

《公平交易季刊》  
第 32 卷第 4 期 (113/10)，頁 107-152  
◎公平交易委員會

## 我國電商採取演算法定價之實務初探及模擬

林常青\*  
胡偉民  
蔡炎龍  
吳莉雯  
黃乾唐  
林宇哲

### 摘要

本研究彙整演算法定價相關的文獻，並利用 Python 蒐集實際資料，應用於機器學習程式，整合出一套檢視線上零售商涉及演算法聯合行為之初步篩選流程。文獻回顧討論如何利用演算法進行相關定價模擬，辨識賣家是否採用演算法與了解常見採用演算法下的價格變化模式。我們也以臺灣電腦與民生商品實際價格探索演算法定價。雖然所選電腦相關商品廠商有使用演算法定價的可能，但價格變動頻率最多約每天 2-3 次，故就回應對手價格變動所需的時間觀察，可能更適合推斷我國線上零售商是否採用演算法定價。再者，由於價格的樣本期間長達 1 年半，本研究也發現不同商品的定價模式可能在不同時期有較大的調整，故也可能是使用了半人工、半演算法的價格調整方式。最後，本研究使用實際資料並利用深度 Q 學習 (Deep

投稿日期：113 年 1 月 21 日

審查通過日期：113 年 10 月 1 日

\* 林常青為國立成功大學經濟學系教授、胡偉民為國立政治大學財政學系教授、蔡炎龍為國立政治大學應用數學系副教授、吳莉雯為國立政治大學財政學系博士班學生、黃乾唐為國立政治大應用數學系碩士班畢業生、林宇哲為昱泉國際股份有限公司資深資料科學家；本報告內容純係作者個人之觀點，不應引伸為公平交易委員會之意見，所有錯誤歸屬作者；通訊作者林常青聯絡方式：701401 臺南市東區大學路一號 成功大學經濟學系，e-mail: [ever@mail.ncku.edu.tw](mailto:ever@mail.ncku.edu.tw)。本文係自公平交易委員會 112 年度委託研究計畫「數位經濟下事業定價策略涉及聯合行為實證分析法之研究」改寫。林常青負責研究方向與架構、文獻資料蒐集整理、實證研究分析、程式模擬分析及彙整團隊意見主筆改寫，貢獻比例 23%；胡偉民負責研究方向與架構、文獻資料蒐集整理、實證研究分析，初稿撰寫，貢獻比例 22%；蔡炎龍負責研究方向與架構，程式模擬設計與分析，初稿撰寫，貢獻比例 20%；吳莉雯負責文獻資料蒐集整理、實證研究分析，貢獻比例 15%；黃乾唐負責模擬程式撰寫，模擬分析，貢獻比例 10%；林宇哲負責實證程式撰寫，資料收集與實證分析，貢獻比例 10%。

Q-Learning) 方法模擬廠商定價。在兩家廠商販售電腦的設定中，發現未經合意使用演算法定價的情況下仍有產生默式聯合行為的可能，即使真實狀況下兩家廠商仍處於競爭狀況。但在市場結構為一大廠、兩小廠販售某民生商品但不同品牌且小廠商採跟隨領導廠商的情境下，模擬的價格未必全部符合聯合行為的價格。實驗的模擬結果呼應了文獻所建議之不同模型和情境設定可能導致不同定價的結果。根據這些發現，本文也對資源有限的競爭主管機關提供務實的政策建議。如：加強數據收集和分析能力、優先使用高效的分析工具並制定基於實證資料的政策，以有效監控和維護市場競爭秩序。

**關鍵詞：**演算法定價、默式聯合行為、定價行為、深度 Q 學習法、定價模擬

## 一、研究背景與簡介

近年來，因為人工智慧<sup>1</sup>的發展，商業運行的面貌有了多方面的改變，例如人工智慧對廠商的勞動力、生產力、技能構成（skill composition）<sup>2</sup>、需求辨識<sup>3</sup>和創新等方面都有正面影響，節省了廠家人力的使用以及改善了廠商的運營效率與利潤。但人工智慧就像兩面刃，在廠商享受資訊科技的便利時，對經濟和社會層面也造成了諸多不利的後果。例如，人工智慧可替代部分的日常重複性工作，而這意味著結構性失業以及收入不均的兩極分化<sup>4</sup>；配合網路效果、規模經濟或範疇經濟，人工智慧在數位商品市場中可能強化在位優勢（incumbency advantage），使市場結構趨向集中，損害市場效率<sup>5</sup>；人工智慧在數位零售市場可能促進默契聯合行為（tacit conclusion）傷害消費者權益與市場效率<sup>6</sup>；人工智慧也可能在壯大數位廠商的市場占有率（下稱市占率）的同時構成參進障礙<sup>7</sup>。

<sup>1</sup> See OECD, “Recommendation of the Council on Artificial Intelligence,” <https://legalinstruments.oecd.org/en/instruments/oecd-legal-0449>, last visited on date: 2024/9/4. 其中定義「人工智慧系統是一種基於機器的系統，可以針對一組給定的人類定義目標做出預測、建議或影響真實或虛擬環境的決策」。

<sup>2</sup> 通常所指為利用電腦或電腦控制的機器人執行原先由人類執行的解決問題、學習、推理和決策制定等工作。

<sup>3</sup> 亦即差別取價，其中包括利用人口統計變數的特質與基於行為表現進行的差別取價。See Paul R. Milgrom & Steven Tadelis, “How Artificial Intelligence and Machine Learning Can Impact Market Design,” in: Ajay Agrawal, Joshua Gans & Avi Goldfarb (eds.), *The Economics of Artificial Intelligence: An Agenda*, 1st ed., University of Chicago Press, 567-585 (2019); Ariel Ezrachi & Maurice E. Stucke, “How Pricing Bots Could Form Cartels and Make Things More Expensive,” *Harvard Business Review* (2016/10/27), <https://hbr.org/2016/10/how-pricing-bots-could-form-cartels-and-make-things-more-expensive>, last visited on date: 2024/9/4.

<sup>4</sup> See Ajay Agrawal, Joshua Gans & Avi Goldfarb, “Economic Policy for Artificial Intelligence,” *19(1) Innovation Policy and the Economy*, 139-159 (2019).

<sup>5</sup> See, e.g., Laura Abrardi, Carlo Cambini & Laura Rondi, “Artificial Intelligence, Firms and Consumer Behavior: A Survey,” *36(4) Journal of Economic Surveys*, 969-991 (2022); Hal Varian, “Artificial Intelligence, Economics, and Industrial Organization,” in: Ajay Agrawal, Joshua Gans & Avi Goldfarb (eds.), *The Economics of Artificial Intelligence: An Agenda*, 1st ed., University of Chicago Press, 399-422 (2019).

<sup>6</sup> See Marcel Wieting & Geza Sapi, “Algorithms in the Marketplace: An Empirical Analysis of Automated Pricing in E-Commerce,” *21-06 NET Institute Working Paper* (2022).

<sup>7</sup> See, e.g., Jacques Crémer, Yves-Alexandre de Montjoye & Heike Schweitzer, *Competition Policy for the Digital Era: Final Report*, Publications Office of the European Union (2019).

人工智慧對於廠商與數位市場的發展影響廣泛，雖然各類的應用現在多仍處於發軔階段，但人工智慧爆炸性的快速成長軌跡，使產、官、學各界都對其未來將如何改變政治、經濟與社會各面向的運行感到好奇與擔憂。本文的主旨目的即在探索其中有關的議題：人工智慧演算法（artificial intelligence algorithm, AIA）對數位零售市場定價行為的影響，而關注的重點則包括如何辨識零售廠商是否採用了演算法定價、如何辨識演算法是否促進了聯合行為，以及了解演算法如何協助聯合行為。

為達成上述目標，我們回顧近期與演算法定價相關的模擬與實證的文獻，特別關注進行定價模擬的相關演算法，以及如何用價格變化模式辨識賣家是否採用演算法<sup>8</sup>。由於演算法定價有利於默式聯合行為之執行，因此在文獻回顧中我們也說明了價格領導賽局、群體理論以及默式聯合行為之間的關聯。

本研究蒐集了我國電商平臺上的電腦與周邊商品以及民生用品的價格資料，並基於文獻中所提及的模式<sup>9</sup>與觀察到的價格互動模式挑選研究標的，此外，我們也以商品間的價格互動變化判斷其所對應的市場結構，並配合效能更強的深度 Q 學習法（Deep Q-Learning）進行模擬廠商的定價行為，以研究其與聯合行為定價間的差距，並將模擬的結果與實際定價的狀況做比較。由於模擬需要設定相關市場結構和成本，且不同的設定可能導致不同的模擬結果，我們在文中介紹了本研究中模擬的相關設定與結果。最後，我們統合前述內容並提出建議事項。

藉由相關文獻對所提供的建議以及進行商品過濾後，本研究從電商平臺的電腦商品中選取高同質性、規格統一、價格變動頻率高的商品進行分析。我們發現電腦相關產品的定價模式主要經歷三個階段，包括同時調整價格或保持相同價差、隨機價格變化、相互試探，最終再回到第一階段，然而有關的模式會因商品差異而有些微調整。相較之下，本研究並未在民生商品價格上發現同樣的價格互動模式：廠商

<sup>8</sup> 目前文獻中並沒有可以顯示賣家是否採用演算法的直接證據，而相關文獻主要以「在一定的期間內改變定價的次數」、「賣家的價格與其他價格間的關聯性」以及「競爭對手的反應時間」等三種常用準則，來判定賣家是否採用演算法定價的嫌疑。See, e.g., Stephanie Assad, Robert Clark, Daniel Ershov & Lei Xu, “Algorithmic Pricing and Competition: Empirical Evidence from the German Retail Gasoline Market,” *8521 CESifo Working Paper* (2020); Leon Musolf, “Algorithmic Pricing Facilitates Tacit Collusion: Evidence from E-commerce,” in: Association for Computing Machinery, *EC '22: Proceedings of the 23rd ACM Conference on Economics and Computation*, 1st ed., Association for Computing Machinery, 32-33 (2022); Wieting & Sapi, *supra* note 6.

<sup>9</sup> See Wieting & Sapi, *supra* note 6 歸納出演算法賣家的五種價格變化模式，包括：「上下抖動」、「突升但緩降」、「緩升而突降」、「區間跳動」與「隨機跳躍」等方式。

價格調整雖頻繁但呈現區間跳動現象，價格互動不像電腦廠商那樣即時。此外，電腦相關產品呈現價格跟隨現象，領導廠商價格改變後，跟隨廠商會迅速跟進。然而，如果有商品價格變動破壞規律或有新廠商進入市場，定價模式會改變。整體而言，本研究認為所選電腦相關商品廠商有使用演算法定價的可能。但電腦商品和民生商品價格變動頻率最多大約每天 2-3 次，與文獻中高頻率變動的情況不同。因此，若以回應對手的價格變動所需時間觀察，可能更適合推斷演算法定價。此外，本研究所觀察的商品價格樣本期間長達 1 年半，發現不同商品的定價模式可能在不同時期有較大的調整，故也認為廠商可能使用半人工、半演算法的價格調整方式。

本研究也利用效能更強的深度 Q 學習法與電腦商品和民生商品的實際資料進行價格模擬。在兩家廠商的狀態下，透過訓練期價格推導各廠商需求曲線，再讓深度 Q 學習產生價格，可以模擬出接近聯合行為的價格，亦即未經合意下單使用演算法定價確有產生默契聯合行為的可能，但我們也發現模擬價格與實際價格間有明顯差異。在市場結構為一大兩小廠商（共三家）的情境下，領導與跟隨模型能較好刻畫市場狀況。此時深度 Q 學習產生的模擬價格，使一家跟隨廠商採用產生聯合行為之價格，另一家則採用介於聯合行為與跟隨者的價格，但領導廠商仍採用原模型下的領導價格。結果顯示，所有廠商考量對方決策時，未必全部形成聯合行為價格，而此結果可能受到市場結構的影響。我們的模擬結果呼應了文獻中所指出的，不同模型和情境設定可能導致不同結果，但有機會趨向聯合行為價格的現象。因此，本研究認為，在管制演算法定價時，應視情況逐案處理。此外，本模擬的結論也受限於需求函數形式和競爭狀態的假設以及成本和資料估計值的取得情形。

本研究的貢獻如下：首先，本研究是國內第一個利用 Python 爬蟲程式收集平臺電商價格資料以探究廠商間是否採用演算法定價的研究。我們收集電商平臺上的電腦與周邊商品以及民生用品的價格資料，並發現所選電腦相關商品廠商有使用演算法定價的可能。且以回應對手的價格變動時間，可能更適合推斷我國的演算法定價。其次，本研究是第一篇利用真實資料，以效能更強的深度 Q 學習法模擬廠商定價。利用兩家電商平臺上販售電腦的資料進行訓練，可知未經合意下單使用演算法定價仍有產生默契聯合行為的可能。此外，本研究也是第一篇考慮市場結構為一大兩小廠商（共三家）領導與跟隨情境下，利用民生商品真實資料與深度 Q 學習法進行模擬，發現一家跟隨廠商採用產生聯合行為之價格，另一家則採用介於聯合行為與跟隨者的價格，但領導廠商仍採用原模型下的領導價格。因此使用演算法，未必全部形成聯合

行為價格，且受市場結構影響。而根據這些方法與發現，本文也對資源有限的競爭主管機關提供務實的政策建議。如：加強數據收集和分析能力、優先使用高效的分析工具並制定基於實證資料的政策等，以有效監控和維護市場競爭秩序。

本研究將彙整現有的理論與實證性文獻所得到的模擬與估計結果，並以我國資料檢視人工智慧在定價的實際應用。因此，本研究除主旨與研究背景外，將在第二節介紹默式聯合行為經濟理論、實證文獻與法院判例，以及介紹演算法定價實證與模擬相關文獻，第三節將採用我國電商平臺的實際案例說明採用演算法定價的可能，第四節將介紹如何利用模型及演算法模擬默式聯合行為並比較實際狀況。最後，於第五節總結本文並提供政策建議。

## 二、文獻回顧

本節將分為兩部分說明與默式聯合行為相關的理論與實證文獻，以及與演算法定價相關的實證性文獻。在默式聯合行為的部分主要簡略地說明關於價格領導（price leadership）賽局與群體理論（Folk Theory）與默式聯合行為的關聯，以及選取近年與默式聯合行為的運作有關的實證性論文和法院的案例。與演算法定價相關的實證性文獻則分別說明模擬文獻中常用的 Q 學習法與深度 Q 學習法，而後彙整近年與演算法定價相關的代表性論文。

### （一）與默式聯合行為有關的理論性文獻

根據競爭法，顯式聯合行為指的是一組廠商間為了達到避免競爭的目的，而相互溝通以協調與監控彼此的行為<sup>10</sup>；默式聯合行為則是指廠商間不經過溝通，而達成行為上的一致性 or 同步性（coordination of conduct）<sup>11</sup>。雖然美、歐的司法體系對於顯式聯合行為有寬嚴不同的態度<sup>12</sup>，但法律對於默式聯合行為的規範態度則一致的模

<sup>10</sup> See Luke Garrod & Matthew Olczak, “Explicit vs Tacit Collusion: The Effects of Firm Numbers and Asymmetries,” *56 International Journal of Industrial Organization*, 1-25 (2018).

<sup>11</sup> See Joseph E. Harrington Jr., “A Theory of Tacit Collusion,” *588 The Johns Hopkins University Department of Economics Working Paper* (2012).

<sup>12</sup> 顯式聯合行為在歐盟受 101 法案（Treaty on the Functioning of the European Union Art. 101）的約制，而在美國由休曼法（Sherman Act）禁止，只要廠商行為符合顯式聯合行為的要件，就須承受嚴厲的處罰，甚至監禁。

糊不清。雖然在經濟與法律文件中都對默式聯合行為表現擔憂，但卻又明確的指出默式聯合行為在沒有聯合行為證據的情況下設定超競爭價格本身並不違法<sup>13</sup>。

在經濟與法律的概念中，廠商間溝通的有無是區分顯式聯合行為與默式聯合行為的最重要概念。Green et al.<sup>14</sup>整合了經濟與法律領域關於默式聯合行為的定義，並對其進行了分類。他們依據「發起」與「執行」兩階段是否有溝通，而將經濟學中的聯合行為分類——顯式聯合行為（explicit collusion）與默式聯合行為（tacit collusion），與法律概念中的分類——默契合意（tacit agreement）、顯式聯合行為（explicit collusion）和默契協調（tacit coordination）整合，而將聯合行為更細膩的分成弱顯式聯合行為（weak explicit collusion）、強顯式聯合行為（strong explicit collusion）以及默契協調（tacit coordination）三類<sup>15</sup>。

Green et al.<sup>16</sup>指出，聯合行為需要通過溝通與資訊交換來建立和施行，這種行為通常被視為顯式聯合行為。相對地，默式聯合行為發生於廠商在市場中意識到彼此的相互依賴，尤其是當他們知道他們的利潤受到競爭對手行為的影響時。這種洞察力若成為常識，則廠商即便在缺乏溝通的情況下也能建立和執行聯合行為。經濟學文獻普遍認為，在高度集中的市場中，壟斷行為可能自發產生。但在互相依存的市場中，廠商透過觀察並對競爭對手的行動做出反應來協調行為，這可能導致與傳統「協議設定價格」不同的結果。如果沒有額外的證據顯示廠商之間有組織性的協調，則不易被反壟斷機構認定為聯合行為。

關於默式聯合行為，有兩個主要的賽局理論架構：價格領導理論和群體理論。價格領導模型指的是在寡占市場中，一個廠商（領導者）先確定價格或其他變數，其他廠商（追隨者）則採取類似的價格行為。這種模型顯示了廠商間在定價或數量策略上的相互依賴，而這種相互依賴的定價行為因為不需額外協商<sup>17</sup>可能被視為一種默式聯合行為。

<sup>13</sup> 美國最高法院在 1993 年對 *Brooke Group v. Brown and Williamson* 反壟斷案件的裁決。

<sup>14</sup> See Edward J. Green, Robert C. Marshall & Leslie M. Marx, "Tacit Collusion in Oligopoly," in: Roger D. Blair & D. Daniel Sokol (eds.), *2 The Oxford Handbook of International Antitrust Economics*, 1st ed., Oxford University Press, 464-497 (2014).

<sup>15</sup> 在經濟學中，廠商在發起或執行階段有溝通即視為顯式聯合行為。法律領域則將只在執行階段溝通的行為定義為顯式聯合行為。如果僅在發起階段溝通而執行期間無溝通，則稱為默契合意。Green 等人將這種情況定義為「弱顯式聯合行為」，而執行期間有溝通的則稱為「強顯式聯合行為」。不論在經濟或法律中，沒有在任何階段溝通的則定義為默式聯合行為。

<sup>16</sup> See Green et al., *supra* note 14.

<sup>17</sup> See Joe S. Bain, *Industrial Organization*, 2nd ed., John Wiley & Sons, 132 (1968).

群體理論為賽局理論的一部分，關注於重複賽局中達成的 Nash 均衡。這個理論指出，只要參與者有足夠的耐心（折現因子表示），任何階段的可行且個體理性回報都能達到均衡。Schelling 於 1960 年<sup>18</sup>首次提出此理論與默式聯合行為的關聯，而 Scherer 於 1970 年<sup>19</sup>進一步探討了其在定價中的應用，指出價格因重複使用可能成為焦點（focal point）。早期理論，如 Friedman 於 1977 年<sup>20</sup>的研究，假設在廠商完全耐心和完整市場信息下，寡頭壟斷市場可達到包括壟斷性均衡的多種均衡狀態。隨後的理論，如 Fudenberg & Maskin<sup>21</sup>和 Radner<sup>22</sup>，以及 Mailath & Samuelson<sup>23</sup>，展開了在信息完整度和耐心程度更寬鬆的條件下的研究。這些研究表明，在廠商足夠耐心的情況下，寡頭市場可在無需或極少溝通的環境下自然形成聯合行為。

在探討默式聯合行為理論時，價格領導理論與群體理論成為關鍵的架構，因它們未特別強調溝通的重要。Stigler<sup>24</sup>指出聯合行為成功的關鍵在於阻止廠商背離協議：由於高價格和低產量的誘因，廠商可能會降價以獲得更高市占率。Bagwell & Staiger<sup>25</sup>使用重複賽局和價格領導理論分析聯合行為，認為這是一種在短期降價利益與長期價格戰成本間權衡的行為。Sugaya<sup>26</sup>強調群體理論的互惠機制，玩家偏離協議會遭到懲罰，並且他們的行動需要與其他玩家的過去行動協調。Stigler<sup>27</sup>認為，為維持聯合行為，廠商間需要有一個架構來控制互動，包括定價、資源配置和執行機制。Friedman<sup>28</sup>

<sup>18</sup> See Thomas C. Schelling, *The Strategy of Conflict*, 1st ed., Harvard University Press (1960).

<sup>19</sup> See Frederic M. Scherer, *Industrial Market Structure and Economic Performance*, 1st ed., Houghton Mifflin Company (1970).

<sup>20</sup> See Milton Friedman, "Nobel Lecture: Inflation and Unemployment," *85(3) Journal of Political Economy*, 451-472 (1977).

<sup>21</sup> See Drew Fudenberg & Eric Maskin, "The Folk Theorem in Repeated Games with Discounting or with Incomplete Information," *54(3) Econometrica*, 533-554 (1986).

<sup>22</sup> See Roy Radner, "Repeated Partnership Games with Imperfect Monitoring and No Discounting," *53(1) The Review of Economic Studies*, 43-57 (1986).

<sup>23</sup> See George J. Mailath & Larry Samuelson, *Repeated Games and Reputations: Long-run Relationships*, 1st ed., Oxford University Press (2006).

<sup>24</sup> See George J. Stigler, "A Theory of Oligopoly," *72(1) Journal of Political Economy*, 44-61 (1964).

<sup>25</sup> See Kyle Bagwell & Robert W. Staiger, "Collusion over the Business Cycle," *28(1) RAND Journal of Economics*, 82-106 (1997).

<sup>26</sup> See Takuo Sugaya, "Folk Theorem in Repeated Games with Private Monitoring," *89(4) Review of Economic Studies*, 2201-2256 (2022).

<sup>27</sup> See Stigler, *supra* note 24.

<sup>28</sup> See Friedman, *supra* note 20.

是首篇在重複賽局理論中考慮收益貼現的研究，強調短期與長期成本收益的權衡，並假設廠商行為完全透明。Ivaldi et al.<sup>29</sup>探討了缺乏溝通的聯合行為賽局，指出廠商可以透過重複互動來維持高價格，但降價可能引發報復。

Fudenberg & Maskin<sup>30</sup>假設在廠商間無溝通但有充足公開訊息的情況下，廠商能夠完美監控對手行動，每個玩家根據自身策略和其他玩家過去行動調整策略。Fudenberg, Levine & Maskin<sup>31</sup>放鬆了這一假設，即使在不完全的公共資訊下，只要有關行動的共同訊號存在，合作仍可持續。這引發了在「不完整訊息—不完美監控」條件下的群體理論發展，探討了在廠商間缺乏溝通且訊息不完整的情況下，群體理論均衡所需的訊息條件邊界。Mailath & Samuelson<sup>32</sup>等研究探索了私人訊息下的群體理論。Sugaya<sup>33</sup>提出，隨著時間的推移，僅依賴私人訊息協調變得困難，探討了在私人監督下合作的可能性。Piccione<sup>34</sup>和 Ely & Välimäki<sup>35</sup>使用了無置信均衡概念，在幾乎完美監控下展示了群體理論在囚犯兩難中的應用。Matsushima<sup>36</sup>引入噪音監控假設，證明了群體理論在囚犯兩難下的有效性。Kandori<sup>37</sup>和 Yamamoto<sup>38</sup>分別在多人情境中發展出「弱 BFE (belief free equilibrium) 均衡」和擴展了 BFE 的概念。Sugaya<sup>39</sup>在兩人賽局設定中加入了私人訊息和利益折現，發現群體理論成立的充要條件，證明即使在沒有顯式溝通的情況下，群體理論也能成立，並且時間足夠長時，溝通不是必需的。

<sup>29</sup> See Marc Ivaldi, Bruno Jullien, Patrick Rey, Paul Seabright & Jean Tirole, “The Economics of Tacit Collusion,” *186 IDEI Working Paper* (2003).

<sup>30</sup> See Fudenberg & Maskin, *supra* note 21.

<sup>31</sup> See Drew Fudenberg, David Levine & Eric Maskin, “The Folk Theorem with Imperfect Public Information,” *62(5) Econometrica*, 997-1039 (1994).

<sup>32</sup> See Mailath & Samuelson, *supra* note 23.

<sup>33</sup> See Sugaya, *supra* note 26.

<sup>34</sup> See Michele Piccione, “The Repeated Prisoner’s Dilemma with Imperfect Private Monitoring,” *102(1) Journal of Economic Theory*, 70-83 (2002).

<sup>35</sup> See Jeffrey C. Ely & Juuso Välimäki, “A Robust Folk Theorem for the Prisoner’s Dilemma,” *102(1) Journal of Economic Theory*, 84-105 (2002).

<sup>36</sup> See Hitoshi Matsushima, “Repeated Games with Private Monitoring: Two Players,” *72(3) Econometrica*, 823-852 (2004).

<sup>37</sup> See Michihiro Kandori, “Weakly Belief-Free Equilibria in Repeated Games with Private Monitoring,” *79(3) Econometrica*, 877-892 (2011).

<sup>38</sup> See Yuichi Yamamoto, “Characterizing Belief-Free Review-Strategy Equilibrium Payoffs under Conditional Independence,” *147(5) Journal of Economic Theory*, 1998-2027 (2012).

<sup>39</sup> See Sugaya, *supra* note 26.

Green & Porter<sup>40</sup>在寡頭壟斷定價研究中使用 Cournot 設定的超級賽局，發現少數市場主導者可以通過理性計算自己的價格決策和預測競爭者反應，從而在無公開溝通的情況下維持超競爭價格。Marshall & Marx<sup>41</sup>補充指出，在塊狀需求、不確定性較大的需求或買家策略性行為的情況下，即使在長期互動中，個別廠商仍可能秘密背離協議，影響聯合行為的最大化利潤。

Abreu<sup>42</sup>探討在聯合行為中，缺乏溝通但可完全監控的情況下，廠商如何透過最適懲罰來維持最大利潤。另外 Abreu, Pearce & Stacchetti<sup>43</sup>將研究擴展到不完全監控的情況。Brock & Scheinkman<sup>44</sup>在 Bertrand 設定的超級賽局中研究了弱顯式聯合行為，發現在這種設定下可實現價格上漲，並探討了產業中廠商數量對價格的影響。Lambson<sup>45</sup>則研究了在 Bertrand 設定的超級賽局中透過弱顯式聯合行為實現最大利潤的可能性，指出最適懲罰結構在此設定下相較於 Cournot 設定更為簡單。

## （二）與默式聯合行為有關的實證性文獻

本研究發現近十年來探討經濟與會計領域的論文中，涉及產業的默式聯合行為的相關論文大致可歸納出以下類型：依據「促進聯合行為的機制」進行分類則有探討「多市場接觸」的美國航空業<sup>46</sup>、智利的製藥業<sup>47</sup>、美國保險業<sup>48</sup>，探討「公開資

<sup>40</sup> See Edward J. Green & Robert H. Porter, "Noncooperative Collusion under Imperfect Price Information," *52(1) Econometrica*, 87-100 (1984).

<sup>41</sup> See Robert C. Marshall & Leslie M. Marx, *The Economics of Collusion: Cartels and Bidding Rings*, 1st ed., MIT Press, Chapter 1.4, 9-17 (2012).

<sup>42</sup> See Dilip Abreu, "Extremal Equilibria of Oligopolistic Supergames," *39(1) Journal of Economic Theory*, 191-225 (1986).

<sup>43</sup> See Dilip Abreu, David Pearce & Ennio Stacchetti, "Optimal Cartel Equilibria with Imperfect Monitoring," *39(1) Journal of Economic Theory*, 251-269 (1986).

<sup>44</sup> See William A. Brock & José A. Scheinkman, "Price Setting Supergames with Capacity Constraints," *52(3) Review of Economic Studies*, 371-382 (1985).

<sup>45</sup> See Val E. Lambson, "Some Results on Optimal Penal Codes in Asymmetric Bertrand Supergames," *62(2) Journal of Economic Theory*, 444-468 (1994).

<sup>46</sup> See Federico Ciliberto & Jonathan W. Williams, "Does Multimarket Contact Facilitate Tacit Collusion? Inference on Conduct Parameters in the Airline Industry," *45(4) RAND Journal of Economics*, 764-791 (2014); Federico Ciliberto, Eddie Watkins & Jonathan W. Williams, "Collusive Pricing Patterns in the US Airline Industry," *62 International Journal of Industrial Organization*, 136-157 (2019).

料披露」的美國金融業<sup>49</sup>、美國大型傳統航空業<sup>50</sup>、美國汽車市場<sup>51</sup>，探討「結合」的歐洲的維他命市場<sup>52</sup>、航空與化學品製造業<sup>53</sup>、美國醫療市場<sup>54</sup>，探討「領導與跟隨」澳大利亞汽車零售業<sup>55</sup>、西班牙銀行市場<sup>56</sup>、啤酒市場<sup>57</sup>，另外還有用多種市場的現狀探討共同所有權的作用<sup>58</sup>以及以智利的婦產醫療協會探討產業協會對促進默式聯合行為的作用<sup>59</sup>的論文，以及具有雙邊市場 (two-sided market) 特性的線上平臺<sup>60</sup>與

- 
- <sup>47</sup> See Jorge A. Chilet, “Gradually Rebuilding a Relationship: The Emergence of Collusion in Retail Pharmacies in Chile,” *Working Paper* (2017).
- <sup>48</sup> See Haizhen Lin & Ian M. McCarthy, “Multimarket Contact in Health Insurance: Evidence from Medicare Advantage,” *24486 NBER Working Paper* (2018).
- <sup>49</sup> See Thomas Bourveau, Guoman She & Alminas Žaldokas, “Corporate Disclosure as a Tacit Coordination Mechanism: Evidence from Cartel Enforcement Regulations,” *58(2) Journal of Accounting Research*, 295-332 (2020).
- <sup>50</sup> See Gaurab Aryal, Federico Ciliberto & Benjamin T. Leyden, “Coordinated Capacity Reductions and Public Communication in the Airline Industry,” *89(6) Review of Economic Studies*, 3055-3084 (2022).
- <sup>51</sup> See Jeremy Bertomeu, John H. Evans III, Mei Feng & Ayung Tseng, “Tacit Collusion and Voluntary Disclosure: Theory and Evidence from the U.S. Automotive Industry,” *67(3) Management Science*, 1851-1875 (2021).
- <sup>52</sup> See Mitsuru Igami & Takuo Sugaya, “Measuring the Incentive to Collude: The Vitamin Cartels, 1990-99,” *89(3) Review of Economic Studies*, 1460-1494 (2022).
- <sup>53</sup> See Robert H. Porter, “Mergers and Coordinated Effects,” *73 International Journal of Industrial Organization*, Article 102583 (2020).
- <sup>54</sup> See Matt Schmitt, “Multimarket Contact in the Hospital Industry,” *10(3) American Economic Journal: Economic Policy*, 361-387 (2018).
- <sup>55</sup> See David P. Byrne & Nicolas de Roos, “Learning to Coordinate: A Study in Retail Gasoline,” *109(2) American Economic Review*, 591-619 (2019).
- <sup>56</sup> See Paula Cruz-García, Juan F. de Guevara & Joaquín Maudos, “Bank Competition and Multimarket Contact Intensity,” *113 Journal of International Money and Finance*, Article 102338 (2021).
- <sup>57</sup> See Nathan H. Miller, Gloria Sheu & Matthew C. Weinberg, “Oligopolistic Price Leadership and Mergers: The United States Beer Industry,” *111(10) American Economic Review*, 3123-3159 (2021).
- <sup>58</sup> See Andrea Pawliczek, A. Nicole Skinner & Sarah L. C. Zechman, “Facilitating Tacit Collusion through Voluntary Disclosure: Evidence from Common Ownership,” *60(5) Journal of Accounting Research*, 1651-1693 (2022).
- <sup>59</sup> See Jorge Alé-Chilet & Juan P. Atal, “Trade Associations and Collusion among Many Agents: Evidence from Physicians,” *51(4) RAND Journal of Economics*, 1197-1221 (2020).
- <sup>60</sup> See Thomas Eisfeld, “Unite and Conquer: Seller Collusion in Multi-Sided Markets,” *Working Paper* (2023), [https://congresscreator.org/system/files/papers/UniteConquer\\_Eisfeld\\_0.pdf](https://congresscreator.org/system/files/papers/UniteConquer_Eisfeld_0.pdf), last visited on date: 2024/9/4.

共享汽車市場<sup>61</sup>中的默式聯合行為之探討。雖然上述文獻對個案進行了研究，但這些研究主要僅能表明在這些產業中相關的營運模式具有默式聯合行為的嫌疑，至於這些行為是否真的屬於默式聯合行為，或者是未發現證據的顯式聯合行為，則需留待經濟與法律相關領域的更深入探討。

### （三）與默式聯合行為有關的法院案例

由於默式聯合行為的判定不易，以下僅彙整了三個涉及默式聯合行為的案例，每個案例分別展示了公開資料披露、領導與跟隨以及自發性平行行為等不同的機制。

第一個案例是 *U.S. v. Airline Tariff Publishing Company, et al.*<sup>62</sup>。該案件發生在 1992 年，主要涉及的機制是公開資料披露：八家主要美國航空公司及航空運價公布公司（Airline Tariff Publishing Company，下稱 ATP）被控違反休曼法第 1 條。它們涉嫌使用 ATP 的票價傳播服務協調票價變動，導致消費者支付更高的機票價格。然而，法院允許航空公司使用 ATP 系統設定票價和就聯合運輸及代碼共享進行通信，但禁止它們就穩定或提高票價達成協議。

第二個案例是 *American Tobacco Co. v. United States*, 328 U.S. 781 (1946)<sup>63</sup>，該案件涉及的機制為領導與跟隨。該案件主要是因為當時美國菸草公司以及 Liggett and Myers 和 R.J. Reynolds 菸草公司，共占有美國至少 68% 的香菸市場份額，且被指控在 1931 年，當 R.J. Reynolds 突然提高香菸價格後，其他公司迅速跟進的聯合行為。法院判定這些占主導地位的公司合謀建立壟斷，違反休曼法第 2 條。

第三個案例則是 *Brooke Group Ltd. v. Brown and Williamson Tobacco Corp.*, 509 U.S. 209 (1993)，涉及的機制為自發性平行行為。Liggett 控告 Brown and Williamson（兩家公司均為美國香菸市場的主導公司）以低於成本的價格銷售產品，迫使 Liggett

<sup>61</sup> See Pravesh Koirala & Forrest Laine, “Algorithmic Collusion in a Two-sided Market: A Rideshare Example,” arXiv:2405.02835 (2024).

<sup>62</sup> U.S. Department of Justice, “Final Judgment: U.S. V. Airline Tariff Publishing Company, Et Al.,” <https://www.justice.gov/atr/final-judgment-us-v-airline-tariff-publishing-company-et-al>, last visited on date: 2024/9/4.

<sup>63</sup> Sean Carroll, “American Tobacco Co. v. United States,” Quimbee, <https://www.quimbee.com/cases/american-tobacco-co-v-united-states>, last visited on date: 2024/9/4; FindLaw, “American Tobacco Co. v. United States, 328 U.S. 781 (1946),” <https://caselaw.findlaw.com/court/us-supreme-court/328/781.html>, last visited on date: 2024/9/4.

提高普通香菸的價格，從而保護 Brown and Williamson 在品牌香菸上的超額利潤，這違反了克萊頓法（Clayton Act）第 2(a)條。法院認為 Brown and Williamson 的行為並未對競爭造成損害，因為市場上非專利品牌香菸的增長並未放緩，且製造商之間在經濟領域的價格上沒有發現明顯的協調行為，且認為在掠奪性定價環境中，寡頭壟斷者之間的自發性平行行為並不會產生損害。

#### （四）與演算法定價相關的實證性文獻

演算法定價為一新興現象，相關實證研究仍然較少，且主要使用高頻數據。重要研究包括 Assad et al.<sup>64</sup>關於德國零售汽油市場，Musolff<sup>65</sup>針對 Amazon.com，Calder-Wang & Kim<sup>66</sup>關於美國租賃市場以及 Wieting & Sapi<sup>67</sup>關於 Bol.com 的研究。這些研究發現演算法定價對市場有顯著影響：Assad et al.發現約 30% 的加油站可能採用演算法定價，且油價與廠商是否使用演算法有關，Musolff 發現賣家能以演算法定價避免 Bertrand-Nash 競爭價格結果，定價的動態過程會出現 Edgeworth 循環（Edgeworth Cycle），且平均價格會有成長的趨勢。Calder-Wang & Kim 發現使用演算法定價的物件會依據需求彈性調整租賃價格與數量。Wieting & Sapi 則發現當同質性商品的賣家數量中等，且其中兩個賣家採用演算法定價時，商品價格會特別高。此外，演算法可以降低多產品獨占賣家之市場價格。

為了辨識賣家是否採用演算法，Assad et al.使用三個指標：價格變動次數、變動幅度和競爭對手反應時間。Musolff 觀察到 Amazon 上部分廠商的價格動態類似於 Edgeworth 循環，而 Wieting & Sapi 提出將價格變動次數標準化，並將高於兩個標準差的變動次數視為使用演算法的證據。他們還將演算法後的價格變動模式分為五類，分別為上下抖動、突升但緩降、緩升而突降、區間跳動、隨機跳躍。

---

<sup>64</sup> See Assad et al., *supra* note 8.

<sup>65</sup> See Musolff, *supra* note 8.

<sup>66</sup> See Sophie Calder-Wang & Gi Heung Kim, “Algorithmic Pricing in Multifamily Rentals: Efficiency Gains or Price Coordination?,” *SSRN Paper* (2024), <https://ssrn.com/abstract=4403058>, last visited on date: 2024/9/4.

<sup>67</sup> See Wieting & Sapi, *supra* note 6.

## （五）與演算法定價有關的模擬方法

以下與演算法定價有關的模擬方法主要彙整自 Calvano et al.<sup>68</sup>、Sanchez-Cartas & Katsamakas<sup>69</sup>與 Hettich<sup>70</sup>。包含 Q 學習法（Q-Learning）。此外，為改善 Q 學習法，近期又有深度 Q 學習法（Deep Q-Learning）。

### 1. Q 學習法

Q 學習法是強化學習（reinforcement learning）的一種形式，它根據環境反饋，無需事先了解賽局或市場結構，就能尋找到最佳的報酬（利潤）策略。強化學習是由電腦根據設定好的最佳化獎勵目標，自動找出最佳策略的方法。具體來說，在本論文中，「狀態」 $s$  是觀察到兩家電商的價格對（price pair），「動作」 $a$  是預測目標電商的定價行為。雖然我們可以直接學習策略函數  $A(s) = \alpha$ ，但訓練資料較難以準備（因為我們希望學出來是最大利益考量的定價策略，儘量避免其他因素干擾），因為不知「正確答案」為何。於是本論文採用學習價值函數（value function）的方法，而 Q 學習是預測  $Q(s, \alpha)$  的值（期望的最終獲利），成功學會，那麼在某個實際狀態  $s$  下，可以窮舉所有的可能動作（定價），找到最大的就是最佳動作。

如果狀態的可能性是有限的，可以採用一般的 Q 學習法窮舉計算所有可能性。這種方法的一個主要特點是其簡潔性，但主要缺點是收斂速度慢。它需要追蹤各種可能的行動（如在本計畫中的定價行為）和狀態，如果行動範圍廣泛，可能會引起計算上的維度問題。此外，在使用矩陣時，如果行動或狀態是連續變量，可能會產生偏差。然而，本研究考慮的狀態情況過多，即使可以限縮到某種有限狀態，也不需要這樣的限制。因此，我們採用神經網路為 Q 函數的模型，亦即深度 Q 學習的方式，來克服前述使用一般 Q 學習法所可能遭遇的問題。

---

<sup>68</sup> See Emilio Calvano, Giacomo Calzolari, Vincenzo Denicolò & Sergio Pastorello, “Artificial Intelligence, Algorithmic Pricing, and Collusion,” *110(10) American Economic Review*, 3267-3297 (2020).

<sup>69</sup> See Juan M. Sanchez-Cartas & Evangelos Katsamakas, “Artificial Intelligence, Algorithmic Competition and Market Structures,” *10 IEEE Access*, 10575-10584 (2022).

<sup>70</sup> See Matthias Hettich, “Algorithmic Collusion: Insights from Deep Learning,” *SSRN Paper* (2021), <https://ssrn.com/abstract=3785966>, last visited on date: 2024/9/4.

## 2. 深度 Q 學習法

考慮到 Q 學習法的缺點和在狀態與行為數增多時 Q 矩陣過於龐大難以學習的問題，因此改用深度 Q 學習法。這種方法使用深度神經網路代替產生龐大的離散 Q 矩陣，從而使狀態和行動能夠連續化。

深度神經網路主要是由神經元 (neuron) 堆疊組成，在輸入向量以及輸出向量之間存在數層隱藏層 (hidden layer) 進行運算學習。每個隱藏層由數個神經元組成，神經元的基本運算為  $\sigma(W^T x + b)$ ，其中  $x$  為輸入向量， $W$  與  $b$  分別是深度神經網路所要學習的參數，分別代表權重與偏差值， $\sigma$  為激活函數 (activation function)，通常用非線性的函數做轉換。學習的方法是定義一個損失函數 (loss function) 量化深度神經網路預測值跟輸出向量間的差距，並藉由對損失函數做反向傳播演算法 (backpropagation) 以更新參數，作為深度神經網路的學習。

深度神經網路主要分為基於策略 (policy based) 和基於價值 (value based) 的方法。策略基礎方法以狀態為輸入，輸出各行動的機率，選擇最高機率的行動，稱為策略函數，但這種方法的訓練數據較難獲得，且更新網路不直接。價值基礎方法直接學習 Q 值，輸入狀態和行動，輸出對應的 Q 值，目標是用深度神經網路取代 Q 矩陣。

在深度 Q 學習訓練中，除了主要模型設計，還採用經驗重播 (experience replay) 技術。這個技術將經驗 (例如狀態、行動、獎勵和下一狀態) 儲存在記憶體中，並在訓練時隨機抽取這些經驗。這種隨機抽取方法有助於打破數據的時間相關性，減少獲得局部最優解的風險，同時允許使用舊資料進行訓練，而不需要頻繁獲取新資料。

另外也固定目標網路 (target network) 來處理偏差值，在訓練資料中的 Q 值使用 Temporal Difference (TD) 學習法，其計算為：

$$Q(s^t, \alpha^t) = r^t + \gamma(\max_{\alpha} Q(s^{t+1}, \alpha)), \alpha \in A$$

上式中  $s^t$  為環境狀態  $S = \{s_1, s_2, \dots, s_m, \dots\}$  且  $\alpha^t$  為潛在可採的行動  $A = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ ，並令第  $t$  個迭代下所選的行動  $\alpha^t$  在環境狀態為  $s^t$  下的報酬為  $r^t = R(s^t, \alpha^t)$ ，且會產生後續新的狀態  $s^{t+1} = s_{ij}^{t+1} \in S$ 。右邊的 Q 值就是由自身深度神經網路計算得出來的結果，其中， $\gamma$  是折扣因子 (discount factor)，表示未來獎勵的折扣率，通常介於 0 和 1 之間。但每次深度神經網路更新後會造成 Q 值學習

的不穩定，將上式拆解成訓練等號左邊價值函數的評估網絡（evaluation network），以及等號右邊最適反應的目標網絡（target network），並讓目標網絡經過固定一段時間再直接從評估網絡得到的深度神經網路函數關係來進行更新。此兩種方法用於訓練過程中，可使訓練更為穩定。

### 3.採用深度 Q 學習法的理由

在本實證上採用深度 Q 學習法的理由如下<sup>71</sup>：

- (1) 處理複雜狀態空間：實證資料的狀態通常是較為複雜而大量，要以神經網路的方式去學習 Q 函數，能有更快速有效的學習，是我們採取深度 Q 學習而非傳統 Q 學習的主因。
- (2) 強化學習的適用性：深度 Q 學習是一種強化學習方法，適用於需要通過反覆試驗和學習來最佳化策略的情境。電商平臺的定價策略就是一個典型的例子：廠商需要不斷調整價格來應對市場變化並最大化利潤。這些學習以最大化利潤為目標，可觀察電商單以利潤考量的定價行為。
- (3) 模型的靈活性和泛化能力：深度 Q 學習具有很強的靈活性和泛化能力，能夠適應不同類型的數據和多變的市場環境。這隱含我們可以在不同的商品和市場條件下應用同一套方法，並取得穩定的效果，這對於實證研究尤為重要。
- (4) 高效處理大量資料：實證資料往往數量龐大且更新頻繁。深度 Q 學習通過經驗回放和批量更新技術，能夠高效地利用大量歷史資料進行訓練，並快速適應新的資料變化，這使得在實證資料上保持高效的模型訓練和預測能力。

---

<sup>71</sup> 本文未採用在賽局模型更能顯示出競爭者互動策略的策略梯度法、Actor-Critic 或 AlphaGo Zero 的主要理由如下：(1)策略梯度法（policy gradient）如前所述，就是要直接學  $A(s)$  這個策略函數（policy function）。就因它需要直接學習策略，訓練資料準備不易，技巧上會運用大量的數據，以試著隨機或經設計初始策略來完成許多次回合（episodes），意即一段時間定價的過程。在我們的研究中，市場定價策略可能非常複雜，數據量不足，不易設計初始策略，因此我們選擇更為穩定的 Q 學習方法。(2) Actor-Critic 方法將策略和價值函數分開學習，確實可以加快收斂速度。然而，它比深度 Q 學習需要更多的超參數調整和更複雜的訓練過程，對於我們的實驗環境來說，訓練和調試的成本過高。(3) AlphaGo Zero 採用了自我對弈和蒙地卡羅樹搜尋（Monte Carlo tree search）等結合深度學習的方法，適合於超大型的策略空間。對於我們的定價問題來說，市場狀態和行動空間相對簡單，數據量不足，使用 AlphaGo Zero 會顯得過於複雜且計算成本過高。

綜上所述，深度 Q 學習法的特性使其成為在實證資料上應用的合適方法。我們相信該方法能夠幫助我們更準確地模擬和預測廠商的定價行為。

## （六）利用演算法進行模擬的相關文獻

以下文獻回顧近期的演算法定價研究，研究主要使用模擬數據和 Q 學習法演算法，多數採用 Cournot 或 Bertrand 競爭模型。研究聚焦於演算法應用、品質及其對競爭的影響。

Brown & MacKay<sup>72</sup>研究了美國五大電商在過敏藥品類別的定價，發現即使非聯合行為也可能導致價格超過 Bertrand 均衡。Calvano et al.<sup>73</sup>指出即使在不完善監測環境中，演算法也能學會聯合行為。Werner<sup>74</sup>探討了演算法在自我學習定價上的聯合行為效果，發現它可能削弱市場競爭，特別是在少數廠商使用時。Abada & Lambin<sup>75</sup>運用電力公司的交易資料探討默契合謀行為，發現演算法定價在沒有溝通的情況下，僅經由觀察價格即可快速形成類似勾結的結果。Xu et al.<sup>76</sup>檢驗不同的平臺的推薦系統，利潤導向抑或需求導向對市場結果的影響，並發現當廠商採取利潤導向系統時，會增加賣家利用演算法的合謀，而若是採取需求導向的推薦系統，則會增進市場競爭。這些研究皆呈現演算法定價對市場競爭結構的深遠影響。

Klein<sup>77</sup>研究了 Q 學習法在雙占、依序無限重複賽局設定下進行定價的結果，發現其可能導致勾結行為。Q 學習法會先降低價格賺取短期利潤，然後重啟價格至勾

<sup>72</sup> See Zach Y. Brown & Alexander MacKay, “Competition in Pricing Algorithms,” *15(2) American Economic Journal: Microeconomics*, 109-156 (2023).

<sup>73</sup> See Emilio Calvano, Giacomo Calzolari, Vincenzo Denicolò & Sergio Pastorello, “Algorithmic Collusion with Imperfect Monitoring,” *79 International Journal of Industrial Organization*, Article 102712 (2021).

<sup>74</sup> See Tobias Werner, “Algorithmic and Human Collusion,” *SSRN Paper* (2023), <https://ssrn.com/abstract=3960738>, last visited on date: 2024/9/4.

<sup>75</sup> See Ibrahim Abada & Xavier Lambin, “Artificial Intelligence: Can Seemingly Collusive Outcomes Be Avoided?,” *69(9) Management Science* (2023).

<sup>76</sup> See Xingchen (Cedric) Xu, Stephanie Lee & Yong Tan, “Algorithmic Collusion or Competition: The Role of Platforms’ Recommender Systems,” arXiv:2309.14548 (2023).

<sup>77</sup> See Timo Klein, “Autonomous Algorithmic Collusion: Q-Learning under Sequential Pricing,” *52(3) RAND Journal of Economics*, 538-558 (2021).

結水準，並最終將較高定價視為最佳策略。Asker et al.<sup>78</sup>探討了不同學習路徑的演算法對市場定價和競爭的影響。研究發現，在非同步更新下，價格高於 Nash 均衡，而同步更新則迅速趨向 Nash 均衡。Sanchez-Cartas & Katsamakas<sup>79</sup>分析了演算法定價對平臺競爭和均衡結果的影響。他們發現演算法能正確學習平臺的價格結構，Q 學習法在對稱情況下帶來的利潤高於粒子群最佳化（Particle Swarm Optimization）演算法，且存在兩個對稱均衡：採用 Q 學習法或 Price-Matching。其中，Price-Matching 為代理人帶來最高利潤，而不對稱的演算法配置可能導致較低的價格和利潤。Normann & Sternberg<sup>80</sup>研究在寡占市場中，演算法定價存在與否與市場價格變動的關係。結果顯示當市場上存在演算法時，競爭對手知道演算法的存在與否對於競爭沒有顯著的影響。此外，當有其中一家廠商使用演算法定價時，在市場上形成的勾結會提高所有廠商的利潤，然而其他未使用演算法之廠商的利潤則顯著高於使用演算法定價之廠商的利潤。Dou et al.<sup>81</sup>檢視 Q 學習法在各種演算法交易的模式下是否會促使廠商發生聯合行為。結果顯示在交易效率高且噪音風險很低的情況下，價格觸發策略會使 AI 投機者維持勾結並達到 Nash 均衡。Wang et al.<sup>82</sup>研究在給定對手使用 Q 學習法（Q）定價時，應選擇 Q 學習法還是簡單規則定價演算法（simple rule-based algorithm, R）與其競爭。結果發現在採用 Q-R 情境中，賣家的利潤比在雙方採用 Q-Q 中更高，且價格競爭趨緩、賣家福利提升。Hettich<sup>83</sup>利用深度 Q 學習法以模擬兩家到多家廠商採用演算法定價是否有默式聯合行為的可能，也發現若廠商數超過 10 家，聯合行為將會消失。隨著廠商數的增加，廠商的利潤會逐漸下降，甚至下降至 0。

<sup>78</sup> See John Asker, Chaim Fershtman & Ariel Pakes, “Artificial Intelligence, Algorithm Design, and Pricing,” *112 AEA Papers and Proceedings*, 452-456 (2022).

<sup>79</sup> See Juan M. Sanchez-Cartas & Evangelos Katsamakas, “AI Pricing Algorithms Under Platform Competition,” *SSRN Paper* (2024), <https://ssrn.com/abstract=4027365>, last visited on date: 2024/9/4.

<sup>80</sup> See Hans-Theo Normann & Martin Sternberg, “Human-Algorithm Interaction: Algorithmic Pricing in Hybrid Laboratory Markets,” *152 European Economic Review*, Article 104347 (2023).

<sup>81</sup> See Winston W. Dou, Itay Goldstein & Yan Ji, “AI-Powered Trading, Algorithmic Collusion, and Price Efficiency,” *Jacobs Levy Equity Management Center for Quantitative Financial Research Paper* (2024), <https://ssrn.com/abstract=4452704> or <http://dx.doi.org/10.2139/ssrn.4452704>, last visited on date: 2024/9/4.

<sup>82</sup> See Qiaochu Wang, Yan Huang, Param V. Singh & Kannan Srinivasan, “Algorithms, Artificial Intelligence and Simple Rule Based Pricing,” *SSRN Paper* (2023), <https://ssrn.com/abstract=4144905> or <http://dx.doi.org/10.2139/ssrn.4144905>, last visited on date: 2024/9/4.

<sup>83</sup> See Hettich, *supra* note 70.

從目前的演算法定價文獻來看，大多數實驗是基於模擬數據，尤其集中於雙占或最多三家廠商的競爭分析。這主要是由於演算法模擬設定的複雜性和計算負擔，使得結論難以在更複雜或更多廠商的情境下明確歸納。研究表明，即使市場中出現了演算法，價格或其他變數也不一定直接趨向壟斷性競爭。此外，從政策角度來看，最好是根據個案來評估反壟斷法對競爭的影響。未來的研究可能會發現，在更複雜的市場設定下，演算法定價的結果會更多樣化，對市場競爭的影響也更加不確定，因此這是一個值得持續研究的領域，以便了解競爭問題的脈絡並探索適當的政策工具。

### 三、我國電商演算法定價初探

在瞭解文獻上如何利用演算法進行相關定價模擬，以及辨識賣家是否採用演算法與瞭解常見的價格變化模式後，本章將利用我國電商平臺的價格資料進行初探。除了辨別我國電商平臺的廠商是否採用演算法定價，並瞭解目前所採用的模式。本章將先介紹資料來源、商品挑選、資料收集流程，並判斷平臺商品是否採用演算法調價的可能性。

#### （一）資料來源

良好的資料是研究演算法是否能促使默式聯合行為中不可或缺的要素。本研究將蒐集本國線上零售商的商品數據，並且挑選若干同質性商品作為主要檢測的對象，盡量縮短資料蒐集的間隔，以觀察價格在高頻數據中的變化情形。

本計畫以電腦商品與某一民生用品作為研究對象，以探究是否有利用 AI 修改價格的可能性以及是否能以 AI 定價達成隱性聯合行為的可能。本計畫先依商品之同質性高、規格是否統一並有可比較性、價格變動頻率高、價格真實與透明、資料數量龐大與易取得性作為選取的標準。兩者唯一的差別就是民生用品之價格變動頻率不如電腦相關設備商品，但仍有部分廠商在該日調價的前提下，進行一日 2 次以上的調價。

#### （二）資料蒐集流程

在 B 平臺與 C 平臺中，鎖定電腦商品一（搭配配件一型號 1 與配件二型號甲）、

某電子商品以及民生用品，先用 Python 爬蟲程式將近兩年所有時間與價格資料進行收集，並將爬下來的所有資料作資料篩選與處理後，以個別規格分類成各自的資料庫。資料原筆數分別為 88,138、52,221 以及 856 筆，使用其中的 2,989、366 以及 856 筆進行分析。

### （三）平臺商品調價與演算法調價的可能

由於商品繁多，我們僅針對部分調價較大的商品進行分析：包含 C 平臺的某電子商品、B 平臺 DIY 組裝電腦商品配件一型號 1 與配件二型號甲的組合。為與電腦商品進行比較，我們也考慮 B 平臺上的某民生商品價格，以凸顯演算法定價的特性。

#### 1. 某電子商品

某電子商品資料來自於 C 平臺，觀察 2022/07/04~2023/04/27 平臺上五家廠商的價格變動（如圖 1 所示），分析時排除價格完全沒有任何改變的廠商，另外也排除離群值的廠商。剩下的兩個有高度變動的廠商為黑色實線以及灰色虛線兩家廠商。




圖 1 某電子商品各廠價格走勢圖

資料來源：本研究自行整理。

價格調整可大致分為四個階段，階段一（2022/07/04~2022/07/26），在此期間灰虛線廠商為價格跟隨者，在價格變動中有 8 次調整在黑色廠商變動後 1 分鐘內進行，4 次 1 分鐘~2 分鐘之間，1 次 2 分鐘~3 分鐘之間；階段二（2022/07/27~2022/07/31）黑色廠商價格時間上變化短暫進入隨機的波動；階段三（2022/08~2023/03/16）灰虛線廠商仍為價格跟隨者，在價格變動中有 17 次調整在黑色廠商變動後 1 分鐘內進行，7 次 1 分鐘~2 分鐘之間，7 次 2 分鐘~4 分鐘之間，9 次 4 分鐘~10 分鐘之間；階段四（2023/03/17~2023/04/27）此時灰虛線廠商多數仍為價格跟隨者，有 5 次在 1 分鐘內跟著黑色廠商調價完成。

整體而言，該電子商品的價格波動模式較類似於區間跳動（或稱價格交替）。有較高的機率競爭廠商採用演算法定價，是因為價格的調整模式有兩個重要的特色：(1)兩家廠商會在同一時間將價格調到相同的定價，且之後調價時間幾乎一致，變動次數幾乎相同。(2)灰虛線廠商作為價格跟隨者，超過 20 次以上調價時間都在 1 分鐘內完成。

表 1 C 平臺某電子商品各階段調價次數

	1 分鐘內	1-2 分	2-3 分	2-4 分	4-10 分
階段一	8 次	4 次	1 次		
階段二	隨機波動				
階段三	17 次	7 次		7 次	9 次
階段四	5 次				

資料來源：本研究自行整理。

## 2. 電腦商品

電腦商品一販售於 B 平臺，配置是配件一型號 1 與配件二型號甲，觀察 2022/06/01~2023/02/28 市面上六家廠商如圖 2 所示。從圖形中價格的互動可明顯將資料分為高價組黑實線、黑虛線廠商和低價組深灰實線、深灰點線、深灰虛線廠商。以下將分別針對這兩組廠商互動進行分析。因低價組較無規律可循，且處於互為競爭的狀態，故主要探討高價組（黑實線、黑虛線）。

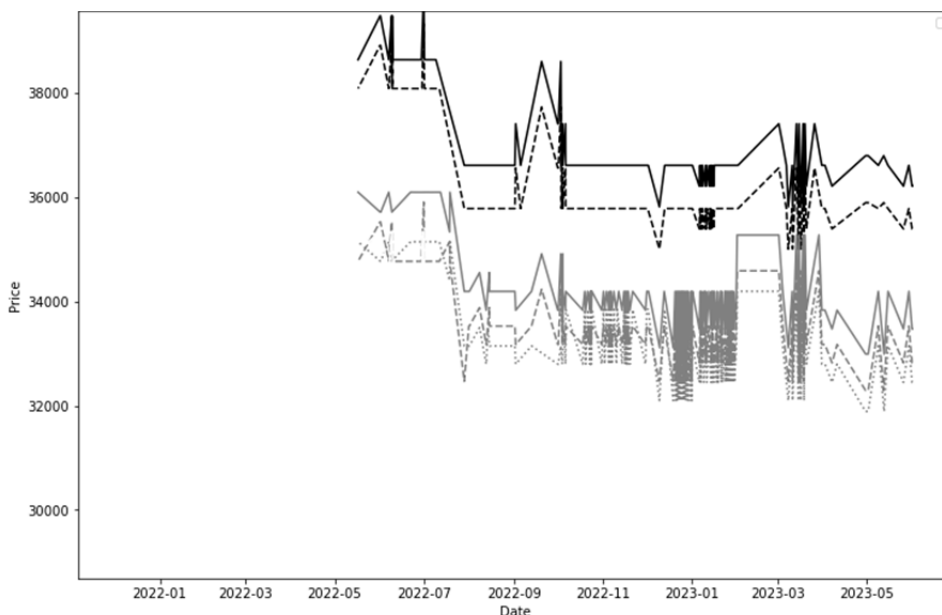


圖 2 電腦商品一各廠價格走勢圖

資料來源：本研究自行整理。

表 2 B 平臺某電子各階段調價次數

	1 分鐘內	1-2 分鐘	2-4 分鐘	其他
階段一	100% (8 次)			
階段二	100% (9 次)			
階段三	93.7% (15 次)	6.7% (1 次)		

資料來源：本研究自行整理。

整體而言，電腦商品一的價格波動模式較類似於區間跳動。有較高的機率競爭廠商採用演算法定價，是因為價格的調整模式有兩個重要的特色：(1)一般而言，調整價格不會 1 元、1 元反覆來回調價（階段二「相互試探」），因此推測廠商在此階段時，相互試探對方是否也使用演算法定價，且該階段高價廠商的調價時間皆在 1 分鐘內完成。(2)所有廠商都會在相同時間一同調整價格，廠商的平均調價時間和次數近乎一致。

另外一方面，由於觀察期間長達 1 年半，在觀察階段後期調價期間不像前期大幅變動，平均 3 天到 8 天調動一次價格的現象可能與實體通路或電子商務上下架行為有關，故可能後期係採用半人工、半演算法的價格調整方式。至於前期頻繁調價

是否為市場結構所造成，本研究認為若正好少數廠商有類似產品並以演算法進行價格跟隨，則這類的價格波動模式也較易出現。若廠商數太多，則模式可能更為混亂，若廠商數少但只有一家以演算法進行價格跟隨，則波動應不致如此頻繁。

### 3.某民生商品




圖 3 某民生商品價格走勢圖

資料來源：本研究自行整理。

最後，我們也挑選平臺上看似部分廠商使用演算法定價，但進行價格跟隨時又似乎採人工定價的某一民生商品，與前述電腦商品的定價模式進行比較。我們選定 B 平臺上的三家某一民生商品品牌進行分析，分別為黑點線、黑實線與黑虛線三家廠商，觀察時間為 2021/08/11~2023/08/12。值得注意的是，某一民生商品廠商對其產品販售的單位並不統一，無法以產品的售價進行分析，故在分析時先將價格進行標準化，以單位價格進行後續的討論，並將三家廠商各時期的價格詳繪於圖 3 中。值得注意的是，黑實線廠在所有某一民生商品品牌中，單位定價最高，且黑點線廠與黑虛線

廠會在黑實線廠調價後進行調價。另一方面，在調價行為上，黑點線廠與黑虛線廠之間並未觀察到一致性，故我們視黑實線廠為該類商品的領導廠商，而黑點線廠與黑虛線廠分別為黑實線廠的跟隨廠商，故分開探討黑實線廠和兩家廠商的情形。

從黑實線廠和黑點線廠兩家廠商調價模式來看，長期而言價格是以階梯形態逐漸進行調升，我們進一步以每階段價格大幅調升（超過 6%）為標準，可以將跟隨者黑點線廠的價格再細分為三個階段，分別為階段一「黑實線廠平均單位定價為 119.41 元，黑點線廠平均單位定價為 63.46 元」、階段二「黑實線廠平均單位定價為 124.77 元，黑點線廠平均單位定價為 67.45 元」、階段三「黑實線廠平均單位定價為 139.01 元，黑點線廠平均單位定價為 73.48 元」。

統計黑實線廠調價後，黑點線廠進行調價的次數為 108 次，其中黑點線廠在 0.24 天立刻跟隨調價的次數為 38 次（占全部跟隨次數的 35.19%）；黑點線廠在 0.24~1.2 天內立刻跟隨調價的次數為 6 次（5.56%）；黑點線廠在 1.2~2.4 天內立刻跟隨調價的次數為 5 次（4.6%）；黑點線廠在 2.4~3 天內立刻跟隨調價的次數為 2 次（1.85%）。而黑點線廠在黑實線廠調價後超過 3 天才調價為 58 次，占全部跟隨次數的 53.7%。也因此，我們則認為使用演算法進行調價的可能性較低。

其次，從黑實線廠與黑虛線廠兩家廠商調價模式來看，長期而言價格也是以階梯形態逐漸進行調升。仿照前述黑實線廠與黑點線廠的調價模式，我們將觀察時間內廠商的價格變動也分為三個階段，分別為階段一「黑實線廠平均單位定價為 120.35 元，黑虛線廠平均單位定價為 65.58 元」、階段二「黑實線廠平均單位定價為 126.37 元，黑虛線廠平均單位定價為 69.24 元」、階段三「黑實線廠平均單位定價為 139.82 元，黑虛線廠平均單位定價為 74.41 元」。統計黑實線廠調價後，黑虛線廠進行調價的次數為 142 次，其中黑虛線廠在 0.24 天立刻跟隨調價的次數為 28 次，占全部跟隨次數的 19.71%；黑虛線廠在 0.24~1.2 天內立刻跟隨調價的次數為 6 次（4.23%）；黑虛線廠在 1.2~2.4 天內立刻跟隨調價的次數為 8 次（5.63%）；黑虛線廠在 2.4~3 天內立刻跟隨調價的次數為 1 次（0.7%）。而黑虛線廠在黑實線廠調價後超過 3 天後調價為 99 次，占全部跟隨次數的 69.71%。我們則認為使用演算法進行調價的可能性較低。

我們觀察到黑點線廠與黑虛線廠會在黑實線廠調價後進行調價，但調價行為不見得在固定的某些時間發生，故黑點線廠與黑虛線廠的定價演算法是否自動偵測領導廠商的價格變化值得商榷；另一方面，黑點線廠與黑虛線廠未調整下的其他時間

也會改變售價，而且黑虛線廠若發生價格改變往往一天變動超過 2 次（其中有一次是在中午前後）。因此，該產品零售商定價模式更可能是以人工調整為主，或以半演算法半人工的形式來進行<sup>84</sup>。

根據 Assad et al.<sup>85</sup>我們發現電腦相關各個廠商的調價行為有價格跟隨的現象，當領導廠商價格發生改變後，跟隨廠商會在短時間內一同進行價格的調整，且調整的速度很快。但當有人率先破壞調價規律或有新廠商在此時加入市場，定價模式會因此改變。一般而言，廠商的定價都在同一區間內進行震動，價格波動模式較類似於區間跳動。綜上所述，我們認為電腦相關商品廠商有使用演算法調價的可能。但反之在民生商品上，價格變動的頻率大約最多每天在 2-3 次，這和文獻上<sup>86</sup>價格調整有更高頻的變動有著相當大的差異。故以我國目前的現況，若用一天內價格變化的次數或許不是理想的評斷方法。相反地，若以回應對手的價格變化所需的時間來進行觀察，或許可以提出更直接使用演算法定價的推測。此外，由於本研究觀察的價格樣本時間長達 1 年半，也發現不同商品的定價模式在不同時期可能有進行較大調整的現象，而可能採用半人工、半演算法的價格調整方式。

#### 四、利用演算法模擬市場定價

前一節中我們已經發現電商平臺上廠商定價採用演算法的可能性。在本章中，我們將使用我國電商平臺廠商販售電腦商品與民生商品的實際資料，進一步利用效能更強的深度 Q 學習模擬廠商定價，探究是否有達成聯合行為的可能，並比較實際定價的狀況。由於模擬需要設定相關市場結構與成本設算，且不同的設定也可能產生不同模擬結果，以下我們將介紹本研究中模擬的相關設定，並說明相關模擬結果。

##### （一）兩廠商下市場結構相關設定

為求概念上的釐清並為了利於後續模型的擴充，本研究現階段先考慮雙占市場多期競爭模型：假設市場上有兩家競爭廠商，於  $t = 1, \dots, T$  期進行競爭或聯合行

<sup>84</sup> 黑點線與黑虛線價格的相關係數為 0.722，黑實線與黑虛線價格的相關係數為 0.5846，黑實線與黑點線價格的相關係數為 0.5144。

<sup>85</sup> See Assad et al., *supra* note 8.

<sup>86</sup> See, e.g., *id.*; Wieting & Sapi, *supra* note 6.

為，其需求函數分別設定如下<sup>87</sup>：

$$Q_{1t} = a_1 - bp_{1t} + \gamma p_{2t} + \varepsilon_{1t}, \quad (1)$$

$$Q_{2t} = a_2 - bp_{2t} + \gamma p_{1t} + \varepsilon_{2t}, \quad (2)$$

其中參數  $(a_1, a_2, b, \gamma)$  為正且假設需求之不確定變動  $(\varepsilon_{1t}, \varepsilon_{2t})$  彼此獨立， $(a_1, a_2)$  為兩異質廠商的需求線截距項， $b$  為自身價格變動一單位對需求的影響， $\gamma$  為競爭商品價格變動一單位對需求的影響，在此，我們假設  $b$  與  $\gamma$  對兩廠商是對稱相同的。在給定共同成本  $c_t$  的條件下<sup>88</sup>，可解出未進行聯合行為的均衡價（Bertrand Nash）如下<sup>89</sup>：

$$p_{1t}^N = [(4b^2 - \gamma^2)]^{-1}[2ba_1 + a_2\gamma + b(2b + \gamma)c_t + 2b\varepsilon_{1t} + \gamma\varepsilon_{2t}], \quad (3)$$

$$p_{2t}^N = [(4b^2 - \gamma^2)]^{-1}[2ba_2 + a_1\gamma + b(2b + \gamma)c_t + 2b\varepsilon_{2t} + \gamma\varepsilon_{1t}]. \quad (4)$$

類似地，可解出進行聯合行為（Monopoly）的廠商均衡價格如下：

$$p_{1t}^N = [2(b^2 - \gamma^2)]^{-1}[ba_1 + a_2\gamma + (b^2 - \gamma^2)c_t + b\varepsilon_{1t} + \gamma\varepsilon_{2t}], \quad (5)$$

$$p_{2t}^N = [2(b^2 - \gamma^2)]^{-1}[ba_2 + a_1\gamma + (b^2 - \gamma^2)c_t + b\varepsilon_{2t} + \gamma\varepsilon_{1t}]. \quad (6)$$

<sup>87</sup> 值得注意的是，線性需求函數僅是其中一種特定的函數形式，Q 學習模擬本身並不受限於此函數形式，亦可採用常用的指數（exponential）型或其他函數形式。本研究採用線性需求函數，主要理由是為了簡化分析，但也可能與實際市場情況有所偏離。若放寬此假設而採用非線性需求函數（如對數或指數形式）可能導致均衡解更複雜，但也可能更貼近現實市場。然而是否如此，需要進一步的檢驗資料與建立模型，但這與本研究透過簡單模擬進行演示的目也有所偏離。此外，如果本研究納入需求的動態變化和季節性因素的考量，可能使模型更準確反映市場波動。放寬此假設雖可增進市場洞察，但會大幅提高均衡解的計算複雜度和分析成本。在權衡之下，我們選擇保持線性需求函數假設，以確保模型的可操作性和結果的可解釋性，但同時了解這可能限制了對某些複雜市場動態的捕捉。

<sup>88</sup> 在成本模型的假設上，若能獲得更精確的成本資料，模型預測可能更為準確，但目前本研究團隊無法取得更好的成本資料。

<sup>89</sup> 在競爭狀態假設的影響上，本研究假設特定的競爭模式（如 Bertrand-Nash 或下一小節中的領導與跟隨模式）。放寬此假設，並納入更多競爭模式（如 Cournot 競爭）可能產生更多樣化的均衡結果，並或能衡量結果是否更貼近市場現實。然而，這也會在現有的基礎上顯著增加模型的複雜度和計算負擔。同樣，考慮競爭狀態的動態變化和市場進入退出可能更準確反映實際市場動態，但也會大幅提高模型的複雜性和資料需求。權衡這些因素後，我們選擇保持當前的競爭模式假設，以在模型的可處理性和市場現實性之間取得平衡，同時承認這可能限制了某些市場變化的捕捉。

假設從  $t = 1, \dots, S < T$  廠商未採取聯合行為的競爭，給定  $t = 1, \dots, S$  的實際資料  $(p_{1t}, p_{2t}, c_t)$  並利用非線性最小平方法即可解出一組估計參數  $(\hat{a}_1, \hat{a}_2, \hat{b}, \hat{\gamma})$  讓樣本的均方誤最小：

$$MSE = \sum e_{1t}^2 + \sum e_{2t}^2, \quad (7)$$

其中  $e_{1t} = [(4b^2 - \gamma^2)]^{-1}[2b\varepsilon_{1t} + \gamma\varepsilon_{2t}]$  且  $e_{2t} = [(4b^2 - \gamma^2)]^{-1}[2b\varepsilon_{2t} + \gamma\varepsilon_{1t}]$ 。一旦得出  $(\hat{a}_1, \hat{a}_2, \hat{b}, \hat{\gamma})$  等估計值，即可獲得競爭價格與聯合行為價格，及在該價格下個別的需求量。據此需求量，廠商的利潤為  $\hat{\pi}_{jt} = \hat{Q}_{jt}(\hat{p}_{jt} - c_t), j = 1, 2$ 。值得注意的是，若模擬的結果一家的價格非常接近於勾結，另一家不接近，則  $\hat{\pi}_{jt}^S$  並不會很接近勾結，這是因為計算個別廠商需求量時，仍需要另一家廠商的價格。最後，為了衡量模擬下超競爭的程度<sup>90</sup>，我們計算

$$r_{jT} = T^{-1} \sum_{t=1}^T \frac{\hat{\pi}_{jt}^S - \hat{\pi}_{jt}^N}{\hat{\pi}_{jt}^M - \hat{\pi}_{jt}^N} \quad (8)$$

其中， $\hat{\pi}_{jt}^S$ 、 $\hat{\pi}_{jt}^M$  與  $\hat{\pi}_{jt}^N$  分別表示模擬、勾結 (Monopoly) 與競爭 (Nash) 下廠商  $j$  於時點  $t$  下的利潤。在我們的設定中， $r_{jT}$  為介於 0 到 1 的數值。若兩家廠商模擬的價格結果，和 Monopoly 都一樣，則該比例為 1，若模擬的價格結果和 Nash 都一樣，則該比例為 0。

## 1. 模擬使用的資料與成本設算估計

本研究進行模擬時所採用資料源於 B 平臺上販售的電腦商品一，其配置為配件一型號 2 與配件二型號甲。資料期間為 2022/01/01~2023/06/01，選擇以兩個時間長度較長的中價位廠商進行各樣的模擬分析。我們將 2023 年的新年後作為測試期間，這是因為該段期間的價格經歷了跟隨、躍升，再逐步降價的過程，可讓研究人員了解演算法定價於各階段的結果。此外，本研究將 2023 年新年前視為競爭期，因這段期間的價格先有一段期間滑落，之後平均價格趨於平穩但兩家廠商採取不同波動程度的價格跟隨。

<sup>90</sup> See Calvano et al., *supra* note 68 也有類似的衡量。因為實際資料中成本會變動，採用累加利潤會造成衡量失真，無法真實反映各期超競爭的程度。故先計算各期比值，再平均。

估計競爭與聯合行為的價格時需要進行成本估算。目前本研究主要採用最低價格成本法：由於高度競爭市場中利潤微薄，故取同類商品的最低價格為成本。為避免價格浮動過於劇烈或價格浮動次數不平均導致的估計困難，我們採用移動平均價格來計算最低成本。

## 2.執行方法

我們以此模擬模型為基礎，選取兩家廠商，過去一期的價格為輸入狀態，可採取的價格自聯合行為到競爭行為價格分為  $m = 5$  組進行模擬，並套用於真實資料觀察兩者的定價行為<sup>91</sup>。相較於 Calvano et al.<sup>92</sup> 假設邊際成本為固定，在真實資料上，我們將最低的廠商價格設為成本，也因此成本的估計值會隨著時間而波動，以這樣假設條件下的競爭價格以及聯合行為價格也會跟著成本一起變動；使用深度 Q 學習法解決 Q 矩陣過於巨大的問題時，我們將狀態直接定義於真實資料數據，行為設定則與使用 Q 學習模擬時相同，為使收斂較為穩定，選取  $m = 5$  為可採取行動範圍，後續階段的狀態則是根據自家模型的定價結果以及對家的真實價格，也就是  $s^{t+1} = (\alpha^t, p^{t+1})$  設定每 100 個期間 (epochs) 訓練完評估網絡 (evaluation network) 後，以評估網絡去更新目標網絡 (target network)。

在訓練資料方面，我們選取到 2022/12/31 以前的資料作為訓練資料，共 522 筆，並以最低成本法，用 Nash 模型推得出兩家廠的需求參數

$$\hat{b} = 1.237, \hat{\gamma} = 0.864, \hat{a}_1 = 17641.805, \hat{a}_2 = 17692.990.$$

在第一次實驗當中，我們分別對兩家廠商都各使用一個神經網路模型做深度 Q 學習訓練，各模型對自家的定價策略去做訓練模擬，兩個模型在訓練期間互不干涉，訓練資料並不包含任何對方廠商模型定價的結果，將對方實現的價格視為固定，作獨立訓練。在 2023/01/01 後為測試資料，僅用當天的價格為初始狀態，後續使用兩個模型的定價結果，不再使用真實資料，觀察兩個模型之間的定價策略。

<sup>91</sup> 本模擬中深度 Q 學習法的其他設定為：episode = 500, epoch = 100,  $\delta = 0.8$ ,  $\epsilon$ -greedy = 0.2。 $\delta$  指預測獎勵與實際獎勵的差異，機器在訓練模型時會藉此來調整模型的權重，使模型更精準； $\epsilon$ -greedy 是在 Q 學習法或深度 Q 學習法中，模型試圖學習一個價值函數（本文為廠商利潤），以預測在不同狀態下執行不同動作的價值。當進行決策時  $\epsilon$ -greedy 會進行隨機選擇當前被計算為最高價值的動作。

<sup>92</sup> See Calvano et al., *supra* note 68.

### 3. 模擬結果

以單一模型去同時訓練兩家廠商的定價策略，在訓練階段，依舊使用真實資料作為狀態輸入，但將下階段狀態的定義改為兩家廠商的價格皆由模型決定，亦即  $s_{t+1} = (\alpha_1^t, \alpha_2^t)$ ，讓訓練資料中包括對方模型定價的結果。在此設計下一個模型會有兩倍的訓練資料。訓練資料為 2022/12/31 以前的資料。並只使用 2023/01/01 的定價作為真實資料，之後的狀態皆由模型定價所決定。則可以發現，兩廠商一開始從競爭均衡價格出發，而後逐步調高，最後皆收斂於聯合行為價格，這樣的結果也與文獻上的模擬一致。此外，如圖 4 所示，到時間中期後，廠商一的模擬價格 Predict1（灰實線）與廠商二的模擬價格 Predict2（淺灰實線）重合。特別是後半期，兩廠商的模擬價格重合在 Monopoly（黑虛線）的價格上。整體而言，廠商一與廠商二之利潤率分別為 0.2901 與 0.2916。

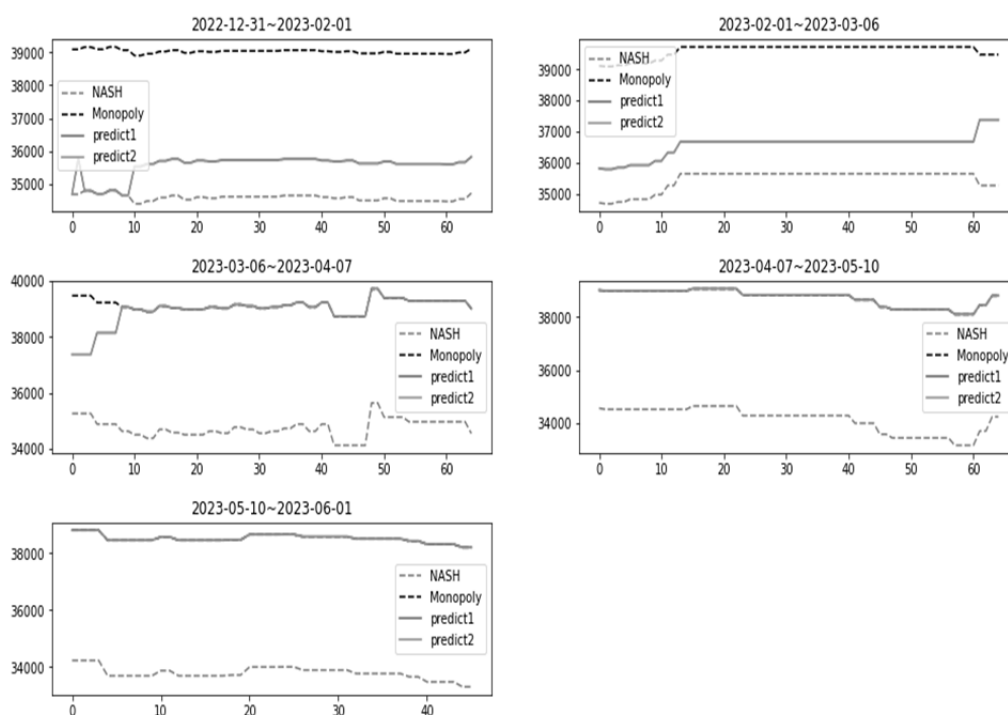


圖 4 單一模型兩家廠商在測試資料的結果<sup>93</sup>

資料來源：本研究自行整理。

<sup>93</sup> Predict1（灰實線）與 Predict2（淺灰實線）與 Monopoly（黑虛線）高度重合。

## (二) 三家廠商模擬結果（領導與跟隨模式）

其次，我們進一步考慮某一民生商品在平臺上的價格競爭，這類商品的特色是在市場上有一領導品牌。為方便模擬的展現，我們挑選包括領導品牌的三家廠商。資料期間選擇 2021/08/13~2023/08/12 的價格資料。對資料預處理的方式與先述小節的實驗內容相同，將時間單位統一為半天（12 小時），共有 1,460 筆資料；在成本方面則使用國際紙漿價格的月均價格作為本小節資料的成本價格，而以平均某單位的價格作為觀察值。

### 1. 模型設定

由於有三家廠商，我們假設各廠商的需求函數如下：

$$q_i = a_i - bp_i + \gamma \left( \sum_{j \neq i} p_j \right) + \varepsilon_i, \quad i, j = 1, 2, 3, \quad (9)$$

其中  $a_1, a_2, a_3$  均顯示不同產品間具有異質性， $b$  表示自身價格對需求的影響， $\gamma$  表示替代品價格對需求的影響， $\varepsilon_i$  為需求衝擊。根據前述需求函數，可以推導出以 Bertrand 為競爭模式的 Nash 均衡價格如下：

$$p_{1t}^N = \frac{1}{2(2b^2 - r^2)} [(2b - r)a_1 + (a_2 + a_3)r + b(2b + r)c_t + (2b - r)\varepsilon_{1t} + r(\varepsilon_{2t} + \varepsilon_{3t})], \quad (10)$$

$$p_{2t}^N = \frac{1}{2(2b^2 - r^2)} [(2b - r)a_2 + (a_1 + a_3)r + b(2b + r)c_t + (2b - r)\varepsilon_{2t} + r(\varepsilon_{1t} + \varepsilon_{3t})], \quad (11)$$

$$p_{3t}^N = \frac{1}{2(2b^2 - r^2)} [(2b - r)a_3 + (a_1 + a_2)r + b(2b + r)c_t + (2b - r)\varepsilon_{3t} + r(\varepsilon_{1t} + \varepsilon_{2t})]. \quad (12)$$

另，若三家廠商進行勾結，則此時 Monopoly 的均衡如下：

$$P_{1t}^M = \frac{1}{2(b^2 - 2r^2)} [(b - r)a_1 + (a_2 + a_3)r + (b(b - r) - 2r^2)c_t + (b - r)\varepsilon_{1t} + r(\varepsilon_{2t} + \varepsilon_{3t})], \quad (13)$$

$$P_{2t}^M = \frac{1}{2(b^2 - 2r^2)} [(b - r)a_2 + (a_1 + a_3)r + (b(b - r) - 2r^2)c_t + (b - r)\varepsilon_{2t} + r(\varepsilon_{1t} + \varepsilon_{3t})], \quad (14)$$

$$P_{3t}^M = \frac{1}{2(b^2 - 2r^2)} [(b - r)a_3 + (a_1 + a_2)r + (b(b - r) - 2r^2)c_t + (b - r)\varepsilon_{3t} + r(\varepsilon_{1t} + \varepsilon_{2t})]. \quad (15)$$

最後，若市場是採取領導與跟隨的競爭模式（Stackelberg 模型），則此時領導廠商（在我們的設定下是第三家廠商）的價格為：

$$p_{3t}^{LF} = \frac{(2b - r)(-\varepsilon_{3t} + c_t - a_3)}{2r + 2r^2 - 4b^2 + 2br} + \frac{4bc_t r - 2b(a_1 + \varepsilon_{3t})r + 2c_t r^2 - (\varepsilon_{2t} + a_1)r^2 - a_2(r + 2b)r - (2b + r)\varepsilon_{1t}r}{(2b + r)(2r + 2r^2 - 4b^2 + 2br)}, \quad (16)$$

而兩跟隨廠商的價格為：

$$p_{1t}^{LF} = \frac{-2bc_t + 2ba_1 - c_t r + \varepsilon_{2t} r + ra_2 + 2b\varepsilon_{1t}}{4b - r^2} + \frac{r^2 + 2br}{4b^2 - r^2} [p_{3t}^{LF}], \quad (17)$$

$$p_{2t}^{LF} = \frac{-2bc_t + 2ba_2 - c_t r + \varepsilon_{1t} r + a_1 r + 2b\varepsilon_{2t}}{4b^2 - r^2} + \frac{r^2 + 2br}{4b^2 - r^2} [p_{3t}^{LF}]. \quad (18)$$

我們利用市場結構的假設，估計相關參數，並在需求衝擊為 0 下估計 Monopoly · Nash 以及領導與跟隨等競爭模式下所對應的各廠商價格、對應的需求與利潤。

## 2. 估計結果

在此設定下，我們假設三家廠商中一家為領導者，另兩家為跟隨者<sup>94</sup>。得到的估計數值為

$$\hat{b} = 1.361, \hat{\gamma} = 0.263, \hat{a}_1 = 151.714, \hat{a}_2 = 148.489, \hat{a}_3 = 357.168.$$

很明顯可以發現領導廠商的個別需求  $\hat{a}_3$  遠大於其他兩個跟隨廠商，另兩個跟隨廠商的市場需求  $\hat{a}_1$  與  $\hat{a}_2$  較小且類似。使用此估計值算出來的 Leader-Follower 價格

<sup>94</sup> 我們曾考慮兩小廠（廠商 1 與廠商 2）的競爭係採前一小節兩家廠商的 Nash 模式，且假設領導廠（廠商 3）對這兩家廠商並無影響。但可發現兩廠商 Nash 均衡與 Monopoly 均衡價格線太過接近，在此狀況下兩廠商進行勾結的動機較低。其次考慮三家廠商以 Nash 競爭。然而，由估計值帶入後發現領導廠商 Monopoly 的價格小於自身的 Nash 價格，這隱含以三家廠商於前期同時進行 Nash 價格競爭的設定並不合理。

以及 Monopoly 價格結果如圖 5 所示。也因此，我們將以 Leader-Follower 作為基礎來衡量模擬下超競爭的程度

$$r_{jT} = T^{-1} \sum_{t=1}^T \frac{\dot{\pi}_{jt}^S - \dot{\pi}_{jt}^{LF}}{\dot{\pi}_{jt}^M - \dot{\pi}_{jt}^{LF}} \quad (19)$$

其中， $\dot{\pi}_{jt}^S$ 、 $\dot{\pi}_{jt}^M$  與  $\dot{\pi}_{jt}^{LF}$  分別表示模擬、勾結 (Monopoly) 與領導與跟隨下廠商  $j$  於時點  $t$  下的利潤。

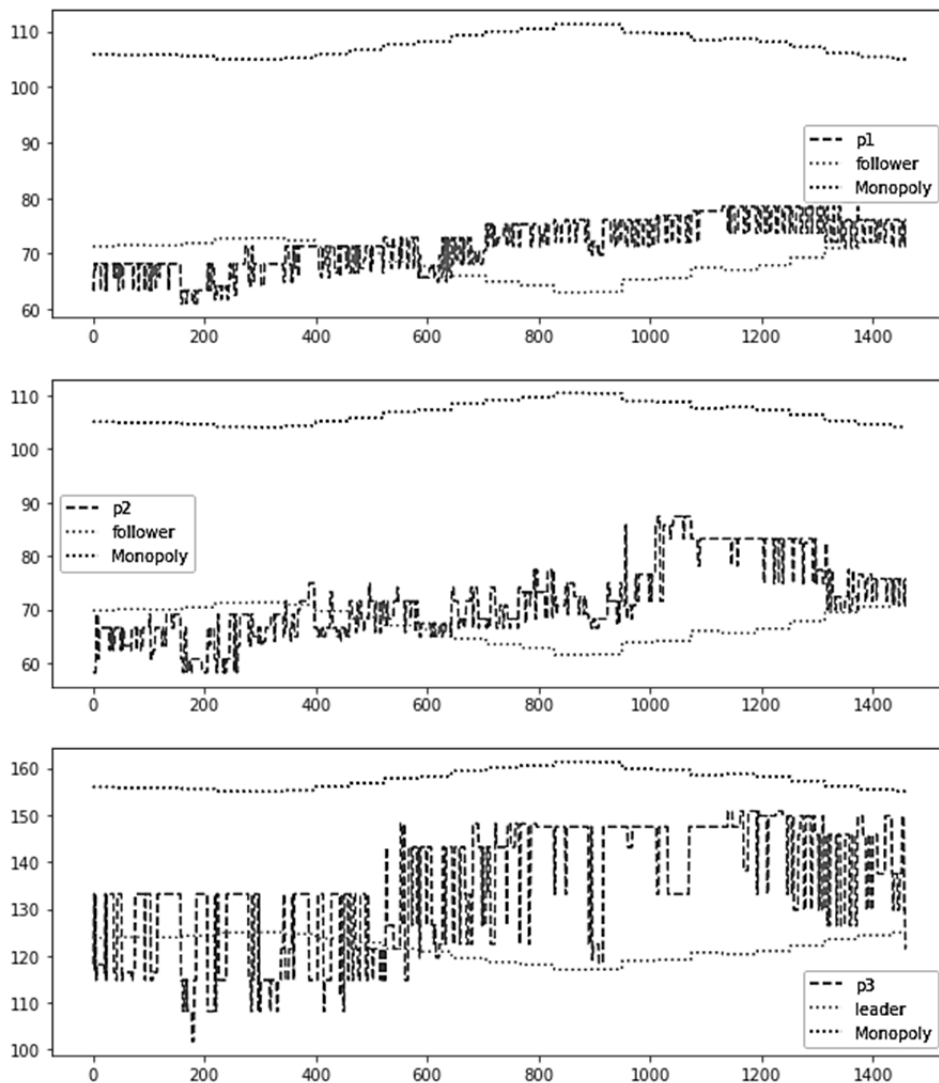


圖 5 三家廠商 Monopoly 和 Leader & Followers 價格圖表

資料來源：本研究自行整理。

### 3. 演算法學習與模擬的相關設定

在求出個別廠商的需求函數後，即可進行深度學習與模擬實驗。在此實驗中將下一階段狀態的三家廠商價格皆採用模型預測的行動，也就是  $s^{t+1} = (a_i^t, a_j^t, a_k^t), \{i, j, k\} = 1, 2, 3$ ，換句話說，就是不受限於真實資料，三家廠商可以預見並考量其他廠商也採取定價法下的最佳反應；此訓練方式就如同先前兩家廠商的實驗，訓練資料包含對方模型定價結果。

### 4. 模擬結果

我們考量將下一階段狀態的三家廠商價格以模型預測的行動來替代，也就是不受限於真實資料，三家廠商同時預見並考量其他廠商也採取定價法下的最佳反應。第二種實驗的訓練結果如圖 6。有趣的是，模型建議跟隨的兩家廠商採取更積極的行動。例如，第一家跟隨廠商可以定價在聯合行為（Monopoly）的價格，而第二家跟隨廠商（因需求較低）則考慮介於勾結價格與跟隨者價格之間。明顯地，這樣的定價模式都比原來跟隨者的定價模式為佳。領導廠商的定價，因第二家廠商並未選擇 Monopoly 價格，第三家廠商也仍保有市場領導廠牌的地位，故如同原先 Leader-Follower 的模型，深度 Q 學習預測仍定價於領導者的價格。此時，三家廠商之利潤率（以 Leader-Follower 模型為基準）分別為：0.6904（廠商一），0.7489（廠商二）與 0.2410（廠商三）。

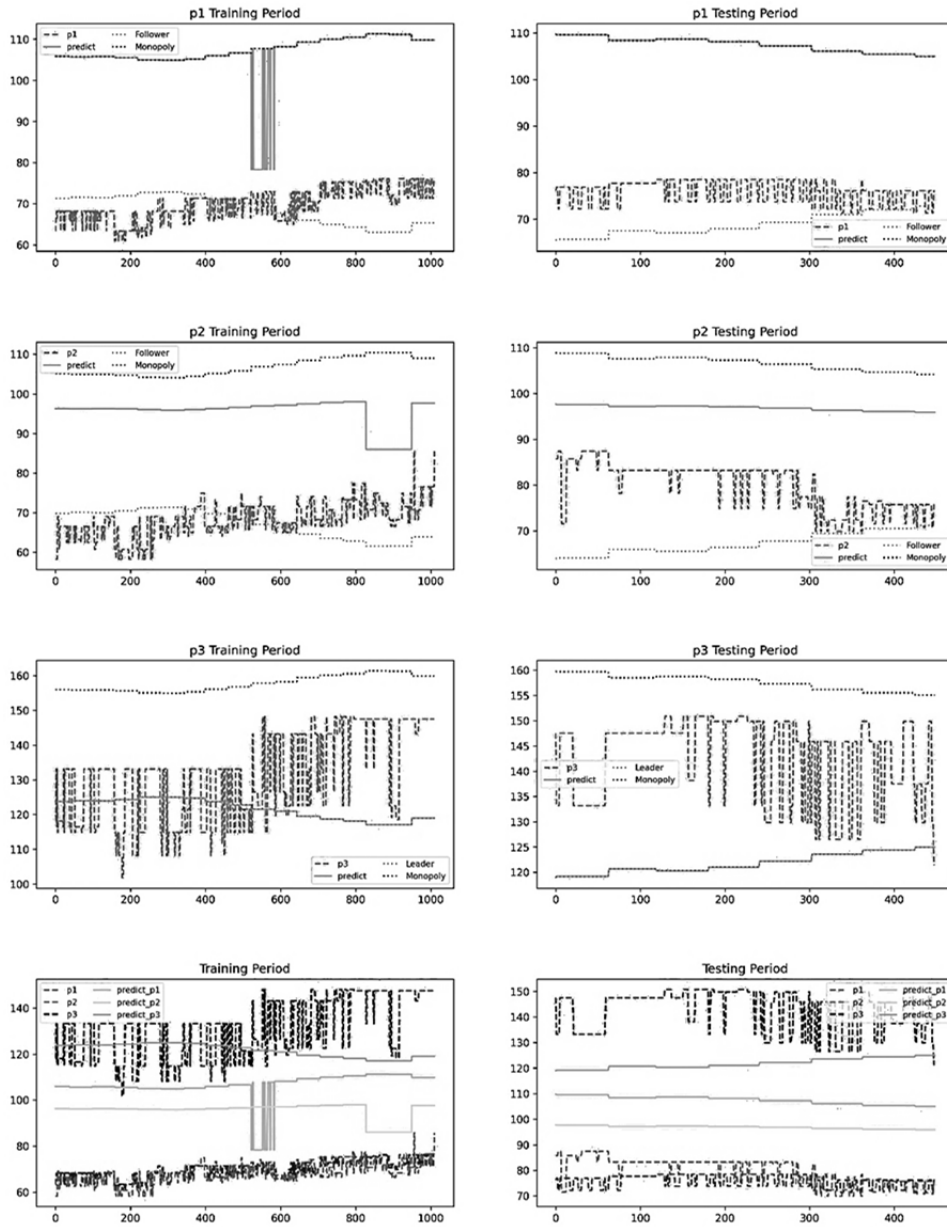


圖 6 Leader & Followers 公式下三家廠商同時考量模型預測之訓練和測試價格

資料來源：本研究自行整理。

### (三) 本節小結

在兩家廠商的狀態下，只由訓練期價格推出各廠商的需求曲線，並讓深度 Q 學習產生的價格相互進行訓練，則能像文獻產生接近於聯合行為之價格，也可以發現該特定方式的模擬價格與實際價格資料的不同。而在一大兩小廠商（共三家）的市場結構下，也發現若讓深度 Q 學習產生的價格策略納入彼此的考量以相互進行訓練，則其中一家跟隨廠商會建議採用產生聯合行為之價格，另一家則建議採用介於聯合行為與跟隨者的價格，領導廠商仍採取原模型領導地位的價格。前述的實驗模擬也呼應文獻中在不同的模型與情境設定，會導致不同的結果，但也有機會收斂於聯合行為價格。故在結論上本研究也傾向 Sanchez-Cartas & Katsamakas<sup>95</sup>所指出不同的演算法會導致不同的結果，因此如果要設置管制演算法定價的規定，也不該一視同仁設定通用的管制規定，而應該逐案處理。

在本研究中，我們的模擬結果受限於需求函數形式、競爭狀態的假設以及成本和資料估計值。要獲得穩定的均衡解，通常需要滿足以下條件<sup>96</sup>：(1)需求函數的正確性：需求函數需要準確反映市場實際情況。如果需求函數形式過於簡化或不符合實際市場動態，均衡解將不穩定。因此，選擇適當的需求函數形式並進行充分驗證是必要的。(2)競爭狀態的假設合理性：競爭狀態的假設應該貼近現實。例如，在寡占市場中，我們假設市場上僅有少數幾個主要競爭者，這樣的假設有助於模擬出更接近實際的均衡結果。如果假設的市場結構與實際情況差異過大，模擬結果將難以穩定。(3)可靠的成本和資料估計：準確的成本估算和真實的市場數據是模擬成功的基礎。數據的準確性和完整性直接影響模型的訓練和預測精度。如果數據存在偏差或不完整，均衡解的穩定性將受到影響。但本模擬結果有諸多的限制，例如：須假設需求函數的形式（如本計畫是採線性的），需求也沒有結構改變，並假設資料前期廠商所處的競爭狀態（如兩個廠商是 Bertrand-Nash，三個廠商是 Leader-Follower 模型）。其次，本研究沒有辦法取得適合的資料來估計生產成本（這也是大部分有關研究所面臨的困境），因此必須經過假設而得到廠商成本。最後，本節模擬主要是呈現在沒有合意下單使用演算法定價亦會產生默式聯合行為的可能。但仍需檢驗前述模擬所假設的條件與成本是否都符合現況，才能認定對市場效率似無妨害。

<sup>95</sup> See Sanchez-Cartas & Katsamakas, *supra* note 69.

<sup>96</sup> 亦請見前揭註 87、88 與 89 的討論。

## 五、結論

本研究為國內第一篇利用電商平臺真實資料，以效能更強的深度 Q 學習法模擬廠商定價來執行 AIA 模擬技術的論文，旨在了解人工智慧演算法對數位零售市場定價的影響。為此，本研究彙整了與演算法定價相關的理論與實證性文獻，參考其中的模擬估計結果，並配合 Python 爬蟲程式蒐集實際的資料後應用於機器學習程式，整合出一套檢視事業（特別是線上零售商）涉及演算法聯合行為之初步篩選步驟：(1) 辨識商品的賣家是否採用演算法定價的方法或商品在市場中價格模式、(2) 商品賣家採用演算法定價的情況與市場銷售價格的關聯，以及(3) 利用模擬探究可能結果。並以臺灣電腦與民生商品價格初步探索演算法定價。整體而言，所選電腦相關商品廠商有使用演算法定價的可能。但電腦商品和民生商品價格變動頻率最多大約每天 2-3 次，與歐美文獻中<sup>97</sup>高頻率變動的情況不同。因此，若以回應對手價格變動所需時間觀察，可能更適合推斷演算法定價。此外，觀察價格樣本長達 1 年半，發現不同商品的定價模式可能在不同時期有較大的調整，故也可能使用半人工、半演算法的價格調整方式。在模擬上，我們也發現未經合意下單使用演算法定價仍有產生默契聯合行為的可能。但在市場結構為一大兩小廠商（共三家）的情境下，未必全部形成聯合行為價格，且受市場結構影響。實驗模擬呼應文獻中指出不同模型和情境設定導致不同結果，但有機會趨向聯合行為價格。

根據目前研究結果，我們發現廠商有超競爭定價（價格超過邊際成本）。雖然本研究在資料取得方面面臨一定的限制，但我們利用模擬和分析方法，探索市場定價的潛在機制，為市場監管提供可參考的做法。由於本研究沒有辦法取得適合的資料估計生產成本（這也是大部分有關研究所面臨的困境），必須經過假設而得到廠商成本，因此在衡量「有礙市場效率的程度」時產生偏誤。其次，根據陳和全<sup>98</sup>之論文，廠商對於市場訊息有所掌握，輔之以對於競爭對手行為的預測，即使是在競爭市場下也很可能得出超競爭價格的結果。所以，就「定價樣態是否可能有礙市場效率」而言，競爭價格本身並不是一個適當的比較指標（benchmark），而必須找一個

<sup>97</sup> See, e.g., Assad et al., *supra* note 8; Wieting & Sapi, *supra* note 6.

<sup>98</sup> 陳和全，「演算法超競爭價格與合謀之關聯——經濟學分析途徑」，AI 元宇宙與競爭法學術研討會，台灣公平交易法學會（2023）。

新的競爭價格外且能代表效率配置的價格，否則無法有效說明現有的價格偏離效率價格的程度。

本研究的貢獻在於對線上零售商（包括電腦商品與某民生物品）的價格蒐集、價格變動模式與演算法定價的常見模式進行初步分析。雖無法探究零售商的實際定價模式，但可通過模擬或實證方法，研究「非契約、非協議或非其他方式之合意」下的可能定價模式及其與法定聯合行為下定價模式的偏離。實驗模擬結果顯示不同模型和情境設定會導致不同結果，有時會收斂於聯合行為價格。儘管存在模擬結果上的差異，我們的研究證實某些演算法在特定條件下可能推動價格上升，這對政策制定和市場監管提供明確的警示。本研究支持 Sanchez-Cartas & Katsamakos<sup>99</sup>的觀點，即不同演算法導致不同結果，建議管制演算法定價的規定應逐案處理。我們建議，未來的政策制定應充分考慮演算法定價對市場競爭的不同影響，並因應不同情境靈活調整監管方式。此外，演算法定價本質上是輔助默式聯合行為的工具，但本研究的偵測步驟與操作流程未涉及人類代理人的存在（亦即 Ezrachi & Stucke<sup>100</sup>中所指之信使情境），因此只能間接推定演算法定價是否具有聯合行為嫌疑。如果價格趨勢上升且影響消費者權益和經濟效率，即便未明確發現廠商合意，仍應提醒執法單位檢視廠商間可能存在的聯合行為。

我們的研究方法在需求函數的準確性、合理的競爭狀態假設以及可靠的成本和數據估計等條件滿足的情況下可以獲得穩定的均衡解。針對資源有限的競爭主管機關，本文在研究方法上有以下的政策意涵：(1)強化資料收集與分析能力：競爭主管機關宜投資於資料收集和分析技術，以提高對市場動態的監控能力。通過建立高效的資料收集系統，能夠實時監測市場價格變動，從而及時發現潛在的聯合行為。特別是針對具高度聯合行為嫌疑的電商，競爭法主管機關可逐步收集相關成本資訊，利用公開價格資料，分析價格競爭模式，並以實際商品價格為基礎，模擬廠商間價格是否有達成默式聯合行為的可能。但仍須謹慎評估價格變動是否真能反映默示聯合行為的可能性，而非單純的市場波動。(2)優先使用簡單且有效的分析工具：在資源有限的情況下，競爭主管機關可以優先使用如深度 Q 學習等計算效率較高且能有效捕捉市場行為的工具，這些工具在監控和分析市場競爭行為方面具有很大的潛力。建置深度 Q 學習的模型，相對的資源需求並不高，是很適合的工具，但其應用

<sup>99</sup> See Sanchez-Cartas & Katsamakos, *supra* note 69.

<sup>100</sup> See Ezrachi & Stucke, *supra* note 3.

結果應結合更多證據進行審慎解讀，避免過度依賴單一工具來判斷廠商間的行為是否構成聯合行為。(3)政策制定基於實證資料：本研究所提出的方法能為政策制定提供實證資料支持，協助競爭主管機關在市場監管中作出更加精準和有效的決策，雖然尚無明確證據顯示廠商存在聯合行為或演算法操縱的確切結論，但透過資料驅動的分析可以更有效地評估市場行為，並為政策制定提供依據，從而促進市場公平競爭。亦值得注意的是，前述的模擬雖然在需求函數、競爭模式與成本設算上採用特定的假設，而放寬上述假設也可能影響部分政策建議。但核心建議仍然有效，例如：強化資料收集與分析能力的建議在任何情況下都是必要的；逐案處理的建議在更複雜的市場環境中更為重要。

就本研究的實際發現上亦有以下的建議事項：(1)不同情境下即使相同演算法也會導致不同結果，因此在管制演算法定價上應逐案處理。特別是演算法定價是默式聯合行為的輔助工具，但無法直接偵測定價過程是否有主導的人類代理人。(2)若觀察到價格變動呈現 Edgeworth 循環，尤其谷底維持時間較短時，可能與演算法價格重置有關，此時需警惕此循環導致價格上升可能損害消費者權益和經濟效率。

## 參考文獻

### 中文部分

陳和全，「演算法超競爭價格與合謀之關聯——經濟學分析途徑」，AI 元宇宙與競爭法學術研討會，台灣公平交易法學會（2023）。

### 外文部分

Abada, Ibrahim & Lambin, Xavier, “Artificial Intelligence: Can Seemingly Collusive Outcomes Be Avoided?,” *69(9) Management Science* (2023).

Abrardi, Laura, Cambini, Carlo & Rondi, Laura, “Artificial Intelligence, Firms and Consumer Behavior: A Survey,” *36(4) Journal of Economic Surveys* (2022).

Abreu, Dilip, “Extremal Equilibria of Oligopolistic Supergames,” *39(1) Journal of Economic Theory* (1986).

Abreu, Dilip, Pearce, David & Stacchetti, Ennio, “Optimal Cartel Equilibria with Imperfect Monitoring,” *39(1) Journal of Economic Theory* (1986).

Agrawal, Ajay, Gans, Joshua & Goldfarb, Avi, “Economic Policy for Artificial Intelligence,” *19(1) Innovation Policy and the Economy* (2019).

Alé-Chilet, Jorge & Atal, Juan P., “Trade Associations and Collusion among Many Agents: Evidence from Physicians,” *51(4) RAND Journal of Economics* (2020).

Aryal, Gaurab, Ciliberto, Federico & Leyden, Benjamin T., “Coordinated Capacity Reductions and Public Communication in the Airline Industry,” *89(6) Review of Economic Studies* (2022).

Asker, John, Fershtman, Chaim & Pakes, Ariel, “Artificial Intelligence, Algorithm Design, and Pricing,” *112 AEA Papers and Proceedings* (2022).

Assad, Stephanie, Clark, Robert, Ershov, Daniel & Xu, Lei, “Algorithmic Pricing and Competition: Empirical Evidence from the German Retail Gasoline Market,” *8521 CESifo Working Paper* (2020).

- Bagwell, Kyle & Staiger, Robert W., "Collusion over the Business Cycle," 28(1) RAND Journal of Economics (1997).
- Bain, Joe S., Industrial Organization, 2nd ed., John Wiley & Sons (1968).
- Bertomeu, Jeremy, Evans, John H. III, Feng, Mei & Tseng, Ayung, "Tacit Collusion and Voluntary Disclosure: Theory and Evidence from the U.S. Automotive Industry," 67(3) Management Science (2021).
- Bourveau, Thomas, She, Guoman & Žaldokas, Alminas, "Corporate Disclosure as a Tacit Coordination Mechanism: Evidence from Cartel Enforcement Regulations," 58(2) Journal of Accounting Research (2020).
- Brock, William A. & Scheinkman, José A., "Price Setting Supergames with Capacity Constraints," 52(3) Review of Economic Studies (1985).
- Brown, Zach Y. & MacKay, Alexander, "Competition in Pricing Algorithms," 15(2) American Economic Journal: Microeconomics (2023).
- Byrne, David P. & de Roos, Nicolas, "Learning to Coordinate: A Study in Retail Gasoline," 109(2) American Economic Review (2019).
- Calder-Wang, Sophie & Kim, Gi Heung, "Algorithmic Pricing in Multifamily Rentals: Efficiency Gains or Price Coordination?," SSRN Paper (2024), <https://ssrn.com/abstract=4403058>.
- Calvano, Emilio, Calzolari, Giacomo, Denicolò, Vincenzo & Pastorello, Sergio, "Artificial Intelligence, Algorithmic Pricing, and Collusion," 110(10) American Economic Review (2020).
- Calvano, Emilio, Calzolari, Giacomo, Denicolò, Vincenzo & Pastorello, Sergio, "Algorithmic Collusion with Imperfect Monitoring," 79 International Journal of Industrial Organization (2021).
- Chilet, Jorge A., "Gradually Rebuilding a Relationship: The Emergence of Collusion in Retail Pharmacies in Chile," Working Paper (2017).
- Ciliberto, Federico, Watkins, Eddie & Williams, Jonathan W., "Collusive Pricing Patterns in the US Airline Industry," 62 International Journal of Industrial Organization (2019).

- Ciliberto, Federico & Williams, Jonathan W., “Does Multimarket Contact Facilitate Tacit Collusion? Inference on Conduct Parameters in the Airline Industry,” *45(4) RAND Journal of Economics* (2014).
- Crémer, Jacques, de Montjoye, Yves-Alexandre & Schweitzer, Heike, *Competition Policy for the Digital Era: Final Report*, Publications Office of the European Union (2019).
- Cruz-García, Paula, de Guevara, Juan F. & Maudos, Joaquín, “Bank Competition and Multimarket Contact Intensity,” *113 Journal of International Money and Finance* (2021).
- Dou, Winston W., Goldstein, Itay & Ji, Yan, “AI-Powered Trading, Algorithmic Collusion, and Price Efficiency,” *Jacobs Levy Equity Management Center for Quantitative Financial Research Paper* (2024), <https://ssrn.com/abstract=4452704> or <http://dx.doi.org/10.2139/ssrn.4452704>.
- Eisfeld, Thomas, “Unite and Conquer: Seller Collusion in Multi-Sided Markets,” *Working Paper* (2023), [https://congresscreator.org/system/files/papers/UniteConquer\\_Eisfeld\\_0.pdf](https://congresscreator.org/system/files/papers/UniteConquer_Eisfeld_0.pdf).
- Ely, Jeffrey C. & Välimäki, Juuso, “A Robust Folk Theorem for the Prisoner’s Dilemma,” *102(1) Journal of Economic Theory* (2002).
- Friedman, Milton, “Nobel Lecture: Inflation and Unemployment,” *85(3) Journal of Political Economy* (1977).
- Fudenberg, Drew, Levine, David & Maskin, Eric, “The Folk Theorem with Imperfect Public Information,” *62(5) Econometrica* (1994).
- Fudenberg, Drew & Maskin Eric, “The Folk Theorem in Repeated Games with Discounting or with Incomplete Information,” *54(3) Econometrica* (1986).
- Garrod, Luke & Olczak, Matthew, “Explicit vs Tacit Collusion: The Effects of Firm Numbers and Asymmetries,” *56 International Journal of Industrial Organization* (2018).
- Green, Edward J., Marshall, Robert C. & Marx, Leslie M., “Tacit Collusion in Oligopoly,” in: Blair, Roger D. & Sokol, D. Daniel (eds.), *2 The Oxford Handbook of International Antitrust Economics*, 1st ed., Oxford University Press (2014).

- Green, Edward J. & Porter, Robert H., “Noncooperative Collusion under Imperfect Price Information,” *52(1) Econometrica* (1984).
- Harrington, Joseph E. Jr., “A Theory of Tacit Collusion,” *588 The Johns Hopkins University, Department of Economics Working Paper* (2012).
- Hettich, Matthias, “Algorithmic Collusion: Insights from Deep Learning,” *SSRN Paper* (2021), <https://ssrn.com/abstract=3785966>.
- Igami, Mitsuru & Sugaya, Takuo, “Measuring the Incentive to Collude: The Vitamin Cartels, 1990-99,” *89(3) Review of Economic Studies* (2022).
- Ivaldi, Marc, Jullien, Bruno, Rey, Patrick, Seabright, Paul & Tirole, Jean, “The Economics of Tacit Collusion,” *186 IDEI Working Paper* (2003).
- Kandori, Michihiro, “Weakly Belief-Free Equilibria in Repeated Games with Private Monitoring,” *79(3) Econometrica* (2011).
- Klein, Timo, “Autonomous Algorithmic Collusion: Q-Learning under Sequential Pricing,” *52(3) RAND Journal of Economics* (2021).
- Koirala, Pravesh & Laine, Forrest, “Algorithmic Collusion in a Two-sided Market: A Rideshare Example,” arXiv:2405.02835 (2024).
- Lambson, Val E., “Some Results on Optimal Penal Codes in Asymmetric Bertrand Supergames,” *62(2) Journal of Economic Theory* (1994).
- Lin, Haizhen & McCarthy, Ian M., “Multimarket Contact in Health Insurance: Evidence from Medicare Advantage,” *24486 NBER Working Paper* (2018).
- Mailath, George J. & Samuelson, Larry, *Repeated Games and Reputations: Long-run Relationships*, 1st ed., Oxford University Press (2006).
- Marshall, Robert C. & Marx, Leslie M., *The Economics of Collusion: Cartels and Bidding Rings*, 1st ed., MIT Press (2012).
- Matsushima, Hitoshi, “Repeated Games with Private Monitoring: Two Players,” *72(3) Econometrica* (2004).
- Milgrom, Paul R. & Tadelis, Steven, “How Artificial Intelligence and Machine Learning Can Impact Market Design,” in: Agrawal, Ajay, Gans, Joshua & Goldfarb, Avi (eds.), *The Economics of Artificial Intelligence: An Agenda*, 1st ed., University of Chicago Press (2019).

- Miller, Nathan H., Sheu, Gloria & Weinberg, Matthew C., “Oligopolistic Price Leadership and Mergers: The United States Beer Industry,” *111(10) American Economic Review* (2021).
- Musolff, Leon, “Algorithmic Pricing Facilitates Tacit Collusion: Evidence from E-commerce,” in: Association for Computing Machinery, *EC '22: Proceedings of the 23rd ACM Conference on Economics and Computation*, 1st ed., Association for Computing Machinery (2022).
- Normann, Hans-Theo & Sternberg, Martin, “Human-Algorithm Interaction: Algorithmic Pricing in Hybrid Laboratory Markets,” *152 European Economic Review* (2023).
- Pawliczek, Andrea, Skinner, A. Nicole & Zechman, Sarah L. C., “Facilitating Tacit Collusion through Voluntary Disclosure: Evidence from Common Ownership,” *60(5) Journal of Accounting Research* (2022).
- Piccione, Michele, “The Repeated Prisoner’s Dilemma with Imperfect Private Monitoring,” *102(1) Journal of Economic Theory* (2002).
- Porter, Robert H., “Mergers and Coordinated Effects,” *73 International Journal of Industrial Organization* (2020).
- Radner, Roy, “Repeated Partnership Games with Imperfect Monitoring and No Discounting,” *53(1) The Review of Economic Studies* (1986).
- Sanchez-Cartas, Juan M. & Katsamakos, Evangelos, “Artificial Intelligence, Algorithmic Competition and Market Structures,” *10 IEEE Access* (2022).
- Sanchez-Cartas, Juan M. & Katsamakos, Evangelos, “AI Pricing Algorithms Under Platform Competition,” *SSRN Paper* (2024), <https://ssrn.com/abstract=4027365>.
- Schelling, Thomas C., *The Strategy of Conflict*, 1st ed., Harvard University Press (1960).
- Scherer, Frederic M., *Industrial Market Structure and Economic Performance*, 1st ed., Houghton Mifflin Company (1970).
- Schmitt, Matt, “Multimarket Contact in the Hospital Industry,” *10(3) American Economic Journal: Economic Policy* (2018).
- Stigler, George J., “A Theory of Oligopoly,” *72(1) Journal of Political Economy* (1964).
- Sugaya, Takuo, “Folk Theorem in Repeated Games with Private Monitoring,” *89(4) Review of Economic Studies* (2022).

- Varian, Hal, “Artificial Intelligence, Economics, and Industrial Organization,” in: Agrawal, Ajay, Gans, Joshua & Goldfarb, Avi (eds.), *The Economics of Artificial Intelligence: An Agenda*, 1st ed., University of Chicago Press (2019).
- Wang, Qiaochu, Huang, Yan, Singh, Param V. & Srinivasan, Kannan, “Algorithms, Artificial Intelligence and Simple Rule Based Pricing,” *SSRN Paper* (2023), <https://ssrn.com/abstract=4144905> or <http://dx.doi.org/10.2139/ssrn.4144905>.
- Werner, Tobias, “Algorithmic and Human Collusion,” *SSRN Paper* (2023), <https://ssrn.com/abstract=3960738>.
- Wieting, Marcel & Sapi, Geza, “Algorithms in the Marketplace: An Empirical Analysis of Automated Pricing in E-Commerce,” *21-06 NET Institute Working Paper* (2022).
- Xu, Xingchen (Cedric), Lee, Stephanie & Tan, Yong, “Algorithmic Collusion or Competition: The Role of Platforms’ Recommender Systems,” arXiv:2309.14548 (2023).
- Yamamoto, Yuichi, “Characterizing Belief-Free Review-Strategy Equilibrium Payoffs under Conditional Independence,” *147(5) Journal of Economic Theory* (2012).

**An Empirical Analysis of Collusive Behaviors in Pricing Strategies  
in the Digital Economy**

Lin, Chang-Ching\*

Hu, Wei-Min

Tsai, Yen-Lung

Wu, Li-Wen

Huang, Chien-Tang

Lin, Yu-Che

**Abstract**

This study consolidates the literature on algorithmic pricing and, by using a web crawler program, collects real data applied to machine learning programs. It integrates a preliminary screening process to examine potential algorithmic collusion among online retailers. Our literature review explores the link between algorithmic pricing and tacit collusion, examining sellers' adoption of algorithmic pricing methods, their correlation with market prices, and the types of algorithms used. We explore algorithmic pricing in the initial investigation of computer and consumer good prices in Taiwan. While there is a possibility that computer-related product retailers use algorithmic pricing, the frequency of price changes is approximately 2-3 times a day. Therefore, observing the time required to respond to competitors' price changes may be more suitable for inferring whether Taiwanese online retailers adopt algorithmic pricing. In addition, observing price samples over a period of 1.5 years reveals that pricing models for different products may undergo significant adjustments at different times, suggesting a semi-automated pricing adjustment

---

Date submitted: January 21, 2024

Date accepted: October 1, 2024

\* Lin, Chang-Ching is a professor in the Department of Economics at National Cheng Kung University; Hu, Wei-Min is a professor in the Department of Finance at National Chengchi University; Tsai, Yen-Lung is an associate professor in the Department of Applied Mathematics at National Chengchi University; Wu, Li-Wen is a master's student in the Department of Finance at National Chengchi University; Huang, Chien-Tang is a graduate of the master's program in the Department of Applied Mathematics at National Chengchi University; Lin, Yu-Che is a research assistant at InterServ International Inc. Corresponding author: Lin, Chang-Ching, e-mail: [ever@mail.ncku.edu.tw](mailto:ever@mail.ncku.edu.tw). Department of Economics, National Cheng Kung University, No.1 University Road, Tainan City, Taiwan.

method. We use actual data and employ deep Q-learning to simulate firm pricing. In a scenario with two online retailers selling computers, we find that algorithmic pricing without explicit agreement may still result in the possibility of tacit collusion, even though the two retailers are actually in a competitive situation. However, in a market structure with one large and two small online retailers selling a certain consumer good under different brands, where the small retailers follow the dominant retailers, simulated prices may not entirely reflect collusive behavior. The experimental simulations are aligned with the literature, emphasizing that different models and contextual settings lead to diverse outcomes. Based on these findings, we also provide policy recommendations for competition authorities with limited resources. These include enhancing data collection and analytical capabilities, prioritizing the use of efficient analytical tools, promoting cross-sector collaboration, and developing evidence-based policies to effectively monitor and maintain market competition.

**Keywords:** Algorithmic Pricing, Tacit Collusion, Pricing Behavior, Deep Q-Learning, Pricing Simulation.