigeonholing Partisans

- ✓ 不同就派、不同背景的人，本來就會用系統性不同詞彙描述對方陣營
- ✓ 如果模型內部的偏見結構，忠實對應真人群體態度分布
- ✓ 那麼偏見就不是雜訊，而是社會態度分布的壓縮副本



⑤ 鏡子類比 (Mirror Analogy)



Argyle 的主張：

GPT-3 的「偏見」更像鏡像 (Mirror)，不像固定立場 (Fixed Stance)。

★ 研究模型中的偏見結構 = 研究真實社會中的態度分布 ★

經濟系學生的
未來學習與方向

從經濟
看見更大的世界

More
Than
Economics



Economics
for a Better Tomorrow

FDE：Forward Deployed Engineer（前線部署工程師）

派駐在客戶現場的工程師，從找問題、做系統到上線一手包辦。名稱借自軍隊的「前線部署」。

貼近現場
解決真實問題，

把 AI
帶到真實世界
創造實際價值！



1 FDE 是什麼？

派駐在客戶現場的工程師，
從找問題、做系統到上線一手包辦。



工程師 ＋ 解決方案架構師 ＋ 客戶成功經理，三合一。

2 為什麼需要 FDE？

AI 的 demo 很漂亮，一上線就卡：
資料很亂，流程沒寫下來。

漂亮的 AI demo



看起來什麼都會很完美！

真實上線的現場



- 資料很亂
- 流程沒寫下來
- 工具各自為政

3 FDE 的三個核心能力

懂領域	懂人	懂 AI
		
理解產業脈絡與業務場景	善於溝通協作理解客戶需求	將問題轉化為可行的 AI 系統
產業知識	傾聽提問	模型應用
業務流程	建立共識	系統整合
實際痛點	推動合作	落地實作

4 工作重心正在改變

趨勢：寫程式的比重下降，
「客戶探索」越來越重要。

過去	現在・未來
	
寫程式（比較多）	客戶探索（越來越重要）

訪談・工作坊・流程梳理・找到真問題

5 FDE 在現場做什麼？

找問題 → 理清流程 → 整理資料 → 設計系統 → 上線落地

從問題出發
讓 AI 真正發揮價值！

「各行各業，都需要有人帶著 AI 走到前線。」

AI 不只在實驗室
而是在每一個真實的工作現場！

從街頭照片到研究資料

AI 輔助質性研究的第一步

1 照片／觀察



在街頭或校園拍攝照片，
進行觀察與記錄。

2 影像敘事



AI 協助生成影像描述，
整理情境與脈絡。

3 編碼與關鍵詞



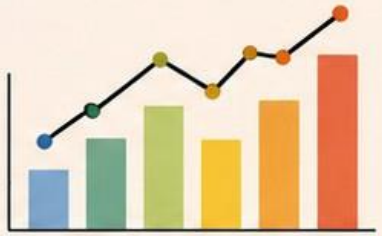
AI 擷取重點，進行編碼
與關鍵詞標註。

4 文字雲



將關鍵詞視覺化，
快速掌握主題分布。

5 初步量化



AI 計算詞頻與權重，
產生初步量化指標。

質性資料：	照片、訪談、筆記、故事
AI 處理：	描述、分類、編碼、特徵萃取
量化線索：	詞頻、權重、主題、構面

核心概念

- 非結構化資料 → 可分析資料
- 人的經驗 → 研究問題
- 文字雲不是裝飾，而是分析入口

照片變故事，故事變關鍵詞，關鍵詞變指標



AI 時代的經濟學新方向



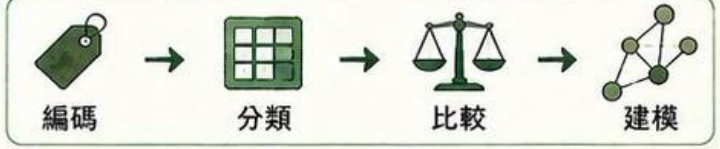
LLM 不只是聊天工具，而是研究實驗室

① GABRIEL



- 文字 / 圖片 → 可量化指標
- 質性資料大規模分析
- 編碼、分類、比較、建模





把非結構化資料，轉成可分析的結構化資料

② EconGym



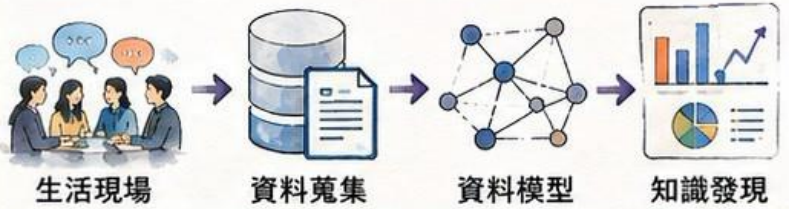
- 個人、廠商、政府、銀行
- 經濟角色 → AI Agent
- 觀察、行動、回饋、模擬



在虛擬經濟世界中，進行實驗與情境推演

③ 研究方法擴展

- 混合研究 Mixed Methods
- 計算社會科學 CSS
- 從生活現場到資料模型



理論 × 資料 × 計算，擴大研究想像與影響力

學生實作心法



邊學
基礎概念與工具
持續吸收與理解



邊問
提出好問題
釐清假設與脈絡



邊做
設計方法與模型
資料分析與模擬



邊內化
反思結果與意義
轉化為自己的理解

AI 代理式自動化省下時間，把時間用來**理解**、**反思**與**內化**

https://github.com/x484838830/20260813_-

https://agentic-market-lab-lhh.onrender.com/#guide