108 年委託研究報告 4

演算法與聯合行為等重大限制競爭議題之研究

公平交易委員會

中華民國 108 年 12 月

108 年委託研究報告 4

（PG10806-0043）

演算法與聯合行為等重大限制競爭議題之研究

受委託單位：國立中正大學

研究主持人：陳和全

協同主持人：陳志民

研究期程：中華民國 **108** 年 **4** 月至 **108** 年 **11** 月

研究經費：新臺幣 **77.3** 萬元

公平交易委員會委託研究

中華民國 **108** 年 **12** 月

（本報告內容純係作者個人之觀點，不應引申為本機關之意見）

目次

目次 I

表次 VIII

圖次 IX

提要 X

第一章 緒論 1

第一節 研究主旨 1

第二節 背景分析 2

第三節 研究方法 9

第二章 訂價演算法的運行與邏輯 12

第一節 演算法的意義與表達 14

第二節 訂價演算法的基本邏輯 16

單一狀態自動訂價演算機 19

兩狀態自動訂價演算機 20

多狀態自動訂價演算機 21

第三節 學習型訂價演算法 23

(一)督導式學習(supervised learning) 23

(二)無督導式學習(unsupervised learning) 24

(三)半督導式學習(semi-supervised learning) 25

(四)強化式學習(reinforcement learning) 25

Q-learning 26

一個手算簡易 Q 學習說明 34

Attraction-based learning 42

解決 *Q-learnig* 的缺點：深度學習 42

Featuring 44

第四節 本章結論 47

第三章 訂價演算法改變市場與行為 49
第一節 訂價演算法改變市場環境 49
(一)市場結構 50
廠商數目 50
參進障礙 50
市場透明度 52
互動頻率 53
(二)需求面波動 54
(三)供給面變動 55
(四)廠商結構 56
(五)買方力量 56
小結 57
第二節 訂價演算法導致市場失靈 59
訊息隱密度變高 59
參進而立足之阻礙變大 59
知識傳播單調化 60
第三節 訂價演算法的效率與功能 60
(一)訂價演算法促增市場供需效率 60
就供給面而言 60
就需求面而言 61
(二)訂價演算法促增廠商決策效能 62
「價格與利潤」關聯預測 64
「價格與市場狀況」關聯比配 66
第四節 訂價演算法改變合謀樣態 67
(一)監控演算法(Monitoring algorithms) 68
(二)平行演算法(Parallel algorithms) 68

(三)信號演算法(Signalling algorithms) 76
(四)自學演算法(Self-learning algorithms) 78
小結 80
第五節 本章結論 81
第四章 訂價演算法促進合謀 83
第一節 合謀的概念與定義 83
Concerted practices 83
當前法例仍要求須具備人為溝通證據 85
第二節 寡占市場的互依決策 85
競爭市場的同向價格趨勢為結構必然 86
有意採行不利自我的訂價策略？ 86
棍棒與蘿蔔的兩手策略 88
第三節 寡占問題與適法見解 92
廠商相互間的依存與自覺 92
同時提價是策略必然抑或共識意圖 93
合意過程難以舉證 94
經濟分析鑑定的獎懲機制正是合意企圖之本源 95
第四節 訂價演算法強化寡占問題 97
第五節 訂價演算法促成合謀案例 98
(一)實務判例 99
Meyer v. Kalanick (2016) 99
U.S. v. Topkins (2016) 102
CMA v. GB eye (2016) 103
U.S. v. Aston (2015) 106
ECJ's Judgment in Eturas (2017) 106
U.S v. Airline Tariff Publishing Company (1992) 108

DOJ v. Traders for Major Banks (2017) 109
Webtaxi (2018) 110
EC v. Container liner shipping companies (2009).....112
(二)自學演算法的學術模擬合謀.....113
Shakya, Kern, Owusu and Chin (2012).....113
Nambiar, Simchi-Levi and Wang (2018).....113
den Boer and Zwart (2015).....114
Hanaki, Sethi, Erev and Peterhansl (2005) 115
Waltman and Kaymak (2009).....117
Calvano et al (2019a).....117
Calvano et al (2019b).....120
Henderson et al (2003).....121
Klein (2018) 122
小結.....123
第六節 本章結論 123
第五章 訂價演算法促成其它競爭法相關行為.....125
第一節 關於常見策略 125
(一)維持轉售價格.....125
EC v. Asus and other three (2018) 126
(二)費率等同條款.....127
Booking.com etc. (2015).....127
Amazon Marketplace (2012).....128
(三)掠奪訂價.....129
Amazon v. Quidsi (2011).....129
Google Maps v. Evermap (2012) 130
Malden et al. v. Uber (2016).....130

Desoto Cab v. Uber (2017) 132
印度 Meru v. Uber (2016) 134
南非計程車業 v. Uber (2015) 134
第二節 差別訂價 135
訂價演算法幾乎可行使一級差別訂價 136
小消費市場因廠商合謀而致傷害仍屬違反競爭法 138
第三節 結合審查 139
高度差別訂價下小市場因廠商合謀而受害的案例 139
訂價演算法對結合審查的新挑戰 142
第四節 企圖獨占 143
Philadelphia Taxi Association v. Uber (2016, 2017, 2018) 144
第五節 濫用市場地位 147
German Bundeskartellamt v. Lufthansa (2018) 148
第六節 不公平行為 149
Uber 於歐盟 (2017, 2018) 149
Uber 於台灣 (2016) 151
第七節 本章結論 152
第六章 訂價演算法及競爭法執行 154
第一節 競爭法的適用疑問 155
法院要求須有策略以外的額外因素證明 155
智能體合作下的人主體課責 157
智能體真的具有「理解」能力嗎？ 158
如何找尋智能體合作的證據 158
獎懲機制是關鍵性因子 159
第二節 人主體 v.智能體 161
顯然 a 關係的強烈人主體角色 162

具 c 關係的模糊人主體角色.....163
顯然 c 關係的微弱人主體角色.....164
第三節 判斷合謀的新課題.....165
訂價演算法三功能增進合謀.....166
執法者須先行判斷智能體決行的分量.....167
人主體-智能體僱傭模式的弱點.....168
第四節 訂價演算法可能違法樣態.....169
(一)仰賴人為合謀的監看型演算法.....169
(二)共用相同資料數據的訂價演算法.....169
(三)使用相同訂價演算法的廠商.....170
(四)委託第三方之訂價演算法代為決行.....171
(五)可預期的訂價演算機制.....172
(六)信號式的訂價演算機制.....173
(七)自學型訂價演算法.....174
小結.....174
第五節 本章結論.....176
第七章 執法者的因應.....179
第一節 各國態度.....179
美國.....179
歐盟.....180
加拿大.....181
英國.....181
澳洲.....182
日本.....182
第二節 建議之因應策略.....184
(一)區別人主體與智能體的角色.....185

(二)發展測試與檢驗編程 185
靜態檢定方法.....186
動態檢定方法.....187
(三)援引資訊技術與人才 187
(四)採用演算法作為證據 189
(五)另闢結果導向途徑 190
(六)從設計端進行管理 190
(七)事先產業結構調查 191
(八)事前結合控制審查 192
(九)考慮先期補救措施 193
(十)或用顯失公平途徑 193
第三節 本章結論 200
第八章 結論.....202
附錄 馬可夫過程與貝爾曼方程.....209
參考文獻 211
中文資料.....211
Books & Articles.....211
Cases 219
News/Magazines.....222
摘 要.....225
ABSTRACT.....230

表次

表 2.1 真實環境獎勵矩陣 36
表 2.2 機器人初始記憶 36
表 2.3 機器人的學習與更新記憶過程 38
表 2.4 機器人的記憶更新 39
表 2.5 完成學習的 Q 值矩陣.....40
表 3.1 演算法對共謀的影響 (整理自 OECD 2018) 58
表 3.2 訂價演算法分類 80
表 4.1 影響勾結的因子 91
表 5.1 依交通問題之特徵分類.....140
表 5.2 依政治傾向之特徵分類.....141
表 5.3 依交通問題與政治傾向之特徵分類 141
表 6.1 訂價演算法違法樣態與執法思維分類.....175
表 7.1 各國基本態度 183
表 7.2 建議因應策略與執行方法.....198

圖次

圖 2.1 有限自動演算機時序流程示意 17
圖 2.2 永遠合作策略的單狀態自動機 19
圖 2.3 以牙還牙策略的兩狀態自動機 20
圖 2.4 嚴格策略的兩狀態自動機.....21
圖 2.5 處罰 *n* 期策略的多狀態自動機 22
圖 2.6 自動演算機演算程序.....27
圖 2.7 機器人所處真實環境.....35
圖 2.8 機器人完成學習的最佳策略 41
圖 3.1 監控演算法示意 69
圖 3.2 價格跟隨策略之平行演算法示意 70
圖 3.3 信號演算法示意 77
圖 3.4 學習演算法合謀之示意.....79
圖 4.1 Calvano et al. (2019a)背離行動實驗的價格反應.....119
圖 4.2 Calvano et al. (2019a)背離行動實驗的利潤反應.....120
圖 6.1 機器演算法參與市場競爭之流程示意圖.....162

提要

關鍵詞：訂價演算法、機器學習、寡占問題、額外因素證明、單方行為、合謀、獎懲機制

一、研究緣起

演算法作為訂價工具，已非常普遍，尤其於線上平台交易之運用最多。證據顯示 ，Amazon 中的許多賣家已經開始運用了自己的訂價演算法(pricing algorithm)，而同時，Amazon (或其它平台業者)本身也提供了賣家一些簡單訂價法則的演算法。因應此一新興時勢，一些第三方廠商也已開始販售更精密的訂價演算法給零售業者，甚至直接接受委託而為零售業者做電腦訂價事宜之決行。於是，競爭法之適用，必須因應的予以檢視。機器演算法該如何在競爭法中被看待？其所產生的競爭行為該如何被規範？更核心的，「無人不能自行」，訂價演算法與人類之間千絲萬縷的關係，在競爭法上該如何予以角色定位？這都是數位時代中，競爭法主管機關所必須面對的新課題。

二、研究方法及過程

檢視廠商採用「訂價演算法」後之策略行為，於競爭法規標準架構上的適用。首先介紹訂價演算法基本邏輯、分類與利弊、及協助廠商效率運作的功能，這是執法人員面對平台經濟該具有的基本知識裝備。隨後，本研究繼續探討訂價演算法對市場結構、廠商行為、及可能被用為合謀工具的樣態。訂價演算法如何促進合謀已是全球當前討論焦點，因此本計畫先從法律面的合謀定義、再從經濟學合作賽局中獎懲機制分析，驗證合謀可能性更強但更難偵測，同時採取法務案例及學術模擬確認訂價演算法合謀的出現。其它競爭法相關議題，本計畫亦從理論與法例中提供執法人員須進一步留意，例如維持轉售價格、費率等同條款、掠奪訂價、差別訂價、企圖獨占等。本計畫透過人主體/智能體僱傭模型，分析兩者於競爭法上扮演的輕重角色，檢驗訂

價演算法的可能違法樣態。最後，提出當前執法人員面對此新型商業的因應方案。

三、重要發現

訂價演算法協助廠商達到更精良的配置效率、更準確估計所面對的環境(尤其是需求)、在既存市場條件下尋找最佳化價格、因應市場條件改變而快速進行價格調整、對客戶進行個人化訂價，但亦同時導致市場失靈，其中最大者是參進者立足存活不易、反競爭行為獲得執行的有力工具、而合謀勾結也變得容易執行。反競爭行為雖藉由訂價演算法來執行，然仍顯然必經人為決策，現時競爭法框架仍可適用。合謀行為則可依賴於雙方廠商訂價演算法間程式互通而達成，其中人為因素深淺不一。深者，由人為因素著手框以競爭法；淺者，則由演算程式尋索獎懲機制，理論上可行、實務很難。於是，仿效國外競爭法機構，引進充裕的資訊人才，藉由其資工能力進行解讀、譯碼、追索、或測試與檢驗程式，亦可就設計源頭予以管理。訂價演算法使用量較多的產業，可著手進行結構調查，並予以提醒相關競爭法規定與原理、或予以教育訓練。

四、主要建議事項

訂價演算法所涉及的競爭法議題，基本上當前競爭法架構足以應付；當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。惟訂價演算法的普遍運用，使得勾結行為的確認，變得更為艱難，因此執法人員必須擁有更新的調查技術。在外部偵察未能達到充分時，則或兼用寬恕政策及犯罪罰款，給予企業自我檢測與合作的誘因。

（一）立即可行之建議

教育訓練執法人員對演算法邏輯的熟悉，引進充分資訊人才，進行網路偵

測、搜尋、監視、與比對，並發展測試與檢驗程式的定規模式，有計畫的採用演算法結果作為證據。同時，進行產業結構調查、施予相關人員訂價演算法適用競爭法之訓練，並對訂價演算法普及的市場提出警示。

（二）長期性建議

資訊人員隨時監視與偵測訂價波動，發展偵測編程中獎懲機制的偵察模式。進一步的，就使用訂價演算法的廠商，採取設計源頭管理，宣導訂價演算法可能涉案樣態、以及寬恕政策及犯罪處罰，提供廠商自我檢測與合作的誘因。於結合審查時個人化訂價所產生區段化消費群，亦須發展出檢測或偵測能力，並輔以適當的補救措施。

第一章 緒論

第一節 研究主旨

演算法作為訂價工具，已非常普遍，尤其於線上平台交易之運用最多。證據顯示[1]，Amazon 中的許多賣家已經開始運用了自己的訂價演算法(pricing algorithm)，而同時，Amazon (或其它平台業者)本身也提供了賣家一些簡單訂價法則的演算法。因應此一新興時勢，一些第三方廠商也已開始販售更精密的訂價演算法給零售業者，甚至直接接受委託而為零售業者做電腦訂價事宜之決行。

廠商訂價由過去人類決行，演變為今日的自動化機器決行，導致廠商競爭模式改變，從而競爭法所規範之樣態，翻出了新風貌。於是，競爭法之適用，必須因應的予以檢視。機器演算法該如何在競爭法中被看待？其所產生的競爭行為該如何被規範？更核心的，「無人不能自行」，訂價演算法與人類之間千絲萬縷的關係，在競爭法上該如何予以角色定位？這都是數位時代中，競爭法主管機關所必須面對的新課題。

對此新課題，競爭機關執法人員首要之務，自是得先認識數位時代中的主角—訂價演算法，才能接著去追踪他所可能產生的問題(尤其在廠商競爭關係中)，然後再進而探討當前競爭法對其行為的可能或不可能規範。本計畫之主旨亦即在此。

本計畫首先將對訂價演算法的運行邏輯、實業運用、與發展分類，進行歸納、整理、與介紹；然後，探討其之於商業模式的運用、於商業營運決策模式的改變、於市場結構的衝擊、與對市場競爭所產生的新範式。隨後，連接至競爭法範圍，討論新角色的法律定位、訂價能力、與訂價模式，並相對

[1] Competition & Markets Authority (2018), Pricing algorithms: Economic working paper on the use of algorithms to facilitate collusion and personalized pricing.

於舊傳統以人為主角的競爭模式，如何比照？如何差異？產生如何新問題？而公平法該如何涵蓋？這其中，尤以勾結(一致性行為)所產生的模糊分際，最受討論與關注；而其次受關注的，則是促進競爭效果或對消費者差別訂價等議題，亦將觸及。由於本計畫主旨乃聚焦於「訂價演算法」對競爭法適用之衝擊，因此，關於演算法商業發展與運用的部分，將僅以一節進行介紹而不作深論。

借鑒國外經驗，自是本研究不可或缺的部分。國外相關案例的收集、說明、與分析，甚至整理出演算法可能違法疑慮樣態，或是事先偵測與查察的可能方式，亦將一併提出，或可提供競爭法主管機關之參用。

第二節 背景分析

以大數據為基礎的數據驅動創新(data-driven innovation)在現代商業經營模式已愈來愈重要，同時帶動了演算法(algorithms)更進一步被發展，不僅可對交易者進行追踪、預測與影響，甚至協助交易者決行策略，對當代社會與商營模式產生莫大衝擊。機器演算法商業的特色是，快速收集競爭廠商們的數據，其策略決行與反應只在瞬息之間，因此，企業經營與競爭成本大幅降低、市場呈現高度透明化，完全改變傳統的市場競爭結構。

機器演算法接收輸入項(input)並衡諸當前狀態(state)，瞬息間決定回應行動。於是，市場競爭中，人類的角色開始弱化。

2018 年 2 月 5 日美股突然產生爆炸性下跌，被認為導因於多數金融公司使用機器演算法執行複雜交易指令所致，據估計，S&P 500 指數交易中，大約有 50%以上已是由機器演算法來完成決行。由於人類投資者一般對於殖利率上升至某一關鍵幅度時就會觸動拋售股票而轉進債市的概念，也都如實的編製進入機器演算法運行。於是，所有機器演算法快速且同時的偵測出逼近觸發點，隨即不約而同的快速決定拋售股票與買進債券，導致股票市場容易

呈現大起大落的現象。

這一熟悉而簡單的股市事件，提供了我們幾個值得留意的觀察面向。第一，演算法已開始普及於企業決策。第二，人類賦予演算法決行法則。第三，人類賦予演算法決行法則之深度與廣度。第四，演算法所為之相同決行，是人類理性必然？抑或巧合？第五，演算法所為之相同決行，是人類行為？抑或機器行為？第五，相關法律如何看待？

如同金融市場股票買賣演算法的普及，許多其他產業的廠商競爭，也已開始意識到了演算法優勢的利用。Ezrachi and Stucke (2016)指出，「為了增益商業決策以及競爭差異化的自動化過程，而對演算法之利用」，構成了所謂的「演算法商業(algorithmic business)」。這個新興商業，不僅只是改變了廠商與他廠互動的模式，也改變整個產業競爭與發展模式。該書指出：「當一些廠商使用演算法而變得更有效率，其它廠商自然會感受到壓力，而開始數位化自己的營運、也開始發展類似的演算法，於是多數廠商都將依賴自動化系統，計算機科學家們就將更有誘因去研發新技術先進編程，而廠商們也有高度誘因去跟進此一演算法的更新與應用。」[2]

雖然目前部分產業仍然處於利用演算法之初級階段，但已經可以看到，愈來愈多商業不斷的增進其對演算法的依賴。此等依賴不外乎於兩個面向[3]：第一，利用演算法進行預測分析(predictive analytics)。一般演算法會被用來衡量未來各個可能結果出現的可能機率，其衡量方法都是根據過去數據進行分析，並對當前需求、價格變動、消費者行為與偏好、評估風險、及可能影響市場環境的內生或外在衝擊(例如新廠進入、費率波動、甚至是天然災害)進行預測。這對於廠商的決策可以產生莫大價值，促成廠商更效率擘劃其商業策略，甚至發展過去所不曾有過的創新與客製化服務。第二，演算法亦可用來

[2] Ezrachi, A. and Stucke, M.E. (2016), Virtual competition: the promise and perils of the algorithm-driven economy, Harvard University Press.
[3] OECD (2017a), Algorithms and collusion: competition policy in the digital age.

優化經營過程(to optimize business process)，減低廠商生產與交易成本、區段化消費者、或有效率因應市場情況而訂定最適價格，於是獲得競爭優勢。

一言以蔽之，演算法交易比人類更快速的確認市場狀態，更快速的予以反應(交易)，提增了交易效率與多重社會效率，甚至包含解決疾病與貧窮。然而，它也產生了令人擔憂的問題。它還是人類所能控制的嗎？人類到底控制了多少成分？

歐盟競委員會主席(European Commissioner for Competition) Margrethe Vestager (2017)[4] 說到：「演算法自動決策的方法甚至可能侵蝕了我們的民主。近來，社交媒體(social media)已是新聞的重要來源… 於是社交媒體演算法的範疇內，創造了另一個實境(reality)，是我們所擔憂的，因為它餵給人民一個接一個的故事，但卻是，都不是真的。」「自動機所創造的挑戰是真實存在的。如果他們幫助廠商固定價格，他們就真實的使我們整個經濟體運作得更差…至於競爭執法者，我們必須很清楚的表達，廠商們不能隱藏在電腦編程後面而規避了所有勾結的責任。」「沒有人可以認為使用軟體為他們達成協議，就可免於固定價格的責任。」

既是如此，我們不免要思考，人類(人主體)與機器自動演算法(智能體)之間的關係，到底是一個怎麼樣的關係？

傳統競爭法是發生於人主體(human agent; HA)決定層次，在演算法普遍後，自動化代理人(automation agent, AA;智能體)則為一個可以自我運行的代理人，接受著人主體賦予其之不一程度的決行設定(構成代理人關係)，同時，多個智能體間彼此互通「想法」，而形成前所未有的另一層次關係。智能體接受人主體賦予決策模式與程度、並與其他智能體互動，各選擇決策行動，形成一個市場競爭的 outcome，而影響消費者。在高度發展下的自動化訂價演算機，因已足以對消費者偏好、地區、習性與瀏覽紀錄、以及對市場各廠行

[4] Vestager, M. (2017), Algorithms and competition, speech at the Bundeskartellamt 18th Conference on Competition, Berlin.

動決策，進行快速偵測並據以形成新分析資料，於是，可以不斷因應新環境而不斷決策新行動，這不斷的調整過程，其實可能只在踵息之間。

在演算法基底商業(algorithm-based business)中，如若智能體所運用的演算法、或決策分析的數據資料庫來源，與其他智能體相同，則對外部事件(例如成本或需求改變)的反應將會相當雷同，而生一致行為，構成合謀疑慮。或者，智能體被編撰了類似於「比照訂價(matching)」或「以牙還牙(tit-for-tat)」等可被預期的固定反應與決行法則(rule)，則易生他者配合而致高價的出現。而更進化的兩個智能體，則可以自我學習而「互通款曲」，以致超競爭價格的合謀狀態；有時，僅給予智能體一個追求最大利潤目標的指令，在其不斷接收環境與對手訊息(例如價格變動)，然後不斷的試誤嘗試、累積經驗，也可以最終達到彼此和同於超競爭價格的結果。

透過訂價演算法獲致超競爭價格現象，已經獲得多方關注。例如， Mehra (2016a, 2016b) and Ezrachi and Stucke (2016, 2017a, 2017b), Ballard and Naik (2017), Capobianco and Gonzaga (2017), Deng (2017, 2018), M. Gal (2017a, b),及 Okuliar and Kamenir (2017)。其中，如若人主體涉及通訊而合謀者，適用競爭法並無爭議；而當智能體扮演合謀中的重要角色時，例如，智能體的自我調適或自我學習而達致之超競爭價格結果，這可准視為廠商的勾結嗎？

對於(隱性)勾結，法理上的論述不少，我們先由傳統判例釐清關於勾結(collusion)的定義，才能站穩腳跟的往數位時代延伸。一些重要判例摘錄如下：

> 「Where the circumstances are such as to warrant a jury in finding that the conspirators had a unity of purpose or a common design and understanding, or a meeting of minds in an unlawful arrangement, the conclusion that a conspiracy is established is justified.」[5]
>
> 「There must be direct or circumstantial evidence that reasonably

[5] American Tobacco Co. v. United States 328 U.S. 781, 809-10 (1946)

tends to prove that the [firms] had a conscious commitment to a common scheme designed to achieve an unlawful objective.」[6]

「While a conspiracy involves an agreement to violate the law, it is not necessary that the persons charged meet each other and enter into an express or formal agreement, or that they stated in words or writing what the scheme was or how it was to be effected. It is sufficient to show that they tacitly came to a mutual understanding to allocate customers.」[7]

整理之，也就是說，法院認為共謀協議不必然指向碰頭商議等等明示通訊(explicit communication)，而是只要有足以證明「meeting of minds」、「conscious commitment to a common scheme」、或「mutual understanding」的直接或間接證據即可。這些說明都指向一個共同的精神狀態(mental state)，亦即「廠商間存在一個限制競爭的共同理解(common understanding)」[8]。在 European Union General Court 則定義 agreement 為「joint intention 共同意向[9]」、「concurrence of wills 一致心意[10]」。

法例上「一致心意」「共同理解」的定義，在經濟分析上，讓寡占市場成為一個敏感的結構。

經濟學理中，寡占的特色，就是廠商互依決策(interdependent actions)。以數量為競爭策略的庫諾模型，策略上必然呈現反向變動的策略性替代(strategic substitutes)，而以價格為手段的 Bertrand 模型中，訂價則必呈同向走

[6] Monsanto Co. v. Spray-Rite Serv., 465 U.S. 752, 768 (1984)
[7] United States v. Suntar Roofing, Inc., 897 F.2d 469, 474 (10th Cir. 1990)
[8] Harrington, Jr., J.E. (2018), Developing competition law for collusion by autonomous artificial agents. Journal of Competition Law & Economics 14 (3), 331–363.
[9] Judgment of the Court of 15 July 1970. ACF Chemiefarma NV v Commission of the European Communities Case 41-69.
[10] Judgment of the Court of First Instance of 26 October 2000. Bayer AG v Commission of the European Communities

勢的策略性互補(strategic complements)[11]。基於面對相同的市場需求與原理，價格調動成為互相緊扣的兩條線，是彼此揣摩並互相依賴的各自決行，這就是 Posner (1969)所指出的「寡占問題(oligopoly problem)」。「寡占市場中的互依及互相自我知覺(interdependence and mutual self-awareness)，可能導致隱性勾結，這是一個非社會所欲但卻掉在競爭法所及之外的結果」。

實務上的長期競爭(重複賽局)，經過長時期互動，廠商自然會建構於歷史經驗而產生未來對手可能策略的預測與期待，當這個預期模式形成後，即為競爭廠商間的一種 common understanding。於是，一廠商即可透過當下策略的刻意選擇，釋放出「我欲如何」的訊息，期望對方廠商收悉後可以配合行動(必須有利可圖)。這樣的過程，在寡占市場中，很容易產生，而且不必任何通訊，因此很難被觀測。它是否構成競爭法中所謂的隱性勾結，在無確實外顯證據之下，很難斷論。目前競爭法主管機構對這個問題所提供的解法，仍然有限。

在機器演算法的出現後，上述的寡占問題變得更為顯著，也造成競爭法適用與判斷上更大的困難。

訂價演算法的出現，更精準的偵測價格變動、消除不理性元素、減低因失誤導致合作瓦解的機會，於是，傳統上被認為較易偵測出勾結的市場結構(低廠數、高透明、高參障)，被提增了勾結隱匿性，而原不具寡占問題的非寡占市場結構，也因此可能產生出勾結。訂價演算法比人類更成功的安排出一個勾結結構[12]。

在傳統寡占市場中，一個廠商單方行為、誘引意識平行(conscious parallelism)、建構具限制競爭的協同行為，在現行法律標準下，要證明它已是很難。而當訂價演算法等自動化演算機進入商業後，訂價演算法之間彼此互

[11] Bulow, J, Geanakoplos, J. and Klemperer, K. (1985), Multimarket oligopoly: strategic substitutes and strategic complements. Journal of Political Economy 93.
[12] Mehra, S.K. (2016a), US v. Topkins: can price fixing be based on algorithms? Journal of European Competition Law & Practice 7 (7), 470–474.

動(algorithmic interactions 或 meeting of algorithms)是否等同於 meeting of minds (競爭法下的協議定義)？ 仍然無有定論。同時，機器學習的發展，將使得智能體與其人主體間的僱傭(principal-agent)聯結更為減弱，於是演算法的即時自動反應與訂價能力，使獲利廠商或個人在擔負法律責任上，將更形疑惑與難辨。

除了協議合謀此議題之外，訂價演算法也會引起其它挑戰。早期網路興起形成天涯若比鄰的感覺，產品之地理區域市場界定於是被大大的放寬。而在 2014 FTC 報告指出，一個 data broker 擁有幾乎全美每一消費者的 3000 個數據段(data segments)[13]，如此的個人枝微末節特徵面向正足以把消費者區段出大數量族群，於是很多區段消費群將變得很小。這些微小消費區段群，完全沒有買者力量，只被餵以不同樣式價格與折扣組合表單，而被精密的差別訂價，市場窄化細緻到難為其它競爭者所窺知。在大數據與訂價演算法商業之下，市場可能極度的被窄化了。

雖然單方面的差別訂價並不當然違法，但訂價演算法促成的細緻窄化市場並價格歧異，則可能顯著的影響到未來的結合審查；因為窄化的市場界定，將使特殊群段(segment)因廠商結合而遭受高度壟斷。於是，競爭法主管機關在進行結合審查時，亦必須具有廠商演算法訂價能力，才能洞悉廠商所細分區段的消費群。要能洞悉廠商的細分區段消費群，非常困難，卻是結合審查時所必須面對的全新課題。就執法機關而言，增進了解競爭法於訂價演算法的適用與因應，裝備應用自動機器演算法的能力，是不可避免的趨勢。

同樣的，競爭法執行者為偵測勾結，除了必須確知訂價演算法如何促進形成與維持勾結之外，或許還必須發展全新的調查方法或投以更多的資源。事實上，為因應此一新局面，美國 FTC 已經增設技術研究與調查辦公室(Office of Technology, Research and Investigation; OTRI)，聘任技術專家與電腦科學家，

[13] McSweeny, T. and O'Dea, B. (2017), The implications of algorithmic pricing for coordinated effects analysis and price discrimination markets in antitrust enforcement. Antitrust 32 (1), 75-81.

擴充其組織的內部專家[14]。

總之，自動訂價機器，具有能力依供需狀況去隨時改變價格，而且快速的、高頻的彼此互動，於是，很容易的可以偵測與反應於背離勾結者、很容易的減低錯誤與意外導致的背離行動、同時減少了部門的鬆散性，都能夠顯著的促進隱性勾結[15]。而這些特性，正都是當前競爭法適用經驗上所不曾碰過，於是，執法者面對的這些訂價機制，是一個全新的挑戰。

第三節 研究方法

本計畫之研究設計，基於五個面向，並涵括八章。概念面向包含：

(一) 經濟概念為基礎

先行鋪陳經濟理論模型，尤以寡占問題涵意的解析與合作賽局獎懲機制的說明，演繹互依決策的存在，以做為隱性勾結論證上的理論背景。

(二) 演算法邏輯理解

說明與理解演算法的運行邏輯、演算法的分類(例如監視型演算法、平行式演算法、信息式演算法、及自我學習式演算法)、演算法的誘因共容與選擇。以此理解演算異於人類決策、以及其與人類決策之交集點，做為解析公平法課責與否之論證基礎。

(三) 文獻收集與整理

整理演算法對商業模式與產業結構的影響，論述傳統中易於觀察出勾結的市場結構，面對演算法新局後的改變，其中尤其透明度與參進障礙為主。

[14] Federal Trade Commission (2015), Press Release of 23 March, BCP's Office of Technology Research and Investigation: The Next Generation in Consumer Protection.
[15] 前文 Competition & Markets Authority (2018).

(四) 推論演算法對市場競爭的衝擊

論述演算法之於競爭法的影響，陳述勾結的運行、差別價格的產生、市場的窄化，並經濟推導演算法特性所導致的勾結難易變化。

(五) 歐美相關案例分析

以歐美實務案例說明，更深化演算法之問題呈現

本計畫主旨聚焦於檢視廠商採用「訂價演算法」後之策略行為，在競爭法規標準架構上的適用，再基於前述五個面向概念，於是本計畫之章節共設定為八章。除第一章緒論之外，第二章先對訂價演算法運行的基本邏輯進行介紹，並分析當代學習型演算法之分類與利弊。對執法機關人員而言，欲掌握訂價演算法與競爭法關係，惟從了解訂價演算法運行邏輯開始，故本章雖不直接碰觸競爭法，但卻是執法人員該具有的基本知識裝備；其中尤以強化學習與深度學習在商業競爭中最受入矚目。同時，本章也分析了訂價演算法如何協助廠商達到效率訂價的運作，我們分別從「價格與利潤」及「價格與市場狀況」間的比配運作談起。

第三章則探討演算法對於市場結構所產生的衝擊，分別分析各面向結構受到衝擊後，對於廠商勾結可能性，產生了正向或負向影響。並進一步的，我們依 OECD 的訂價演算法四分類，分別詳述其促成或維續廠商勾結的可能性。

第四章將針對運用訂價演算法之下的「寡占問題」進行仔細剖析，探究隱性合謀的被促成與強化，並於末節大量引介實務法例及學術案例，作為理論實務與相互印證。「寡占問題」正是隱性合謀之根源，而在無訂價演算法的市場中，其適用競爭法已顯相當模糊；在訂價演算法的出現與被運用後，將使這問題的解析更形困難。故列為專章剖析。

前一章基本上是專論合謀，而在第五章，我們將整理訂價演算法運用之後，廠商在非合作策略上所可能涉及違反競爭法的樣態。例如，維持轉售價格、最優惠條款、掠奪訂價、差別訂價、或企圖獨占等，都將會有實際案例的說明與介紹。

最重要的，第六章，我們開始探討競爭法的適用。由關鍵性的「獎懲機制」出發，分別人主體與智能體的適法性，再進而探討寡占問題中智能體行為的判斷，並在第四節歸納整理出訂價演算法可能涉及隱性合謀的行為樣態。

最後，第七章則整理目前各國對訂價演算法在適用競爭法上的態度與作法，作為公平會在因應訂價演算法商業時的參考。然後，第八章作了本計畫的結論。

第二章 訂價演算法的運行與邏輯

Stucke and Ezrachi (2017)認為，為了助益商業決策與自動化過程以達競爭差異優勢，廠商們不斷的增用複雜的演算法，稱其為「演算法商業(algorithmic business)[16]」。今日，訂價演算法於演算法商業應用中，已經相當普及。例如，航空運價發布公司(ATPCO)，擁有英國航空、達美航空、荷蘭航空在內 430 家航空公司票價數據，於 2018 年白皮書中透露推出動態定價引擎，「將允許航空公司在評估乘客與當前市場資訊後，根據行程站點與更廣泛細分計算，進一步調整票價」，不同的折扣與不同的附加旅行產品會因而不斷被創造出來[17]。

或許，金融系統可能是當代社會中最徹底的計算自動化領域。在這領域中，演算法多少可以自由的介入干涉一些正在加速的動亂漩渦事件、或一些可以持續帶來金流的數量產出，而且其中的迴圈過程，可以完全沒有人類角色[18]。2018 年 2 月 5 日美股突然產生爆炸性下跌(explosive speed of the fall)，一般咸認是因多數金融公司使用機器演算法執行複雜交易指令所致[19]，據估計，在 S&P 500 指數交易中，已大約有 50%以上是由它來完成決行。雖暴跌之前的美國就業市場才剛報告出薪資強勁成長現象，但股票劇跌正因這個經濟好現象加上訂價機器演算法所致。經濟好，促使國債價值跌、殖利率升、而價格降；當殖利率上升至關鍵點(多數是在 3%)時，將觸發(trigger)投資者改賣出股票、而轉進債市，此一人類決策法則亦編製進機器演算法。由於，所

[16] Stucke, M.E. and Ezrachi, A. (2017), Two artificial neural networks meet in an online hub and change the future (of competition, market dynamics and society). Legal Studies Research Paper Series.

[17] Morris, H. (2018). Airlines are starting to price their seats based on your personal information – but is it legal? The Telegraph, February 27. 文同提及，依據英國公平貿易辦公室(OFT)在 2014 年的研究統計，隨客戶訊息訂價的公司，其收益不一定最大化，因為技術成本太高。

[18] Lowrie, I. (2018), Algorithms and automation: an introduction. Cultural Anthropology 33 (3), 349-359.

[19] BBC NEWS (2018). Did robot algorithms trigger market plunge? February 6.

有的機器訂價演算法快速且同時的偵測出逼近觸發點，終至引發出快速且同時的拋售股票與買進債券動作[20]，導致股票市場呈現自由落體般的失速下墜[21]。

位於紐約的 Athena，是一家運用演算法進行高頻交易的公司，他使用一套複雜電腦程式去執行一個市場本已熟悉的操縱手法，就是，對公開交易股票的收盤價進行標記，然後通過一個精密演算法操縱 NASDAQ 股票收盤價。在被指控的 2009 年 6 月至 12 間，Athena 利用這一套演算法，在 NASDAQ 下午 4 點收盤之前的最後 2 秒進行大量股票買賣，以推動股票收盤價呈現出略高或略低現象，每日被如此操縱的股票多達數萬股。這套交易演算法在其公司內部被稱為 Gravy。雖然 Athena 是一家相對較小的公司，但透過這套演算法，這些被操縱股票在收盤前數秒鐘，Athena 的買賣占了整個 NASDAQ 交易量七成，亦即 Athena 在這段時區中，完全支配了這些股票的買賣。Athena 亦正是透過收盤前快速操作，讓該日交易定單呈現不平衡(即收盤時某股票沒有足夠的收盤訂單來匹配買賣單)，於是收盤前 NASDAQ 就會進行封閉式拍賣，以最優惠價格成交所有未平倉訂單，Athena 再由此套取利潤。此類操作被證交會(Securities and Exchange Commission)於 2014 年確認不當，而處以 100 萬美元罰款[22]。

線上零售業的訂價演算法運用，不惶多讓。以 Amazon 為例，其 Marketplace 在全球已有約 200 萬第三方商家，而銷售其平台上暢銷品項(約一千多項)的第三方商家中，約有 20%採用演算法訂價；採用演算法訂價的產品，其價格波動性則約增長 10 倍[23]。許多訂價系統研究廠商開始兜售訂價軟

[20] 同上註 BBC NEWS (2018)。此次暴跌的機器演算法觸發點，據觀察是在債券殖利率漲幅 2.9%。

[21] CCN BUSINESS/Business (2018). Dow plunges 666 points -- worst day since Brexit, February 2. 當天道瓊指數收盤跌 666 點(2.5%)，是 2016 年六月英國脫離歐盟公投(Brexit turmoil)以來，美股最大單日百分點跌幅，也是自 2008 金融危機以來，最大單日指數跌幅。

[22] Securities and Exchange Commission (2014). Administrative Proceeding File No. 3-16199. In the Matter of Athena Capital Research, LLC.

[23] Leber, J. (2016), Algorithmic pricing is creating an arms race on Amazon's marketplace, June

體，例如 Xsellco、RepricerExpress、RepriceIt、Appeagle 都是專門用來主動偵測競爭對手調價並跟進削價的軟體，甚至 Amazon 本身也提供自家訂價演算法給其平台零售商。據估計，Amazon 對其平台品項每天共約重新訂價 250 萬次，亦即每一品項平均每十分鐘就變動一次價格[24]。

韓國的 BRIAS (The Bid Rigging Indicator Analysis System)則企圖針對可疑標單進行操縱分析。該單位收集自 2013 年起的 51 個中央單位、216 個地方單位、以及 26 個公營事業的投標相關資訊，分析與預測投標操縱的機率，其量化運行是基於不同類型訊息不同權重進行計算，包含投標成功率、參與投標家數、投標價格[25]。

在演算法商業的今日，訂價演算法已普遍成為商家追縱競爭者價格與隨時重訂價的工具。於是，面對新型商業型態、新型訂價工具，競爭法執法人員欲規範、檢視、或框架此等新型商業模式，當然唯有從認識訂價演算法的基本運行邏輯開始。本章就由此開始。

第一節 演算法的意義與表達

雖然並非所有的自動裝置(automation)都具演算過程(algorithmic)，但所有的演算法(algorithms)則必定都是自動化的。事實上，典型當代的自動裝置，都依賴於計算指令、控制與訊息溝通的演算法組裝(algorithmic assemblages)。這些組裝的運用，從單純的數學與計算領域到廣泛的社會技術基礎面，已經在組織中與當代社會世界中，產生了強烈的、持續的、無限度的改造。

根據資料與計算機科學家們的定義，可以說，演算法是「一組形式化程序運作於一組特定數據上，在一定有限時間內產生一範圍特定產出。」「一個

14.

[24] Mehta, N., Detroja, P. and Agashe, A. (2018), Amazon changes prices on its products about every 10 minutes—here's how and why they do it, August 10.

[25] OECD (2013), Policy roundtables: Ex officio cartel investigations and the use of screens to detect cartels.

結構化的決策過程，利用一組規則或流程(如決策樹)並基於輸入數據及決策參數，自動計算以提供結果」[26]。直覺上來說，一個演算法是一系列規則或指令，被遵循的去執行某些工作項目(an algorithm is a sequence of rules that should be performed in an exact order to carry out a certain task)，也可稱它為一套「計算程式」，具有良好定義的具體計算序列步驟。美國司法部反托拉斯副助理檢察總長 Barry Nigro 說「演算法就是由人類設定來告訴電腦做什麼的一堆 if-then 敘述。Wilson and Keil (1999)指出：「一個演算法是簡單運算的明確精準列表，機械化的與系統化的應用於一組標誌或標的(例如棋子組態、數字、蛋糕成分…等等)。[27]」標誌的初始狀態即是 input，而最終狀態即為 output。演算法是一個結構化的決策過程，利用一組規則或流程(如決策樹)並基於輸入數據及決策參數，自動提供出結果。

演算法有許多形式表達，例如文字、圖形、編碼、或甚至編程。因為電腦的進化，演算法已進步到可以自動重複執行包含複雜計算與數據處理的項目，對人類而言，這些項目的處理是非常昂貴的。近期在人工智慧與機器學習的發展下，更把演算法帶進了一個更新穎的境界，讓電腦可以解決複雜問題、比人類更有效率的預測與決策、以及更易達致社會政策目標。

演算法是一套數學與計算程序，用來運作例如交通路線安排、MRI 圖形診讀癌細胞、或者交友網站上配對等等任務。然而，一個演算法只是一些概念、一個探索性方法、以及幾行編碼的描述，其之運行，仍有賴於具備處理能力、存取方法、與數據供給，還得確保其計算架構持續的完全整合於社會歷程(social process)。我們知道，沒有消費者的烘焙坊不會存在，相同的，做為一組演算法，它必須要有特定事項要完成、有特定問題要解決、或者有數據要去解析與消化。

---

[26] 參見 Cormen, T.H., Leiserson, C.E., Rivest, R.L. and Stein, C. (2009). Introduction to Algorithms, 3rd ed..

[27] 參見 Wilson, R.A. and Keil, F.C. eds. (1999), The MIT Encyclopedia of the Cognitive Sciences.

於是，對於演算法效率性的評估，簡單說，就是要洞悉社會所需並有能力解決社會所需。因此，優良的演算法，不僅要有能力從巨大數據中進行處理與確認型態(patterns)，還要有能力處理相鄰運算例程、具有良好材料基礎設施(material infrastructure)、甚至還具有預測操縱人類的能力。事實上，基於各個不同應用領域，要組成一個具功能的演算法，不僅須要整合硬體與數字串流，還須整合組織結構、模擬化基礎設施，還要使其置身於社會經濟歷程中運作、產生問題、並行解決問題。例如，Lyft 或 Uber 演算法應用之核心，是分析消費者、計程車業者、以及地圖數據，同時創造與監看汽車、人體、金錢等巨大流量的真實變化。Amazon shipping center 物流演算法之核心，則不僅基於歷史上的交易、運送狀況、及員工績效進行分析，還藉此進行預測以便可以更積極的管理產品存貨、控制員工職務與績效、治理倉庫之間的包裹流動、以及進行與外部組織(如 FedEX 與郵局)的互動。

第二節 訂價演算法的基本邏輯

一個自動機(machine; automation; agent；智能體)是一種演算上的數學模型，它是一個抽象的機器，但卻存在於任一時間點上的某一狀態(state)下，它會因應某些外部輸入(inputs)而從一個狀態改變成另一個狀態。由既有狀態改變成哪一個狀態，即為「轉變(transition)」過程。於是，描述一個自動演算機，一般而言，將包含五個基本元素：有限的狀態集(states)、初始狀態(initial state)、有限輸入項集合(inputs)、有限輸出項集合、輸出函數(output function)、轉換函數(transition function)。

在計算機科學中，「有限自動機(finite automation)」，最簡單但卻是一個應用上的核心模式，其之命名來自其有限的存儲容量[28]。我們以兩家廠商競爭來

[28] 有限狀態自動機(finite-state machine, finite-state automation, finite automation, state machine)的「有限狀態」，意味著有限的存儲區。狀態是有限數量的，而每一狀態則應對著一個反應

看，假設廠商 i(或決策者 i)的自動演算機記為 M_i。

當廠商 i 處於既有某一環境狀態下看到廠商 j 選擇了某一行動後，將會回以一個自己的行動選擇。於是，廠商 j 的可能行動集合(記為 A_j)，即為廠商 i 的(有限)輸入項集合，其內部元素記為 a_j。而廠商 i 本身的可能行動集(記為 A_i)即為其因應對方行動而可採用的反應策略集，也即是他的(有限)輸出項，其內部元素則記為 a_i。

一個自動演算機 i 於當期(t)，基於對當期既存狀態(s^t)的認知，加上環境中其它變數(a_j^t)的對其輸入後，他即由可用行動集中擇取了一個行動作為反應(a_i^t)。該選何一行動做為反應(輸出)？這一反應規則即為「輸出函數」，記為 $\lambda_i: S_i \rightarrow A_i$。於是，於某個特定狀態下，自動演算機將會選擇哪個特定策略做為回應(輸出)，函數即是 $\lambda_i(s_i) = a_i$。一自動演算機認知狀態、接收輸入、然後產生回應輸出的示意圖，如圖 2.1 所呈現。

此處之輸出項僅依賴於當前狀態 s_i，而與輸入項(a_j)無關，我們稱其為 Moor machine。假若輸出改為$\lambda_i(s_i, a_j) = a_i$，意味著輸出項(數值)同時取決於當前狀態與輸入項的，此一設計稱其為 Mealy machine。

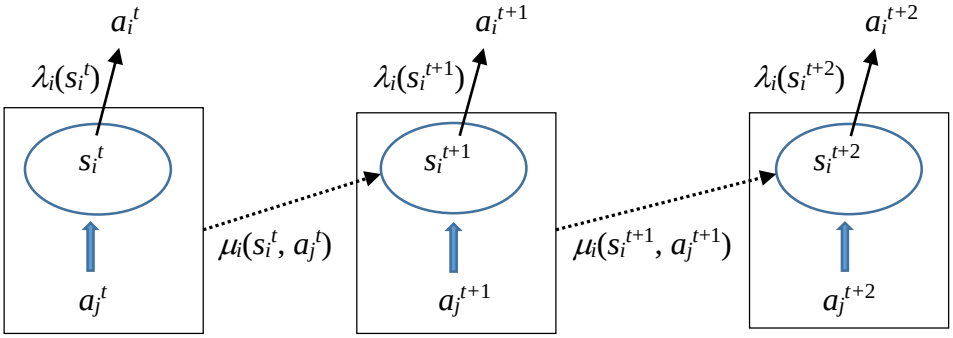

圖 2.1 有限自動演算機時序流程示意

行動，於是，又常被以用「狀態/行動」的表格矩陣來表達；惟因有限，故表格可以表達。相對的，Turning machine 則是具有無限的存儲區磁帶，也因無限，故不再是用表格可以表示的。後者可以做的計算任務，可能是前者做不到。一般認為 Turning machine 雖然簡單，但是可以有能力模擬出任何演算法的邏輯。

當廠商 i 逢某一行動輸入、處某一環境狀態下而選某一行動做為反應後，則一回合互動完成。原環境狀態因接收輸入項(s_i)的影響，而變成一個新的狀態，狀態的轉變規則，即為「轉換函數」，記作 $\mu_i: S_i \times a_j \rightarrow S_i$。某一特定狀態接受 inputs 後轉變為另一特定狀態，函數即是 $\mu_i(s_i, a_j) = s_i'$。更新後的狀態，可能與過去某一個狀態相同，也可能不同，惟相同狀態就會有相同反應。假若一個狀態於接收輸入項後，其轉換狀態唯一確定，稱為「確定性(deterministic automation)有限自動機」，否則為「不確定性(nondeterministic)有限自動機」。

當然，在整個長時決策過程中，每一時刻，決策者 i(或自動演算機 Mi)定會處於一個特定狀態(state)，所有可能狀態的集合記為 S_i，是有限的。集合內各別元素則以 s_i 表示；一般而言，一個演算機都會有一個設定的起始狀態，可記為 $s_i^0 \in S_i$。

於是，決策者 i 的自動演算機 M_i，一般會以六元組 $<S_i, s_i^0, A_j, A_i, \lambda_i, \mu_i>$ 標記之。

進一步的，我們以兩廠囚犯困境的超賽局(supergame)為例[29]，說明(與圖示)文獻中相關的不同策略的迴圈運行。

假設兩廠 i 與 j 各自選擇了自動機 M_i 與 M_j。第 1 期，任一自動機都選擇初始狀態(即 $s_i^1 = s_i^0$)、並據此既有狀態而選定行動 $a_i^1 = \lambda_i(s_i^1)$，然後面臨對手 j 行動 a_j^1，既有狀態更新而進入第 2 期：$s_i^2 = \mu_i(s_i^1, a_j^1)$。在第 2 期，$M_i$ 依據既有狀態 $s_i^2 = \mu_i(s_i^1, a_j^1)$選定行動 $a_i^2 = \lambda_i(s_i^2)$，然後面臨對手 j 行動 a_j^2，於是既有狀態更新而進入第 3 期…。簡示如下：

$$s_i^1 \xrightarrow{a_j^1} s_i^2 \xrightarrow{a_j^2} \cdots\cdots \xrightarrow{a_j^{m-1}} s_i^m \xrightarrow{a_j^m} s_i^{m+1}$$

在無限期之下($t = 1 \rightarrow \infty$)，以第 t 期表述：第 t 期，自動機 M_i 依據既有狀

[29] 所謂 supergame 是指相同的靜態賽局被重複無限次。

態 s_i^t (而 M_j 處於 s_j^t) 選定行動 $a_i^t = \lambda_i(s_i^t)$，然後面臨對手 j 行動 a_j^t，於是下一期的既有狀態即更新為 $s_i^{t+1} = \mu_i(s_i^t, a_j^t)$。競爭兩廠各有自動機將產生一系列產出(outcome)，$(a_i^t, a_j^t)_{t=1}^{\infty}$，以及一系列狀態，$(s_i^t, s_j^t)_{t=1}^{\infty}$。

前述過程說明，即示意圖 2.1 之呈現。提醒的是，不同時期，其狀態可能相同、也可能不同，但若狀態相同，則必然輸出相同行動。

由於廠商競爭是日復一日在市場上過招，不斷的進行決策對壘，因此，採用自動演算法計算重複性的交手，最為恰當，也因此，它最早被用來分析重複賽局(repeated game)。以囚犯困境賽局為例，一般常見的策略有幾種，而代表廠商的自動機(智能體)可以從一些策略中做選擇，以與對手廠商競逐[30]。

單一狀態自動訂價演算機

例如在重複囚犯困境賽局中，最簡單的一個策略是，不論對手如何回應，我採用「永遠合作」；這是一個單一狀態的自動機(one-state machine)，如圖 2.2 所示。假設演算法的初始狀態(s_i^0)為合作(故我接著必選合作)，則任一期狀態(s_i^t)、在對手任一行動下(a_j^t)，接著下一期將永遠都是合作狀態(我必選擇合作)，亦即：$s_i^{t+1} = \mu_i(s_i^t, a_j^t) =$ 合作狀態 $= s_i^0$、而 $a_i^{t+1} = \lambda_i(s_i^t) =$合作。這個自動演算法機制中，只存在一個狀態。

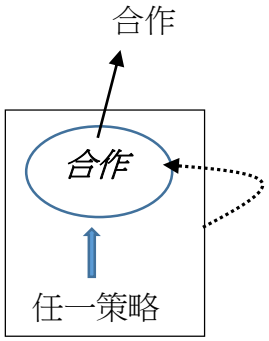

圖 2.2 永遠合作策略的單狀態自動機

[30] Rubinstein (1986)是第一位把自動化機置引入重複賽局，主要分析囚犯困境策略模式。

兩狀態自動訂價演算機

兩個狀態的自動演算機，則例如採用「以牙還牙(tit-for-tat)」策略，其演算法原則在於「永遠跟進對手策略」，如 2.3 圖所示。於是，對手採用合作動作，即形成合作狀態，若對手採用不合作行動則形成不合作狀態。假設初始狀態為合作狀態。我一開始($s_i^1 = s_i^0$)必選合作(因既有合作狀態)，然後，於任一期狀態(s_i^t)下，若對手採合作行動(a_j^t=合作)，則下一期新狀態仍為合作狀態(則我必再選合作)，亦即：$s_i^{t+1} = \mu_i(s_i^t, a_j^t)$ =合作狀態= s_i^0、而 $a_i^{t+1} = \lambda_i(s_i^t)$ =合作。相反的，於任一期狀態(s_i^t)下，假若對手採用的是不合作行動(a_j^t=不合作)，則下一期新狀態變為不合作狀態(則我必選不合作)，亦即：$s_i^{t+1} = \mu_i(s_i^t, a_j^t)$ = 不合作狀態、而 $a_i^{t+1} = \lambda_i(s_i^t)$ =不合作。這個自動演算法機制中，只存在二個狀態，而有四個迴圈(loop)：合作狀態後還是合作狀態、合作狀態後變為不合作狀態、不合作狀態後還是不合作狀態、不合作狀態後變成合作狀態。

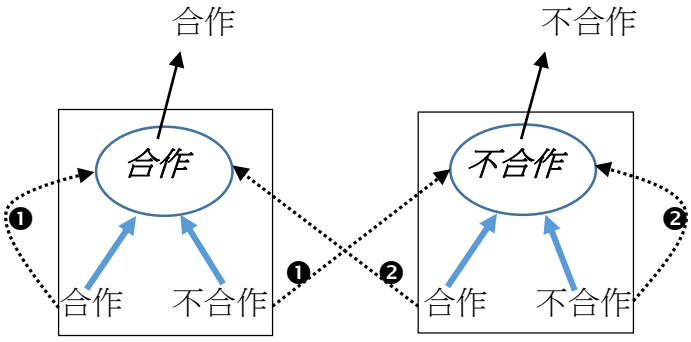

圖 2.3 以牙還牙策略的兩狀態自動機

另外，我們熟悉的「嚴格策略(grim strategy)」，也是一個兩狀態自動機，其演算法原則在於「持續採用合作，而一旦對手採用不合作，則改採永遠不合作」，如圖 2.4 所示，依舊假設演算法給定初始狀態(s_i^0)是對手選擇合作行動(此亦記為合作狀態)。這一自動演算機制存在兩個狀態，一是合作狀態，一個是不合作狀態。凡在某一時期，其前面任何一期都是合作狀態、且該期對手亦選擇合作，則下一期仍是合作狀態(我必將選合作策略)；但若該期之前已

是不合作狀態、或者該期對手選擇了不合作，則下一期即轉換為不合作狀態(於是我必選擇不合作)。

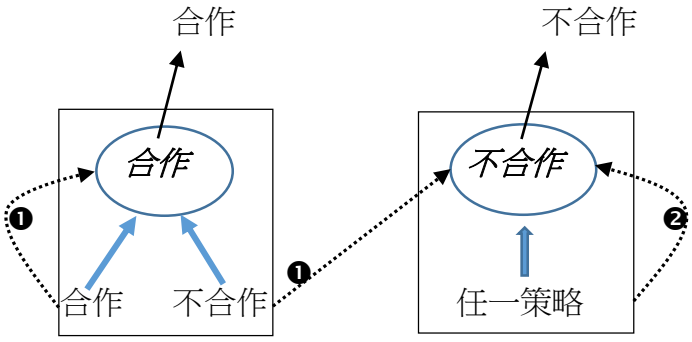

圖 2.4 嚴格策略的兩狀態自動機

可以說，以牙還牙策略，是針對對手採不合作行動時，隨即給予一期處罰(即我跟進採不合作行動、拉低對手報酬)；而嚴格策略則是針對採不合作行動的對手，給予永遠無限期的處罰(即我永遠採不合作、永遠拉低對手報酬)。處罰期愈長，則彼我雙方處於低報酬的時期愈長，長期而言，彼我都沒有得到好處。但處罰期太短，則或許對手受損不大，而不足以嚇阻其之不合作。於是，一個適當 n 期的處罰，也可以被設計出來。

多狀態自動訂價演算機

(n+1)個狀態的自動機，例如處罰 n 期的重複賽局。假設演算法給定初始狀態(s_i^0)仍為合作狀態(則我必選擇合作)。若既存合作狀態而對手輸入合作行動，則下一期仍為合作狀態(我必再合作)；若既存合作狀態而對手輸入不合作行動，則下一期為第 1 次處罰狀態(我將不合作)；若既存第 1 次處罰狀態，不論對手輸入何種行動，下一期為第 2 次處罰狀態(我必不合作)；…；若既存第 n-1 次處罰狀態，不論對手輸入何種行動，下一期為第 n 次處罰狀態(我必不合作)；若既存第 n 次處罰狀態，不論對手輸入何種行動，下一期都為合作狀態(我必重回合作)。於是共有 n+1 個狀態：一個合作狀態、n 個序列處罰狀

態。其演算時序示意如圖 2.5。

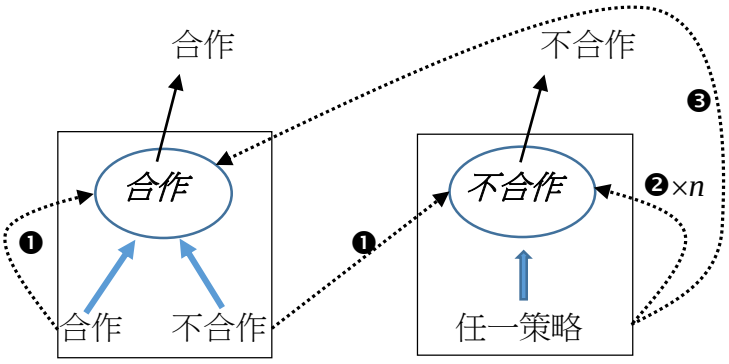

圖 2.5 處罰 *n* 期策略的多狀態自動機

前述過程演繹，說明兩廠競爭已轉變為兩個自動演算機的競合(M_i 與 M_j)，由於自動演算機為廠商所選定，因此一些文獻就稱這些自動演算機為其廠商之代理(agent)，或稱其為智能體 (intelligence agent)。智能體將彼此競爭，並自所有可能策略中(例如前述的四個策略)，選出一個可以獲取最大利潤者。令 $s^t = (s_i^t, s_j^t)$, $t = 1, 2, \ldots$.是自動演算機制的系列狀態組合，而令$a^t = (a_i^t, a_j^t)$, $t = 1, 2, \ldots$ 則為重複賽局中系列實際策略(行動)組合。

在演算自動機互相交手中，根據 Rubinstein (1986)所描述，一般會有兩個時期，第一是引介期(introductory part of the play)，假設是由第 1 期至第 t_1 期；另一個是循環期(the cycle of the paly)，假設為第 t_1+1 期至第 t_2 期(故共 T 期 = t_2-t_1+1)。引介期是彼此互動調整期間，目的在於「互相學習」，然後底於穩定結果並持續至終。當長時期維穩於一特定結果時，這時期即為循環期。於是，決策者 i 的平均報酬，被定義為循環期內的單期平均報酬，亦即$\pi_i(M_i, M_j) = \frac{1}{T}\sum_{t=t1}^{t2} u_i(s^t)$。對一決策者 i 而言，一個最佳自動演算機，即是給定對手自動機之下，帶給 i 更大期均利潤、或相同期均利潤而有更小運行狀態者[31]。

[31] 達到相同功能的有限自動演算機中，具有相對最小狀態個數者，則存儲空間愈小，成本可以愈小。狀態數目常被用來衡量有限自動演算機的規模(size)。

第三節 學習型訂價演算法

學習型演算法(Learning algorithm)被用於機器學習中，是幫助推進模仿人類學習過程的一種演算法；方法與技術，種類很多，例如包含羅吉斯回歸、線性回歸、決策樹、隨機森林(random forest;包含多個樹狀分類器的集合)、最近鄰居法(nearest neighbors; 又稱 KNN 演算法)[32]、以及神經網絡(neural network)。不論哪一種運算方法，其共同目的都在於從資料數據中實驗或訓練，達到學習，然後建構、描摹、或「攝影」出真實世界模式。

在演算法發展到可以教導機器學習後，人工智慧(Artificial Intelligence; AI)成為一個非常有效的工具。AI 是電腦科學中很大的一個支脈，研究與設計智能體(intelligent agents;智能代理人)，因為這些智能體可以執行很繁重困難的任務，而足以被認為具有智能。機器學習(Machine learning; ML)[33]是 AI 的子領域，藉由資料數據與經驗中不斷重複學習的演算法，設計出具有智能的自動裝置。

機器學習演算法(machine learning algorithms)，依據其學習型態，大抵上可以區分為三個大類：

(一)督導式學習(supervised learning)

演算法利用一組標籤化數據樣本來學習出一個通用法則(general rule)，藉此法則來應用於模型或對於未曾標籤數據進行識別並給予標籤。

一般而言，收集到的資料數據，是自然數據或者是人類產生的數據，可

[32] 這是用於圖形辨識。操作時，先輸入包含特徵空間(feature space)中的 k 個最接近樣本，然後演算法會輸出一個分類族群，或者利用回歸輸出該物件的屬性數值，是一種無母數統計方法。

[33] 機器學習源自於型態識別(pattern recognition)與學習理論(learning theory)的研究與發展。電腦演算法由資料數據中自動發現規律性，並藉此採取動作把資料數據進行不同類型分類，這即是一般所謂的型態識別，亦常翻譯為圖形識別。當類型愈多，則狀態可能愈多，於是每期的識別次數就愈多，也就愈為費時與燒錢。

能是圖片、音頻、視頻、新聞稿、推特、或 x 光影像…等等各類型，是純粹的原始資料，並沒有對其進行任何解釋或標示，我們稱此為「未標籤化資料(unlabeled data)」。取用一部分未標籤化資料，針對其內每一部分給予一個有意義且可代表其內容訊息的標籤或劃分，就成為「標籤化資料(labeled data)」。例如，標示含牛圖片為牛、含馬圖片為馬，標示該音頻資料中所講出的文字、該視頻資料中所進行的動作、該新聞呈現的主題、該推特頁面中的總體情緒狀態、該 x 光片中斑點是否為癌等等。一開始，這個標籤化動作須由人類來做，然後餵給電腦，讓它不斷的重複訓練，以學習識別這些數據資料與其標籤意義的關係，定形慣化成一套映射函數(識別函數)，作為往後識別資料的通用法則。形成識別函數後，再取另一部分未曾標籤的數據資料，測試該演算法正確識別的準確度(此為交叉驗證 cross-validation)。這個過程即是機器演算法的訓練階段(training period)，經此之後，該演算法即可被運用於模型。

督導式學習的養成與訓練，通常是在學習形成一個映射函數，這個函數可以是一條回歸函數，於是給定輸入項時就會輸出一個數值預測；可以是一個分類方法，而輸出一個類別；亦可以是一組結構化輸出，輸出一個向量且呈現各元素之間的關聯。

(二)無督導式學習(unsupervised learning)

演算法機器從無標籤、無分類、無型態的資料數據中，不斷的測試與學習，企圖從中識別出資料數據間所存在的共通性，然後對於新輸入的每一新資料數據進行判斷是否存在著這一個(些)共通性；並於判斷存在何類型共通性後，據以進行該有的回應動作。

這一學習模型並無標籤化資料作為訓練階段，機器必須透過尋找資料的特徵，自己進行分類。因此在學習識別潛在分類的過程中，常會利用一些數學集群(clustering)分析，以對於數學性質的最大化或最小化過程，區段分塊成

集群，而不是(像督導式學習)企圖依了解資料的正確內容來進行分類；因此，無督導學習又稱為無督導集群(clustering)。無督導學習亦可學習構成一個機率密度函數，於是給定一個輸入項，就會產出一個預測發生的機率值。透過無督導學習，往往可以識別出資料數據中所隱藏的結構與型態。

(三)半督導式學習(semi-supervised learning)

督導式學習仰賴人工就資料數據進行標註，機器學習出來的結果，正確性比較高，但很費人力成本。無督導式則是由機器透過大量資料數據尋找特徵並進行分類，誤差較大，但節省人工。半督導學習，則是只標註少部分資料，訓練電腦透過這些資料找出特徵，再對其它資料進行分類。是目前較常用的方法。

事實上，無督導式學習的結果若被人類發現有誤而予以糾正，此時智能體即成為督導式學習。例如郵件演算法自動篩檢垃圾郵件，一旦我們發現錯誤而從垃圾桶中拉回該郵件，演算法即獲取該類型「不是垃圾」標籤識別，此一步驟即又是督導式學習。因此，半督導式學習是常出現的一種學習模式。

(四)強化式學習(reinforcement learning)

機器學習演算法的學習模式，一般分類大抵就是前三項：督導式、無督導式、及半督導式。但亦有文獻將強化式學習列為另一項，因為人類為其建構了一個「選對獎勵、選錯沒分」的設計，讓機器於試誤中自學出對與錯。「選對獎勵」類似於督導模式，惟此模式並非透過標註資料，而是透過獎勵的累積績效值。

所以，強化式學習是不標註任何資料的，但會告知電腦其選擇的某一步是正確或是錯誤(此即當下決策所處的環境狀態與所欲達成目標)，然後由機器不斷的逐步嚐試、得到正確與否的回饋、再綜合歷史經驗進行另一步決策，

不斷的「嚐試與失誤」、不斷的學習，然後尋找出可以最大化目標值的一個行動策略[34]。有別於督導式學習，給予標註資料以學習正確答案；強化式學習雖不進行資料標註，但會給予逐步結果是正確與否的評比(獎勵值)。因此，強化式學習是一種「目標導向(goal-oriented)」演算法，設計者給予一個特定目標，讓機器透過邊做邊學而知如何達到該特定目標，也可邊做邊學而知如何在許多步驟之後達成該特定目標的最大值。例如，最終可以正確的辨認出長頸鹿，或在一個賽局中最終贏取最大分數。

這類型演算法的學習，可以從空白紙開始，然後在適當條件下，學習並達到超人類的表現；其學習過程，一如小孩成長，做錯決定則受處罰、做對決定則給獎勵。長期正確的某一決定會累積出更高的獎勵值(經驗值)，從而會有更大機率於未來再次被選為決行，即是「強化(reinforcement)」之由來。因此，在強化式學習中，預期的長期報酬現值(Value)與短期獎勵(Reward)是最重要元素，是一種把過去經驗形成回饋循環圈(feedback loop)的學習過程。

Q-learning

目前在實務應用上，強化式學習演算工具普遍使用 *Q* 學習途徑，也是演算法相對最流行的模型。於是，不具資訊領域知識者，要確實有感覺的了解訂價演算法邏輯，則理解 *Q* 學習的逐步學習過程，當是一個最佳途徑，也可說，是一個不得不選擇的途徑。

自動機演算法每一時刻都會偵測其所處的狀態(state; $s^t \in S$)、據此選擇一個行動(action; $a^t \in A$)，並獲得立即報酬(immediate reward; $r^t \mid s^t$)，而狀態隨後進行更新，進入了下一期($s^t \rightarrow s^{t+1}$)。在下一期狀態下，自動演算機再據此狀態而選擇了一個行動、並獲得了新一期的立即報酬($r^{t+1} \mid s^{t+1}$)。演算法依據達成目標的設定，而選擇一組各期行動(即構成一個策略)，即所謂最佳策略(strategy or policy)；在最佳策略上的各期行動則是一個最佳行動。自動演算機

[34]所謂動態環境，例如是駕駛中的車輛、正玩中的遊戲，其所產生的是分秒的串流數據。

的演算過程，如示意圖 2.6：

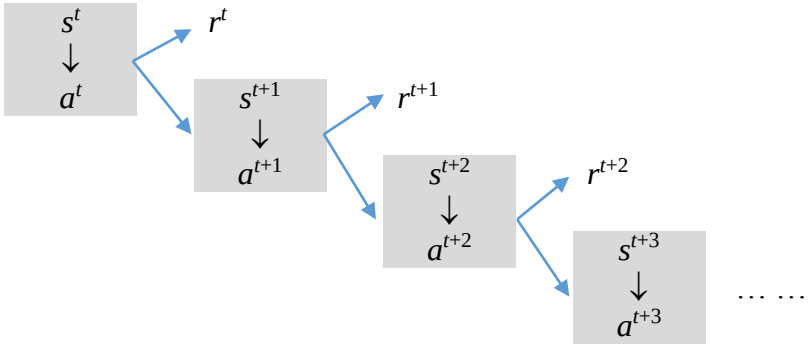

圖 2.6 自動演算機演算程序

強化學習的目的，就是要找出一個最佳的策略，可以讓長期總報酬最大。由於既有狀態是前一期狀態的函數、前一期狀態則又為其前一期狀態的函數，亦即既有狀態中的訊息包含了過去歷史經驗，只要依據當期既有狀態就可以推斷出未來狀態[35]。

每一狀態下的行動選擇，都會獲得一個立即報酬(immediate reward)，並由此進入一個新狀態，這個狀態其實可視為一個影響「長期奔向目標途徑」好壞走勢的起點。因此，若以長期報酬最大為目標，則在「大的立即報酬」與「優良的新狀態起點」間，有些時候可能會出現一些抵換(tradeoff)。也就是說，一個獲取長期最大預期價值的策略，其每一單期行動(action)並未必一定是最大即期報酬。自動演算機透過不斷的實驗與訓練，會找出一個讓預期長期價值最大的策略，此即為最佳策略，而這個最佳策略即指導著每一期該選擇怎麼樣的行動。然而，「新狀態所帶來的未來可能長期利益」，在當期時，實際上並未發生，因此，自動演算機會以過去歷史經驗來進行推估，這就是機器的學習過程。

學習理論主要有兩支，一為信念導向模型(Belief-based model)、一為選擇

[35] 若由機率來表示，基於過去各期狀態與基於前一期狀態所推估的下一期發生機率是一樣的：$\text{Prob}(s^{t+1}= s' \mid s^t) = \text{Prob}(s^{t+1}= s' \mid S^1,\dots s^t)$。

強化模型(Choice reinforcement approach)。前者假設參與者追蹤著其他人之過去決行歷史(history of previous play)，藉此形成這些人未來會怎麼做的認定(belief)；一旦我「認定」對手會怎麼做，則將傾向於選擇一個最佳反應(best-response；即讓自己預期報酬最大)。後者則對每一策略於過去所產生報酬為評比，基於累積評比(即強力度 stock of reinforcement)加權強化每一策略優劣，亦即每一策略將以過去績效「強化(reinforced)」。信念導向模型主要被運用於決策與賽局中，而強化模型則主用於心理學；前者在使用訊息上，並不特別去呈現被選中策略的過去績效，而後者不會去呈現別人過去如何決行的歷史。傳統理論中的強化式學習，多數利用被動式學習(passive leaning)，接受設定的訊息；而在 *Q*-學習中，則是透過實驗探索，不斷與環境互動互撞而累積經驗成長，可歸類於主動式學習(active learning)[36]。

Q-learning 對每一狀態上各行動所能協助奔向目標的價值，給予一個基於歷史經驗累積的評分，稱為 *Q* 價值。因此，若以狀態為列、行動為欄，則可構成一個「狀態-行動」*Q* 值矩陣，這是自動演算機的腦袋(記憶)，會隨著逐次碰撞真實環境心得而逐次的不斷更新，並予以記憶住。

一自動演算機於對方行動選擇後，其當下所處的狀態就確定下來(即 *Q* 值矩陣中的某一列)，於此既定狀態下，該自動演算機即可評估每一行動會帶來的各個相對應價值(即累積績效值、累積經驗值)，因此 *Q* 值又被稱為一個「行動-效用」函數(action-utility function)、或一張「行動-效用」對照表。由於某一既定狀態(s)下，自動演算機選擇了某一行動(a)，除了隨即獲得報酬 r 外，並將進入一個新狀態(s')，自動演算機於此新狀態上再次的選擇行動(a')、再次的獲得立即報酬(r')、並再次的進入另一個新狀態，如此相同的模式不斷重複。只是，每一期都產生了一個報酬值、也都會進入一個新狀態，因此，某一當期狀態(s)之某一行動(a)的 *Q* 值，可計算為 $\max Q(s,a) = r + \max Q(s',a')$，其中

[36] Calzolari, G., Denicolò, V. and Pastorello, S. (2019a), Artificial intelligence, algorithmic pricing and collusion. SSRN.

上標 prime 代表新的一期，這是貝爾曼方程式的基本模式(容後詳述)，而且 $Q(s',a')$是自動計算機於當期而對下期的預期，其最大值之推估必須從其經驗記憶中去擷取。隨著期數推移，自動演算機的歷史經驗愈來愈豐富，因此某時期出現(或再出現)的狀態-行動組合值 $Q(s',a')$，會具有更新的學習經驗來推估其值，就愈會精良、而漸漸收斂於真實價值。這是學習過程。當然在狀態 s 之下，Q 值最大者即代表該行動 a 具有協助奔向目標的最大績效。

當整個 Q 價值矩陣表數據趨於收斂時，即自動演算機學習完成。在學習過程中，面對著某一狀態，自動演算機的目標是最大化長期總體利益；於是若一味依記憶固守著單期最大 Q 值，則於某一狀態下必然是固定的擇取某一行動，結果，無法充分去碰撞學習真實環境，也就無法挖掘更多環境訊息與更多優良策略。因此機器學習在行動選擇上，會分配選擇機率給予非當前最大 Q 值的行動。有的是依據經驗 Q 值分布各個行動機率值，更常用的是，給予當期最佳行動一個很大機率分配值，然後剩餘的比率則均勻分布於所有其它非當期最適行動上。

透過分配非當期最適行動亦有被選中機率，可以挖掘此時非最佳行動於面臨各狀態時的可能表現程度，才能藉此進行評比各行動的因應績效，也從而挖掘、測試、與收集出更多新變動的環境訊息(例如需求或市場狀況的變化)，對未來的決策品質更能掌握。這一模式即為 exploration (開發探索、林中兩鳥)，通常亦被稱為「實驗」；而對於當期最佳行動給予一個很大的分配機率，即是 exploitation (緊握榨取、手中一鳥)。

假令決策者觀察到狀態 $s^t \in S$、而後選擇行動 $a^t \in A(s^t)$、並得到報酬為 r^t，於是系統依機率函數 $F(r^t, s^{t+1} \mid s^t, a^t)$ 進入下一時期狀態 s^{t+1}。在簡單設定下，r^t 與 s^{t+1} 可以是簡化為(s^t, a^t)的確定函數。

由於求解過程使用不斷的迭代法，函式中往往只會出現當期(設為 t)與下一期(t+1)的相關性，於是文獻中時常令無上標的時序變數表示當期、而有上標「′」的變數則代表下一期，例如：t 當期狀態 $s^t = s$、下一期(t+1 期)狀態則

表示為 $s^{t+1} = s' \in S$；t 期行動 $a^t = a$、而下一期行動則表示為 $a^{t+1} = a' \in A$...等等。

決策者的目標在最大化報酬串流 $E[\sum_{t=0}^{\infty} \delta^t r^t]$，其中$\delta$ 為折現因子。假設處於當期狀態(s)，自動演算機所選擇的當期行動(a)，必須有助於建構奔向長期目標的有利途徑，這就是最適策略。在最適策略之下，抉擇的行動未必是獲得當期最大 Q 值者。若遵守最適策略，則在當期狀態 s 下所選擇的最佳行動 a，其預期長期價值 $V(s)$，邏輯上，必然等於由下一期狀態(s')起的預期長期價值 $V(s')$加上當期立即報酬，亦即 $V(s) = r + \delta V(s')$，其中δ為折現因子。以方程式來表達：

$$V(s) = \max_{a \in A}\{E[r|s,a] + \delta E[V(s'|s,a)]\} \qquad (2.1)$$

此即貝爾曼價值函數(Bellman's value function)[37]，是求解動態規劃問題上的常用方程式。機器學習的 Q 價值函數，是一個追求最適策略的預期長期價值，故可以式(1)模式來表示成(2.2)式：

$$Q(s,a) = E[r|s,a] + \delta E\left[\max_{a' \in A} Q(s',a')|s,a\right] \qquad (2.2)$$

- 當期狀態 s 時採行動 a 的長期預期價值
- 預期當期立即報酬
- 預期新產生狀態 s' 下，搜尋記憶中的最大 Q 值(與特定行動)

式(2.2)是自動演算機於某一回合出現組合(s,a)，所得到的該狀態行動預期長期價值。由於自動演算機對於真實環境是無知的，故必須透過不斷的決策碰撞環境以獲得真實回饋，然後逐步調整與修訂出任一組合(s,a)貼近真實

[37] 關於價值函數，請參閱文末附錄「馬可夫過程與貝爾曼方程式」。

評價的 $Q(s,a)$。所以，我們定義(2.2)式是一輪試驗所得的 $Q(s,a)$值。

事實上式(2.1)與式(2.2)，意義上是相通的。我們同時以選擇行動 a 來最大化(2.2)式兩端：

$$\max_{a\in A} Q(s,a) = \max_{a\in A} E[r|s,a] + \delta E\left[\max_{a\in A}\max_{a'\in A} Q(s',a')|s,a\right]$$

然後定義 $\max_{a\in A} Q(s,a) = V(s)$，則上式變為：

$$V(s) \equiv \max_{a\in A} Q(s,a) = \max_{a\in A} E[r|s,a] + \delta E\left[\max_{a\in A} V(s'|s,a)\right]$$
$$= \max_{a\in A}\{E[r|s,a] + \delta E[V(s'|s,a)]\} = (2.1)$$

亦即，只要定義 $V(s) \equiv \max_{a\in A} Q(s,a)$，則 Q 價值函數即等於貝爾曼方程式。文獻上之所以用 Q 命名，是因為 Q 值是行動 a 的累積經驗價值，可被視為行動 a 的「Quality」[38]。

在不知基本模型之下，亦即不知下一期狀態機率分布函數 $F(r^t, s^{t+1}\,|\,s^t, a^t)$ 之下，Q 學習是一個估計 Q 價值函數的有效方法。這個估計方法，必須假設有限元素 S 與 A 的前提、而且 A 並非決定於 S，如此一來，Q 函數即可表示

[38]人類或類神經代理人(智能體)選擇一個策略(strategy)做為某一段時期內的政策(policy)，於此政策指導下，在每一期中選出最佳行動(action)，而獲得報酬。長期下來，每一行動會累積出不同的報酬值(或績效)，表彰出該行動(策略)在長期競爭中之優劣，並於機器學習中提供未來時期再被選取的機率高低依據。我們可以如此想像：AI 智能體手上擁有許多武器，在面臨某一特定環境的時段中，他會選定某一武器作為手段，在此手段政策下，再於每一期不同狀態中擇取行動。為了測試不同武器的厲害，對於那些未被選定為手段者，在每一期都會偶而有一些小機率被推出來試用，長期下來，藉此即可以累積出足以評比每一武器優劣的經驗值，由此得知，最佳武器是何者。武器對智能體就是一種演算法、一種策略(strategy)或政策(policy)；武器可以多種，而行動則是在某一特定策略指導下而選用的每一期動作，經驗值則是各策略的績效累積值。此一績效值該如何進行累積而為指標，各有不同，例如前一節所介紹的引值導向(attraction-based)或 Q 值計算。如果 AI 手中只有唯一策略，則經驗值(績效指標)等於被降階為對各個「行動」的優劣評比，這即是本文數學所呈現的簡化模型。

成一個 $Q = S \times A$ 的矩陣[39]。Q 學習演算法，通常由一個給定的起始值 Q^0 開始，利用不斷重複模式，對 Q 矩陣進行估計。

假設演算法在 t 期，面臨 s 狀態而選擇 a 行動，則將隨即觀測到立即報酬 $r^t(s,a)$與新一期狀態(s^{t+1} 或簡易表達為 s')，這是真實環境對演算機行動的反應。同時，自動演算機在 t 期時對於新一期狀態 s'，是一種預期，尚未實際碰到，故只能從其記憶中搜尋出可以預期得到最大 Q 值的一個行動，亦即 $\max_{a \in A} Q^t(s', a)$。於是，自動演算機身處狀態 s 而採用行動 a 時，可以學習得出組合(s,a)的預期新價值：$r^t + \delta \max_{a \in A} Q^t(s', a)$，其中$\delta$為未來價值的折現因子。然而，在記憶中其實也已經存在有 $Q(s,a)$的值，故面對這一新學習所得的經驗值，自動演算機採取了隨時更新法則：

新 $Q(s,a)$ = (1-α)[舊 $Q(s,a)$] + α[新一輪學習值]

= (1-α)[舊 $Q(s,a)$] + α[式(2.2)]

$$\Rightarrow\ Q^{t+1}(s,a) = (1-\alpha)Q^t(s,a) + \alpha\left[r^t + \delta \max_{a \in A} Q^t(s', a)\right] \qquad (2.3)$$

- 新 (s,a) 組合 Q 值
- 舊 (s,a) 組合 Q 值
- (s,a)組合的的當期立即報酬
- 於新產生狀態 s'下，搜尋記憶中的最大 Q 值(與特定行動)

Q 值的不斷更新累積(即經驗值累積)，就是學習過程，其中第二項(新一輪學習值)，就是演算機學習的來源，而$\alpha \in [0, 1]$，代表學習速率(learning rate)。若$\alpha = 0$，則面臨狀態 s 時，機器人將一律只選擇過去經驗中使 $Q(s,a)$最大的行動 a，一律只憑著過去記憶。若$\alpha \neq 0$，則過去經驗只占一部分權重，另一部分則是來自於新遭遇的增添。α愈大，代表愈關心未來、愈令各個非當期最佳

[39] 在許多的模擬文獻中，當期狀態即競爭對手的當期策略選定，亦即，我於確認對手策略(即當期狀態)後，做出反應動作。於是，各個可能狀態搭配各個可能反應動作，得到各個不同的 Q 值。

行動亦有機率被選中、亦是更多學習。然而，較大的α反而有可能會破壞學習，尤其當實驗程度相對廣泛時，自動演算機將會很快的忘記一些過去所曾學習到的經驗。因此，在電腦科學領域中，一般都是令α值大約為 0.1。在每期新經驗增添過程中，那些當期未被選中的所有其它行動(或非當期狀態者)，即 $s \neq s^t$ 且 $a \neq a^t$，因沒有新遭遇，故此期就沒有 Q 值更新，亦即 $Q^{t+1}(s,a) = Q^t(s,a)$。

透過不斷的實驗、不斷的累積與更新 Q 值，終至於收斂，訂價演算法即可學習到最適行動為 $a(s) = \text{argmax}\,[Q(s,a)]$。為了逼近真實 Q 矩陣，自動演算機並不是一律從記憶中選取當期狀態下的最大 Q 值行動；即使是那些非最大 Q 值行動，也都分配給予小機率可以被選到，藉以開發並收集新資訊(此為 exploration 開發模式)，以改善未來決策。若分配更大機率於非當期最適行動，即意味著分配予當下可獲取最大 Q 值的最適行動(此為 exploitation 榨取模式)機率變小；兩者之比重分配，目前在經濟文獻上並未尋找出一般性最適法則。基本上，探索學習雖有助於協助未來更優決策，但卻很耗費成本。而在 Q 學習演算法領域中，並不必刻意尋找這一配比如何可以最佳，而是直接令其為外生指定[40]。文獻中最簡單的開發政策，一般稱其為ε-貪婪模型(ε-greedy model)，賦予當下最適行動(即當前狀態下帶來最大 Q 值的行動)一個很高機率值ε，然後剩餘的機率 1-ε 則均勻分布於所有其它非當期最適行動上；進階設計中，可令 1-ε 依相對 Q 值分配於當期非最適行動上，亦可令ε 隨時間改變而遞增。例如，令$\varepsilon^t = 1 - e^{-\beta t}$；則當 t=0 則ε=0，$t \to \infty$則$\varepsilon \to 1$，意味著，一開始是純隨機選擇行動，而隨著時間愈久，則愈來愈加重對當前最大 Q 值行動的貪婪。其中，$\beta > 0$，是探索參數(exploring parameter)，其值愈大將愈加速貪婪增長，亦即加速探索的減低。

Q 學習之所以普遍，是因為只要符合一些簡單而一般性要件，則 Q 矩陣就會收斂至最適策略：第一，探索程度須隨著學習愈多而愈遞減；第二，任

[40] Calvano e al (2019a)。

一狀態的所有可用行動都具有會被選中的機率；第三，當時間趨近無窮大時，則貪婪行動必須趨近 1。然而，*Q* 學習的演算過程卻緩慢的，因為它每一次就只能更新矩陣中的一個值，而要讓矩陣能趨近真實值，則每一格數值往往必須被碰到非常多次數才可。於是，面對較複雜狀況(例如狀態集或行動集較大)時，要達到收斂則極為費時。

Q 學習仍然有其致命弱點。在與對手競爭的過程中，我之行動是取決於過去歷史過招，我的行動則帶出一個新的狀態，於是狀態的出現，受到過去歷史行動的影響。在一個重複賽局中，過去歷史行動數量龐大，隨著競爭時間愈久，狀態集合將會幾何倍數膨脹，無法負擔。為了解決這個問題，基於有限理性假設，一些文獻提出，儘管是機器人，其有限記憶也是幾期而已(例如 *k* 期)。另外，由於新狀態的出現取決於所有競爭者行動，但對手行動選擇可能每期不一樣，或許基於他也正在實驗或學習之中，則機器人在最適化過程中所面對的環境將呈現非定態模式，這也常常導致 *Q* 矩陣無法收斂。事實是，自動演算機會把對手行動視為環境的一部分，而無視於對手可能是與我進行著策略性競爭互動。

一個手算簡易 Q 學習說明

最後，我們以一個簡易的迭代法 *Q* 學習，做為一個理解上的範例[41]。假設一個機器人(智能體)可能在台北市五個地點(0,1,2,3,4)，目標是選搭公車到達第六個地點(假設為公平會、地點 5)。任一地點 *i* 開往地點 *j* 的公車即為行動 *j*，故理論上行動集合中有六個行動(0,1,2,3,4,5)可供選擇。實際上，並不是每一地點都有六線公車，因此，只有確實存設的公車線才是該點上的可用行動(possible actions)，而不存設的公車線則是永遠不可能於該點被選到的行動。若 *i* = 5(在點 5)，則選擇公車線 5 到達 5 是必然、代表持續停留在地點 5；但

[41] 改寫自 Mnemosyne Studio, Q-Learning: Step-By-Step Tutorial.

若 $i \neq 5$(不在點 5)，則因地點 i 並非目的，故選擇公車線 i(而停留於 i)是永遠不會被選的動作。前述的六個地點，是機器人所可能身處的狀態(state)。

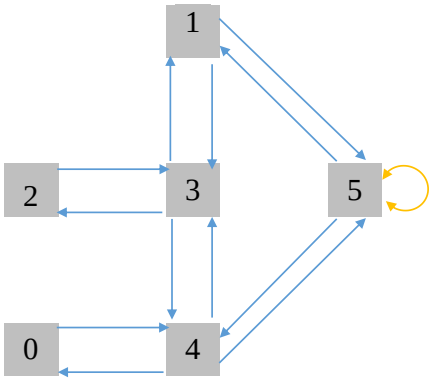

圖 2.7 機器人所處真實環境

假設這一城市的交通網線(即狀態與行動的關係)，如圖 2.7 所示。例如，狀態 1 有 3 線與 5 線公車可供選擇、狀態 2 僅有 3 線可選擇，依此類推說明。而在狀態 5，除了有 1 線與 4 線公車可選擇外，另有一本身迴圈，代表狀態 5 本身已是目標地，當機器人處於狀態 5，自當會持續留在這個狀態。這類型的目標被稱為「吸引目標(absorbing goal)」。

前述說明，即是一個機器人所面臨的真實環境，而為了機器人運算，我們必須把環境以報償處罰機制改寫，我們假設，於某一狀態下，未設置的公車線，機器人當然無以選擇，因此這些不可用公車線將一律以-1 來表達其之不可用；而於此一狀態下可用公車線(possible actions)，機器人自會從中擇一，所被選擇者若未直達目的地(狀態 5)，則該行動將給予報酬 0，而直達目的地的行動則將給予報酬 100。因此，我們建構了表 2.1 的真實環境獎懲矩陣(Reward matrix)，用以描繪機器人欲達目標時所面對的真實環境。然而，這一真實環境是是機器人完全不知的，他必須透過逐步學習與試驗來探索出真實世界的這一面貌[42]。

[42] 於此，為了簡易，我們假設機器人知道狀態集與行動集。應用上，我們亦可假設狀態並

表 2.1 真實環境獎勵矩陣

R

State \ Action	0	1	2	3	4	5
0	-1	-1	-1	-1	0	-1
1	-1	-1	-1	0	-1	100
2	-1	-1	-1	0	-1	-1
3	-1	0	0	-1	0	-1
4	0	-1	-1	0	-1	100
5	-1	0	-1	-1	0	100

機器人學習，我們必須給予一個腦袋，用以記憶長期的學習經驗。過去基於達成目標前提而有較優績效的行動，基本上要給予較高評價並記憶住，亦可用以作為下一期選擇行動時的參考基礎。為此，我們另外製作一張「狀態-行動 *Q* 值矩陣」，用來表達機器人腦袋(記憶)中，某一特殊「狀態-行動」組合的長期累積評價(以奔向目標而言)。一開始，機器人未有任何經驗，故大腦完全空白，也就是初始 *Q* 值矩陣每一元素皆為 0，如表 2.2。這是機器人一開始的量化認知。

表 2.2 機器人初始記憶

Q^0

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	0	0	0
2	0	0	0	0	0	0
3	0	0	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

非完全為機器人所知悉，則在學習過程中，機器人每發現一新狀態，就會在 *Q* 矩陣中新增添一列狀態。

假設機器人處於某一時點狀態 s，隨機選擇了特定行動 a，則特定「狀態-行動」組合(s,a)出現、且得到環境給予的當期立即報酬 $r(s,a)$，並隨即進入下一期新狀態(s')，此時將擇取記憶中讓狀態 s'得最大 Q 值的行動(設為 a')，亦即$\underset{a'\in A}{\text{argmax}}\{Q(s',a')\}$。這一隨機選擇，讓他學習了行動 a 在狀態 s 時可能帶來的價值，亦即 $r(s,a)+\max_{a'\in A}\{Q(s',a')\}$，這是一輪的學習新經驗，惟組合$(s,a)$已經有過歷史經驗值存在，因此必須予以更新。我們採用式(2.3)的更新法則：新 $Q(s,a)$= (1-α)[舊 $Q(s,a)$] + α[新學習值]。若不關心未來變化，就不須新學習，只須就記憶中擇取最大價值即可，亦即選取記憶中的最大 $Q(s,a)$。但若考慮未來可能性，就必須納入新學習心得一同考量，如同式(2.3)。於此，為方便手算操作過程，我們進一步簡化式(2.3)如下，並令δ=1、學習參數α = 0.8：

$$Q^{t+1}(s,a) = Q^t(s,a) + \alpha\left[r^t + \max_{a\in A} Q^t(s',a)\right]$$

我們以手算來呈現機器人學習的經驗值更新，並詳細的展現於表 2.3。智能體在無指導下(即無監督學習)，由某一狀態開始，接續一個一個狀態的移動，不斷經驗累積學習，直至達到目標，則此時完成了一回的探索活動；並隨即再啟動另一回合的探索。每一回合的探索，即等於一個訓練場合，於此中，智能體探索環境(即報酬矩陣)、獲得報酬、直到達標；一回合接著一回合的探索，則不斷的增進填實原本皆為 0 的初始 Q 值矩陣，而達到最適化達標途徑。

首先第 0 回合假設為機器人的開始，此時他的經驗值記憶是表 2.2 的 Q^0。在第一回合訓練中，我們設定他處於狀態 1，於是他有 3 與 5 的可用行動。假設他隨機的選擇到了 5，出現(1,5)的特定「狀態-行動」組合，此組合記憶值為 0、得立即報酬 100 (達標)、並進入新狀態 5(有行動 1,4 可選)，但不論是(5,1)或(5,4)，其記憶值為為 0，故新的 $Q(1,5)$ = 原 $Q(1,5)$ + 0.8[立即報酬

+$\max_{a\in A} Q^t(s',a)$] = 0 + 0.8*[100+0]=80，並進行此組合之記憶更新，如表 2.4 之 Q^1 所示。

表 2.3 機器人的學習與更新記憶過程

(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)
訓練回合	身處狀態 s	可用行動	隨機選行動 a	$Q(s,a)$	立即報酬 $R(s,a)$ (表 3.1)	下期狀態 s'	下期可用行動 a'	預期下期可能行動 Q 值 $Q(s',a')$	$Q(s,a)$記憶更新 =(5)+[(6) + 0.8*max(9)] (α=0.8)	更新後 Q 值表
0				0						3.2 Q^0
1	1	3,5	5	$Q(1,5)$	r (1,5)=100	5	1,4	$Q(5,1)=Q(5,4)=Q(5,5)=0$	0+0.8*(100+0) =80	3.3 Q^1
2	3	1,2, 4	1	$Q(3,1)$	r (3,1)=0	1	3,5	$Q(1,3)=0$ $Q(1,5)=80$	0+0.8*(0+80)= 64	3.3 Q^{2A}
	1	3,5	5	$Q(1,5)$	r (1,5)=100	5	1,4	$Q(5,1)=Q(5,4)=Q(5,5)=0$	80+0.8*(100+0) =160	3.3 Q^{2B}
3	1	3,5	3	$Q(1,3)$	r (1,3)=0	3	1,2, 4	$Q(3,1)=64$, $Q(3,2)=Q(3,3)=0$	0+0.8*(0+64) =51.2	3.3 Q^{3A}
	3	1,2, 4	4	$Q(3,4)$	r (3,4)=0	4	0,3, 5	$Q(4,0)=Q(4,3)=Q(4,5)=0$	0+0.8*(0+0)=0	3.3 Q^{3B}
	4	0,3, 5	5	$Q(4,5)$	r (4,5)=100	5	1,4	$Q(5,1)=Q(5,4)=Q(5,5)=0$	0+0.8*(100+0) =80	3.3 Q^{3C}
4	0	4	4	$Q(0,4)$	r (0,4)=0	4	0,3, 5	$Q(4,0)=Q(4,3)=0$ $Q(4,5)=100$	0+0.8*(0+100) =80	3.3 Q^{4A}
	4	0,3, 5	5	$Q(4,5)$	$r(4,5)=100$	5	1,4	$Q(5,1)=Q(5,4)=Q(5,5)=0$	80+0.8*(100++ 0)=160	3.3 Q^{4B}
...										
n										3.4 Q^n Q^{n*}

假設第二回合是處於狀態 3，其將有行動 1,2,4 可以選擇，並假設他隨機的選擇到行動 1，出現(3,1)的特定「狀態-組合」、此組合經驗值為 0、立即報

酬為 0、並進入新狀態 1(有行動 3,5 可選)，組合(1,3)與(1,5)分別記憶值為 0 與 80，故此時新的 $Q(3,1) = 0 + 0.8*(0+80) = 64$，並進行此組合記憶更新(表 2.4 之 Q^{2A})。由於此時進入的新狀態是 1，並未達到目標 5，故機器人會再由此狀態繼續學習。在狀態 1 之下，有行動 3 與 5，假設隨機的選擇到行動 5，將出現(1,5)特定組合、記憶值為 80、立即報酬 100、並進入狀態 5(有行動 1,4 可選)，但不論是(5,1)或(5,4)，其記憶值為為 0，故此時新的 $Q(1,5) = 100 + 0.8*(100+0) = 160$，並做了記憶更新如表 2.4 之 Q^{2B} 所示。因已達到目標 5，故此回合訓練結束，並啟動第三回合訓練。

在表 2.3 中，第三回合的訓練，我們假設機器人在狀態 1。學習過程一如前述，亦可由表中清晰解讀。不斷的訓練、不斷的學習，如表 2.3 中的第四回合、第五回合…一直不斷，則同一狀態行動組合不斷的出現、就愈增加真實價值認識，於是若再次碰到、則其所能帶來的累進經驗價值就會愈來愈小，這個特性展現於學習參數α，在數學意義上，它構成了等比級數累進概念。因為$\alpha < 1$，故等比級數累進終究會收斂，於是在相當多回合訓練後，Q 矩陣中的每一值都會趨於收斂、且會收斂於逼近真實環境的狀況。當收斂值出現時，我們說，這機器人的學習已經完成。例如本例將收斂於表 2.5 之 Q^n, 為了易於觀測，通常我們會以最大 100 來進行規整，如表 2.5 之 Q^{n*}。

表 2.4 機器人的記憶更新

Q^1　更新 Q(1,5)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	0	0	80
2	0	0	0	0	0	0
3	0	0	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

Q^{2A}　更新 Q(3,1)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	0	0	80
2	0	0	0	0	0	0
3	0	64	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

Q^{2B} 更新 Q(1,5)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	0	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

Q^{3A} 更新 Q(1,3)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	51.2	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

Q^{3B} 更新 Q(3,4)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	51.2	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	0
5	0	0	0	0	0	0

Q^{3C} 更新 Q(4,5)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	0	0
1	0	0	0	51.2	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	80
5	0	0	0	0	0	0

Q^{4A} 更新 Q(0,4)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	80	0
1	0	0	0	51.2	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	80
5	0	0	0	0	0	0

Q^{4B} 更新 Q(4,5)

State \ Action	0	1	2	3	4	5
0	0	0	0	0	80	0
1	0	0	0	51.2	0	160
2	0	0	0	0	0	0
3	0	80	0	0	0	0
4	0	0	0	0	0	160
5	0	0	0	0	0	0

表 2.5 完成學習的 Q 值矩陣

Q^{n} 最終收斂值

State \ Action	0	1	2	3	4	5
0	0	0	0	0	320	0
1	0	0	0	256	0	400
2	0	0	0	256	0	0
3	0	320	204.8	0	320	0
4	256	0	0	0	0	400
5	0	320	0	0	320	400

Q^{n*} 歸整於 100

State \ Action	0	1	2	3	4	5
0	0	0	0	0	80	0
1	0	0	0	64	0	100
2	0	0	0	64	0	0
3	0	80	51.2	0	80	0
4	64	0	0	0	0	100
5	0	80	0	0	80	100

前述說明中，於機器人所處的當下狀態，我們往往說他將「隨機的」擇取可用行動，這是學習過程所必須的。以上述的第三回合為例，所處狀態為 1、最新記憶為 Q^{2B}，於是在可用的兩個行動 3 與 5 中，顯然的 $Q(1,5)=106 > Q(1,3)=0$，若只著眼於當下最佳，則只要碰到狀態 1 就必然永遠選擇行動 5，如此一來，行動 3 就不會被選擇到，就永遠無法估計它的價值。而若是隨機選取，長期訓練下，行動 3 的價值即可以被估計出來。在更細密的機器學習中，也不純然是均等分配機率給予所有行動，而是會基於當下 Q 值高低進行機率分配，也就是，Q 值高者有較高機率被選中、低者則被選中機率較低。

基於最終收斂結果的表 2.5 之 Q^{n*}，我們把各「狀態-行動」組合的 Q 值，填寫於公車網路圖上。假設現在機器人被置於地點 2、目標依舊是地點 5，則由學習的歷史，即可以輕易知道帶給他最大價值的到達路線，亦即最佳策略。如圖 2.8 所示，途徑 2-3-1-5 或 2-3-4-5 具有最大價值，是本例的最佳策略。最佳策略是達到目標且具有最大價值的一種安排，在每一時點選擇一個服從於此一安排的行動，即為該時點的最佳行動。須注意的是，最佳行動是基於有利於達成總體(或長期)最佳化而言，與只看短期最大 Q 值行動有所不同。

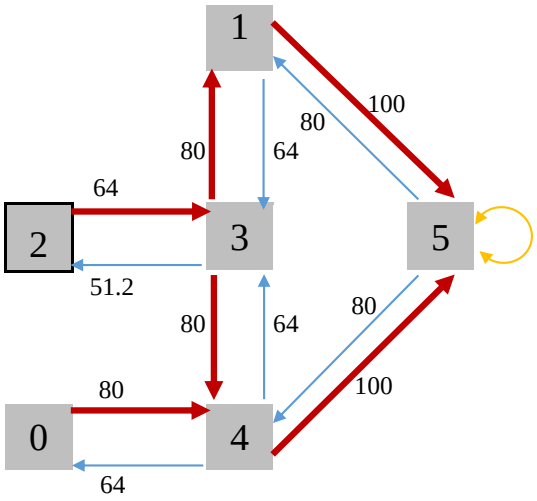

圖 2.8 機器人完成學習的最佳策略

Attraction-based learning

假設，決策者 $i = 1, \ldots, n$、其策略集 $S_i = \{s_{i1}, s_{i2}, \ldots s_{ij}, \ldots s_{i.mi}\}$、利潤表示為$\pi_i(s_i, s_{-i})$。在第 t 期時，假設決策 i 之實際決策記為 s_i^t，而他人的實際決策則記為 s_{-i}^t，於是第 t 期 i 之利潤記為$\pi_i(s_i^t, s_{-i}^t)$。為了評估每一策略的過去績效，文獻上用「引力值(attraction)」來計算[43]，以$A_i^{j,t}$表示決策者 i 於第 t 期採用 j 策略(s_i^j)後的引力值，每一策略初始值(事先給定值)則可表達為$A_i^{j,0}$。若 j 策略是第 t 期最佳反應策略而被選中(即$s_i^j = s_i^t$)，實際得報酬$\pi_i(s_i^t, s_{-i}^t)$；但為了持續因應長期競爭且開發未來可能更好結果，其它非最佳反應策略(即當$s_i^j \neq s_i^t$)仍應保有於未來出線的可能性，於是我們依經驗估計其可能得值$\pi_i(s_i^j, s_{-i,t})$，並乘以以δ<1 折扣權重表示其並非最佳策略，故得 $\delta\pi_i(s_i^t, s_{-i}^t)$。我們將以$wp_i^{j,t}$表達前述每一策略之當期預期利潤，以茲簡化；如此一來，則策略 j 於第 t 期引力值累積計算為：$A_i^{j,t} = \varphi A_i^{j,t-1} + wp_i^{j,t}$，φ < 1 亦表示對過去引力值之折扣權重，此即進行「強化」選擇過程。在第 t 期決策完後，隨即可以得出每一策略之引力值，依引力值大小分配下一期每一策略被選中的機率值，分配分式很多，例如：

$$P_i^{j,t+1} = \frac{e^{\lambda A_i^{j,t}}}{\sum_{k=1}^{m_i} e^{\lambda A_i^{k,t}}}$$

於是，一策略過去績效愈好、被選中機率愈大(亦即愈被強化)，而且儘管非目前最佳策略者，仍然有機率會被選中，藉以保持對未來長期變化中任何可能更好選擇之開發。

解決 *Q-learnig* 的缺點：深度學習

簡單 *Q* 學習雖目前被廣泛運用於電腦科學，但卻存在兩個缺點。第一，

[43] Camrer, C. and Ho, T-H. (1999). Expected-weighted attraction learning in normal form games. Econometrica 67 (4), 827-874.

無法處理連續型狀態與行動空間集，只能處理離散型狀態集與行動集，而且離散度愈大，則學習速度愈慢。第二，演算法不知他正在一個競爭賽局中，因此他們的學習是不具策略性的。於是深度學習被進一步的研發出來。

當狀態與行動集變成連續型的，則 *Q* 矩陣就成為一個平滑函數，而深度學習依舊循著(3)式 *Q* 學習過程來更新其值，方法上往往是利用多層次神經網絡來執行。如果狀態與行動是有限但很龐大時，則會利用平滑概似 *Q* 矩陣來加速學習過程；於這方法中，演算法所更新的，不僅僅是每期當期選定行動之 *Q* 值，連同其鄰近行動 *Q* 值也會一併被更新。簡單說，深度學習的邏輯是把(3)式右側的兩項，分開而各別進行更新，這一點正是人類推估時所無法作到的步驟，也從而給深度學習在複雜策略任務中，可以達到一些超人類績效。

深度機器學習(Deep machine learning)，簡單說，就是「比較多層神經傳導」的類神經網路學習，因此，一些深度學習架構也常被稱為深度神經網路(Deep Neural Network; DNN)。由接收端神經元開始、直到產出端的神經元，當中經過許多層次(每層又有許多神經元)的轉化與分析，這中間層次過程即所謂「隱藏層(hidden layer)」，一般只要隱藏層大於三層就會被視為深度學習。在訊息於各層傳導過程中，每一神經元都會有一個權重參數，而類神經網路學習和訓練過程，就是試著找出最佳權重設定，以令產出達到最佳。這種深度學習，基本上是由電腦自行分析資料找出「特徵值」(而不是由人類來決定特徵值)，並且由電腦自主學習與調整參數。在動態串流資料的分析上，毫無疑問的，唯深度機器學習有能力面對，例如用戶篩選、高度文字意境的排序、與預測及剖析的群分。實務運用上，則包含偵測欺詐或數據侵犯、過濾電郵、光學字元識別(optical character recognition, OCR)、及排序；最有名的，當屬 AlphaGo Zero 透過自學圍棋，完勝曾擊敗人類世界圍棋冠軍的 AlphaGo 舊版。

然而，深度學習最大的困擾是不能收斂。但在 2015 年 Google 提出其開放源 TensorFlow，一個作為創建深度學習學模型及更新 *Q* 函數方法架構，其函數庫協助使用者創建運算圖式(computational graph)來執行函數功能，在全

球獲得相當成功的商業價值[44]。這是目前唯一一個應用深度學習於實際市場的案例。

簡單的歸納，可以說，強化式學習是利用報酬來教導演算法機器於環境中運行，*Q* 學習是強化式學習的一個主要方法。而深度學習(deep learning)則利用神經網絡來達成中心目標，例如從圖像中識別字母或單字。進一步的，深度強化式學習(deep reinforcement learning)則是綜合前述兩者，但以 *Q* 學習為基礎。當狀態/行動的實際組合空間太過於龐大(例如下圍棋時)，則 *Q* 學習一定需要很長時間才能收斂穩定(即學習完成)，於是就會改藉助於神經網絡去找出相似的狀態/行動組合空間，方可在龐大狀態/行動組合空間中，逼真而有效的學習[45]。

Featuring

不論是哪一種學習法，傳統的機器學習系統在處理原始資料數據(raw data)的能力上，都面臨了一個重要前置步驟，即萃取特徵(featuring)，從原始形式的資料數據中篩選更好的特徵變數，以提升模型的訓練效果，演算法可以發揮更大作用。

資料科學家從非常多屬性面向(dimension)的原始資料數據中，依相關目標議題，找出資料間的共同屬性與特性，此即「特徵(feature)」，這些特徵再經過轉換(transforming)與處理而適用於機器學習模型。特徵的形式，可以是數字型變數或系列串、可以是原始資料庫的一個次集合、或是原始變數所組合結構的次集合；萃取所得的特徵，質量愈好，對於演算法而言，就可以更簡潔與彈性化其演算模型，通常其預測結果也會更好。可以說，萃取質量是機器學習成敗與否的最重要因素。

---

[44] Lam, A. (2018), What can TensorFlow really do? Some business applications. Oursky Blog of February 14.

[45] Stack Overflow, What's the difference between reinforcement learning, deep learning, and deep reinforcement learning?

許多資料實業家同意，在機器學習的過程中，大部分時間與精力，其實是花在「特徵」的萃取。雖如此重要，卻鮮少被專章探討，甚至連其定義都存在著模糊現象，是否僅指摘取(pick)特徵？抑或其之清洗(clean)與轉換(transform)也都是？莫衷一是。甚至許多機器學習工程學科，都視其為必經步驟、而不切割獨立出所謂特徵工程一詞。不論如何，唯一可以確定的是，這議題在機器學習應用上極為重要[46]。

一個機器學習模型，基本上是「接受特徵(變數)為輸入項、然後輸出預測或分類為產出項」的一種演算法。一個「特徵」代表著某知識面向中的一個項目(item)，例如蘋果與芒果、或者蘋果公司的蘋果商標與真實蘋果，如何描述才能讓機器學習知道兩者差異？或許我們會描述形狀、顏色、或者擺在桌上時有無陰影(實體會有陰影、商標圖案則無)等等，這些屬性描述就是特徵(features)。又如訓練電腦偵測臉部圖像，我們會摘取的特徵項目，一般包含眼睛顏色、輪廓、外形曲線、眼角形狀等等；演講的識別則會摘取音素(phonemes)、噪聲比(noise ratios)、音長(length of sound)、相對噪聲功率(relative power)；而垃圾電郵過濾，則會摘取字串、部分講辭、郵件結構、文法正確性等等[47]。這些摘取的特徵，就是準備輸入電腦模型訓練的變數了。

然而所從原始資料所取出來的特徵數據，屬性與量度皆不相同，基本上無法在模型運轉以進行訓練或預測，因此這些特徵必須先經過處理。把紛雜屬性與不同量度轉化成可以比較或運算的基準，這是「數據預處理(data preprocessing)」過程，例如，標準化規格、定性轉定量編碼、缺失值處理、非線性轉化。規格化後的特徵數據資料，必須再基於目標而從中篩選有意義者輸入機器學習，才能有效進行訓練；有意義的特徵數據指的是，必須彼此間具有差異性(否則就等於高度相關變數)、又必須與目標具有相關性。這就是特徵選擇(feature selection)。其方法有變異數、相關係數、卡方檢定，或者根據

[46] Sanadhya, A., Feature engineering: a closer look. Retention Science.
[47] 同前文 Sanadhya, A.

目標函數逐次選取(或排除)若干變數，或者先由機器學習的演算法模型進行訓練、得到各特徵變數的權值係數，再依大小撿選。被篩選出來的「有用」變數，就可以直接進入演算模型中訓練了。惟選出的有用特徵變數矩陣或會過於龐大，導致計算量龐大，訓練時間太長、太不效率，此時必須再進一步把變數有效減量、但又不能誤減重要的特徵變數，於是進行降低維度(dimension reduction)的過程。方法上，前述模型篩選是可用途徑，另外也可利用主成份分析法或線性判別分析法等等。這三個步驟是特徵處理過程中最常被分類的，惟因特徵工程本無明確定義，因此名稱或分類範圍各有不同說法。

當然，人為萃取非常費時與燒錢，而透過深度學習(deep learning)，即可執行「自動化特徵萃取(automatic feature extraction)」。傳統的機器學習中，由輸入項到產出項的過程中，包含了特徵萃取、形成特徵、輸入特徵給機器學習演算法等基本過程步驟。但在深度學習中，這三個步驟是合一的、是同時的、而且是層級漸進複雜式萃取，這有賴於類神經網絡 (artificial neural network)的創造與運用；利用複雜軟體企圖複製人類神經元的活動，使電腦學習更快且更精準[48]。

以 YouTube 的推薦系統為例，它包含兩組類神經網路，一組先依某用戶歷史資料由數百萬個視頻資料庫中，形成與用戶特徵最相關的一群(約數百個)，然後再由另一組類神經網路，依與該用戶最相關用戶群的使用品項，推估出該用戶可能使用的潛在品項評價值，約一二十個依排序推播給該用戶。前一個類神經所進行的即「基於品項(item-based)協同過濾」，而後一類即為「基於用戶(user-based)協同過濾」。

推薦系統的目的是把可能會被喜愛而需求的品項推播給某用戶，因此用戶特徵的擷取與分析是最主要的工作。用戶特徵面向可以很細劃分，包含年

[48] A.I. Wiki, A beginner's guide to deep reinforcement learning.

齡、地區、性別、過去看過的電影、瀏覽過的網站、買過的食物、退過的貨…等等，構成多維度向量空間。每一個用戶的多維度空間彼此間產生交集，或大或小，於是演算法基於某些特定目的(例如想推薦電影)，找出交集較大的一群用戶做為一個分類類別，彼此參考；這一群用戶即是特徵值相似度最高的一群，於分類技術是以「相關性」進行分析。原則上這群特徵類似的用戶，在電影觀賞上必具有相似的偏好，於是，若甲看過 A 與 B 影片、而乙看過 B 與 C 影片，就可推播 C 給甲、推播 A 給乙。這過程即所謂「協同過濾(collaborative filtering)。基於用戶(user-based)的協同過濾，會先找出與某用戶具高度相似興趣的用戶群，這群用戶使用品項集中仍未為該用戶使用過的，就推薦給該用戶。基於品項(item-based)的協同過濾，則是利用某用戶過去使用過的品項，找出用過類似品項的其他用戶們還用過哪些相似的品項集，再由這集合中挑出該用戶仍未買用過的品項推薦給他。這是目前最廣泛使用的推薦方法。這過程的分析可以利用評價數值與矩陣分解，推估出甲對尚未觀賞的 C 的評價值、乙對尚未觀賞的 A 的評價值，於是可以精確的知道甲與乙對一些潛在品項的需求強度。前述簡單的用戶/電影兩維度分析，可以一如本計畫對 Q-learning 的手算例子，以手算把一個原始記載矩陣拆解成兩個恰當矩陣乘積，而把其中沒有評值(即未觀賞)的影片，推估出評值。協同過濾演算法種類很多，應付小量維度的，可以以記憶為基底、而應付多維度的則多以模型為基底。更大量維度的分解，就得依賴深度學習。

第四節 本章結論

訂價演算法與人類之間千絲萬縷的關係，在競爭法上該如何予以角色定位？這都是數位時代中，競爭法主管機關所必須面對的新課題。機器演算法接收輸入項(input)並衡諸當前狀態(state)，瞬息間決定回應行動。於是，市場競爭中，人類的角色開始弱化。

本章首先介紹訂價演算法的意義與表達及其演算基本邏輯，對於輸入、產出、與狀態等演算法的基本元素與運行，做了詳細說明，以利執法人員由此進入演算法的世界。目前學習型訂價演算法正開始發展，本章亦對於其四種分類進行詳細介紹，包括督導式學習、無督導式學習、半督導式學習、及強化式學習。事實上，無督導式學習的結果若被人類發現有誤而予以糾正，此時智能體即成為督導式學習。例如郵件演算法自動篩檢垃圾郵件，一旦我們發現錯誤而從垃圾桶中拉回該郵件，演算法隨即獲取該類型不是垃圾標籤的識別，亦是半督導式學習。在實際應用中，最為廣泛的，當屬強化式學習中的 *Q* 學習，於是我們以不透過電腦編程的模式，由一步一步手算過程中，一窺訂價演算法 *Q* 學習的運行邏輯，務必令執法人員完全熟識演算法的運作模式。關於與演算法高度相關的特徵工程與推薦系統，我們亦做了一些介紹。

這是一個全面而簡易的運作邏輯盤點，基本上這是執法人員面對平台經濟，該具有的基本知識裝備。

第三章 訂價演算法改變市場與行為

在演算法商業中，訂價演算法相當普遍，而其快速偵測與反應競爭者價格變動的能力，異於傳統價格傳遞速度，是最主要的變革之處。經濟學中不完美訊息專題，便是針對價格調動可能不為其它競爭者所知悉、或競爭者知悉時間遲滯；然而在使用動態訂價演算法的商家而言，價格訊息呈現完美。過去經濟學所分析的真實市場環境，已經產生了大變化，這個變化，有必要予以釐清。

第一節 訂價演算法改變市場環境

訂價演算法被運用於商業競爭後，其輕易快速監視市場與廠商行為、並快速最佳化反應的能力，深深的衝擊了影響合謀成形的市場環境結構，底下我們將分類逐一檢視。

促成勾結的市場結構，傳統上最重要的兩個是：廠商數目與參進障礙。假若其它條件不變，一般而言，廠商數目愈多則協商或共識聚焦(focal point)相對更不易，以致於達成合作的可能性更小；同時，成功勾結後所能剝削的消費者剩餘，因分食者眾也將致個別獲利變小而減低合作或持續合作的誘因。成功勾結後將產生較高利潤，然而一旦市場的參進愈容易(參進障礙愈小)，愈高的合作利潤將吸引愈多的新廠、以愈快的速度加入競爭，而使合作利潤愈快速的減滅，於是合作或持續合作的誘因大幅降低。

這兩個市場結構，在訂價演算法的運用之後，產生了重大變化。

(一)市場結構

廠商數目

市場廠商數目愈多，一般傳統認為，合謀將愈難達成、也愈難持續。原因不外乎幾個：第一，廠商多則產品差異化可能就大，協議難度增大；第二，廠商多則需協同合謀更多家廠商才足以對市場產生影響力，於是協議和同更難。第三，合謀者數目一多，每一成員分享的好處愈減，降低合謀意願、增加合謀後背離誘因。第四，廠商數目愈多，則「搭便車」的未參與者，其數目也會愈多，因此參與者誘因更為降低、背離誘因也更大。

合謀必然內建著「背叛」因子，因為合謀需減抑一己所欲以成全大局最大，惟一己之減抑雖將可分配到較大利潤，卻也使自己處於非最適決策的狀態。於是，由一己理性角度而言，單方背離以獲取更大利潤的行動，才是符合最適決策法則，這使得任一合作分子都永遠具有著背離的誘因。

因此，及時偵測出成員背叛，將可有效嚇阻背叛、有效維穩合作。傳統市場競爭中，偵測背叛是一個相對艱難的使命，尤其在低度集中的產業，市場與廠商訊息收集很難、價格透明度很低、偵測背離艱難，跟進調價與否的訊息接收太慢，處罰背離也未能即時，這都使得合謀生成或持續面臨困難。於是許多防止背叛的機制設計，也因應而生。

不過，訂價演算法的運用，卻輕而易舉的解決了前述難難問題，它可以輕易快速的監視市場與廠商行為，並且隨時快速的進行最佳反應，隨時提供廠商有效的跟進調價、偵測背離、即時處罰。於是，儘管在廠商很多的低度集中產業，依舊可以有效的進行協同、監視、與執行處罰，依舊可以有效的進行共謀勾結。

參進障礙

演算法可以被用來快速識別市場威脅，例如，即時預報(nowcasting)系統

讓既存廠商可以先發制人的併購潛在競爭者，或者讓既存廠商快速的針對參進者做出積極的反制策略(例如針對性的特殊訂價)。然而，潛在參進者亦可藉助於演算法，由線上收集市場與既存廠商的資料數據，並掌握市場訊息，藉此事先進行分析與擬定方針，可以找到有效的切入利基與阻礙的因素，也可以大幅降低參進成本。於是，在運用演算法之後，既有廠商與潛進廠商都可藉此各有獲益，演算法對於「參進障礙」結構的衝擊，正負關係也就難以明確判定[49]。

以網路市場為例來說明。網路市場廠商營運的主要特徵，在於網路外部性與產品多元互補性，這兩者促使廠商必須同時追求規模經濟效益與範疇經濟效益，於是導致網路市場總是存在少數極大型廠商，並建構出自然參進阻礙(natural barriers)。這類型市場，先驅廠商或既存廠商，居於先動者優勢，規模較大，且較易收集到更大量資料數據，利於發展出更精準的訂價演算法與策略、提供更多結合多項任務能力的免費服務與軟體、或推出數位管家協助進行多方決策的一站滿足，更鞏固與強化了既有的優勢、規模、與利潤；而更多用戶的參與，數據收集更多，就再次的推增了優勢與規模，逐漸的，促使市場家數自然不斷的變少，也進一步導致新廠參進更為困難。

這類型大廠基於用戶數據匯流與分析，可以容易且快速的參進另一個市場。而一般新進參與者，理論上，基於平台創業成本很低、上架容易、毋須店面、沉沒成本小，因此參進容易；然而實際運轉成功卻極具挑戰，受限於網路外部性，欲跨過關鍵數量(critical mass)達到穩定立足的規模，必須具有可觀的期前投資建立龐大用戶流量或品牌知名度。另一方面，一般而言，由於多數廠商沉沒成本不大，因此退出也相對不難。我們給予定調為「參進容易、退出不難、但立足艱困」，以台灣電子商務而言，立足約需 3 至 5 年，而目前跨過第一道門檻 10 億元營收者約有七十家。

[49] 請參見 OECD (2016), Big data: bringing competition policy to the digital era.

Khan(2016)提到「線上嬰兒產品零售是像鞋業或鐵路業呢？」她認為，線上嬰兒產品無須巨額投資或固定成本，因此不像鐵路業。但又說，也不像鞋業，因為為了持續生存，必須建立出穩定的品牌知名度與維持相當大的平台流量，這相當燒錢[50]。

市場透明度

市場透明度(market transparency)愈高，廠商愈容易知悉競爭者產品差異與價格改變，有利於彼此協談達成合作共識；也因容易知悉彼此行動、價格波動、知悉是否有背離行為，故有利於勾結的維穩持續。

訂價演算法自動分析數據資料，然後轉化為行動，且可決行出最佳化行動，此過程所最需求的基本投入項，便是詳細而即時的資料數據(real-time data)。於是，廠商為了從訂價演算法中獲得效率決策的利益，必然願意盡力收集存儲市場訊息。

收集存儲訊息資料的自動化方法也因應而生，直接藉由技術來自動取得，例如 online cookies、smart cards (智能卡)、bar codes (條碼)、voice recognition (語音識別)、radio frequency identification (RFID,無線射頻識別)等等技術。擁有這類型收集存儲資訊的廠商，我們稱其具有「演算法競爭優勢(algorithmic competitive advantage)」。一(些)廠商擁有這優勢，終將激發其他廠商起而效仿以免落居劣勢，於是，自動化收集資訊方法逐漸蔚為整個市場的普遍現象，形成「演算法商業(algorithmic business)」。在此類型商業環境中，幾乎每家廠商都普遍且不斷的、即時的收集與觀察競爭對手行動、消費者選擇、或市場環境改變，等於是創造出一個幾乎完全透明的市場。這樣的全面高度透明，營造了有利於合謀勾結的市場環境[51]。

---

[50] Khan, L.M. (2016), Amazon's Antitrust Paradox, The Yale Law Journal 126 (3), 710-805.

[51] 同前文 Ezrachi, A. and Stucke, M.E. (2016)。若這類型市場環境實現，則廠商會發現，透過線上數據流分享，可以獲取更多訊息，而所有廠商也將因此通用至相同訊息庫，合作勾結的達成必將更形容易。

資料數據的及時可得性，並非導致市場高透明的唯一因素，還得要有識別或正確解讀資料的能力。一個具有強大數據資料挖掘與分析、偵別策略操作不確定性、及預測能力的訂價演算法，才能於透明而龐大的數據資料中，區別對手是否跟進？合作成員是否正在背離？是否是有意的背離(intentional deviation)抑或只是因應市場條件改變的必然反應？或是單純失誤？具有如此正確解讀能力，才能真正使市場行為完全透明，而可以避免不必要或錯誤的報復行動[52]。

互動頻率

假若廠商能夠於極短時間內獲知市場訊息或競爭者行動，並於極短時間內進行自我行動的因應調整，則不僅能夠快速偵知合作過程中對手的背離行為，也可以快速積極的對背離者施予報復與處罰，可以有效的嚇阻合作者背離誘因，促進合作勾結的長期維持。訂價演算法的運用，正好提供了這樣的成效，因為它促成廠商間的高頻率互動(frequency of interaction)。

在傳統的實體商店競爭架構下的價格調整，一來費時、二來執行成本昂貴。但在數位網路市場競爭中的價格改變，基本上，其頻率可以依照著經理人所需。訂價演算法加上自動化機器的被運用於數位網路，使價格與資訊可以即時更新，使廠商對於合作中背離者可以立即報復；甚至，市場巨量資料與機器學習的結合，幾乎可使訂價演算法精準預測對手行動，甚至可以先行預期對手可能的背離行動。

法國與德國競爭機關的聯合報告指出，「(演算法)透過處理所有可得訊息並進行監視、分析，預測競爭對手對於當前與未來價格的可能反應行動，於是，競爭廠商們可能很容易的找到一個大家都會同意的長期超競爭價格水平。」[53]

[52] OECD (2017a), Algorithms and collusion: competition policy in the digital age.
[53] Autorité de la Concurrence and Bundeskartellamt (2016), Competition law and data.

(二)需求面波動

需求波動頻繁，對於合謀造成莫大破壞力量。Green and Porter (1984)基本上認為，市場需求大幅衰退(價格下跌)時，背離之長期利損大減，故合謀者易生背離。於是，在訊息不充分下，成員廠商常會無知的把因需求減少所致之市場價格走跌狀態，誤為是其他成員欺騙多賣之故，因此常常一面臨市場價格走跌狀態，就祭起價格戰爭以為處罰，導致合謀很容易的崩解。為此，作者提出扳機價格策略(trigger price strategy)，為避免誤判而錯殺忠誠合作成員，一廠商將願意等到市價跌出某一幅度之外時，才啟動報復性價格戰[54]。另一方面，Rotemberg and Saloner (1986)則認為，市場景氣繁榮時，需求大增、市價走揚，此時趁機偷偷多賣即可獲取短期超額暴利，是以背離誘因大增，合謀狀態很容易就此瓦解。前者是主張「市場衰退容易引發合謀瓦解」，而後者則主張「市場繁榮容易引發合謀瓦解」[55]。而 Hassan(2006)設定需求存在不確定性波動，其實證結果則得出與 Rotemberg and Saloner 一致看法[56]。

實務上，不論景氣(需求)是波動走向繁榮抑或波動走向衰退，都容易觸發合謀狀態的解體。廠商於每期決策時，考慮是否繼續遵守合謀的兩個算計權衡，其一是背離的當期暴利，其二是背離的未來長期利損。競爭均衡產量偏多(價格偏低)，而合謀旨在減產以提高市價，於是每一合作成員將處於「邊際收益>邊際成本」的非最適決策，此時多賣(即背離)將可帶來暴利，形成了合謀中必然內建背離因素。市場(需求)繁榮時，邊際收益更高，背離的當期暴利更高，提增了成員的背離可能性。而當景氣(需求)低迷時，合謀利潤不高將使「未來長期利損」現值較小，促成合謀成員背離的誘因變大。根據 Suslow

[54] Green, E.J. and Porter, R.H. (1984), Noncooperative collusion under imperfect price information. Econometrica 52 (1), 87-100.
[55] Rotemberg, J.J. and Saloner, G. (1986), A supergame-theoretic model of price wars during booms. The American Economic Review 76 (3), 390-407
[56] Hassan, S. (2006), Optimal timing of defections from price-setting cartels in volatile markets. Economic Modelling 23, 792–804.

(2001)針對 1920-39 年間、47 個產業中的 72 個國際卡特爾協議進行研究分析，發現時常經歷起起伏伏景氣波動的卡特爾，其瓦解機率較高；同時，經歷景氣低迷時又比經歷繁榮時，其瓦解機率高[57]。

在訂價演算法等自動機制主宰的數位網路市場中，價格的改變頻率可以分分秒秒，市場環境、需求、消費者訊息偵測、取得、與回應，快速即時。於是，對於環境需求變化即可快速因應訂價，而形成新一輪合作狀態，因誤解為成員背離欺騙而致聯盟瓦解的機率變得較小。同時，對於真正的背離行動，廠商快速偵知與報復，使得背離之短期暴利大幅減小、而長期利損變大，有效防堵合謀者背離的機率變得更大。加上巨量資料與機器學習結合所發展出來的學習式演算法，正逐步往精準研判與預測競爭者行動的途徑上前進，於是，在傳統架構分析中足以動亂合謀生成與穩定的需求波動，在訂價演算法商業中的影響力會下降。

(三)供給面變動

在演算法商業中，影響供給面的兩個主要因素，一是創新、二是提升經營效率[58]。

一廠商的創新，使品質或營運模式更獨特的有利於自己產品銷售，於是既有合謀的長期利得相對變得很小(等於背離的長期利損變小)，自己的背離誘因變大；另一方因未創新而陷於不利競爭，對背離者的報復能力變得更小。於是勾結合謀變得更難持續。在不斷模式創新的市場中，廠商不斷以演算法技術創新作為競爭優勢與績效來源，於是這類型產業中的合謀勾結，將會變得相對不易。例如搜尋引擎、導航 app、配對平台(matching platforms)等產業。

---

[57] Suslow, V.Y. (2001), Cartel contract duration: empirical evidence from international cartels. Working Paper.

[58] 創新可以是品質改善或獨特性、技術改進或新穎與親善等等，而營運效率的提升，可以是內部組織改善、冗員裁汰、品項與渠道配置、或人員士氣激勵、誘因設計精實…等等。雖兩者在經濟學分析上都造成供給曲線向右位移，但所著重之面向不同。

演算法影響供給面的第二因素，主要源於經營效率提升。一方面，演算法協助廠商服務與生產進行差異化配置、改善效率、節省成本；二方面，則因此而加劇各廠間成本不對稱(cost asymmetry)。配置效率差異或成本差異都有效的使廠商質性差異變大，協議以獲致共識焦點愈難，且低成本優勢廠商更難有意願合謀。於是，合謀勾結不易生成、亦不易維續。

(四)廠商結構

競爭廠商之規模、品質、以及營業策略，若差異過大，則欲協議出共識焦點將會變得很難。相似的，廠商的成本水平、產能利用率、市場份額、及客戶忠誠度，若差異愈大，也愈難協談聚焦。在訂價演算法運行之下，雖同類商品價格可能愈趨一致，但總體廠商之產品類型與營運模式差異化將會愈大，於是廣泛合謀不易產生，但單品項合謀卻很可能產生。

(五)買方力量

若眾多的小競爭商或購買者(fringe competitors and buyers)全體形成了強大的購買力量，而足以與大廠商們議價，則大廠合謀將較不易形成。這些眾多的小廠(或消費者)，在演算法商業中，是可以有機會透過(訂價)演算法，一方面進行聯合，二方面收集大廠資訊，增進其市場力量(或買方力量)，可以制約或破壞廠商的協同企圖。

一些演算法軟體，利用數據分析消費者偏好、選擇購買的產品服務、議價與執行購買、甚至自動的形成買者聯盟以確保最佳條款，在這過程中，人類決策可能完全被略過。這樣的演算法，可能是消費者基於自身利益而編寫出來的，可能來自於外部廠商的提供，Gal and Elkin-Koren (2017)稱這些演算法助理為「演算法消費者(algorithmic consumers)」[59]。相對於「數位管家(digital

[59] Gal, M.S. and Elkin-Koren, N. (2017) Algorithmic consumers. Harvard Journal of Law &

bulters)」，我們特稱其為「數位買家(ditigal buyers)」或「算法買家」。算法買家在動態市場上的一個最重要效應，就是顯著的改變了消費者需求。改變的最基本形式是，購買產品的成本下降而品質提高；當然所謂品質面向，也包含了隱私權、可用性、與評價等等。進一步的，Gal and Elkin-Koren (2017)指出，藉由軟體，市場上形成了「演算法買家團體(algorithmic buying groups)」，團購足以降低賣家偵悉個別用戶偏好訊息(因為現在呈現的都是總體資料)，減少廠商操作圖利或傷害競爭的可能。例如 CamelCamelCamel 軟體，當消費者所欲產品價格達到某一特定水平時就會發出警訊，該演算法就會協助消費者在 Aamzon 平台上用最低價格買到產品；而更精良的演算法，會建議消費者是否立即購買該產品、或者等待預期的價格下降，例如，航班價格集成器 Kayak。更進一步的演算法，消費者可以委諸以購買決策，令演算法代理人利用數據預測消費者偏好，然後協助其最佳化的產品服務選擇、議價與執行交易，更可能組成消費者團體來獲得更佳的購買條件，例如 Groupon、LiveingSocial、及 Google Offers 等所提供的搜尋與比價服務以及團購服務。

就經濟學分析而言，當賣家只能對大眾訂定單一價格時，亦即，則個別消費者剩餘被剝削就更小，足以增進消費者總體福利。但對一些少數個別用戶而言，因為無法被個別識別，也可能失去被個別供給好價格的機會。美國聯邦反托拉斯局指出，只要這類型買者團體交易，不超過該產品相關市場銷售額之 35%，則這樣的 buying group 就被認為是創造了「正競爭效應」[60]。

小結

因訂價演算法運用之後，市場結構對合謀影響所產生的衝擊，一如前述，並整理綜述於后(表 3.1)，提供簡易參閱。

Technology 30 (2), 309-353.

[60] 同前文 Gal, M.S. and Elkin-Koren, N. (2017).

表 3.1 演算法對共謀的影響 (整理自 OECD 2017a)

因素	傳統結構下對勾結的影響	演算法運行商業下對勾結的影響
市場結構		
廠商數目	數目愈大則愈不利勾結	不論廠商數目多寡，因收集數據與策略反應快速，都更易勾結
參進障礙	障礙愈大則愈有利勾結	既存廠商更易建構障礙。新進者因更容易取得市場訊息、且因平台創業成本相對較小，故參進變得容易。惟網路外部性之下，參進後欲穩定立足存活，則相對的艱難
市場透明度	透明度愈高則愈有利勾結	透明度將更大幅的提增，更容易勾結
互動頻率	互動頻率愈高愈有利勾結	互動頻率將更大幅的提增，更容易勾結
需求面變動		
需求成長	景氣成長或衰退都易致勾結瓦解	景氣成長或衰退不易影響勾結狀態
需求波動	景氣波動大則易導致勾結瓦解	景氣波動大並不易影響勾結狀態
供給面變動		
創新	不利合謀	創新者的合謀利益將變得更小，更不易於合謀
成本歧異	不利合謀	差異化將變得更大、更不易於合謀
廠商結構		
產品與經營異質	異質化愈大則愈不利合謀	個體廠商差異化將變得更大，合謀更為不易。
買方力量		
購買者團體	買者力量愈大愈不利於合謀	促成買方力量集結、演算法買家出現，可致廠商合謀更為不易

第二節 訂價演算法導致市場失靈

訂價演算法改變了市場環境，一者，訊息隱密度變高，二者，參進而立足之阻礙變大，三者知識傳播單調化，可能導致市場失靈出現。。

訊息隱密度變高

訂價演算法的編程與運算並不透明，隱秘了廠商決行的思考邏輯；於是，消費者面對競爭產品，無法具有有效且清楚選擇的能力，而執法者也將缺乏充足可靠訊息與專業來確定其合規與否。演算法是交易與商業上的秘密，就算其中部分被廠商公開分享(或予執法者)，其長串複雜的編碼程式與運算模式，依舊極度難解；與此同時，其運算結果卻又是高頻變動且高度個人特徵化，追縱與定性分析很難。運算模式難窺、運算過程難解、運算結果難究，於是對訂價演算法之效應評估非常之難。

參進而立足之阻礙變大

精準訂價演算法的發展必須投入高昂的固定資產成本，例如數據挖掘軟體、機器學習軟體、數據中心等基礎設備，於是廠商經營必須達於規模經濟效益，方能有效降低平均成本。另一方面，訂價演算法必須可以進接與擷取廣泛多樣資料數據料來源，方能不斷累積廣泛經驗與學習，藉以更新模型中的關聯與型態(relations and patterns)，因此，廠商經營必須具備範疇經濟效益。高度規模經濟與高度範疇經濟之需求，無疑的，對新廠參進造成了高度阻礙。

惟另一方面，數位經濟以技術導向，破壞性技術往創造出新的獲利模式，此為新廠參進的可能途徑。再者，由於技術市場並未被獨占，在現在技術下，尋找新的營業商機、區塊、或模式，亦是參進後生存之道(例如專門拍賣二物品的旋轉拍賣 Carousell)。事實上，數位經濟的廠商，參進者眾，惟生存不易。

知識傳播單調化

廣泛多元的大數據收集，協助了演算法進行更細密的依特徵分類消費者，區段化消費者可以達到很細微地步，然後給予不同區塊類型族群不同價格、不同訊息、不同產品組合；不僅價格可以個人化裁定(personalized price)，在知識與訊息的投遞上，也以個人興趣與偏好進行推播。被細化的不同消費群，各自被餵以各自偏好的資訊，幾何強化「偏信」自我原本認知與信念，隔絕了網路世界帶來的多元多樣概念。靜態短期中，看似個人效用獲得最大滿足，但動態長期下，人類知識不易累積、跨越交流、溝通合作，限縮了人類想像力與開創力[61]。過往經驗告訴我們，創新多來自於多元知識、跨學科途逕、與多樣文化概念激盪的相互外溢(spillovers)效果。

第三節 訂價演算法的效率與功能

事實上，訂價演算法的大幅進步與效率，建構於數位經濟的大幅躍進。也就是說，大數據數位經濟的發展舖墊了訂價演算法被運用的溫床。談訂價演算法效率之前，有必要簡易整理演算法對整個環境的效率增進。

(一)訂價演算法促增市場供需效率

就供給面而言

大數據具量大廣深、即時處理(now-casting process)、與微細分類。各式各樣的演算法，把人類所思所欲化為自動化操作，於是廠商們於實務上想要的精簡成本、物流效率、原物料與成品控管、運籌管理、部門交換、市場交易、財務規畫、經營策略等等，都可以依據即時產生的數據、即時的規劃計

[61] Sunstein, C. (2009), Republic.com.他警示，演算法傾向於偏選訊息而強化我們既有的信念，導致自我「回聲室」的現象。

算、並即時的動作因應，從而達到最佳的配置效率。某些演算法還可以提供廣泛的品質與服務改善效應，例如，幫助產品與服務的改善、精緻、與發展。搜尋引擎透過用戶的詢問與點擊資料，快速的確認出某用戶最想要的相關結果，並快速的提供個人化建議；線上媒體亦常透過用戶的瀏覽歷史與個人資料，對用戶提出了快速的興趣項目推薦。

數據的便利與即時，提供了動態訂價演算法(dynamic pricing algorithms)崛起的契機，於是透過動態訂價演算機，廠商可以在一小時、數分鐘、或幾秒鐘內快速完成學習其自身銷售、對手價格或其他變數，不斷且快速的試誤而建構出「型態(patterns)」[62]，並在接收到新資訊後，立即調整訂價。更進一步的，針對一個(群)不同特性的客戶進行個人化訂價(personalized prices)，依不同住區、瀏覽紀錄、是否無線使用者之特性，而給予個別用戶個人化訂價，實行更有效的價格差異(price discrimination)。這些都發生在學習型演算法(learning algorithms)的運用中，也已被廣泛應用於飛機、旅館、運輸、水電及零售產業。

就需求面而言

Gal and Elkin-Koren (2017)認為，演算法可以用來比較價格與品質，用來預測市場趨勢、並進行快速決定，因此可以幫助大幅降低搜尋與交易成本，幫助消費者更理性的決策，強化了買者力量。例如網路數位「另一半」「管家」APP，可以幫助消費者與其它網路系統溝通並代為執行決策，不懂得如何善用網路購買的消費者，就可以利用這類型 APP 進行自己購買策的最佳化。

CamelCamelCamel 軟體幫助消費者在 Aamzon 平台上購買產品時，可以最低價格買到。當所欲產品達到某一特定水平時，就會發出警訊給消費者。

[62] Pattern 是「一再重複出現的事項」。在軟體工程中，「每一個 pattern 是一個包含三部分的法則，用以表示一特定情境、一個問題、一個解答之間的關係(Each pattern is a three-part rule, which expresses a relation between a certain context, a problem, and a solution.)」可參見 Alexander, C. (1979)頁 62。

更精良的演算法，會建議消費者是否立即購買該產品、或者等待預期價格下降，例如，航班價格集成器 Kayak[63]。

當更進步的演算法出現，消費者可以將購買決策委諸於它。數位代理人可以利用數據來預測消費者偏好、最佳化產品服務選擇、議價與執行交易、還可能組成消費者團體來獲得更佳的購買條件。這會顯著減低蒐尋與交易成本、增進理性選擇、甚至增加買者力量，例如，搜尋與比價服務以及團購服務(例如 Groupon, LiveingSocial and Google Offers)，都具有這些效率增進的功能。

訂價演算法最常產生的需求面效率，不外乎：提供比價資訊而有利消費者轉買、協助偵測廠商價格的相似度而有利需求面競爭、可能創造出買方平台而增進買方力量。

總結而言，演算法的潛在效率有幾點：

(1)達到更精良的配置效率

(2)更準確的估計廠商所面對的環境(尤其是需求)

(3)在既存市場條件下，尋找最佳化價格

(5)對市場條件的改變，快速的進行價格調整

(5)對客戶進行個人化訂價。

(二)訂價演算法促增廠商決策效能

在市場競爭，具學習能力的訂價演算法，無疑是最誘人的。Chen et al (2016)以 Amazon Marketplace 為研究對象[64]，收集最受歡迎 1641 個產品的四個月數據，對每一產品的前 20 大賣家收集每 25 分鐘頻率訊息，包含價格、排比、與特徵。他們偵測發現，大約有 543 個賣家採用了演算法訂價，而且採用訂

[63] 但其風評不一，有人研究利用它預測與建議，會反而多支付了平均 2%。

[64] Chen, L., Mislove, A. and Wilson, C. (2016), An empirical analysis of algorithmic pricing on Amazon marketplace.

價演算法的商家，平均更具策略上的多樣性與成功性，有更高的訊息回饋，而且其產品有更高機率被 Amazon 收錄於每日必買推薦盒(Buy Box)。

學習型訂價演算法(Learning algorithm; LA)是利用資料數據在進行更佳的訂價決策，所謂「更佳」，意指達成更高績效(performance)，如利潤、收益或其它目標。在面對當前市場各種條件下，智能體(自動演算機)依據過去經驗資料，選擇一個訂價演算程式(pricing algorithm; PA)，由它去對當下狀態選出一個價格。

過去經驗資料包含：過去價格資料(自己甚或對手的)、過去收益資料(很可能只有自己的，因為對手的收益會是秘密)、一些影響需求的其它變數(例如星期幾與季節性)、以及一些影響利潤最大化的其它變數(例如生產成本、存貨成本、存貨水位等等)。基於過去不同市場狀態的不同訂價而產生不同績效分數，學習演算法會針對當前所面臨的整體市場情況(例如包含星期幾、季節與存貨等)開出一個最佳訂價模式，亦即選擇當前的自動訂價演算程式，而價格也就隨之被訂定。價格被訂定後、銷售與利潤隨之算出。所得出的銷售與利潤，與當前的市場情況、甚或加上對手價格選擇，即形成了一個新的觀測資料點(即新增的一個歷史經驗)，供給學習型演算機利用並繼續改善其訂價演算。獲得新經驗(訊息)的訂價演算機，再次面對新的下一期市場情況，再次選擇新價格(即演算程式)，而再獲得新數據資料觀測點，並再藉以更新改善其演算程式選擇。如此不斷的繼續著…。

於是長期中，不斷隨時間推移，自動演算機會愈來愈精良，但這並不代表已經臻於完美，畢竟環境狀態隨時改變，固守於某一個特定程式或策略，將喪失透過不同演算規則去挖掘更多關於環境情況的訊息(尤其是產品需求)。因此，學習型自動演算機的最佳策略，不僅要關注當前報酬，也同時著眼未來的績效；透過現在所學習的經驗，提升未來決策的品質與績效。於是，學習型自動演算機的最佳策略，不僅要以當下最佳行動「緊抓當下利潤(earning; exploitation;手中一鳥)」，還要保留小機率選中「非當下最佳行動」的可能性，

以學習更多環境情況，利於「開發未來績效(learning; exploration;林中兩鳥)」。

一般而言，學習型訂價演算法，對廠商決策所帶來的好處，可分兩類：協助廠商識別出最佳化價格、並因應市場情況改變而快速調整價格。前者，訂價演算法透過取得更多的數據資料，建構「價格與利潤」關聯訊息，更精良的協助廠商識別並預測出最大化利潤的價格水平。後者，以取得的更多數據資料，因應所面臨的當前市場情況，針對消費者特徵面向裁製個人化訂價，亦即建構一個「價格與市場情況」比配的關聯訊息。

「價格與利潤」關聯預測

關於第一類型的好處，「價格與利潤」關聯預測，是推解出可達最大利潤的價格，這一般都是透過訂價演算機中的「最佳策略分析模組」來完成，常見於「估計-優化」型的演算程式上(estimation-optimization algorithms)」。

估計-優化型的學習型演算程式，通常包含一個「推估模組(estimation module)」與一個「優化模組(optimization module)」。前者依據歷史資料經驗對廠商所面臨的當前環境進行推估，而後者則是基於所推估出來的當前環境，擬定一個達到最大績效的策略[65]。

推估模組的功能，主要是推估廠商所面對的市場需求函數，這任務已在許多計量經濟學模型中被實踐過。常見的需求推估方法，例如迴歸(如最小平法或最大概似法)；而自動計算機領域發展出來的「類神經網絡(artificial neural network, ANN)」方法，也是常被運用的一種。廠商所面對的需求函數一旦被推估出來，即可建構出「價格與銷售」關聯，並形成預期利潤函數(或績效函數)，以便掌握不同價格所得到的不同利潤。然後，藉由「優化模組」進行模擬與計算，而預期出最大利潤(或績效)時的價格水平，此為最佳價格策略。當然，若有出現成本訊息，則須視其為一個資料數據，而一同在推估模組中納

[65] Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019b), Algorithmic pricing: what implications for competition policy? Review of Industrial Organization 55 (1), 155-171.

入考量。

推估-優化型演算法，是較傳統也是較普遍的方去，研究文獻頗多。例如，Shakya et al (2012)設計線性迴歸(線性或指數形式)、最大概似法(多項式 multinominal)、及類神經網絡(backpropagation 反向傳播算法的 ANN)四種推估方法，並發現類神經網路方法獲得最佳的平均表現[66]。Nambiar et al (2018)則是利用過去價格與銷售進行迴歸分析，推估該廠需求函數後再計算最大化預期收益時的訂價水平[67]。另外，den Boer and Zward (2014) 則以最大概似法(maximum likelihood)建立其需求估計模組[68]。

隨著新資料數據的不斷產生，這類型演算程式會不斷改良且不斷推測其估計與優化選擇，這正是其學習過程。當然，也可以對每一行動或策略的過去績效累積(經驗值)進行評比，做為下一期選擇策略的一個加權值。

與此不同的，強化學習型的訂價演算法，比較沒有前述兩個模組的涇渭分明，反倒是二者合一。這類型訂價演算法從過去不斷的行動(策略)所累積的經驗值(即績效值)，直接分出各行動的優劣，以此優劣評比(即經驗值高低)賦於該行動於新一期被選中為反應策略的機率權重。這過程因為不顯然的運行該廠所面對環境(或需求函數)之推估，因此被視為無模型(model free)演算法。

例如 Hanaki et al (2005)研究重複囚犯困境賽局，植基於「引力導向學習(attraction-based learning)」，智能體於每一時期將使用一特定訂價演算方法來訂定當期價格，並可以定期有改選其他訂價演算方法的機率(一個隨機的小機率，文中於模擬時設定為 5%)，此機率分配於非當前選定的各個訂價演算法，並依各訂價演算法過去績效高低權重而定。模擬實驗發現，於 26 個訂價演算

[66] Shakya, S., Kern, M., Owusu, G. and Chin, C.M. (2012) Neural network demand models and evolutionary optimizers for dynamic pricing. Knowledge-Based Systems 29, 44-53.

[67] 在經濟計量理論中，內生性問題是導致估計偏誤的原因之一，此處所採用的這一個隨機干擾項，可以緩和這個問題。參見 Nambiar, M., Simchi-Levi, D. and Wang, H. (2018), Dynamic learning and pricing with model misspecification.

[68] Den Boer, A.V. and Zwart, B. (2015), Dynamic pricing and learning with finite inventories. Operations Research 63(4), 965-978.

法中，以牙還牙、嚴格策略、處罰一期策略、處罰直到對手報復(Punish until the opponent retaliates)這 4 個傳統熟知的策略，具有最佳績效表現[69]；同時發現，僅有簡單的學習，最終兩個演算法之間者會出現隱性合作，而「處罰直到對手報復」獲得了最高的引力值[70]。

Calvano et al (2019a)則是使用 *Q* 學習模擬了重複囚犯困境。*Q* 學習源自於 Sutton and Barto (1998)，其文中決策者對每一策略會形成一個估計得值，記為 *Q*，並以此 *Q* 值集合計算出最大期望報酬的混合策略，再以此策略指導每一期的行動選擇，於是，每一期會有一個估計 *Q* 值與一個實際報酬值，兩者差異以權數修飾後併入下一期 *Q* 值的修正數；*Q* 值將如此不斷的每期修正，成為智能體的學習過程。其模擬發現，高達 52%的期間，智能體會達致勾結狀態(即採用維穩於高價的策略)，而尤以一期處罰策略最多(達 42%)[71]。

「價格與市場狀況」關聯比配

第二類型的好處，是對「價格與市場狀況」之間進行隨時關聯比配，藉以協助廠商尋求出最有效率的訂價。這一能力主要是築基於大數據的操作與運用，常被稱為動態訂價，也就是訂價自動機(automation of prices)於高頻數據串流中快速決行的過程。利用訂價自動機的廠商，對銷售、對手價格或其他變數進行學習，可以在一小時、數分鐘、或幾秒鐘之內完成，而且接收新資訊後，也可立即調整價格。也就是說，不論是銷售、存貨、對手訂價、或任何其它可被觀測的高頻率變數，一旦產生變化，則廠商訂價都可隨時快速因應的調整完成。

自動訂價機加上大數據運用的另一個好處是，透過所收集的消費者細微

[69] 處罰直到到對手報復的策略是，一開始採用合作策略，一旦對手採用不合作，則我隨即採用不合作，而且一直持續如此，直到對手採用不合作時，我即回復合作策略。
[70] 參見 Hanaki, N., Sethi, R., Erev, I. and Peterhansl, A. (2005), Learning strategies. Journal of Economic Behavior & Organization 56 (4), 523-542.
[71] 同前文 Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019b).

末節等形形色色訊息與資料，例如一個消費者的上網時間日子、點擊行為、購買紀錄、或其族群屬性資料，自動訂價演算機依此多面向特徵與類型、把消費者細微的區塊化，然後針對不同區塊特色的客戶，裁製出個人化價格，構成更有效率的價格差異。例如 Home Depot、Orbitz、及 Staples 這些經銷商，依據消費者住在區、瀏覽紀錄、是否是無線使用者等等特性，對一網站使用者訂定不同價格。

利用過去資料數據來預測價格與利潤關聯時，若能偵測用戶區位與瀏覽紀錄等細微資料而進行區塊化，則亦可計算出不同區塊消費者如何衝擊「價格利潤」關聯。於是，當前某(些)用戶區位與瀏覽紀錄被確實識別之後(亦即市場狀況被識別)，自動訂價演算機就可以針對這些被識別區塊(即市場動況)，裁製出一個足以攫取最大利潤的價格，此正是進行「價格與市場情況」之配比與優化。

總結而言，學習型訂價演算法具有幾個潛在效率：(1)估計一廠所面對的環境(尤其是需求)。(2)在既存市場情況下，尋找最佳化價格。(3)對市場情況的改變，快速進行比配價格的調整。(4)對區塊化客戶裁製個人化訂價。

第四節 訂價演算法改變合謀樣態

廠商透過價格面向的合作，維持高於競爭價格與利潤，此仍違反競爭法。若是顯性共謀(explicit collusion)，執法者尋找證據容易，惟若隱性共謀(tacit collusion)，則執法者將面臨舉證上的困難。廠商運用訂價演算法之後，自動演算機具有極高的決行自主力，可免於人為的顯然溝通協議，即可協助廠商達致超競爭價格，還能替代人類即時監視與反應，而更有效的持續於超競爭價格水平。換句話說，在演算法基底商業中，自動訂價演算法可能取代人類溝通管道，而直接促進隱性協同(tacit coordination)行為。

訂價演算法於營業模式中，所扮演的功能角色，各有不同。OECD(2017a)

依功能性而歸納出訂價演算法的四個類型，我們依序分述如下[72]。

(一)監控演算法(Monitoring algorithms)

廠商決策首要掌握市場狀態與他廠決行訊息，這有賴於充分資訊數據的收集、篩檢、與分析。收集資料愈充分愈即時，則廠商愈能謀定最佳反應策略；同時，透過訂價過程釋放一己企圖訊息、或回應他廠動作的訊息釋放，都可被充分即時收訊與觀測，故容易彼此會意而合約，而合約後也更容易持續維穩。監控型的訂價演算法，其主要功能即在於有效協助收集競爭者營運決策訊息、並進行資料數據篩檢；無疑的，此類演算法促增了廠商合謀生成與持續。

雖然市場價格是公開的，但並不意味著市場就具有透明化；真正的透明化，當在廠商必須亦具有收集競爭者資料數據且準確分析的有效能力。目前，廣為熟悉的比價網站，即具有如此的功能；而市場上也存在許多透過網站直接收集資料的集成器(aggregators)[73]，例如 Google 閱讀器、抓蝦中文 RSS 線上閱讀器、新浪點點通閱讀器，又如搭載於宏碁個人電腦 eSobi 網路資訊整合軟體，具新聞閱讀、跨網搜尋、以及個人資料庫三大功能。集成器是一種可以直接取得線上企業更新訊息的軟體服務，另外一類的應用軟體(例如網路機器人)，則可以自動的不斷的自各網站上挖掘抓取相關資料(web scraping)[74]。這些技術盛行於數位市場，促成市場透明化，增進廠商訂價演算法的準確與及時，大幅提升競爭廠商間互相勾結的便利性。而這些演算法技術經過長期

[72] 同前文 OECD (2017a).

[73] 集成器是一種應用軟體或服務的總稱，可用來閱讀 RSS 與 Atom 格式資訊內容。RSS 與 Atom 是一種訊息來源格式規範，用以集成經常發布更新資料的網站，是由網站更新訊息至個人載具之上。

[74] Web scraping 意指利用程式技巧來挖掘抓取網站上的內容，英文同意用詞還有 web harvesting, web data extraction, web screen scraping, web data mining。例如網路機器人(internet bot; web robot; WWW robot; bot)應用軟體被專用於網路上進行自動任務，其中被使用最廣泛的機器人是「網路爬蟲(web crawler; web spider)，它在網站伺服器中自動依按任務去抓取、分析、並歸檔所有訊息。

發展後，也有可能擴及至線下產業。

透過自動收集軟體所收集到的資料數據，再交由監控型訂價演算機去進行監控、偵察，並迅即對價格變動回應、對背離協議者發動報復，使背離者長期利損加劇、短期暴利大減。比之於傳統廠商模式，監控型訂價演算法更強烈的容易促成與維續合謀。例如設定一個鈑機價格(trigger price)，一旦發現他廠降價至低於這一門檻水平，則我方就發動報復(即價格戰)，把價格拉回至競爭水平(回復競爭狀態)。可以說，訂價演算法所建構的合謀狀態，很難以被打破，除非是來自於訂價演算機的自我失誤[75,76]。這類型演算機的運作流程，示意如圖 3.1。

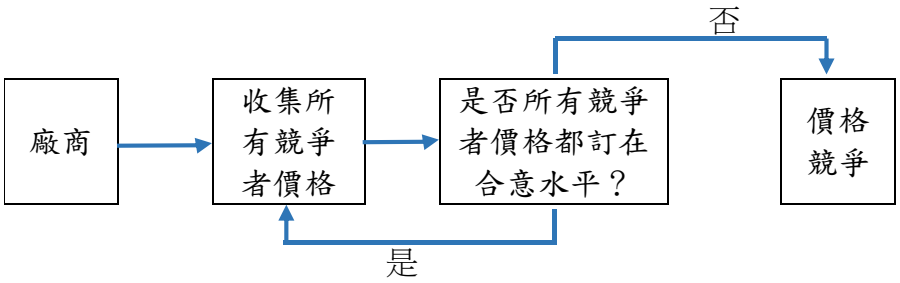

圖 3.1 監控演算法示意

監控型演算機具有促成與維續合謀協議的功能，惟合謀協議本身的確立與執行，卻無法單單借由此一類型訂價演算機來達成，仍須搭配人為其他通

[75] Love, J. (2015), Technology is out of your control and why you should celebrate, IT world Canada。文中指出，一些演算法可以讓廠商即時的、自動的跟進競爭者網路價格，藉此保持競爭力。然而在英國(2015)，卻曾因演算法的失誤，導致價格落崖失速下跌(形成價格戰)，即至發現價值數千美元大螢幕電視機的下單流速異常時，才發現該品項只被標價幾分錢，然而此時一些賣家已經因此而損失了數萬美元之多。

[76] Sutter (April 2011, CNN)。文中指出，The Making of a Fly 這本書於 2011 年 4 月 8-18 日期間，在 Amaozn.com 上由 23 美元飆升至 23698655.93 美元(含運費)，這是網路機器人動態訂價的結果。在市場競爭中，跟進比照訂價是一個普遍做法，一演算法 A 之訂價法則是 $P_A=1.27059P_B$，而另一演算法 B 的訂價法則為 $P_B=0.9983PA$，於是互相競價結果形成一個上升螺旋。

訊手段。Ezrachi and Stucke (2016)亦曾提出訂價演算機分類，其第一種類型「信使(Messenger)」，是指由電腦或演算法充當「通風報信」角色，而若真有合謀，仍必須由人類角色彼此協議確定。此一類型即類似於監控型演算法[77]。

(二)平行演算法(Parallel algorithms)

多個訂價演算法在市場競爭中被廠商運用，可能因為演算法編程的設計或來源，而致對事件反應上具同向的行動(即平行行為)，此等類型即為平行訂價演算法。這類型中最簡單的一個模式是，例如某一家廠商 A 的訂價演算機基於收集所有廠商價格與市場狀態變動，而訂定出了一個最適價格；而另一家(或其他家)廠商的訂價演算機，則簡單設定為「跟隨法則」，跟隨 A 廠所訂價格，於是兩個訂價演算法形成同向的變動價格，構成平行行為。圖 3.2 為其運作流程的示意圖。

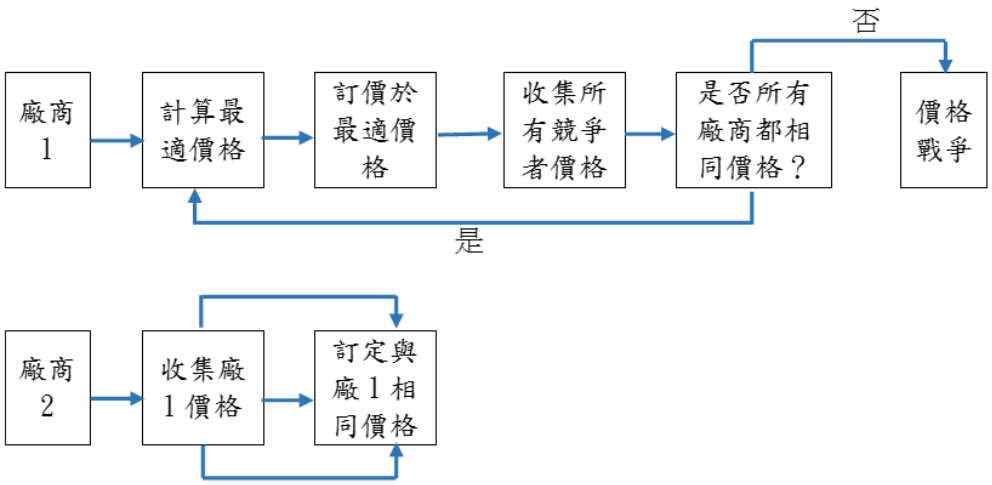

圖 3.2 價格跟隨策略之平行演算法示意

[77] 同前文 Ezrachi, A. and Stucke, M.E. (2016)，並參考 Ezrachi, A. and Stucke, M.E. (2017b), Artificial intelligence and collusion: when computers inhibit competition. University of Illinois Review 2017, 1775-1810.

當然，此類型訂價演算法，若欲彼此促成超競爭價格的合謀狀態，則仍必須隨時監看所有廠商是否已全部跟進訂價？若否，則報復以競爭性的價格戰爭；若是，則領頭廠商(即示意圖中的廠商 1)就會隨時因應市場動態而不斷的隨時更新當下最適價格，以供他廠跟隨。這一個簡單模型中的領導廠商，其訂價演算法其實是包含了監控演算法的內容。訂價演算法中最適價格選擇，需依賴於監控演算法的資料數據充分收集，同時，依賴於監控演算法監控他廠價格，然後再行決定是價格戰或持續合謀的動態高價格。

這類型訂價演算法已經非常自動化，對於合謀的形成，已經不需藉由人為間各形式的大風險繁難溝通。同時，因應於動態市場中不斷的供給與需求波動、以及個廠行動策略變動，廠商在價格、產量、或交易條件上的即時跟進因應調整，都可委由訂價演算法彼此互動而自動完成，免除了傳統上頻繁重啟協談或溝通秘訊的困難，使得合謀維續更為容易；而發覺背離者時，又可即時予以處罰(價格戰爭)，都更強化了合謀的存續。

人類彼此間不存在任何形式的通訊或商談，卻共構競爭廠商之間的一致性行為，這是一個「意識平行(conscious parallelism)」行為。

圖 3.2 所示只是平行訂價演算法之一例，實際上，構成訂價演算法達致平行行為的模式，相當之多。圖 3.2 所示意的，是他廠訂價演算法直接鎖定領導廠訂價，並且採取跟進訂價作為自己長期反應策略。在其它可能產生的模式，例如編程設定令訂價演算法依競爭者價格而為特定反應，最常見者，如比照訂價(matching)、以牙還牙、嚴格策略、價格循環(price cycles)、或處罰 *n* 期。由於這類型反應策略，明白展示自己的固定行為與反應，很容易為其他廠商訂價演算機識別，被他廠預期訂價行為(predictable pricing behavior)，這是 Ezrachi and Stucke (2016)分類中第三類型的「Predictable agents (可預期代理人)」，往往也都促使競爭雙方策略趨於一致而穩定，也是屬於平行演算法。

更進一步的說，不論反應策略如何，如果競爭者具有能力知道或推論出彼此使用相同或相似的訂價演算法，則廠商就能預測彼此對價格變動的可能

因應行為，也屬於這一類型。例如，多個廠商使用類似的演算法，或使用同一演算法供應商所提供的演算法，都容易形成彼此訂價的可預測性。當訂價演算法掌握了對方明確可預期的反應策略後，則廠商就更能夠解釋他廠訂價行為背後的邏輯或意圖，同時，更能夠讓廠商藉由訂價策略變動釋放合謀意圖信號的企圖，更具有成效(見底下信號演算法敘述)。這類型訂價演算法，因彼此演算法相似而大幅降低策略不確定性，有效的促進合謀與其維續。

圖 3.2 是一個極為簡單模式，運用一個永遠跟隨另一廠價格的可預期智能體，簡單如斯，然只要能夠快速且普遍的收集訊息並反應，能夠監視市場價格波動、減低策略不確定性，則就足以在沒有人為顯然通訊下，促成隱性合謀。當然，這樣的合意行為過程，若是藉由人為來操作訂價演算法編程而致，則必有反競爭效應的疑慮，尤其若其動態訂價演算機(dynamic pricing algorithm)被植入不作競爭的程式指令時，人為涉及反競爭效應就更為明顯。動態訂價演算機早已被應用於市場中，雖易涉及前述合謀的疑慮，但不可否認的，其針對需求波動進行供給的調整，可提增供需適配效率，就這一點而言，是促進了競爭效果。例如，目前常用於航空市場、旅館訂票服務市場、以及運輸網路公司等的訂價演算法即是此類。

這一類型演算法的實際法例，或以 2015 年美國 DOJ 控訴 Amazon marketplace 的商家 David Topkins 為唯一成案者，被訴 David Topkins 於 2013 年九月至 2014 年一月期間，與其他賣家協同了海報網路訂價[78]。根據調查的揭露，David Topkins 與其他共謀賣家，針對在美國 Amazon Marketplace 上販售的某些特定海報，協議予以固定價格。為了執行這一協議，這些合謀廠家們並採用相同的特定訂價演算法，隨著這些特定海報的銷售數量，隨時對各自價格進行協同改變，並且編寫電腦程式指令演算法軟體進行符合於協議的訂價。該案 Topkins 被控違反 Sherman Act，最高可判處 10 年刑罰以及個人 1

[78] U.S. v. David Topkins, 2015 U.S. Dist. No. Case3:15-cr-00201-WHO (April 6, 2015).

百萬美元罰金，但最高罰金可以高達犯案利得或受害者利損的兩倍。

同年 12 月，英國競爭與市場局(Competition and Markets Authority; CMA)啟動對 Trod Ltd 及 GB eye Ltd 的調查案[79]。Trod Ltd 及 GB eye Ltd 是專賣運動與娛樂產品及相關產品的公司(例如海報、框架、徽章、貼紙、馬克杯等等)，在全球的運動娛樂產業中具有很好的形象，但因涉及於 Amazon 英國網站上共謀不互相削價而被調查，並終於 2016 年 7 月中旬認罪。這兩家廠商在 2011 年 3 月 24 日起至 2015 年 7 月 1 日止，彼此協議對各自於網路上販賣的海報與框架不互相削價；並利用自動重訂價軟體(automated repricing software)進行自動監視及快速調整海報與框架價格，以確定彼此沒有互相削價。顯然的，這兩家公司先是透過傳統人為方法安排協議運作，再以訂價演算法確保維穩這一安排。協議始於人類間明顯的反競爭協議，故被認定違法。這一個案子是與美國司法部協同調查，因為美國正啟動壁飾銷售的犯罪調查，其中涉案者 Trod Ltd 是英國公司(總部在伯明罕)。Trod Ltd 也隨即在 2016 年八月 11 日於美國的調查案中認罪，於 8 月 27 日為大陪審團彈劾[80]。Trod Ltd 銷售多樣類型人物特色海報，該公司及其總經理 Daniel William Aston 被控訴，最早始於 2013 年 9 月至約 2014 年 1 月期間，針對某些 Amazon Marketplace 上銷售的海報，與其他家廠商共謀協議，採用特殊訂價演算法監視與訂價，以確保線上同一產品賣給購買者時是相同價格(即是固定價格)，而且可以隨時同步的協和價格改變。

另外，也應留意的，平行演算法亦可能因為使用相同資料作分析，而導致使用廠商出現平行行為。例如，當多個廠商使用相同的資料數據庫來源、或者使用匯集自所有競爭者的資料數據，其訂價演算法依據著相同資料，分析市場情況變動之因應，必將做出雷同的反應，則容易形成一致行為。類似

[79] Competition and Markets Authority (2016), Decision of Online sales of posters and frames, case 50223.

[80] U.S. v. Daniel William Aston et al, 2015 U.S. Dist. No. Case3:15-cr-00419-WHO (Aug 27, 2015). https://www.justice.gov/atr/file/840016/download

的，當市場中競爭廠商使用同一個第三方供應商所提供的訂價演算法或資料數據，其所為之決行必然容易協和一致，亦是平行行為。後者，可視為以供應商為軸心，以軸心廠商之某行為(即提供相同的演算法)，而引導另一市場中原彼此競爭的眾買方形成協和一致，此即為 Ezrachi and Stucke (2016)所提出的第二類型「Hub-and-Spoke (軸輻)」演算法。

Hub-and-Spoke 是一種合謀安排。一廠商針對其上游或下游廠商，逐一進行聯絡互動以安排合謀，前者為軸心、後者為輻條，構成軸輻模式的安排；其目的在於保護或提增市場份額、或者維護利潤。這樣的安排牽涉了上下游(軸與輻)之垂直安排，亦有輻員廠商之間的水平合意。

因軸輻安排而涉案的法例，例如，Interstate Circuit, Inc. v. U.S. (1939)一案，由八家製片經銷商與無數的一輪及二輪連鎖戲院構成的電影產業，當製片商新出片時都是先安排於一輪戲院上映，以建立口耳相傳的口碑，一段時日後再另至二輪戲院以較低票價上映[81]。德州五大城市獨占首輪戲院市場的 Interstate Circuit 認為，此舉讓不少觀眾寧願多等些時日再以低價看戲，導致首輪戲院營收流失。於是寫信予八大製片經銷商，分別要他們對播放其製造影片的二輪戲院要求提高票價。每一製片經銷商都接受了要求，但並無直接證據證明其中任何一家與其他家進行彼此勾結、或知道其他家將做什麼。法院認為，本案中的製片經銷商若不能一致接受提議，將可能有重大損失，反之則可有利得，同時，每一製片經銷商都知道該提議也同時在其它經銷商被考慮中；由提議性質與經銷商一致行動中，即可獲得協議(agreement)的推論。

另案 Toys “R” Us, Inc. v. FTC (2000)，因美國玩具市場約由十家主要製造大廠，以及各類型零售商(如折扣店、大批發等)組成，若相同產品在不同管道銷售，高價零售商店的銷售利基將會流失[82]。於是占美國玩具市場約 20%的最大零售連鎖店 Toys “R” Us，去跟個別製造商要求，若欲與其交易就必須同

[81] Interstate Circuit Inc. v United States, 306 US 208, 810 (1939).
[82] Toys “R” Us, Inc. v. FTC, 221 F.3d 928 (7th Cir. 2000).

意其所提出的新政策，包括：大批發商(Warehouse clubs)要賣某一新產品、就必須進全線產品，所有新產品都必須先給他過目並確定是否要賣，而清倉貨也必須先由他決定是否買。第七巡回法院同意 FTC 之認定違反 Sherman Act，並指出本案與 Interstate Circuit, Inc. v. U.S. (1939)類似，但本案更為為明確，因為有通訊上的明確證據存在 。

近例則是 U.S v. Apple (2015)一案[83]，Apple 企圖以其 iPad 進入電子書市場，而當時最大電子書商 Amazon 正透過 Kindle 以非常低的 9.99 美元單價銷售，低於從出版商購買的批發價(約 12-30 美元)。Apple 與當時的六大出版書商都覺得 Amazon 訂價太低、具有市場破壞性；出版商更擔心 Amazon 企圖讓 9.99 美元成為市場常態、再憑優勢回頭要求批發價降至 9.99 美元以下。此時，Apple 線上書店(iBookstore)欲開始銷售電子書，對六大出版商提出新的經營模式，引入代理商訂價(agency pricing)模式，讓六大出版商可以在某一上限內自由訂價自已出版的書，並以 70/30 拆分利潤來優惠出版商，但唯一條件是，六大出版商必須要求所有經銷商(包含 Amazon)同時改採此一代理模式，而且除非這六大中絕大多數願意採用這樣模式，否則他將不建立 iPad 書市；後來有五家參與，並由 MacMillan 出版商出面要求 Amazon 跟進這種訂價模式。法院發現，許多證據顯示，這些出版商確實共同參與這一水平價格固定的合謀，而 Apple 與這些出版商共謀降低零售價格競爭、同時提增電子書價格；Aplle 不僅知道這一合謀，而且還是其中的積極份子。故認定違反 Sherman Act 第 1 條。於 2016 年確定罰款 4.5 億美元。

判例顯示，關於軸輻安排的訴訟，原告仍必須取得水平協議安排的直接證據、或足以充分推論水平協議的間接證據。

[83] United States v. Apple Inc., 791 F.3d 290 (2d Cir. 2015).

(三)信號演算法(Signalling algorithms)

為合謀而明示溝通的冒險性太高，而當競爭者間缺乏自然可及的聚焦點時，若無溝通則又難以相互意會(mutual understanding)以達致隱性合謀。廠商為解決這樣的困難，過去案例顯示，廠商可能會單方面的以價格宣告作為信號(signaling and unilateral price announcement)，藉此價格變動宣告透露出自己協同合謀的企圖，等待競爭者知悉後跟進。Posner 法官說[84]：「假如一廠提價並預期對手會跟進，而後對手真的跟進了，則這廠商行為可以被視為是單方開出一個共同提價的邀約、而且被接受。」

然而，透過策略選定(價格變動)來做為信號釋放，是有代價的。當市場價格達到競爭均衡、且無其它狀況改變時，一廠突然決定提價，因其利潤必然減少，正足以讓競爭對手察覺此一怪異行為而給予關注(此時信號正式被注意到)。競爭對手對此信號進行解讀，知其既非源自市場狀況變化、亦非源於品質提升，則唯一原因必是邀約我協同提價以共享更高利潤之企圖。若我對此信號沒察覺或不接受邀約，則信號釋放期間，發訊者的高價格會讓自己承受損失，而且沒有回補；發訊期間愈長，損失愈大，則就算合謀最後成功，發訊者仍然將比受訊者多了一筆額外代價，形成採用信號策略的一個阻撓力量。在訂價演算法參與的商業競爭中，這一肇因於等待的額外代價，將變得微乎其微；因為廠商間自動訂價演算機快速瞬時互動，調價因應，都幾乎會在消費者發覺之前，就已經完成好幾回合而足夠建立起合謀的共識了。

實務運作上，信號演算法的互動，例如，可以利用一般上網人數最少的時段(如夜深人靜時)，一方訂價演算機快拍自己價格表錄張貼，另一方訂價演算機則即時辨識；或者，公開佈告所有相關詳細數據，但藉由其中編碼暗藏訂價或提價建議的代碼(參見美國航空業 ATPCO 一案)。公開佈告所有詳細數

[84] In Re High Fructose Corn Syrup Antitrust Litigation Appeal of A & W Bottling Inc. et al., United States Court of Appeals, Seventh Circuit, 295 F3d 651, 2002, p. 2.

據，等同於是市場的高度透明，本已足以讓所有廠商更易於和同各部利益與協議，再搭配高度精良訂價演算法後，和同協議則幾乎可以沒有人類角色介入的自動化完成，而且快速效率。

訂價演算法的信號運作邏輯，如圖 3.3 之示意。實際的運作上，自動演算機持續發出新訊息信號(即一個較高訂價、稱為信號價格)，透露高價意願，同時隨時監視著競爭者回送的信號(即回應訂價)；若所有他廠回應訂價皆同我一致，則固定於此一信號價格，合謀成立。若他廠回應訂價有不同於我信號價格者，則再重新訂定信號價格並釋放出，若仍有他廠回應訂價信號不同於我者，則再次重新訂定並釋放；如此不斷更新信號訂價，直至他廠之回應訂價信號完全同我一致，而成為協同價格。此時市場價格會停留於此一超競爭價格，直到市場狀況變動而啟動另一回合的信號議價過程。

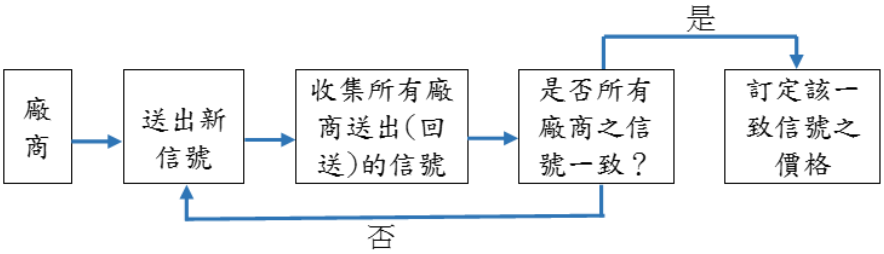

圖 3.3 信號演算法示意

事先公告價格的訊息揭露，促進市場透明化，一方面，可以提升效率、增進競爭效應；另一方面，價格透明化則提供競爭者間據以形成訂價聚焦點，有利隱性合謀之生成，具反競爭效應。在高度動態的網路市場中，廠商規模、產品、營運策略具有更大差異化，自然聚焦點本不易出現，但在自動訂價演算法之下，市場透明化或揭露訊息式的公告價格，都變得輕而易舉，反而更易促成隱性合謀。若與 Ezrachi and Stucke (2016)的四分類相較，信號演算法比較雷同於其第三類型「Predictable agents」演算法。

遠在 1990 年代初期，美國航空業就已利用了如此手段進行固定價格。美國 DOJ 調查認為，卡特爾成員們透過第三方為中心，以精良信號系統隱性的協同彼此價格[85]。航空公司每天把機票訂價訊息傳到 ATPCO (Airline Tariff Publishing Company)，這公司集合所有業者送來訊息後，即時開放給各旅遊業者、電腦訂票系統業者、消費者、及航空業者自己；訊息內容包含價格、旅遊日期、起飛與目的地機場、機票限制、機票起迄日、特殊價格時段等等。透過這個系統，航空公司得以事先公告數周後某天(first ticket date)的價格調漲，如果其它業者也配合此一宣告，則到了這一天，大家就會同時調高價格。有時也會利用票價種類代碼與機票日期註腳做為信號，藉以議談多重市場(multimarket)的協同行為。這些協同行為的成功，主要得力於公司間快速數據交換系統，且可隨時監視與快速反應於各種票價變動，從而無需任何顯然通訊而達成隱性合謀。法理上，隱性合謀並未被競爭法明白禁止，對於此等訂價系統的明白合作，DOJ 卻苦於無法取得任何價格明示合謀的證據，最終只能與航空公司達成協議，令其停止事先公告提價[86]。

(四)自學演算法(Self-learning algorithms)

機器學習宛如一個黑盒子，其過程難以被解構，也難以令人理解其何以達致合謀結果。這個黑盒子，以複雜且快速準確的方法處理原始數據，就像人類的腦袋，最終傳遞出一個最適產出，且不透露任何決策過程背後相關特徵。廠商最終可能達到了合謀目的，卻完全不知情。

一般而言，人類給予自學演算法的指令只有一個，就是達到目標，例如最大化利潤或最適化績效，不會再有其他策略的提示(如可預期代理人)，而是任由其自動的開發、挖掘、運行以達到該目標。過程中，透過機器學習與深

[85] United States v. Airline Tariff Publishing Co., 1994-2 Trade Case. (CCH) ¶70,687 (D.D.C. Aug. 10, 1994).

[86]在競爭法的原則上，若該事先公告提價足以促進消費者福利，是可以例外許可的。

度學習，訂價演算法達到複雜又精緻的境界(例如類神經網絡)。其強大的學習與預測能力，不斷的因應市場各競爭者的動作，不斷的學習與調整；而競爭者間卻宛若親暱隊友一般，如影隨形的隨時知悉彼此行動、隨時互動調整、隨時提攜共往最大績效，於是很容易的可以促成超價格合謀。當市場存有一點可能被操作往合謀狀態時，則學習演算法就一定會透過高速持續試誤，終而達到合謀均衡，而且會很精密的計算出足以獲取最大利潤的價格。甚且，儘管競爭對手並無顯然的同時編製其演算法作為相互呼應，一個自學演算法仍能憑著一己而達致且維穩於獨占價格。自學演算法即是 Ezrachi and Stucke (2016)所提出的第四類型「Digital Eye (數位眼)」演算法。自學演算法的示意，如圖 3.4。

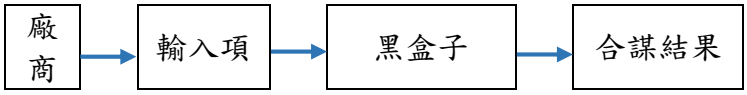

圖 3.4 學習演算法合謀之示意

自學演算法訂價仍未能用於實際商業運轉，故許多應用多停留於學術模擬。例如重複囚犯困境賽局的模擬，早期 Axelrod (1984)發現「以牙還牙」訂價演算法是一個最適策略(即具有最佳表現)[87]。Thomas (2018)以強化式學習(*Q* 學習)所建立的人工智能機(AI agent)模擬則發現[88]，透過每次行動後之報酬取得，智能體快速的發展出如何玩該賽局的直覺；在期數加長之後，更開始熟悉如何應對不同對手，以獲取最大目標值；終而發現，基於比擬「以牙還牙」策略之精神，其所設計之 AI 表現猶勝於「以牙還牙」[89]。Agrawal and Jaiswal

[87] Axelrod, R. (1984), The evolution of co-operation.
[88] Thomas, K. (2018), Building a reinforcement learning A.I. for the iterated prisoner's dilemma using Soar cognitive architecture.
[89] 以牙還牙策略一般具有以下原則：善始、不記仇、定反擊。一開始採用合作，之後只要對手採用不合作，我一定反擊(即不合作)，一旦對手回復合作，則我就隨即改回合作。

(2012)設計的機器學習演算法，其績效亦壓倒性的勝過「以牙還牙」策略[90]。而 Hingston and Kendall (2004)則發現，可逐漸調適策略的智能體(model-based adaptive agents)，相較於不可調適的智能體(non-adaptive agents)，其學習快速而且績效較好[91]。

小結

本節最後，整理 OECD (2017a)與 Ezrachi and Stucke (2016)對於訂價演算法的分類，列表並簡易說明如下，供讀者快速檢閱。

表 3.2 訂價演算法分類

OECD (2017a)四分類	說明
監控演算法 Monitoring Algorithms	收集、處理、監視來自市場競爭者的資料訊息。進一步的，可以知道競爭者價格的改變而隨時予以因應。
平行演算法 Parallel Algorithms	宛若人類經營者各自基於對市場情況改變而所為之一致行為。例如設計隨時跟進競爭者價格的編程，使用價格分享的演算法、或者共同採用第三方設計的演算法。
信號演算法 Signalling Algorithms	釋放訊息以公告意欲合謀或協談共同政策的企圖
自學演算法 Learning Aloorithms	目的是追求最大利潤。基於知悉決策互依性、且要不斷的因應市場其他競爭者行動而改變行動，而固定往最大利潤的持續追求。
Ezrachi and Stucke (2016)四分類	說明

[90] Agrawal, A. and Jaiswal, D. (2012), When machine learning meets AI and game theory.
[91] Hingston, P. and Kendall, G. (2004), Learning versus evolution in iterated prisoner's dilemma.

信使 Messenger	電腦執行人類需求意願。行動策略乃由由人類擇定，而後再藉由電腦演算法來協助執行、監控、警示。
軸輻 Hub-and-Spoke	以一個訂價演算法，替一些競爭廠商們決行市場訂價。
可預期代理者 Predictable agents	人類廠商單方設計一個機制，用以產出可預測型結果、並既定的反應市場狀態改變。
數位眼 Digital Eye	人類廠商單方創造與運用電腦演算法，預期達行某一特定目標(例如最大化利潤)，自動演算機透過學習與實驗而獨自決定達成目標的方法。

第五節 本章結論

本章探討了訂價演算法對市場結構及廠商行為所產生的可能改變、以及它可能被用為合謀工具的樣態。因為訂價演算法之運用，廠商數目與市場供需波動，已不太會衝擊合謀形成或維持；而另一方面則使得廠商參進變得容易、但立足障礙則變得更高，導致網路市場泡沫小廠眾多，而整個市場幾乎集中於少數具有巨大規模的廠商。其結果，導致了市場失靈。一方面，訂價變動頻率變大且歧異性高，消費者不易察覺價格波動情形；二方面，網路市場強烈的外部性，使得廠商必須同時兼具規模效率與範疇效率，方足以穩定立足，加大了參進阻礙；而個人化裁製，則導致訊息、知識、或其它項目的推播偏頗與集中於消費者原本偏好或信任者。

然而，運用訂價演算法的廠商，效率是增加的，更精良的配置效率、更準確的估計環境(尤其是需求)、更有效與快速的尋找最佳化價格、更迅速的對市場變動進行價格調整、更細段化客戶特徵進行個人化訂價。這讓廠商在價格與利潤關係、以及價格與市場狀態關係的動態最適評比，獲得快速而有效率的訂定。訂價演算法也使異質化的可能性變大，創新與成本差異可以提供新廠參進的利基，同時也使隱性合謀變得相對不容易。

訂價演算法並非完全廓清市場不利合謀因素，只是它相對於人類具有更強的廓清能力，於是更能促進合謀。同時，訂價演算法也非現時普及各產業，而只流行於於線上交易相對較多的產業，例如，零售業、旅宿業、交通運輸、股票買賣等；當然可以預期的，不斷會有更多產業產品，躍上線上模式交易。訂價演算法之協助廠商合謀，依功能模式而言，OECD 將其分類為監控演算法、平行演算法、信號演算法、與自學演算法等四種；若依運算進化度分類，Ezrachi and Stucke 則將其分為信使、軸輻、可預期代理、與數位眼等四個類別。

第四章 訂價演算法促進合謀

2018 年 10 月 3 日在參議院反托拉斯競爭政策聽証會前，助理檢察總長 Makan Delrahim 說到：訂價演算法之運用所產生的反競爭效應，對美國與歐盟的執法人員都是一個掙扎中的重要議題；最重要的部分是，美國反托拉斯執法人員認為，凡涉及訂價演算法的勾結案，應依傳統法律標準進行分析。美國司法部反托拉斯署副助理檢察總長(Barry Nigro)於報告中指出：當分析行為是否構成勾結時，分析者必須拿掉訂價演算法牽涉其中的這一事實[92]。雖然一些美國官員主張，現行反托拉斯法已提供了處理訂價演算法促成勾結的必要工具，但是，演算法的運用可能使得確認勾結行為時變得更為艱難，因此執法人員需要更新的調查技術。FTC 前代理主席 Maureen Ohlhausen 則主張，既然偵測訂價演算法勾結很難，則在外部偵察未能充分時，利用司法部寬恕政策及犯罪罰款，應該可以給予企業自我檢測與合作的誘因[93]。

第一節 合謀的概念與定義

訂價演算法可能會變成勾結的促進因子。不論傳統或現代演算法之下，為了達成與維持長時合作均衡，廠商們必須建構一個可以監控彼此互動行為的機制，藉此可以讓所有合謀者得以同意一個共同政策、得以監控該合謀政策之被遵守、得以處罰背離行為來強化該合謀政策。

Concerted practices

合謀(collusion)的形式，一般分為顯性(explicit)與隱性(tacit)。顯性合謀，是透過顯然的協議，或是書面、或是口頭的一種約定；而隱性合謀則不具任

[92] Banicevic, A., Kohlmeier, G.Z.A., Pechersky, D. and Howlett, A. (2018), Algorithms challenges and Opportunities for Antitrust compliance.
[93] 同前文 Banicevic, A., Kohlmeier, G.Z.A., Pechersky, D. and Howlett, A. (2018).

何顯然協議，而是競爭者間意識到彼此利潤與決策互依 (recognizing their mutual interdependence)，然後相互協調並共蹲高價的一種行為。在隱性合謀的狀態下，基本上，每一成員是獨立決定最大化自我利潤的策略，然而卻是達到了一個類似於不競爭的高價結局。

歐盟法院於判例中指出[94]「an agreement reflects "a concurrence of wills between economic operators on the implementation of a policy, the pursuit of an objective, or the adoption of a given line of conduct on the market, irrespective of the manner in which the parties' intention to behave on the market in accordance with the terms of that agreement is expressed." (一個協議反應出經營運者間對於在市場上執行某一政策、追求某一目標、或採用某一特定行為的一致意願，無論成員欲以何種模式行為來和同於此一協議內容)」。

可以說，協議(agreement)涉及到兩個概念，亦即，共識(common will)的存在、與某形式化的表明(暗示或明示)；若缺乏正式協議(final agreement)，即可用「一致行為 concerted practices」來判斷。

在美國，Sherman Act 中用了一些詞句來說明 agreement，包含了 contract、combination in the form of trust、conspiracy。根據最高法院說法，一個協議不一定要明示或正式的，只要它涉及了「a unity of purpose or a common design and understanding or a meeting of minds[95]」以及「a conscious commitment to a common scheme[96]」即屬之。這個定義廣泛到可包含平行行為(parallel conduct)。

在實際案例中，對於平行行為之對待，法院要求必須證明其確為廠商(parties)間協同(coordination)結果，而不單單只是基於寡占互依性(oligopolistic interdependence)的推論而已。這類被要求的附加證明，被稱為 plus factors，

[94] Case T-41/96, Bayer AG v Commission, [2000] ECR II-3383, para 173.
[95] Interstate Circuit Inc. v United States, 306 US 208, 810 (1939); Am. Tobacco Co. v. United States, 328 U.S. 781, 809–10 (1946), at 810.
[96] Monsanto Co. v. Spray- Rite Serv. Corp., 465 U.S. 752, 768 (1984); In re Flat Glass, 385 F.3d at 357.

例如，法院要求須握有參與者為了共採某特定方式行動所為之溝通證明。

當前法例仍要求須具備人為溝通證據

訂價演算法的進入廠商與市場，使得執法者針對「一致行為」區分更形困難。儘管經濟分析已然證明超競爭價格必起於某類特殊合作策略，但當前法院判例，仍要求須具備人為溝通證據方能確認。然而，以複雜編碼做為中介(訂價演算法)來達成共同目的者，其中的人為溝通幾乎不見，幾乎已是委由訂價演算法去完成大部或全部的溝通與執行任務。如此一來，要找到經濟分析之外的證據，相形更難。而且，儘管其結果可依經濟模型推論出或有「獎懲機制」存在，但檢驗或測定此機制，將面臨演算法技術上的阻礙。更進一步且是更基礎的討論則是：自動演算機之間的協同行為，是否適用於現行競爭法架構下的協議(agreement)定義？事實上許多一致行為的出現，往往是人主體間溝通協議與智能體間溝通協議的混合並行，則執法者又當如何去分割界定？

第二節 寡占市場的互依決策

寡占問題，雖是寡占市場競爭的問題，但卻也是該市場結構中的一大特色，那就是，競爭者的決策永遠相互依侍(interdependent)。在簡單的單期競爭中，個別廠商所選擇的策略，將都是一個「憑一己力量足以確保的最好利潤」[97]，於是，不論自己單方的策略如何變動，都是徒勞無功，自己的利潤都不會變得更好；因此，各方都沒了改變策略的誘因，就共構了一個穩定結果，這就是「納許(Nash)」均衡，這是「憑一己力量而確保」的結果。若有如此均衡存在，則我一旦選擇此一策略，對手即別無選擇的被我綁住於相對應的該一策略之上，單方面而言，對手無法動彈；這一策略，我無須期待其他競爭者

[97] 陳和全(2011), 管理經濟與策略。

配合。惟此一策略的形成，仍是個別廠商依據著共同面對的市場需求而計算得出，因此，決行考量上亦必然相互影響。

競爭市場的同向價格趨勢為結構必然

於是，市場在達到競爭均衡狀態之前，意味著，他廠的策略調動，是可能使其自身更好的，同時，我亦會有因應他廠策略調動而變動策略以求更佳結果的誘因。基於面對著相同的市場需求，若以價格為競爭策略，則當對方調降價格，我將面臨客戶與利潤流失，故必定跟進減價以確實保留住客戶；而若對方提價，我將面臨客戶需求增加，故有跟進提價的誘因。如果以數量作為競爭策略，則當他廠減產，我將面臨邊際收益增加(因市價提升)，故我之最佳反應策略必然是增產；反之，若他廠增產，市場邊際收益下跌(因市價走跌)，我的最佳因應策略則必然是減產。於是，價格競爭模型中，廠商的價格漲跌具同向關係，策略上具互補性(strategic complements)[98]；而在數量競爭模型中，廠商的產量增減則呈反向關係，策略上具替代性(strategic substitutes)。

顯然的，價格競爭的寡占市場，競爭價格一般呈現同向調動，亦是一種「有意識平行(conscious parallelism)」的行為，這並不須任何形式化協議，而是最佳策略選擇上的必然，這樣的行為在競爭法上並不構成違法，更無理由指控其意圖進行合謀。因此，執法者若欲證明寡占廠商違反競爭法，仍須多方依賴於其它額外因素(plus factor)證明的取得，例如證明廠商當下處於低利潤率、或採取違背當下最大利益的行動，故有共謀動機。

有意採行不利自我的訂價策略？

作為分析寡占市場踏腳石的單期賽局，沒過去、沒未來，廠商們所為當然就只是求取此時「一己力量可確保的最好利潤」，也就是，於完整事前分析後即一步到位的選擇了競爭均衡策略；對手於是一定被我綁住於一個相對的

[98] 前文 Bulow, J, Geanakoplos, J. and Klemperer, K. (1985).

競爭均衡策略，而無能為力再行透過欺榨我來圖利自己。雙方基於相同的思維模式，就會一致的選擇了競爭均衡策略，而達到了競爭均衡。

然而，多期賽局的寡占市場，均衡將會繁多不一。最簡單假設是無記憶賽局，則不論前期如何運作，對接著下來的一期都沒意義；每一期都是全新的開始，一如單期賽局，其結果是每一期都將是競爭均衡。而在有記憶的賽局中，競爭構面大為擴展，因為過去歷史的解讀，產生了效用，影響了我之推測、預期、與行動。一方競爭者可以透過現在的「釋出善意」，誘使另一方在未來互相合作，如此互動並不出現於單期賽局或無記憶多期賽局之中；因為無未來期望或純然的歷史失憶，當期「釋出善意」將被完全遺忘。於是，無限期或多期而不知何時終結的賽局中，「歷史」因素產生了決策上的作用，現在行動會被解讀與推論，或者現在行動正夾帶著所欲釋放的意圖，對手會依據此等觀測而擬定下一期(或未來)動作。

也因此，在競爭中的某一單期，我可能看到對手並未採用「一己力量可確保的最好利潤」行動，而是採用了一個當期會小於「一己力量可確保的最好利潤」的策略，何以故？是對方決策的失誤？還是對方的有意？如果我們假設決策者都是理性的，那麼就應該是「有意」的行為了！

有意的採用一個讓自我少於「一己力量可確保的最好利潤」策略(例如調高價格)，必然是在傳達著某個訊息或意圖，若能透過這等分析而確認此等意圖，則或許可提作 plus factor。基於寡占市場中的「相互依存與自覺」，廠商知道在策略互補性之下，若對手調高價格，而我跟進調高(合作策略)，則兩者不僅可以同時獲取更高的當期利潤(合作利潤 $C >$ 競爭均衡利潤 N)，還有機會把價格長期維持於這一高水平，獲取未來長期高利潤(合作利潤長期折現)。於是，他廠有意的採用讓自我少於「一己力量可確保的最好利潤」的高價策略，必然是在傳達著邀約我方「共同調高價格」的意圖。

棍棒與蘿蔔的兩手策略

廠商也知道，若我不跟進調高價格(不合作)，則對方的高價將致對方自己當期利潤減少(利潤設為 *N-a*)，我則因相對低價(留在競爭均衡價格)，而可獲得當期暴利的好處(暴利設為 *C+b*)。當然，一些時間後，對手將發現我並未跟進(提價)，他只好回復至原來競爭價格，於是兩廠於未來長期就都只能獲取競爭利潤(*N*)。以矩陣圖表示每一單期下的利潤值如下(即兩廠囚犯困境賽局報償矩陣)：

		對方	
		合作	不合作
我方	合作	*C, C*	*N-a, C+b*
	不合作	*C+b, N-a*	*N, N*

那麼，我要配合跟進提價嗎？這取決於兩個力量的權衡。第一，不跟進提價時的短期淨利得；第二，不跟進提價時的未來淨利損。

若我不跟進提價，短期內的狀態是我低價而對手高價，我獲得暴利(*C+b*)，相對於配合提價之合作狀態利潤 *C* 而言，有 *b* 的淨所得。但我如此做將失去未來長期合作狀態(C)、而只能停留於長期競爭均衡狀態(*N*)，這等於，未來長期的預期損失為 *C-N*。假設不跟進價格將於 *t* 期時間後被觀測，則我不跟進提價的短期淨利得與機會成本(即所失去的長期淨利得或稱為長期淨利損)如下所示(其中δ為折現因子)：

$$\text{不跟進提價的短期淨利得} = \sum_{i=0}^{t-1} \delta^i b = \frac{1-\delta^t}{1-\delta} b \qquad (4.1)$$

不跟進提價的機會成本 = 不跟進提價所失去的長期淨利得

$$= \text{不跟進提價的長期淨利損} = \sum_{i=t}^{\infty} \delta^i (C - N)$$

$$= \frac{\delta^t}{1-\delta}(C - N) \qquad (4.2)$$

若短期淨利得大於長期淨利損，即(4.1) > (4.2)，則我當不跟進提價，此時勾結共謀將無法成形；若短期淨利得小於長期淨利損，即(4.1) < (4.2)，則我當跟進提價，勾結共謀於是成形。長期淨利損可視為「不跟進提價」的處罰(或機會成本)，(4.2)式表示此賽局之處罰期限直到無窮，相當嚴苛，為文獻上所謂的「嚴格策略(grim strategy)」。

對方如此嚴格處罰「我之不跟進提價」，對他而言也未必就是最好的策略。有可能我之沒跟進提價，並非是我刻意視而不見，而可能是我未及時察覺，或我未能正確解讀以致誤認為這是對方廠商內部成本增加或營運調整之單方行為。於是只用一次(期)示意訊息，可能當後來我察覺而想要合作時，卻已沒再有任何機會了。為解決這一遺憾，對方可設計一個機制，當我未跟進提價時，隨之而來的不是永遠不合作的處罰，而是只一段適當長度處罰期，夠讓我方「不跟進提價淨利損」足以大過「不跟進提價淨利得」即可，一過了這一適當處罰期，對方即可再次提價、以再次釋放進行合作意圖，而我將有機會再次觀測、並有機會再次決定合作與否。我若跟進提價則合作成形，我若沒跟進，則對方將再依循前述設計的處罰長度、然後再次發訊。於是，我若每次刻意視而不見對方之合作邀約，則短期利得都將被隨之而來處罰所抵消，長期而言，我之不接受邀約合作是不利的。我們可以把這個處罰期(假設 n 期)的利損，表示如下：

不跟進提價的機會成本 = 不跟進提價所失去的淨利得

$$= \text{不跟進提價時的處罰期淨利損} = \sum_{i=t}^{t+n-1} \delta^i (C - N)$$

$$= \frac{\delta^t (1 - \delta^n)}{1 - \delta} (C - N) \qquad (4.3)$$

讓處罰期淨利損大於不跟進合作的短期利得，亦即讓(4.3) > (4.1)，則需要：

$$\delta^n < 1 - \frac{1 - \delta^t}{\delta^t} \frac{b}{C - N} \qquad (4.4)$$

亦即，處罰期 n 要夠大，大到使(4.4)式成立。其中，當(4.4)式等號成立的 n 值，即是有效處罰的最小長度。

表 4.1 即是以(4.4)式為基調而進行的模擬，當處罰期夠大而使得「短得」小於「長損」時，則勾結就很容易成功。我們把促成勾結所需的最小處罰長度，計算於欄位(6)。

藉由表 4.1，亦可觀測出一些勾結因素的影響與關係。欄位(1)是訊息被偵測的速度，代表我有否跟進對方高價將於 *t* 期之後，方被對方偵測。*t* 愈大，則我不跟進之短期利得將愈大，於是，若要讓我跟進而形成勾結，則對方勢必要拉長處罰期限(*n*)，一如 A1 區模擬數據所現。 欄位(2)是我「跟進」提價與「不跟進」提價時，未來單期所得之利差，亦代表著，我不跟進提價時的未來每期單期利損。於是欄位(2)值愈大，則要促成勾結之處罰期間就可愈短，如 A2 區欄位(6)所示。相反的，欄位(3)是我不跟進提價與跟進提價時，當下短期單期所得之利差，亦代表著，我不跟進提價時的短期單期淨利得。於是欄位(3)值愈大，則欄位(6)之處罰期間就必須愈長，方可促使勾結成功。此為 A3 區所模擬結果。折現率代表對於未來所得與現在所得之間的實質抵換關

係。若折現率為 1，則代表未來一百元價值等同於現在一百元價值；若折現率為 0.5，則代表未來一百元價值，實質上只等於現在的五十元價值。一般而言，我們設定折現率<1，以符合現狀。毫無疑問的，當折現率愈大時，未來利損換成現值來看也相對的會比較大，於是，欲促成勾結的處罰期間就可以比較小，如 A4 區之模擬。

表 4.1 影響勾結的因子

	(1) t (察知對方策略或訊息時間差)	(2) C-N (不跟進合作之未來單期利損)	(3) b (不跟進合作之短期單期利得)	(4) δ (折現率)	(5) $\delta^n \leq$ (則不跟進合作之短期利得<長期利損)	(6) $n \geq$ (處罰期間，則不跟進合作之短得<長損)
A_1	1	3	2	0.8	0.83	0.82
	2	3	2	0.8	0.63	2.11
	3	3	2	0.8	0.36	4.52
	4	3	2	0.8	0.04	14.53
A_2	1	3	2	0.8	0.83	0.82
	1	4	2	0.8	0.88	0.60
	1	5	2	0.8	0.90	0.47
	1	6	2	0.8	0.92	0.39
	1	7	2	0.8	0.93	0.33
A_3	1	3	1	0.8	0.92	0.39
	1	3	3	0.8	0.75	1.29
	1	3	6	0.8	0.50	3.11
	1	3	9	0.8	0.25	6.21
	1	3	11	0.8	0.08	11.14
A_4	1	2	2	0.6	0.33	2.15
	1	3	2	0.7	0.71	0.94
	1	3	2	0.8	0.83	0.82
	1	3	2	0.9	0.93	0.73
	1	3	2	0.99	0.99	0.67

促成勾結的過程一如前述，而一旦合謀形成，高價格(*C*)的維穩，必須防止合謀者暗中背離。我若背離，即我暗中降價而對方仍維持於高價，我必增利(*C*+*b*)而對方減利(*N*-*a*)，直到被對方發現為止(*t* 期)，於是合謀中的背離短利，一如(5.1)式。要防止背離，對方亦可設計一個機制。當對方發現我之背離，隨即降價至競爭策略，雙方同時跌至競爭利潤(*N*)，維持一段時日藉以處罰我之背離。處罰期間長度，可以是直至永遠、也可以是讓我損失足以大過背離短利的適當期間即可。此一處罰期之損失即如(4.2)或(4.3)式所示。阻止我之背離，則處罰長度選擇，必須符合(4.4)式，一如前述。

第三節 寡占問題與適法見解

互依決策的特性在隱性合謀中，是至關重要的因子。廠商經營之首務，無非是對市場需求進行估計，而市場需求則是所有競爭者共同面對、競爭、與創造的對象，廠商藉由市場需求與狀況的評估與認知，獲悉了一個共同所處的環境，進而知覺到決策必然相互影響。這個認知(recognition)已經為競爭者們鋪設了一個本質性的基礎共識(common understanding)，藉此，足以生長發展出無限的可能空間，包含了合作(或勾結)。當市場上廠商數目夠少時，這個基礎共識所能孕育的合作可能性就愈大，此即遠在半世紀之前法官Posner(1969)所關注的「寡占問題(oligopoly problem)：「寡占市場中的高度相互依存與自覺(interdependence and mutual self-awareness)，可能導致隱性合謀，這是一個非社會所欲但卻掉在競爭法可及之外的結果。」

廠商相互間的依存與自覺

針對「相互間的依存與自覺」所導致的隱性合謀，若要求一定要有經濟分析之外的證據(例如附加因素 plus factors)，事實上，將很難處理寡占廠商間許多有害競爭的互依行為。Kaplow (2011)認為「成功的互依協同

(interdependent coordination)產生超競爭訂價，此結果無異於各種特殊方法所獲致的經濟結果」，因此主張競爭法應該包含標準的寡占行為。但 Posner 則警告，法律上「視隱性勾結如同明示勾結」，是很危險的[99]。

理論上，價格競爭的寡占市場，價格策略具有同向調動的特性，構成「有意識平行行為」。實務上，一個簡單的策略，例如比配對手行動，則可將價格僵固於超競爭水平價格(super-competitive price)，此過程無需任何溝通，也正是「寡占問題」的核心。一般認為，高集中度與穩定透明的市場結構，一廠商行動對於對手的影響更大更快，於是互動與依存會更為清晰與快速，此正是演算法商業競爭所面對的現況。

同時提價是策略必然抑或共識意圖

寡占廠商決策過程，相互依賴，彼此間或無某一目標的心意相通。於是一方價格調高之際，若另一方也隨之調高，則這行動是起源於競爭上的策略互補性？抑或是已認知對方企圖而刻意去接受與配合它？這兩個可能性，其結果都呈現意識平行行為(conscious parallelism)，惟前者起源於寡占競爭的結構必然性，而後者則具有一個同登高價的共識(mutual understanding)。前者，當然不違反競爭法，後者之意圖卻難以證明。

基於策略互補性，一廠因預期對手會跟進，而決定現在調高價格，這樣的思維明顯的取決於對手可能反應、明顯的是互依決策，而一旦對手一如預期的跟進提價，「意識平行行為」出現；但是否存在「合會意圖」，將成為是否被認為隱性合謀之「和同作為(concerted practice)」的關鍵。然而，心意合會企圖「共同提價圖利」的念頭，難以證明；也因此，競爭機構常會利用一些反托拉斯工具(手段)來降低寡占問題的出現[100]。例如，結合控制(merger control)的事先審查原則(ex ante merger control rules)，以事先防止可能促增協

[99] Aircraft Cheque Services et al. v. Verizon Wireless et al., No. 14-2301 (7th Cir. 2015).
[100] OECD (2015), Roundtable on competition enforcement in oligopolistic markets.

同效果(coordinated effects)的結構性改變，或以事後審查原則(ex post rules)來防止或降低寡占互依性的可能增加。

不過，不少學者也認為，寡占結構並非不可避免的導致勾結，也因此質疑競爭機構的介入，例如 Whish and Bailey (2012)就認為寡占互依性常被誇大[101]。他認為，由於策略反應會有時間上的遲滯，而且廠商很可能受限於既有產能而無法吸收突增需求，因此，儘管同質產品具對稱結構的兩廠競爭，一廠降價仍可有正利潤[102]，就未必有誘因要去採行隱性合謀。同時，多面向差異化(例如成本、品質、規模、品牌忠誠度之差異)將增添隱性合謀的困難度；而若有眾多小廠存在，也可能制約了寡占者合謀價格；最後，合謀結果的超競爭利潤，也將吸引新廠蜂湧參進而加劇市場競爭。

合意過程難以舉證

不論 Whish and Bailey (2012)如何說，仍然不可否認，寡占問題走向隱性合謀的可能性仍然是存在的，而欲舉出明顯證據卻是艱難的。若無明顯舉證，在競爭法上如何處理寡占中的合意過程？

歐美競爭法執法機關已普遍認為，當競爭者之間具有限制競爭之協議者即屬違法，而所謂協議(agreement)，法院視其為「一組共同信念(a mutual set of believes)」。美國 Standard Oil Co. v. United States (1911)一案中宣稱[103]，只有當對交易「不合理限制(unreasonable restraints)」時，「協議」才被禁止，而契約、聯合、及合謀(contracts, combinations, and conspiracies)之稱謂，於此被全面改以「協議」概念替代。然確認合謀(conspiracy)存在，仍須有具體旁證(circumstances)確保陪審團能夠發覺競爭者間所存在的同一目的(a unity of purpose)、或共同意圖與理解(a common design and understanding)、或心意一

[101] Whish, R. and Bailey, D. (2012), Competition law.
[102] 相關經濟分析請參見 Levitan and Shubik (1972); Kreps and Scheinkmam (1983).
[103] Standard Oil Co. v. United States 221 U.S. 1 (1911)

致(a meeting of minds)於某一非法行為安排[104]。Monsanto Co. v. Spray-Rite Serv. (1984)一案上，法官指出：「必須存在直接或間接證據，足以合理推論證明，廠商有意識承諾一個被設計來達成非法目標的共同密謀(a conscious commitment to a common scheme designed to achieve an unlawful objective)」[105]。

一個合謀包含著一個違法協議，並不代表被訴者必然是互約見面而達成一份顯性正式協議，也不代表他們必然訴諸文字、或寫下如何的密謀或如何的執行。合謀者也可以是隱性的、暗默的達到互相理解、進而分配了消費群[106]。共同意圖與理解、心意一致、相互理解等等，都指涉著「廠商間將以某種形式限制競爭的一種共同理解(a common understanding among firms that they will restrict competition in some manner)」。在歐盟普通法院，協議也被普遍視為一種「共同意向(joint intention) [107]」或「一致意願(concurrence of wills) [108]」。

寡占市場上一個超競爭價格現象，鐵定是意識平行行為，可能是單純平行、也可能是刻意合意。然就算是後者，其因彼此默契理解後的合意行為，其實都是透過彼此策略(價格)訂定與回饋修正的市場競爭過程，是策略本身你來我往互動摸索後的理解、認知與一致，沒有任何策略之外的訊息(例如文件、言語、資料等)於人員之間溝通與傳遞。這種寓合會意圖於價格策略互動，與單純基於市場需求所為之價格平行行為，外顯表徵相同，無法分辨。

經濟分析鑑定的獎懲機制正是合意企圖之本源

若以經濟分析而言，單純意識平行行為與刻意合意行為，差別在於，前者，我以提價回應他人提價將使我有更高利潤，於是提價是策略上的必然性。

---

104 American Tobacco Co. v. United States 328 U.S. 781, 809-10 (1946)
105 Monsanto Co. v. Spray-Rite Serv., 465 U.S. 752, 768 (1984)
106 United States v. Suntar Roofing, Inc., 897 F.2d 469, 474 (10th Cir. 1990)
107 Judgment of the Court of 15 July 1970. ACF Chemiefarma NV v Commission of the European Communities Case 41-69.
108 Judgment of the Court of First Instance of 26 October 2000. Bayer AG v Commission of the European Communities

而後者，我以不提價回應他人提價將使我有最高利潤(亦即不提價才是策略必然)，但是我卻是跟著提價了；此等違反當期最適法則行為，必然是圖謀於未來利益所致。而要讓這個未來利益具有足夠的誘惑力量，就必須讓跟進提價者的長期淨利得利得大於機會成本(即短期利得)；或者說，讓不跟進提價的短期利得小於機會成本(即長期淨利得)。這個設計就是一套「獎懲機制(reward-punishment scheme)」的制約。獎懲機制旨在建構一個適當的機會成本，要讓不跟提價的機會成本足以大過短期利得，如此即可迫使(誘使)長期競爭者有誘因跟進提價，而共達於超競爭價格水平。

於是，區別單純意識平行行為或刻意合意行為，最大的差異在於，競爭者是否於策略運用上，內建了一套獎懲功能，這一基本原則於 Monsanto Co. v. Spray-Rite Serv. (1984)一案中被法官說得簡約而透澈[109]；法官指出，被認為合意勾結的要件，是必須證明「該行為可能會排除了廠商的獨立決行」。就經濟分析而言，一廠商之獨立決行被排除，即是受到了「不跟進則吃棍棒」的威脅。

然而，就算經濟分析確實已確定了「獎懲機制」的存在，依目前法例而言，若無掌握顯然證據，亦不曾單因經濟分析而判決確立違法隱性合謀行為。Monsanto Co. v. Spray-Rite Serv. (1984)該案亦指出，必須檢視此等協同行為是否足以「顯示競爭者並不獨立決行的證據」，例如提出平行行為所伴隨的其它因素(稱為 plus factors)作為證據。這些 plus factors 包含了一些透露勾結或促進勾結措施的意圖，例如訊息交換。

「獎懲機制」本身是建構於系列策略行動與不斷修正的競爭過程，是透過策略行動本身而相互摸索探測與理解，並無策略本身以外的任何訊息通聯。經濟分析雖已足以確認當前高價是緣於一套「獎懲機制」，或者已足以確認，除非競爭者透過一套獎懲機制策略，否則無以獲致超競爭價格；然而在實務

[109] Monsanto Co. v. Spray-Rite Serv. 465 U.S. 752,768 (1984)

上，這套獎懲機制是內建於互動的策略行動之中，並非屬於法院所欲之額外因素證明。因此，若無法找到此套機制曾被形諸文字、面談、溝通或各形式洩露的額外因素以為憑證，執法人員單依經濟分析推論，欲以推斷合意勾結，仍嫌單薄。

第四節 訂價演算法強化寡占問題

一般而言，若市場結構具有廠商家數少、透明度大、參進障礙高時，隱性勾結就更容易被廠商達成，於是執法人員要從中觀測掌握隱性勾結就更為困難。而當訂價演算法運用於市場競爭時，市場結構特徵被劇烈改變，使得原本就難觀測掌握的市場結構，變得更為難以觀測；而那些本來較易觀測(或較不易發生)隱性勾結的市場結構，卻也可能變得不易觀測，甚至可能強化其隱性勾結的可能性，也甚至可能促增那些非寡占結構市場形成隱性勾結的可能。

訂價演算法快速偵測市場各廠價格，快速對變動的他廠價格進行反應，促成市場訂價透明而使競爭廠商間策略互動更為穩定，市場內部也隨之更為穩定。針對新競爭者，廠商有能力於瞬時間採取針對性措施(exclusionary practices)，以阻礙其參進。廠商能夠快速測知對手策略並予以回應，使對手於合作情境下的預期欺騙獲利甚小，減少欺騙可能性。廠商可以充分監視市場狀態與變動，減低錯誤與意外風險，例如，因市場需求波動所致之銷售量變化，將不至於被誤解為對手欺騙。最後，價格的透明與明確，減少公司不同銷售階層人員因不同目標函數而在價格上的操作權變空間，於是因部門鬆散所致之開價不一致現象，可以有效降低。總而言之，訂價演算法強化了公司訂價的透明與固定，促增市場策略互動的穩定性，增加新廠參進的嚇阻力量，提增合作可能性與減低合作狀態的瓦解。

以監控演算法為例，其主要能力在於收集決策訊息並篩檢資料數據，既

掌握競爭者價格、亦可了解市場價格狀態，對於合意勾結可以產生有效的執行、監視、警戒，並即時予背離者處罰，宛若無所不在的偵查與報信者，並有利於持續維穩共謀。而當廠商們把各廠資料數據整合一起，隨時提供大家使用並隨時更新，則各廠根據相同資料數據與環境．對外部事件(例如成本或需求改變)，就很容易產生相同的策略反應，形成平行行為。

當許多競爭廠商購買運用某一(類)訂價演算法時，使用者決策建基於相同演算邏輯與相同資料數據環境，各廠的訂價法則與趨勢必然一致，導致價格一致，也是一種平行行為。如果許多競爭廠商共同委託某第三方以其訂價演算法代為決行，形成軸輻模式演算法，則須檢視該演算法決行的基礎資料數據，是來自於各家廠商提供？或來自於公共訊息收集？學習型訂價演算法，帶來更大的市場競爭變革，其合意一致過程，並未以任何程式或指令編寫，而是自我學習而達成目標的過程，令廠商合謀結果令人無法解釋與掌握。

第五節 訂價演算法促成合謀案例

廠商運用訂價演算法之後，自動演算機具有極精準的執行能力，免去人類決策過程的許多不確定與偏誤風險。第三章分類中的監控演算法、平行演算法、及信號演算法，仍需以人類行為為關鍵，再借由訂價演算法執行、監督、與確保合謀之成建立。因此，現有競爭法架構針對人類行為之合謀處置即以足以。惟在自學演算法發展之下，自學自動演算機之間是否能夠完全替代人類涉入而自行達成合謀？一直是一個有待論證甚或發展的疑點；確信的是，目前實務上仍未能做得到，但學術模擬上則已漸漸指出其可能性。因此，本節計畫分成兩部分，一為實際判例，二為自學演算法近期學術模擬所指出的可能性。

(一)實務判例

Meyer v. Kalanick (2016)

2015 年 12 月 16 日，乘客 Meyer 對 Uber 科技公司的前 CEO 及共同創辦人 Travis Kalanick 提起於 Uber 駕駛人間協調遂行僵固價格(Fixing Price)之違反 Sherman Act 控訴。Meyer 同時提出水平限制(horizontal restraint)及垂直限制(vertical restraint)兩項控訴，前者主張 Kalanic 偶為 Uber 駕駛人與其競爭者(其它 Uber 駕駛人)間具水平協議，後者主張身為 Uber CEO 與其下游每個個別駕駛人具一系列協議以 Uber 訂價演算法進行訂價。Meyer 控訴 Uber 訂價演算法產生超競爭價格(supra-competitive prices，但被告則認為駕駛人可以為了競爭客戶而自由的偏離演算法訂價。紐約南區法院法官 Rakoff 拒絕被告的駁回動議[110]。

Kalanick 主張，個別駕駛人與 Uber 的契約，是基於每一個別駕駛人的獨立行為，不能說成是一種所有駕駛人共同不為價格競爭協議的水平合謀；事實上，駕駛人由這些被控訴的 Uber 措施中獲得許多好處，例如可以分配以最適客戶、享受簡易支付方法。而且，同意使用訂價演算法並無法改變每一駕駛人決定參與 Uber 就是一項獨立決定。法院同意此看法，認定駕駛人之同意使用該訂價演算法，是在清楚知道所有其他 Uber 駕駛人都將採取相同費率之下所為的。

Kalanick 又宣稱，Meyer 所控訴的合謀是實質上不可能的，因為這將牽涉全美成千上萬駕駛人的同意。然而法院認為，該控訴理由在駁回起訴階段，足以充分的拒絕被告駁回要求。原告認為，Uber 駕駛人在他們肯認應用軟體用戶同意書時，就已經同意參與這樣的(合謀)計畫，其書狀中亦指出了多項事件做為水平合謀的間接證據，例如，Uber 為駕駛人籌辦會議聚會；2014 年九

[110] Meyer v. Uber, No. 1:2015-cv-09796-JSR, Doc. 37 at 22-23 (S.D.N.Y. Mar. 31, 2016).Meyer v. Uber, No. 1:2015-cv-09796-JSR, Doc. 37 at 22-23 (S.D.N.Y. Mar. 31, 2016).

月事例中，於駕駛人費談判後，Kalanick 同意調高費率。

在依個案分析原理之下，法院亦認為 Meyer 訴求「垂直固定價格協議」確實在相關市場中具反競爭效果，是充分的。其界定市場「相對新式之行動應用乘車共享服務市場(relatively new mobile app-generated ride-share service market)」，獲得法院認定合理合宜。此相關市場中只包含兩家主要公司，Uber 及 Lyft，而前者占有 80%市場份額。法院認為，計程車或其它傳統車載服務與 Uber 並非合理替代品，因為他們無法一鍵叫車或事先預約；雖然也承認將需要更多細節分析才能獲致完全正確的市場界定，但仍然認為在書狀階段(pleading stage)其市場界定是足以站得住腳的。(按：在現在更多的計程車都開始使用智能手機 app 進行叫車服務，因此包含一般計程車或車載服務的市場，值得更進一步的探討。)

Kalanick 提出請求納入 Uber 公司為本訴訟的必要部分，因為針對 Meyer 主張的救濟必須有 Uber 的出現，而且 Uber 也表示願意辯護其行為，獲得法院批准。

地方法院拒絕被告駁回該案的要求，認為 Uber 線上簽約並未給消費者足夠充分的合理明顯告知(reasonably conspicuous notice)、也未讓消費者明確的表明同意(manifestation of assent)，於是視同未簽約而不准其依協議交付仲裁。

2017 年 8 月 17 日， 第二上訴巡回法院則推翻地方法院判決，認為 Uber 及其前 CEO Travis Kalanick 於線上使用者協議書中已充分適當的告知消費者，凡有糾紛時一律交付仲裁，故准予交付仲裁[111]。

本案中 Uber 以演算法為基礎提出了一個新的營運模式。其 app 聯結了搭載需求者與區內可行駕駛人，告知乘客預估到達時間、來車外貌、以及預估費用，然後從信用卡上扣款。計程費用主要是由 app 的演算法計算，並取決於區內當下叫車需求熱度，即時反應真實需求。

[111] Meyer v. Uber, No. 1:2015-cv-09796-JSR, Doc. 37 at 22-23 (S.D.N.Y. Mar. 31, 2016).

在此新型營運模式中，Uber 一直主張駕駛人並非其公司員工，而只是選擇使用其 app 的獨立契約人(independent contractors)。這也構成了 Uber 被訴訟中的一個主要攻防點。如此一來，成千獨資公司在同一市場中競爭著同一群消費者，卻因共同使用 Uber app 訂價演算法，而訂定相同的價格，招來了僵固價格的反托拉斯控訴。本案中，Kalanick 設計該營運模式且令駕駛人必用其訂價演算法，法官認為此已充分構成了 Kalanick 與其駕駛人之間的軸輻(hub-and-spoke)安排。訂價演算法的使用，正是本案的核心。

雖法官認為原告主張 Uber 構成軸輻安排具充分論述，但因此案最後交付仲裁而未對這一部分進行裁決。

評論者對軸輻安排適用 Uber 商業模式的看法，多不表讚同，例如 Passaro (2018)。他認為[112]，與判例中軸輻案例相比較，Uber 一案存在著強烈差異。首先，原告 Meyer 控訴 Uber 協調和同數千駕駛人以致一致合謀，然而前三案例中，其所牽涉之輻員數目都僅六至十家。第二，過去案例中，顯然的，都是由軸心廠奔走協議以阻抑競爭，Interstate Circuit 因不願意讓低價二輪戲院繼續傷害獲利，故奔走說服主要製片銷售商不要再供應他們影片；Toys "R" Us 為了不讓低價大批發商傷害其獲利，奔走說服主要玩具製造商不要再供應貨源給他們；而 Apple 為了確保自己可以成功進入電子書市場，找了六大出版商，讓他們去壓迫當時相對低價的 Amazon，促其改採與 Apple 相同的訂價結構。Uber 則並無如此的邪惡動機，因此不能說是他與主要輻員廠商間進行了勾結。Uber 提供其 app(含訂價演法)給任一個想要使用它的駕駛人，沒有對任何想參進競爭者阻撓，這些人可以自由退出、自由訂價、或者隨時不提供載客服務。Uber app 的創新訂價演算與訂價，建立於即時真實需求變動，與阻抑競爭或打擊競爭完全無涉；而駕駛人同意使用其訂價演算法，也與其他競爭者是否同時採行不具相互依賴關係。最後，Uber 駕駛人並不存在市場互

[112] Passaro, N (2018), Uber has an antitrust litigation problem, not an antitrust problem. CPI Antitrust Chronicle, May: 38-42.

依性，而市場相依性往往是法院在傳統案例中，引為幅員廠間是否具協議的一個中心論點。前述三案例，輻員市場中的主要廠商，都被軸心廠提供一個相同協議，而且只有當所有輻員廠商都一致同意時，該協議才能對每一家廠商產生真正的經濟利益。反觀，駕駛人成為 Uber 駕駛人之利益，並不依賴於其他所有駕駛人之一致成為 Uber 駕駛人。雖然，更多駕駛人的參與，將會吸引更多乘客使用該 app，每一駕駛人可因此而獲利更多，但基本上駕駛人並不是因預期所有其他人都會加入這個 app，然後才加入的。他們會加入 Uber app 的原因很多，例如透過 app 所建構的安全、公平價格、與可靠的形象，他可以賺取一些單打獨鬥很難擁有的彈性收入。

U.S. v. Topkins (2016)

Poster Revolution 為一家線上海報專賣商店(後於 2012 年九月被 Art.com 併購)，專賣海報、印刷品、框架飾品等產品，並於線上商場(包括 Amazon)直接銷售其海報給消費者。雖然它透過 Amazon 商場(第三方)銷售其海報，但該公司保有訂價與運送的所有決策。該公司與其它銷售海報公司都使用演算法導向訂價軟體(algorithm-based pricing software)來訂定其於 Amazon 商場上銷售的產品，這一軟體會收集所有於 Amazon 商場販售相同某一產品之競爭者的訂價訊息，再依廠商之訂價規則由演算法軟體即時訂價。

公司總裁 Topkins 與其它合謀者被控訴至少在 2013 年九月至 2014 年一月間，共謀對 Amazon 商場上所販售的某些海報僵固訂價。為達成此合謀，Topkins 與合謀人與其他的海報經銷商代表人，共同參與對話與溝通，以討論關於該特定些海報的價格，於是形成提高價格、維持價格、穩定價格後予以僵固的協議。為確實執行這協議，決議對該些特定海報採用同一個演算方法，以進行彼此訂價變化之協調和同。於是，Topkins 親自著手電腦編程，以指令公司的演算法導向軟體依循協議去訂定該些特定海報的價格；而且還彼此不斷的收集、互換、監視、與討論關於該些產品的價格與銷售訊息，以確保達

成價格協議、強化遵守於該達成協議、並監視此等訂價演算法之效率性[113]。美國司法部於 2015 年 4 月 5 日正式提出控訴，是美國對電子商務所發出的第一個訴訟案。因掌握共謀者間討論的證據，明確證實彼此間確實協議同謀這些海報的銷售價格與策略，Topkins 隨即於 4 月 30 日認罪。

本案是美國第一個線上商場起訴案，其創辦人 David Topkins 成為首位被起訴違反反托拉斯法的電子廠商資深經理人。

本案 Topkins 被控違反 Sherman Act，最高可被判處 10 年刑罰以及個人 1 百萬美元罰金，但最高罰金可以高達犯案利得或受害者利損的兩倍。此案是由美國反托拉斯機關的三藩市辦公室所偵察，最終 Topkins 同意認罪協議，支付 2 萬美元犯罪所得並繼續配合政府調察。助理司法部長 Bill Baer 說：「(這)是第一個電子商務企業因勾結而被起訴的案子。不論是在吸煙室協商、或在具複雜訂價演算法的網路上，我們都不容許任何反競爭行為出現。美國消費者有權利享有自由且公平的線上商場，一如於實體商業市場。」[114]

CMA v. GB eye (2016)

英國競爭與市場局(Competition and Markets Authority; CMA)2016 年七月 28 日宣告，處罰一家總部於伯明翰的小型線上零售商 Trod Ltd (專賣小賈斯汀海報)163371 英磅，因他違反競爭法。

2015 年 CMA 於接到 GB eye Limited (trod Ltd 的競爭者之一)伸用寬恕政策後，於十二月啟動對 Trod Ltd 的調查[115]。GB eye 坦承接受 Trod 提議，對某些 Amazon UK 網站上的壁飾海報框架，並不互相削價競爭，也提供了 CMA 相關的違法協議證據。這是英國今年對線上零售商進行調查的第三個案子。

Trod Ltd 及 GB eye Ltd 是專賣運動與娛樂產品及相關產品的公司(例如海

[113] U.S. v. David Topkins, 2015 U.S. Dist. No. Case3:15-cr-00201-WHO (April 6, 2015)
[114] DOJ (2015), News of April 6: Former E-commerce executive charged with price fixing in the antitrust division's first online marketplace prosecution.
[115] 同前文 Competition and Markets Authority (2016).

報、框架、徽章、貼紙、馬克杯等等)，在全球的運動娛樂產業中具有很好的形象，但因涉及於 Amazon 英國網站上共謀不互相削價而被調查，並終於 2016 年七月中旬認罪。這兩家廠商在 2011 年三月 24 日起至 2015 年七月 1 日止，彼此協議對各自於網路上販賣的海報與框架不互相削價；並利用自動重訂價軟體(automated repricing software)進行自動監視及快速調整海報與框架價格，以確定彼此沒有互相削價。顯然的，這兩家公司先是透過傳統人為方法安排協議運作，再以演算法確保維穩這一安排；協議始於人類間明顯的反競爭協議，故被認定違法。Trod 最終認罰 163371 英磅，而 GB 則因舉發卡特爾行為並配合 CMA 調查，於寬恕政策下而免罰。

CMA 卡特爾小組領導資深主任 Stephen Blake 說：「線上商場如 Amazon 讓賣者直銷其產品至消費者，消費者因此有更多選擇且更低價格。線上訂價工具(例如自動重訂價軟體)可以幫助賣者更有效率競爭，從而也能有利於消費者。但在這個案例上，案主卻是利用重訂價軟體來執行非法協議而損害消費者利益。」「線上平台的賣者們必須意識到，彼此協議限制價格競爭是違法的。」

這一個案子是與美國司法部協同調查，因為美國正啟動壁飾銷售的犯罪調查(前述 U.S. v. Aston 一案)，其中涉案者即為本案 Trod Ltd。反托拉斯部門三藩市辦公司對壁飾產業固定價格的調查時，於 2015 年十二月搜索其總裁 Aston 住家同時，亦協同英國 CMA 搜索了 Trod Ltd 在 Birmingham 的總部。

這一案的偵辦只用了不到 8 個月時間，相較往例大約的一年光陰，速度相當快，在其中，CMA 使用了更精巧的科學技術來收集與評估違法證據[116]。2014 年 12 月，CMA 宣佈新設「數位取證與智能主任(Director of Digital Forensics and Intelligence)」，以提升網路的調查取證、協助數位證據的取得與審察、引領自己部內科學取證能力的快速發展。無疑的，一年後，CMA 的數

[116] Tricker, M and Rogers, S. (2016), Online retailers should tread carefully after Trod. Digital Business Lawyer, October, 3.

位取證人員對 Trod 的伺服器與安全數據的取像，成為一項相對簡單的任務了，這些取得的數據可被用來支持 GB eye 已經提呈的證據。

美國 DOJ 起訴 Topkins 並迫其於 2015 年 4 月認罪後，又於八月宣佈舊金山聯邦陪審團彈劾舊金山 Trod Ltd，並於 12 月彈劾其老闆 Daniel Aston 與前述 Topkins 相同的不法行為。據推測，正因美國 DOJ 的連續調查，促使 GB eye 出面向英國 CMA 坦承犯行。Trod 最終於 2016 年八月認罪，坦承固定海報價格。這案子的調查，是一個跨國合作的範例，英國 CMA 配合美國 DOJ，確保兩方協同調查，於 2015 年十二月 1 日，聯合同步搜索 Trod 辦公場所(英國總部)與住家場所(Aston 美國住所)，於是美國可以快速的在 2016 年八月 11 日就讓 Trod 認罪。

不再如傳統協議於「充滿煙味」的房間中進行，本案的線上零售商則是利用交易工具來協和彼此行動，依賴特殊的電腦演算法來協調海報訂價，達成且維穩卡特爾。簡單說，一旦你設計一個正確的演算法、並同意讓他如何運作，則剩下的就由電腦接手處理。這類型電腦軟體並非新型式，很多 Amazon 賣家都採用它來監視競爭者價格，並隨著市價波動而調整自己的價格。但是，使用演算法來執行與維穩卡特爾，則是新型態的競爭法議題。這個全新型式的反競爭，當前舊法是否仍然足以勝任？成了一個爭議與挑戰的話題。

過去的案例依賴於取得成員們溝通的證據，以顯示固定價格的協議或共識執行正在進行中，因為這個「溝通(communication)」是使得卡特爾得以運行的核心元素。一旦這個「溝通」變成為「技術(technology)」替代執行，則卡特爾的外貌與感覺就完全不一樣了。

Trod 是英國今年第三個調查線上零售商的案子，前兩例主要是關於供應商設限線上零售商可以銷售的價格。Trod 這一案，CMA 確實掌握了來自於 GB eye 提供的證據，如果沒有呢？則 Trod 就可以大聲辯白說，演算法自動機掌控了全局，他們自我學習與調整而決定價格。一個 CMA 發言人也說道：「在 Trod 案子中，儘管價格從 2011 年三月至 2015 年七月已經漲了 20%，廠

商勾結的獲利仍然是不可能確認出來的。」這可能說明，在安置演算法之後，公司根本就可以不必再去關心或監視他人價格了，因為電腦絕不會欺騙他們。

在未來，CMA 必須加緊速度分析大數據，藉以曝露出一些利用價格變動以持續維穩的卡特爾。

U.S. v. Aston (2015)

Trod Ltd 為總部設於英國伯明罕的一家公司(在美國則為 Buy 4 Less)，銷售多樣產品，其人物特色海報，包括來自於影片星際大戰、蝙蝠俠、辛普森一家、黑色追緝令、屍行者等等，亦來自於看板名星名人如 Beyonce、Paloma Faith、及 Nirvana。該公司及其總裁 Daniel William Aston 被美國司法部提訴，謂其與合謀者們，至少始於 2013 年九月至約 2014 年一月的期間，針對某些在美國 Amazon Marketplace 上銷售的海報，與其他家廠商共謀協議，採用特殊訂價演算法監視與訂價，以確保線上同一產品賣給購買者時是相同價格(即是固定價格)，而且可以隨時同步的協和價格改變。其被提訴內容與情節，一如前述 U.S v. Topkins，於此不再重述[117]。

本案起源於反托拉斯部門三藩市辦公司對壁飾產業固定價格的調查，於 2015 年八月 27 日提起彈劾，十二月時搜索總裁住家同時，亦協同英國 CMA 搜索了 Trod Ltd 在 Birmingham 的總部。Trod Ltd 於 2016 年八月 11 日於美國的調查案中認罪，於八月 27 日為大陪審團所彈劾[118]。

ECJ's Judgment in Eturas (2017)

Eturas (擁有 E-TURAS)網上旅遊訂房系統為 30 幾個立陶宛旅行社所共同採用，2009 年八月 25 日，Eturas 主席發出電郵給所有旅行社，請對於由現

[117] U.S. v. Daniel William Aston et al, 2015 U.S. Dist. No. Case3:15-cr-00419-WHO (Aug 27, 2015).
[118] DOJ (2016). News of August 11. Online retailer pleads guilty for fixing prices of wall posters: second defendant to plead guilty in ongoing investigation.

行 4%折扣減低至 0-3%折扣進行可否意見表示。事後並透過 E-TURAS 訊息系統發出通知，謂折扣原則上最高為 3%，事後，Eturas 單方的於系統上進行技術修正，也要求各旅行社做一些額外的技術面步驟以配合新政策[119]；惟並未禁止旅行社仍然採用高於 3%的折扣。E-TURAS 系統被用來遂行以演算法限制折扣，於是，這系統是否是被用來促進旅行社間構成一個 hub-and-spoke 協議，用以降低折扣？

立陶宛競爭機關於 2016 年認為，這些旅行社並非獨立隔離的接收這行動訊息，可以合理假設其他人亦收到相同訊息、且很可能會遵守它，於是推論這旅行社曾事先討論過這樣的行動，這是進行協同行為，而予以處罰。

歐盟法院(European Court of Justice; ECJ)不斷重申，廠商必須獨立決行商業行動，不能與會影響市場行為的營運者之間，有任何直接或間接接觸、也不能透露出任一營運者的未來策略。ECJ 認為，線上平台條款確實可以導致管理者與使用者之間的反競爭協議，同時主張，假如旅行社(使用者)知道管理者所寄出的訊息(這可潛在導致反競爭勾結)，則他們就該被先設為參與此一協議行為，除非他們採取步驟以隔離了自己。歐盟法院確認，是否實質上知悉，才是是否存在違法的依據；管理者訊息傳輸，其本身不足以構成實質知悉的假設，但是實質知悉與否，則可以從客觀而持續性的現象(objective and consistent indicia)來推論。同時，假若旅行社曾回給管理者明確反對、或者曾持續性的提供高於合定的折扣，則參與協同之先設即可被成功駁斥 。ECJ 退回此案至立陶宛最高行政法院進一步審查。

立陶宛最高行政法院基於歐盟法院方向，考慮兩點：旅行社是否意識到這一協同行為？他們是否曾經反對過這一行為？依立陶宛競爭委員會收集的資料分析，旅行社可分成三類：(1)知道 Eturas 之設定限制卻沒有反對 (2)知道 Eturas 之設定限制也曾反對 (3)無充分證據顯示知道不知道 Eturas 的設定

[119] Lawrance, S. and Linsner, M. (2017), Eturas-Any conclusions on platform collusion..? Kluwer Competition Law Blog, January 19.

限制。顯然的，只有第一群旅行社可被認定是默契參與此一協同行為，最後只有這一群旅行社以及 Eturas 被處罰。

U.S v. Airline Tariff Publishing Company (1992)

1992 年 12 月 21 日，美國政府控告八家航空業者、航空訂價出版公司(Airline Tariff Publishing Company; ATPC)、及其他共同合謀者，不合理的合作以圖限制彼此間競爭，違反 Sherman Act 第 1 款[120]。

提訟理由有二。其一，這些合謀者至少在 1988 年 4 月至 1990 年 5 月間，透過 ATPC 電腦化播送服務，進行了許多僵固價格的協議、互信、與一致行動，包含共同提價、減少折扣額、以及國內旅遊機票價格設限等。航空公司們每天將機票訂價訊息傳到 ATPC，這公司集合所有業者送來訊息後，即時開放給各旅遊業者、電腦訂票系統業者、消費者、及航空業者自己；訊息內容包含價格、旅遊日期、起飛與目的地機場、機票限制、機票起迄日、特殊價格時段等等。美國政府指出，透過這一系統，彼此間可以(1)交換提議與討論票價的變動、(2)以某些市場票價的調動做為交換其它市場的票價調動、以及(3)作為票價變動幅度、範圍、與時間的彼此保證交換，從而剝奪了消費者由自由競爭中所該得到的服務。

其二，這些合謀者共同參與 ATPC 之該價格播送系統的組織與運作，促成了彼此協同互動：(1)對未來提增票價、設限票價變動、與票價折扣減少作有效率溝通，(2)建立起降機場市場間建議票價的參考與關連，(3)監控他人票價的變動(甚至包含仍未販售的機票)，以及(4)降低對於他人訂價企圖的不確定性。

事實上，透過這個系統，航空公司等同於得以事先公告數周後某天(first ticket date)的價格調漲，如果其它業者配合這個宣告，則到了這一天，大家就會同時調高價格；有時也會利用票價種類代碼與機票日期註腳做為信號，藉

[120] U.S. v. Arline Tariff Publishing Company, Civil Action No. 92-2854.

以議談多重市場(multimarket)的協同行為。這些協同行為的成功，主要得力於公司間快速數據交換系統，且可隨時監視與快速反應於各種票價變動，從而無需任何顯然通訊而達成隱性合謀。

法理上，隱性合謀並未被競爭法明白禁止，但 DOJ 對於此等明明白白合作的訂價系統，卻取得不到任何價格明示合謀的確實證據，只得與航空公司達成協議，令其停止事先公告提價；但若該事先公告提價，可以促進消費者福利，則可以例外許可。

DOJ v. Traders for Major Banks (2017)

美國司法部反托拉斯局起訴三位英國前外匯交易員違反 Sherman Act 第 1 節，合謀僵固與操縱美元歐元兌換價格[121]。紐約南區法院於 2018 年 10 月 26 日宣判無罪[122]。

司法部早於 2013 年即開始調查該案，在第四名(Gardiner)交易員於 2015 年 5 月 20 日達成不起訴協議後，於 2017 年 1 月 10 日起訴。Gardiner 幫助政府作證，指出該三名交易員自 2007 年起即在跨銀行的 Bloomberg 私人聊天室中以「the cartel」群組執行該計畫，該群體有一個「君子協議」，將不進行會導致任一方不利的交易；並依近期交易區間製定外匯基準，同意協定於兩個「日固定匯率」附近，且喊著「一個團隊、一個夢想」口號。陪審團在錄音檔中聽到這四名交易員討論如何進行協同他們的交易。

但 Gardiner 在交叉質問中，承認他一直到被調查前都不知這行為是違法的，又說，他若曾被告知這是違法的，他將會非常驚訝。這使得他的證詞遭受了懷疑。庭訊中，有專家證人指出，在他們交易數據中，事實上有 141 例是被訴者彼此間互相不利的，而且說聊天室在那時的產業，只不過是一個交

[121] DOJ (2017), News of Junuary 10: Three Former Traders for Major Banks Indicted in Foreign Currency Exchange Antitrust Conspiracy.
[122] Morris, D. (2018), DOJ Antitrust Division suffers another trial setback in forex-rigging case, Lexology, Ocober 26.

易員互動的普通場所，交易員在那裏只是另一方(counterparts)的身分，而非競爭方(competitors)。

最後，陪審庭判決證據不足。

Webtaxi (2018)

2018 年 6 月，Luxembourg Competition Authority (LCA)作了一份迥異於多數國家競爭機關的判決，特讓個別免責於水平價格固定卡特爾[123]。本案 Webtaxi 是一個於 2015 年成立的 app，一個以 app 為底的計程車叫訂系統(app-based taxi booking system)，它分配最接近的計程車給客戶，其演算法為獨立駕駛人自動計算出出應適用於客戶的車費，參與這 app 服務的獨立駕駛人必須按月繳費用給 Webtaxi。另一個類似的競爭者向 LCA 提出控訴。

Webtaxi 的訂價模式，在 2017 年 2 月 3 日之前與之後，有所不同。之前的模式是對一次出車給一個最高價格建議，然後駕駛人與乘客可以在此上限內進行議價；之後的模式則是由演算法依每公里單價、出車距離與時間、交通狀況等諸多參數自動計算一個固定價格，不許議價。LCA 認為固定價格模式構成違反盧森堡爭法第 3 條的反競爭水平協議，然因此行為同時帶給消費者更方便快捷叫車服務，產生效率利益(efficiency gains)，因此適用第 4 條的個別豁免。但是之後模式則需進一步檢視。

LCA 確認該平台是一個雙邊市場，包含兩個關係：Webtaxi 與參與駕駛人關係、參與駕駛人與客戶關係；而在平台仲介下，駕駛人同意共同採用 Webtaxi 演算法訂價工具所指定的車費。也就是說，LCA 認定，僅管是嚴厲的協議，也不是當然違法，仍然需審視是否具第 4 條之下的個別豁免。而要符合此豁免，該協議必須完全符合四個條件：(1)該協議帶來經濟效率 (2)該

[123] Ciannino, M. (2018), Webtaxi: the Luxembourg competition authority exempts an algorithmic price-fixing arrangement on efficiency grounds. CORE Blog, July 10. 亦請參見 Picht, P.G. and Loderer, G.T. (2018), Framing algorithms–competition law and (other) regulatory tools. Max Planck Institute for Innovation and Competition Research Paper No. 18-24.

經濟效益的合理比率被轉移至消費者 (3)該協議對該效率之獲致，是不可或缺、必要的、且相稱的 (4)該協議不減低相關市場內的競爭。

關於第一點的經濟效率，Webtaxi 提出五點說明，被 LCA 接受：(a)最近鄰分配叫車減少空車招攬 (b)效率資源配置減少計程業產生的空污 (c)客戶享受每日 24 小時每週 7 天的統一訂價、集中且廣泛的叫車服務 (d)駕駛人更有效率的因應高低峰時段需求而調整供給 (e)LCA 也主動提出認為，客戶熟練於使用 webtaxi 訂購服務可以對整個盧森堡計程車產業帶來附加價值。

關於第二項轉移合理比率的好處給消費者，LCA 發現，在量化分析上，Webtaxi 讓駕駛人訂定較便宜的車費，因為 Webtaxi 訂價比一般計程車費用低，才有市場，同時 Webtaxi 提供隨距離愈遠而費率愈低的措施。結果，演算法訂價可以導致客戶車資的顯著減少。在質化分析上，Webtaxi 平台有效減少客戶等待時間以及空車兜攬的數量，重組了許多計程車行、增加了駕駛人、確保隨時提供潛在客戶需求；同時 LCA 認為，計程車業所致空污的降低，此好處也是必然分享客戶的。

在第三項關於不可或缺的條件上，演算法的統一定價(uniform pricing)且事先給乘客知悉，將可避免客戶的議價；因議價會導致客戶以最佳價考量來叫車，而非可帶來效率利益的最近鄰派車。同時固定價格意味著出車中的意外事故，將完全由車行吸收，免除了乘客這方面的風險。LCA 認為以上好處唯有透過演算法訂價才能確保。在第四項關於維持市場競爭上，LCA 認為在盧森堡只有 26%計程車參與 Webtaxi 平台，因此不認為此固定價格協議傷害了相關市場的健康競爭。

於是 LCA 判決適用個別豁免，是第一個水平反競爭協議被 LCA 適用該條款的案例。

然該案批評者相當多，多數認為，演算訂價事實上是競爭者所編寫、且是同時考慮對手訂價的一種訂價機制；雖然每一次出車都是自動的被 app 分配給最近的駕駛人，致常被認為駕駛人之間並不存在實際或潛在競爭，然而

app 仍是最終為獨立駕駛人決定價格、從而消除使用這平台的所駕駛人間的價格競爭。在美國，這樣的大膽行為將被譴責為一種赤裸裸固定價格行為，而整合這行為者就是 app。雖然 LCA 認為市占率僅 26%，消費者很容易的就可轉用其它計程車，因此合謀不易成功，但並不代表這樣的行為就不是勾結行為[124]。

EC v. Container liner shipping companies (2009)

歐盟 15 家貨櫃班輪運輸公司，自 2009 年起，經常性的利用網站及專業貿易媒體，事先公開公告公司未來的價格增漲，一年內會做好幾次，但每次只公告每櫃增加多大額度、哪些航線、何時實施，而無明白的最終價格[125]。專業術語上稱此為一般比率增漲(General Rate Increase)公告。GRI 通常會在實施前 3-5 星期公告，其他或所有其他運輸商在這段期間內，也會陸陸續續對相同或類似航線跟進宣告其 GRI，不過有些航商也會作延期或修正，可能是為了要等待配合其他航商 GRI 公告。

EC 疑慮 GRI 公告可能不足以提供新形成價格之充分訊息給客戶(傷害客戶)，卻只會讓航商們完全洞悉彼此的訂價意圖、然後協同彼此行為，傷害競爭。2013 年 11 月 EC 正式啟動訴訟程序，調查這等行為是否構成違反 Article 101 of TFEU 及 Article 53 of EEA 協議。2016 年 7 月 7 日貨櫃輪航商們提出承諾，包含：取消 GRI 而改以公告至少呈現五個衡量基準下的總價、不得高於公告期間的最高價格、實施開始期間不超過 31 天等等，EC 經過評估後認為足以充分解決疑慮，故沒有再繼續調查之需要[126]。

---

[124] Evans, D.H. (2018), Webtaxi: a wrong decision on “algorithmic pricing fixing”. Competition Law & Economics, August 9.

[125] European Commission (2016), Press release of 16 February, Antitrust: Commission seeks feedback on commitments offered by container liner shipping companies.

[126] European Commission (2016), Summary of decision of 7 July, relating to a proceeding under Article 101 of the Treaty on the Functioning of the European Union and Article 53 of the EEA Agreement (Case AT.39850-Container Shipping.

(二)自學演算法的學術模擬合謀

Shakya, Kern, Owusu and Chin (2012)

動態訂價是隨著預期需求變動而即時改變價格的策略，以類神經網路進行動態訂價的文章，過去不少，但由此而擇取最適訂價政策者，甚少。本文即是利用類神經網路結合進化演算法(evolutionary algorithms)，達到擇取最優訂價策略的目的。本文首先建構一個估計模組，並使用線性迴歸(線性或指數形式)、最大概似法(多項式 multinominal)、及類神經網絡(backpropagation 反向傳播算法的 ANN)等四種估計方法。估計模組的工作旨在估計與建構需求，一旦需求推估得出，則隨即利用優化模組中的進化演算法(例如基因演算法 generic algorithm)，進行最優策略之擇取[127]。

類神經網路的運用，對於包含多元異質產品服務的各種可能需求估計，具有充足彈性的應付能力；而進化演算法的運用，對於多樣化複雜模型，足以充分的涵蓋與解決的功能。本文模擬發現，當真實需求模型是線性型、指數型、或多項時，這四種估計模組中，以類神經網路具有最佳的平均表現，其績效表現的穩定性最高、適應各種不同情況的能力最強、且找到最正確訂價政策的能力最高。

Nambiar, Simchi-Levi and Wang (2018)

許多關於動態訂價的研究文獻，常常假設需求是一個線性或一般化線性函數[128]，然而一旦前提假設錯誤，則估計參數必然偏誤。因為錯誤的需求假設將導致錯誤的動態訂價，而錯誤的動態訂價又將進一步的引導出錯誤的需求推估，於是形成「價格內生性」的偏誤問題。為解決這一問題，本文提出

[127] Shakya, S., Kern, M., Owusu, G. and Chin, C.M. (2012), Neural network demand models and evolutionary optimizers for dynamic pricing. Knowledge-Based Systems 29, 44-53.
[128] 例如 Qiang and Bayati (2016), Javanmard and Nazerzadeh (2016), and Ban and Keskin (2017)。

一個「隨機價格衝擊(random price shock, RPS)」演算法，一來控制價格內生性效應，二來以獲得不偏誤的參數估計[129]。過程中，首先，仍是利用存在偏誤估計的需求去求出最優化訂價模型，找出一個貪婪訂價(greedy prices)；然後於此一訂價上加入一個隨機價格干擾項，構成了 RPS 演算法的基本概念[130]。干擾項的變異之大小，將由演算法仔細控制，若變異愈大，即更看重開拓與學習需求函數，而變異愈小，則代表價格愈接接貪婪訂價，愈強調對當前最大利潤的掌握與榨取。前者是 exploration、後者是 exploitation ，其權重分配過程，即為「開發-榨取抵換(exploration-exploitation tradeoff)」。接著以 Oracle Retail 時尚精品連鎖商店的大量資料進行實務模擬，結果發現，RPS 演算法比其它一般演算法平均高出 8-20%的收益。

den Boer and Zwart (2015)

決策者之決策，不僅企圖要最優化訂價，還要最優化學習過程，於是這過程中，短期非最優決策也是可能被擇取的。緣於旅館產業產品是由到達日子與停留時間所組成，具有時效性(perishable)，必須於一段期間內出售的、數量是有限的；於是，廠商可能會想從類似需求特徵的產品市場中，去推知旅館業產品之消費行為，正是本文的研究起源[131]。本文的估計模組有三類型需求：線型、指數型、與羅吉特需求，並以最大概似法(maximum likelihood)估計其需求。優化模組則是運用了價格偏離(price dispersion)的應用設計，藉以學習出最優價格策略。模型設計上，銷售季節一開始，會給予廠商一些學習

[129] Nambiar, M., Simchi-Levi, D. and Wang, H. (2018), Dynamic learning and pricing with model misspecification.

[130] RPS 演算法與計量或作業管理上的三類型方法，具有相關。第一，類似於隨機對照試驗(randomized controlled trials, RCT)，利用隨機產生價格來消除選擇偏誤。第二，類似於計量中的工具變數方法(instrumental variables method, IV)，此方法在計量學中被用來估得內生變數的不偏誤參數，此 IV 必須與內生變數相關、但與預測偏誤值不關，而在 RPS 演法中的隨機價格干擾項即扮演著 IV 角色與功能。第三，類似於管理學中的「半短視(semi-myopic)」訂價原則，當過去歷史價格紀錄不夠充分大的時候，則價格將被訂得較遠離貪婪價格(或短視價格)。

[131] 前文 Den Boer, A.V. and Zwart, B. (2015).

時日，稱為後悔期(regret)，用以衡量因期初各期可能未達最適價格之預期收益損失，又稱為「學習成本」。因其目的是為了準確估計需求，只要決策並未太大偏離最優價格政策，則需求參數估計就會快速的被學習而得，此模型符合內生學習的特色。

Hanaki, Sethi, Erev and Peterhansl (2005)

本文是強化學習(reinforcement learning)訂價演算法的模擬研究，直接從過去不斷行動(策略)所累積的經驗值(即績效值)，分出各行動的優劣，並基於此一經驗值大小賦於被選中為反應策略的機率大小[132]。因為這模型設計並不顯然的去推估該廠所面對的環境(或需求函數)，因此被視為無模型(model free)演算法。研究對象則為重複囚犯困境賽局，並整理出 26 個一或二狀態的訂價演算程式(或稱訂價演算機、訂價演算法、訂價演算自動機)，其中包含了「總是訂低價」、「總是訂高價」、「以牙還牙」、「嚴格策略」、「處罰 1 期策略」等常見的訂價演算程式，以供智能體(自動類代理人; Autonomous Artificial Agents)於每一時刻選擇一個。

本文利用「引力導向學習(attraction-based learning)」，智能體於每一時期將使用一特定訂價演算法來訂定當期價格，同時設定其於定期的一段時間後，可以有改選其他訂價演算法的機會。改選機會是一個隨機小機率(文中於模擬時設定為 5%)，每一非當前演算法被分配此機率值之大小，則依各訂演算法過去績效而定。這個設計使得智能體更有機會找到一個在過去表現相對較佳的演算程式；而一個訂價演算法績好壞則以「引力值(attraction value)」計算。假設智能體過去利用 k 訂價演算程式進行訂價的最後一期是第 t-x 期，現在來到了第 t 期(共經過 x 期)，智能體又面臨了選擇機會。假設符號 $A_{k,j}$ 代表 k 訂價演算程式於第 j 期的引力值，則訂價演算程式 k 於第 t 期的引力值計算如下：

[132] 前文 Hanaki, N., Sethi, R., Erev, I. and Peterhansl, A. (2005).

$$A_{k,t} = (1-w)A_{k,t-x} + w\left[\frac{\pi_{t-x} + \pi_{t-x+1} + \cdots + \pi_{t-1}}{x}\right]$$

其中π_j為該智能體於第 *j* 期利潤，而 *w* 為權重參數，0 < *w* < 1，其值愈大將代表愈重視近期表現。亦即，第 *t* 期訂價演算法 *k* 的引力值，是過去 *x* 期使用 *k* 之平均利潤得值(績效)，與過去第 *x*+1 期時的 *k* 引力值，兩者之線性組合(加權平均數)。至於過去 *x* 期中，那些沒被使用到的訂價演算程式，因沒有近 *x* 期的績效，所以它的當期引力值會維持不變。

於是，一個績效愈佳的訂價演算程式，其當期引力值就愈大，被選中為新策略(政策、計算規則)的機率值就會給的愈大。至於過去 *x* 期中，那些沒被使用到的訂價演算程式，因沒有近 *x* 期的績效，所以他的當時引力值會維持不變。本文中，自動演算機 *k* 在第 *t* 期被選中為新策略的機率值為：

$$\frac{e^{\lambda A_{k,t}}}{\sum_{h\in H} e^{\lambda A_{h,t}}}$$

H 是所有實驗中的訂價演算程式，共 26 個。實驗結果，在 26 個演算法中，有 4 個累積出異常高於另外 22 個的引力值，代表這 4 個演算法在這一實驗中，事實上是較好的訂價演算法，可以維穩於較高價格(超競爭價格)，而獲得較高績效值(利潤)。這 4 個演算法分別是傳統上熟知的：以牙還牙、嚴格策略、處罰一期策略、處罰直到對手報復(Punish until the opponent retaliates)。該文的第二部分，隨即改令兩個智能體各以這勝出的 4 個訂價演算法做為策略，進行競爭。雖僅設有簡單的學習，卻最終都會出現隱性合謀，而「處罰直到對手報復」獲得了最高的引力值。

Waltman and Kaymak (2009)

Waltman and Kaymak (2009)考慮簡單的庫諾模型，廠商數目固定、生產完全替代品、具一致成本函數、具固定邊際成本、及線性需求函數，且每一家廠商都委由智能體決定[133]。過去研究多為一個 *Q* 學習智能體與許多採固定價格策略的智能體競爭，於是該 *Q* 學習智能體一律把對手所有固定策略視為環境一部分，固定擇取最佳反應即可。但本文所設定者，則是多家 *Q* 學習智能體彼此間同時競爭互動，也都受限於有限理性。利用電腦進行模擬，每一回，廠商們以庫諾寡占模型進行重複競爭一百萬期，並進行至少一百回合模擬。研究發現，總合產量都比 Nash 數量小、總和利潤都比 Nash 利潤大，平均利得大約是 60%。確實發現了智能體間，最終都學習到了合作。

Calvano et al (2019a)

Calvano et al (2019a)使用 *Q* 學習模擬重複 Bertrand 寡占模型。模擬的市場中共有 *n* 家廠商、各提供一個品牌、固定邊際成本、價格競爭、包含垂直與水平差異化的 logit 需求函數。訂價演算法於競爭中選擇訂價，並允許使用混合策略。當演算法對過往記憶很短(或很快忘記)、或者實驗開發的範疇太過於廣大時，演算法的學習能力就會變得比較差。實驗開發上，採ε-貪婪法，並令實驗比例隨時間幾何遞減，亦即，一開始是單純的隨機選，而後則隨著時間愈久，愈傾向於貪婪選擇(即傾向當期最優行動)。設定智能具有限理性，只有一期記憶(k=1)。當每一參與者在某一策略不間斷被重複 25000 期時，實務上即定義其為收斂，該智能體的學習即視為完成而達於行為穩定，此一策略亦即為最適策略，該模擬即結束[134]。總共模擬 1000 次，每次若超過 10 億期亦將隨即停止[135]。

---

[133] Waltman, L. and Kaymak, U. (2009), Q-learning agents in a Cournot oligopoly model. Journal of Economic Dynamics & Control 32, 3275-3293.

[134] 此即前述 Rubinstein (1986)所描述的第二時期「循環期(the cycle of the paly)」。

[135] 前文 Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019a). .

模擬中的最後 25000 期平均利潤，視為該回合模擬平均利潤，其與 Bertrand-Nash 利潤之差異，相對於完全合謀(即獨占)利潤與 Bertrand-Nash 利潤之差異的比值，被定義為模擬的平均利潤所得(average profit gain；均利得)，即可計算出 1000 次模擬均利得的期望值與標準差。結果發現，1000 次均利得最小值為 40%、最大達 99%；並發現，利得與學習參數(α)及實驗參數(β)高度相關。

非競爭結果無所不在，而其之出現，並非於短期間可得。總體而言，當實驗參數小時，則利得會相對的較小；但當實驗參數與學習參數都很大時，利得則變成最小。均利得未達 100%，並非演算法學習勾結時而成功、時而失敗，而是他們對稱性的學習了「不完整勾結(incomplete collusion)」，這亦可以由訂價穩定的高於納許均衡解而小於獨占解、且訂價分散度小看出，顯示彼此傾向於對稱性訂價，透過單方面有系統學習去達到合謀。

根據 Harrington (2017)定義，勾結是一個情狀，於其中廠商利用獎懲措施來協同勾串彼此行為，藉以圖謀達致超競爭(supra-competitive)結果(a situation in which firms use a reward-punishment scheme to coordinate their behavior for the purpose of producing a supra-competitive outcome。因此獲利水平不是判斷合謀的因子，而是在於促成超競爭結果的那套獎懲機制；亦即合謀的定義，不是要論利潤多大，而是只要存在「偏離則有短期暴利、並將觸動處罰」這現象。

依此定義，本文得到的三個模擬結果，都證實智能體確實可以學習合謀。第一，均利得皆為正。第二，在確定「合作不會成為均衡」的經濟環境設定下，智能體確實學習出訂價於競爭均衡。第三，在合謀出現時，作者嚐試的強行手動調降某一者之價格，作為背離舉動，結果發現，智能體確實會有處罰背離的動作；其處罰大小取決於背離之大小，且有限期間後會慢慢的回到背離前價格水平。第三點完全符合 Harrington 的合謀定義，顯見智能體確實進行合謀。

若智能體無記憶(k=0)，則合謀是不可能的；若折現因子δ=0，則合謀是不

可能變成均衡的(因為背離的短期暴利永遠大於長期合作利益)。在這兩個設計中，智能體決策理當不該會有超競爭結果出現。實驗結果，果真這兩案的均利得大約只有 10%，顯示智能體在 Bertrand-Nash 為唯一均衡的狀況下，確實學習出走往這一均衡訂價的趨勢。

接著，作者在最後一回合模擬時，刻意在價格收斂期，針對某一廠價格手動的給予調降，觀察此行動所引發的廠商回應，如圖 4.1 與圖 4.2 的價格與利潤圖所示。智能體 1(紅色)於第 1 期被強迫突然調降價格(1.6)，此時的智能體 2 仍然無知的維持於高價(1.8)，接著第 2 期智能體 2 就隨即反應調降價格(1.55)。如果智能體 1 目標是重新獲取市占率，則於第 1 期降價後，它理當該在第 2 期觀察智能體 2 的回應，再看是否需要持續變動價格以達到控制市占的目標。但實驗發現，智能體 1 於第 1 期降價後、並無等待與觀察對方回應，而是隨即於第 2 期再度降價，顯然其目標並非在於取得市占控制，而是一種同時包含對自我行為的懲罰動作，這是勾結中很重要的關鍵動作。其文中亦進行另一組實驗，令處罰 5 期，所得結果亦類似，總是在處罰期過後，價格(與利潤)慢慢的回升，大約 10 期左右即又回復到背離前的價格利潤水平。

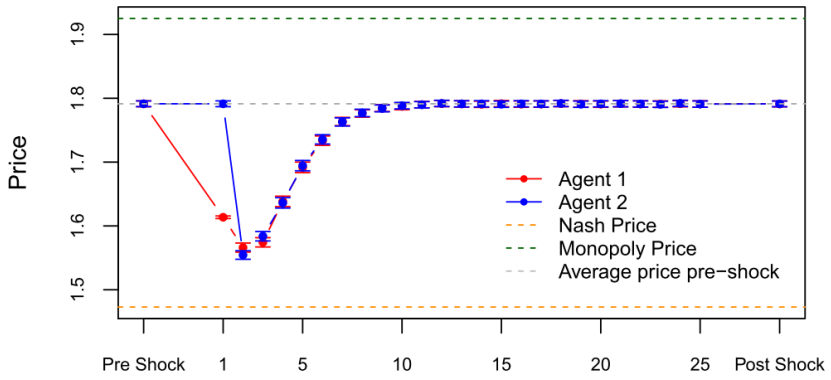

圖 4.1 Calvano et al. (2019a)背離行動實驗的價格反應

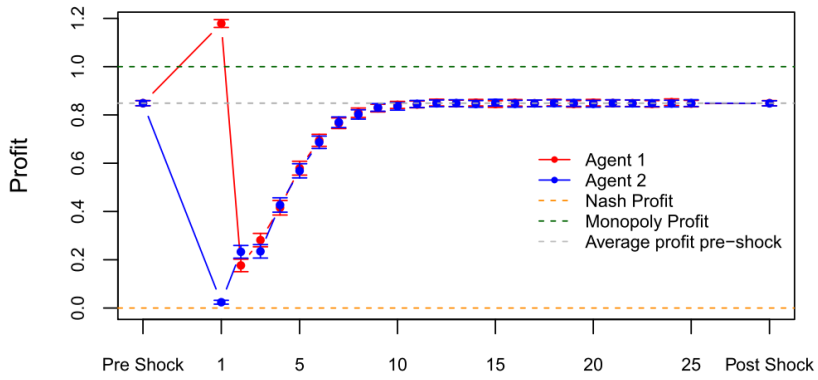

圖 4.2 Calvano et al. (2019a)背離行動實驗的利潤反應

就廠商數而言，確實隨著合謀家數愈大則利潤增額愈小，但其遞減幅度則相對很緩慢。在廠商不對稱議題上，成本優勢者有較大的均利得，但成本劣勢者亦保有相當大的均利得。例如模擬中成本各為 0.25 與 1 時，平均產業均利得為 54%，而成本各為 1 時，均利得則為 80%。

本文以 *Q* 學習訂價演算法進行訂價，合謀會以不完整的形式達成，而且是以處罰作為機制。演算法透過不斷試誤而學習最佳策略，不需任何所處環境的前提知識，他們彼此並無溝通、也無被設計或指令去勾結。

Calvano et al (2019b)

Calvano et al(2019b)利用 *Q* 學習進行模擬無限重複賽局[136]。決策者為兩個 *Q* 學習智能體，每一期有「高價」與「低價」兩個行動可選擇，循著第二章式(3)之學習過程，並設定其學習速率α=0.15、只有一期記憶、實驗機率 ε=0.04，且設報酬折現因子為 0.995。一開始廠商認定高價乃非最適，意味著非最適行動(即高價)被選中的機率僅 2%，也就是說，重複 1 萬次平均出現 4 次勾結；因此，若要讓演算法能充分學習，則重複次數必須很大。於是本文讓每一次實驗模擬都重複 100 萬期，共進行 1000 次實驗，且取每次實驗的最

[136] 前文 Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019b).

後 10 萬期平均利潤作為最適策略結果。初始 Q 值設定為靜態納許均衡之利潤值(亦即設定賽局始於競爭均衡)。

其所設定之無限重複賽局出現了三個子賽局完美納許均衡，包含一個「永遠低價」的競爭均衡、及兩個勾結均衡「嚴格扳機(grim trigger)」與「一期處罰」。「永遠低價」均衡，是不論歷史，廠商一律訂定低價，一如靜態納許均衡。「嚴格扳機」均衡是，廠商一開始訂高價，接著，若前期所有廠商均訂高價，則本期我亦訂高價，否則我將訂低價。「一期處罰」均衡是，廠商一開始訂高價，接著，若前期兩廠訂價相同，則本期我訂高價，否則我訂低價。

在「永遠高價」策略下，則廠商訂高價達 100%，在「永遠低價」策略中，則訂高價達 0%，故在 100 萬期訂價中，廠商達高價次數比例作為該次實驗的利得(profit gain)。結果，在 1000 次實驗模擬中，利得可高達 70%，而若僅計算每次模擬最後 10 萬期，則利得更高達 85%。平均而言，約 24%的期數是競爭狀態(兩者皆低價)、13%的期數是混合狀態(一高價一低價)、63%的期數為勾結狀態(兩者皆高價)；如果單單計算最後 10 萬期，則前述數據分別變為 7%、11%、與 82%。以 63%期數為勾結狀態而言，則意味著，在第 37%期(即第 3700 萬期)時，勾結必然出現。若每分鐘變動一次價格頻率而言，則相當於 257 天。

Henderson et al (2003)

透過不斷的一來一往給價訂價，終達於雙方一致價格，Henderson et al. (2003)設定了七個演算法模擬這一議價過程，最終得到「AgreeProgressive」演算法，具有最高的績效分數(即最高的協議達成率)；尤其在第 15 回合後，不論對手提出什麼訂價，該演算法都會接受(亦即永遠協同)。這篇論文設定的演算法中也包含了「以牙還牙」，這個極為簡單的演算法，它在 Axelrod (1984)模擬中具有最佳的表現，但在 Henderson et al.研究中卻反而只排在第六位的

績效[137]。

Klein (2018)

作者建構於 Maskin and Tirole (1988)的動態競價寡占模型，競爭廠商不斷的先後訂價，測試 *Q* 學習演算法所獲致的穩定價格。其模擬共進行 1000 次，每次競價進行 5000 期(當超過 5000 期時其探索機率已下降至 1%以下)[138]。

本文的第一個模型是一 *Q* 學習演算法廠商面對一固定於獨占價格廠商，結果並不令人驚奇，因為 *Q* 學習廠商最終調整自己價格直到與對方廠商相同。與同步賽局結果相同。第二個模型，作者則令兩家廠商都是 *Q* 學習演算法運作，並無先給予任何環境訊息，而必須自行學習。結果，雙方訂價會收斂至一個固定價格，或者會呈現出類似 Edgeworth 循環價格[139]。總體而言，在六個可能價格(行動)選項的實驗中，最終價格大約都是座落於 Bertrand-Nash 與合謀水平之間，據其文估計平均利得(average profit gain)大約 50% (平均利得是價格與 Nash 差距占合謀與 Nash 差距之比)。當可選用行動增加到 12 項、甚至 100 項時，平均利得會隨著提高，但愈易出現 Edgeworth 循環價格模式。本文的設計上，假設 Markov 行為，亦即廠商訂價只相關於對手當期價格，而與過去雙方訂價歷史無關。類似的競價寡占研究，Salcedo (2016)亦曾證明，在一些條件符合下，若廠商採用固定策略訂價演算法，它會不斷的解讀對方演算法、不斷的調整自己，終使合謀無可避免的出現[140]。

---

[137] Henderson, P., Crouch, S., Walters, R.J. and Q. Ni (2003), Comparison of some negotiation algorithms using a tournament-based approach.

[138] Klein, T. (2018), Assessing autonomous algorithmic collusion: Q-learning under short-run price commitments.

[139]高度競爭的 Edgeworth 市場中，同質產品，有許多競爭者，惟存在許多忠誠消費者，無論價格多高都會買，以致於一些廠商有時會透過提價剝削這一群忠誠消費者而獲取短暫利益，於是造成市場價格高低循環出現。此稱為 Edgeworth 價格循環，通常具有三個時段：(1)市場先是極低價格，導因於競爭者激烈競爭、甚至訂價於邊際成本，企圖等待對方先行退讓而提價。(2)然後市場價格突然出現高幅上漲，因為有一方退讓而提價所致，另一方也會跟進(但仍較低一些)。(3)最後，由高價開始互相削價，市場價格逐次下降，直到均衡(稍高於邊際成本)。

[140] Salcedo, B. (2016), Pricing algorithms and tacit collusion.

小結

關於訂價演算法基底商業，廠商涉法案例，其具體模式，仍多是以訂價演算法做為執行人為協議的工具，因此在適法上，傳統標準架構仍是充分無疑，惟執法人員的偵測與調查，必須與時俱進的能夠面對與管理廠商所使用的新工具。

至於來自於自學型演算法的合謀，目前雖被學者於模擬中證實可能出現，惟其出現仍然受限於模型中的許多假設設定，仍屬於實驗室階段，並未實際商轉。但我們仍應隨時緊跟其進展。

第六節 本章結論

訂價演算法改變了市場環境結構，從而改變了合謀出現的條件。本章針對新型訂價演算法在合謀條件上的衝擊，作出一番分析。

合謀是一種一致性行為，在當前法例上仍需具備人為溝通作為證據。然而寡占的決策互依性必然使得價格競爭的市場，呈現價格同向變動的趨勢，於是同時提價可能是競爭結構的必然，這使得與刻意一致行為的提價，常常不易互相區別開來，這即是所謂的寡占問題。若非結構必然的提價行動，必然是「有所企圖」的提價，在經濟分析中，我們已經發覺這個企圖正是企望對手了解我企圖而願意共同提價。企圖信號的發放，可以透過逐期價格策略的刻意變動、也可以藉以價格策略以外的資訊。前者，建立於「對手跟進提價則享長期高價的合作利潤、不跟進就只能有長期低價的競爭利潤」，亦即一個獎勵與處罰機制的制約；後者則建構於額外非策略變數的作為，釋放合作企圖，但仍需內建一獎懲機制，才能迫誘對手願意配合提價。

毫無疑問，獎懲機制是合謀的必要條件。然而，雖然透過經濟分析上，我們已經足以確認當前高價是緣於一套獎懲機制，或者已足以確認，除非競

爭者透過一套獎懲機制策略，否則無以獲致目前超競爭價格局面；但如同前述，獎懲機制是競爭過程中不斷的系列策略行動，本身是策略變數，並無策略本身以外的任何訊息通聯，因此不屬於法院所欲之額外因素證明。因此，仍需尋找此套機制曾被形諸文字、面談、溝通或各形式洩露的實質因素，才能將其認證。

目前訂價演算法涉及的合謀案例，仍都是以人為溝通協調為主角、再輔以訂價演算法的操作，例 Meyer v. Kalanick (2016)、U.S. v. Topkins (2016)、CMA v. GB eye (2016)、U.S. v. Aston (2015)等。更進一步的學習型演算法合謀，則仍只存在於學術研究中特定設定的模擬，並未實務運作過。

第五章 訂價演算法促成其它競爭法相關行為

一般而言，廠商訂價策略若是基於供需認知而獨立決行，就不會涉及競爭法議題。若偏離供需基本面而著重在於削減對手訂價、打擊對手市占、或企圖減少市場競爭等行為，則顯然須被競爭法所關注；這些行為都是傳統市場中所可能出現的違法樣態，然在廣泛運用演算法的數位經濟中，訂價演算法協助廠商迅速且高頻率的觀察偵測所有其它競爭者的訂價變動、並且(可能)自動的迅速反應，這些違法樣態行為被更容易的付諸實現與執行。其涉法判斷依循既有標準框架，並無疑義，因為訂價演算法只是一個被用來便利執行可能涉及競爭法行為的新型工具，而此等運用仍操之於人。雖在偵辦實務上，了解訂價演算法必須成為執法者的基本素養，方能具有偵測與判斷能力。

第一節 關於常見策略

一些常見於傳統競爭架構的策略樣態，在訂價演算法參與後，也可能出現了新風貌、也已有一些實際案例的發生；例如，維持轉售價格(resail price mantainence; RPM)、最惠條款(most-favored nation clause)、及掠奪訂價(predaotry pricing)等。毫無疑問的，這些策略在訂價演算法協助之下，更容易達成其所欲目的，從而更易觸法。

(一)維持轉售價格

演算法不僅讓市場增加透明於消費者與競爭商，而且還給予了市場的其它參與者，這促進了市場功能卻也促進了供給面的監控，尤其在製造商及零售商的任何協議。當監控成本愈低、則這等協議愈有力，於是反競爭效應就愈形變大。相似的，某種程度上，演算法能建立一個有利市場更為集中的競爭優勢，於是垂直設限更可能出現並對競爭產生更大負面效應。惟目前實務

證據上，演算法到底多大程度的降低監控成本或有利市場集中，仍然證據極少。

在歐盟，演算法或數位平台的使用，曾是最小轉售價格執法上的核心，最小轉售價格被認為是當然違反歐盟競爭法。根據歐委會(European Commission)2017 年的電子商務產業調查，轉售價格所相關的限制是目前電子商務市場上最為普遍的限制競爭樣態，也發現，零售商利用自動軟體進行價格監控與價格訂定者，大量增加。

演算法可以快速彈性的調動價格以因應需求或供給之衝擊，因此 RPM 面臨衝擊時也當然可以快速的調整因應，使得成員背離以套利的誘因大減，鞏固協議。

EC v. Asus and other three (2018)

2018 年六月，Asus(總部台灣)、Denon & Marantz(總部日本)、Philips(總部荷蘭)及 Pioneer(總部日本)四家家電製造商，對於線上普遍產品例如廚房電器、筆電、或高傅真音響等產品，以固定或維持最小轉售價格，限制線上零售商的訂價能力，並且利用先進複雜的監控演算法，有效追縱配銷網絡上的零售價格，借以隨時在價格下降時進行干預，不遵守者將面臨製造商斷絕供貨的威脅，嚴實的限制了零售商間之有效價格競爭。由於線上零售市場，包含最大零售商在內的許多廠商，普遍性的利用訂價算法自動即時的相對應於競爭對手價格變動而調整價格；於是，一廠降(提)價往往會快速帶動其它廠商跟著降(提)價，使單方降價的邊際代價太高，僵固了市場調價的自由性。因此，一個不允許自由調降價格的 RPM 措施，其結果將導致市場普遍維持於高價[141]，亦即，Asus 等製造商對零售商的低價限制，在相關消費電器產品的線上價格競爭上，產生了限制競爭。

[141] European Commission (2018), Statement by Commissioner Vestager on Commission decision to impose fines on four consumer electronics manufacturers for fixing online resale prices, July 24.

歐委會關注的，不是應用新穎科技方法以僵固零售價格是否不涵蓋於既有法律架構中，而是事實上訂價演算法是更有效率的強化了 RPM 效應。歐委會確實發現，這些行為降低了線上零售商的價格競爭，提升了消費者價格[142]。

總部在台灣的 Asus，監控特定電腦及電器產品(如筆電與顯示器等)的零售商訂價，由 2011-2014 年在德法兩國，對於那些售價低於建議的零售商，進行干預要求提升價格。Pioneer 由 2011-2013 年橫跨 12 個國家，除了限制轉售價格之外，為了維持在不同國別有不同的零售價格，對於跨國銷售的零售商則一律拒絕供貨。歐委會依各廠的合作態度給予 40-50%的罰款減免，最後以 Asus 被罰 6352 萬歐元最高。

(二)費率等同條款

費率等同條款(rate parity provisiosn)，也被稱為最優惠條件（most favoured nation clauses; MFN），又與保證最低價格(guaranteed best rate)相同。MFN 有廣義與狹義之分，廣義者(wide MFNs)要求在我處平台或線上商場之價格不得高於任何其它銷售渠道；狹義者(narrow MFNs)則僅要求在我處平台或線上商場價格不得高於自有網站上的價格。這等策略是傳統市場環境中就可能出現的反競爭行為，其所依賴的，仍然是典型的人為溝通與互動所致。惟在數位平台經濟中，透過訂價演算法，觀察偵測上千百供應商或零售商訂價變得輕而易舉，該等行為策略的執行更為容易。於是，對其在比價演算工具平台或線上商場的利用，近十年歐盟反托拉斯主管機關給予了莫大關注。

Booking.com etc. (2015)

首先，2010 年許多歐盟國家啟動調查旅遊平台業者(online travel agents, OTAs)與旅宿供應者(如民宿或旅館業者)之間的上開條款，法國、瑞典、與意

[142] European Commission (2018), Press release of July 24, Antitrust: Commission fines four consumer electronics manufacturers for fixing online resale prices.

大利的調查，在 2015 年終使 Booking.com 決定改以狹義 MFNs 替代原先的廣義 MFNs，Expedia 也隨後跟進，表示願意遵守各國監管機關所修訂的新規則[143]；而德國則完全禁止，不論是廣義或狹義。

旅遊平台業者認為，這個設計在於防止旅宿供應者給予客戶折扣，因為客戶免費使用旅遊平台搜尋與預訂，於一處搜尋到住所後、容易往他處比價而可能外流，形成搭便車的不效率現象。對於旅宿供應者而言，廣義 MFs 使其無法自如的給予旅客折價以便吸引更多客戶，也無法提高訂價以反應平台提高手續費(因為他必須全面於各渠道提價)；於是，要不是以需求減少作為代價來反應某平台手續費提高，要不然就是維持既有既有需求而自我承受手續費被提高。顯然的，後者較為有利，於是導致供應者繼續維持於既有價格而不敢調高，形成「價格地板(price floors)」。由於這樣的價格措施是起源於平台業者為了防止搭便車，一個平台採取如此措施，當然促使其它業者跟進，致使市場價格趨於一致性、且無法自由降價競爭。當產業普遍廣泛採用此等措施時，新進平台業者欲倚賴低手續費招攬供給者的策略，將無法運作，而形成市場參進與創新的阻礙。

Amazon Marketplace (2012)

2012 年英國與德國於接到商家投訴，謂 Amazon 要求所有利用其 Marketplace 平台的第三方商家，不可於他處賣出更低價。10 月分聯邦卡特爾局決定啟動調查，而 Amazon 終於於 2013 年 8 月底決定不再於歐盟使用該等條款[144]。

---

[143] May, K. (2015), Booking.com makes changes to rate parity clauses in Europe, Phocus Wire, news of April 21. https://www.phocuswire.com/Booking-com-makes-changes-to-rate-parity-clauses-in-Europe. *See also:* OTAINSIGHT (2019), The decline of rate parity clauses and what this means for hotels, Blog of April 11. https://www.otainsight.com/resources/blog/the-decline-of-rate-parity-clauses-and-what-this-means-for-hotels

[144] Campbell, L. (2013), Amazon to drop Marketplace price parity, The Bookseller, news of August 29.

(三)掠奪訂價

Amazon v. Quidsi (2011)

Quidsi 電子商務公司，主要營運有 Diapers.com（嬰兒護理）、Soap.com（家庭日用品）與 BeautyBar.com（美容護膚），在 2008 年是一家成長快速的企業。Amazon 見此處商機而於 2009 年提議併購 Quidsi，但被拒絕。於是，Amazon 開始對自家販售的紙尿褲及嬰兒產品大幅降價，達 30%，借以打擊 Quidsi。Quidsi 內部作了一個測試，刻意操作自己價格變動、然後觀察 Amazon 網站，發現其價格也隨即跟著改變，確認 Amazon 有名的訂價機器人(pricing bolts)正籠罩著 Diapers.com。在那段期間，例如，Quidisi 對紙尿褲訂出 45 美元，Amazon 隨即於其網站對該產品削價訂為 39 美元，而會員價將更低。若加上其所提出的免費兩日內送達等諸多服務，Quidisi 估計，在紙尿褲這類產品項上，Amazon 三個月就虧了將近 1 億美元，而 Diaper.com 也因此停滯成長。最終基於對巨大 Amazon 的恐懼，Quidsi 放棄了 Walmart、還是選擇賣給了 Amazon。併購後一個月，Amazon 隨即取消新會員優惠措施，而聯邦貿易委員會(FTC)也開始審查該併購案。雖然確認該併購案將實質減少一個強勁的競爭對手，但因市場上仍有很多競爭公司(例如 Costca, Target)同時在線上線下銷售紙尿褲，故不致於導致獨占，無反競爭結果，而於 2011 年通過該案[145]。

本案 Amazon 以龐大資源支應虧損，以低價進入紙尿褲與嬰兒市場，最終再以併購既有廠商而正式立足該產業，此處法院並未以掠奪視之，而是以進入一新市場的參進競爭。然而 Amazon 購買 Quidsi 後來證實是一個錯誤的投資，並於 2017 年關閉該廠。

[145] 參見 Stone, B. (2013), The everything store: Jeff Bezos and the age of amazon, 239-297. Amazon.com. 亦參見 FTC (2011), Letters and Statements: Amazon.com, Inc. / Quidsi, Inc., March 23.

Google Maps v. Evermap (2012)

2009 法國 Evermaps 控訴 Google 通過免費使用其網站內建地圖(Google Maps)，藉以行使掠奪訂價措施[146]。Evermaps 宣稱在 2009 及 2010 兩年內，Google 此一策略致其虧損至少 80 萬歐元。2012 年巴黎商業法庭認為 Google 企圖消除所有競爭者且把自己商品置於其搜尋結果表的前端，判決需支付 50 萬歐元損害賠款。2013 年巴黎上訴法庭尋求法國競爭法主管意見後，裁決 Google 的行為並非掠奪，並指出一些企業之退出市場並非直接因為 Google 策略所致。

因訂價演算法而正式被提出掠奪訂價訴訟的，基本上都出現在 Uber 系列訴訟，雖仍都不被法院接受，但本文仍羅列於此以供參閱。

Malden et al. v. Uber (2016)

大波士頓地區包含七大團體(計 800 餘家計程車業者)，以 Malden 運輸公司為首，於 2016 年控訴 Uber 採掠奪訂價並企圖獨占。

原告認為，計程車是一個高度管制的產業，用以保護消費者以及確保服務之安全可靠，因此可以經營或駕駛計程車者，都必須花費許多心力與成本方可取得執照，但 Uber 則自認不是計程車業者，故完全不遵循此一產業管制而「管理」運載服務。在 2013 年之前，Uber 經營的訂價模式，基本上，是高於傳統標章計程車而低於其 UberBlack 訂價。2013 年 1 月，Uber 於麻州波士頓五城市首推低於 UberBlack 約 40%成本的 UberX 試營運，在大波士頓區基本費率為 5 美元。同年 10 月份再推出全周免費試乘活動[147]，提增大量需求後，隨即再把基本費率降至 2.5 美元，並以「比計程車便宜 30%」大作促銷[148]。

[146] Competition Policy International (2015). France: Google wins court decision vs Evermaps, November 29.

[147] 該試乘體驗不適於 Uber 的其他車種，例如 UberBlack, SUV, 或 TAXI。

[148] 促銷前的基本費率 5 美元、低於 11 MPH 每分鐘 0.6 美元、高於 11MPH 每分鐘 2.6 美

據此推論，Uber 在大波士頓區應該是處於賠本經銷之中，但以降低駕駛人手續費來補貼駕駛人收入的減少。2014 年 Uber 進一步調降費率 15-34%，並強調在任何城市的 Uber 平均費率將比一般計程車便宜了約 26%；2014 年 6 月再進一步調降 UbeerX 價格約 25%，使其收費只約一般計程車的一半。

原告闡述，一般認為，Uber 之能夠維持低於成本的掠奪價格，是因其募集大量資金備援(因預期未來的豐收)；而這一策略之企圖，在於驅逐競爭者之後再以獨占地位回補損失的利潤，卻也導致 20 億美元的虧損[149]。Uber CEO Travis Kalanick 的聲明以及 Uber 廣告中都曾強調，要在大波士頓區叫車市場(ride-hail market)發起「單方價格戰爭(unilateral price war)」，被認為證明了前述策略與企圖。2017 年 Uber 占叫車市場約超過 80%份額，若無控制，則很可能進一步的驅退所有其他廠商而成為獨占。Uber 基於如上所述的不公平競爭手段及反托拉斯策略，奪走了原告們可觀的利潤、貶值了原告們的資產(例如標章執照)，而且這樣的傷害會持續下去[150]。

法院則認為，對於掠奪價格一項，原告舉證不足。單純說「UberX 訂定低於成本價格，企圖驅逐計程車競爭者」，但卻完全沒提出這六城市計程車的任何證明數據，而代之以華爾街關於 Uber 全球經營收益小於成本，這並無法作為波士頓的叫車市場數據。關於「企圖獨占」一項，法院亦認為原告只是一直說前 CEO 陳述與其廣告已經清晰表明了 Uber 的獨占企圖，卻沒有任何具體意圖(specific intent)事證、或舉出 CEO 的明確陳述。另原告認為 Uber 訂

元、最低消費額為 10 美元，促銷期間則相對減為 2.5、0.4、2.05、與 4 美元。以此推算，新 UberX、舊 UbeerX、及 TAXI 三車種的付費比較，由後灣至市區分別是 8、10、11 美元，羅根機場至金融區分別為 18、24、27 美元，劍橋至南端則分別是 12、27、19 美元。

[149] 分析師推估 2014 年 Uber 損失約 20 億美元，平均旅客一趟行程只付擔成本的 41%。相關內容參見 McDermid (2 Dec 2016).

[150] Malden Transp., Inc. v. Uber Technologies, Inc., 2017 U.S. Dist. LEXIS 213023 (D. Mass. 2017); Miadeco Corp. v. Uber Technologies, Inc., No. 1:15-cv20356, Doc. 120 (S.D. Fla. Mar. 30, 2017); Miadeco Corp. v. Uber Technologies, Inc., No. 1:15-cv-20356, Doc. 120 (S.D. Fla. Mar. 30, 2017); A White and Yellow Cab, Inc., No. 4:15-cv-05163, Doc. 114 at 14 (N.D. Cal. Mar. 5, 2018); Ariekat v. Uber Technologies, Inc., CGC-17-557728 (Cal. Sup. Ct. Mar. 24, 2017); Friendly Cab Company, Inc. v. Uber Technologies, Inc., RG-17-858247 (Cal. Sup. Ct. April 27, 2017).

價本身即已展現出其具體意圖，法院也認為缺乏論證價值，因為對任何廠商而言，「提增銷售與市占率都是正常的商業目標」，而非被禁止的行為。法院也認為原告關於「證明波士頓消費者受害」並未予以說明，這是致命的，因為任何反托拉斯案件均必須證明被告行為確實造成競爭受到傷害，而不能僅是單單提說「Uber 的參進造成叫車市場的供給增多及價格下降」；關於這一項，法官發現原告之論述與 Philadelphia Taxi Association v. Uber (2018)相同。

Desoto Cab v. Uber (2017)

Uber 在三藩市推出以高級轎車提供約車乘載服務，2016 年，原告 Desoto(三藩市最久的計程車公司、後改名為 Flywheel Taxi)等對 Uber 提出控訴，理由有七項：獨占化(monopolization)、企圖獨占化(attempted monopolization)、低於成本銷售的不公平行為(unfair practices)、領導廠商賠本經營之不公平行為、違反商標法(Lanham Act)、企圖干預經濟關係(intentional interference with prospective economic relations)、不公平競爭[151]。

Uber 於 2010 年起，依推出時序分別有 UberBlack(豪華車、基本費率 8 美元+4.9 美元/哩+1.25 美元/怠速分鐘)、UberX(初期訂價低於前款但高於一般計程車)、UberSUV(團體搭載、有執照)、UberTaxi(客戶可指定要有執照駕駛、一般計程車費率+1 美元手續費+20%小費)、UberXL(UberSUV 半價、無執照)。每趟交易完成後，Uber 透過客戶信用卡完成付費轉帳，由其中抽取平均約 25%的手續費，剩餘的則按週轉至駕駛人帳戶。2011 年，Uber 率先採用依即時需求強度訂定不同價格(即所謂 surge pricing;浮動訂價)，於是在需求最尖峰時可能會使客戶付出八倍之多的價格。Uber 由建立之初至 2012 年七月期間，主要經營重點是擺在有執照豪華車的高單價服務面向上，而之後推出的 UberX 轉向平價叫車服務(Ride-Hail Market)，由駕駛者自己提供車輛、自己

[151] Desoto Cab Company, Inc. v. Uber Technologies, Inc. et al., 2017 U.S. Dist. No.C 16-06385 WHA (January 10, 2017)

負責保險與維修…等等。2012 年七月 UberX 剛推出時，其付費合算(5.00 base rate + 3.25/mile + 0.75/idle minute)是高於一般計程車、而低於其豪華型 UberBlack，但在至 2013 年六月的期間，因需求攀升促成漲價(5.75 base rate + 3.75/mile + 0.85/idle minute)；卻又在 2013 年六月突然調降價格(3.50 base rate + 2.75/mile + 0.55/idle minute)，而定名為新 UberX，強調平均付費將低於一般計程車約 10%，由此而展開幾波的持續降價，直到 2014 年六月，自稱價格付費已低到只為一般計程車的 45%。

原告 Desoto 主張 Uber 有龐大的創投基金資金來源，使其足以訂定低於成本的掠奪價格，企圖迫使競爭者退出市場以建立其完全獨占地位；一旦再沒競爭者約制，Uber 將可自由的在三藩市訂定高昂價格。數據上，自 2012 年中以來迄今(2016 年底)，計程車搭載服務產業減少了 65%乘客量、以及 30%以上的駕駛者。其它控訴包含：Uber 誤導公眾對可用性、定價、與安全性的認識，欺騙駕駛者收益的未來性，對殘疾、種族、及性別不同搭乘者具地區歧視(locality discrimination)，且在尖峯時段不合法漲價。關於這些指控，一如其它先前 Uber 被訴的各案。

Uber 回以，乘載分享市場的參進阻礙非常的低，新廠會快速進來削價競爭，使高價回補的企圖不可能實現。事實顯現亦正是如此，近期新公司如 Lyft, Via, Wingz, Juno 等等如雨後春筍於全球各不同城市冒出，並直接與 Uber 競爭。快速參進可能性，使得 Uber 不可能低於成本價，因為低於成本價後他將永遠無法回補。

針對原告指控 Uber 導致他們顯著利益損失與聲譽損害，法院認為原告沒有證明其利益與任何 Uber 利潤的相關性、或與任何 Uber 客戶有契約關係。原告控訴 Uber 違反了不能地區歧視(locality discrimination)及不能低於成本銷售(below cost sales)兩項，指出相關法律明定，任何企圖破壞產品正規經銷商的競爭，或者防礙任何有意成為正規經銷商者之競爭，都將造成地區歧視；而 Uber App 的創新、廣告、分享、與配銷此舉，正足以構成地區歧視。但法

官認為，原告僅止於如此宣稱，並無提出任何證據或事實，而不予接受。原告認為 Ubeer 透過 App 而得以持續以低於計程車業者成本的價格來銷售，企圖傷害競爭者或破壞競爭。法院則認為，原告只掌握計程車業者自身的價格與成本，但指控 Uber 低於成本銷售則是必須與 Uber 的成本相較，惟原告並未舉證出 Uber 價格、產品成本、以及營運成本，故也未接受此一說法。最後，法院批准 Uber 的駁回動議[152]。

事實上，法院在許多案例中已再而三的表示過：「掠奪訂價非常的難以證明」，「一競爭者訂定低價格，通常不是企圖迫退他人後再提價的證據，卻往往是於競爭場域失敗者的不滿所提出」[153]。

印度 Meru v. Uber (2016)

印度無線叫車公司(Meru)控訴 Uber 濫用獨占力[154]。原告認為，在德里首都區域的無線叫車市場上，Uber 占有全區每日叫車 65828 趟中的 33000 趟，約 50%，並透過此一優勢而安排了反競爭措施，包含掠奪訂價與誘引對手駕駛人以消滅競爭。Competition Commission of India (CCI; 2016)駁回此案，認為原告並無提出證據證明 Uber 在相關區域中濫用市場力。上訴法院則要求重新調查，認為(1)CCI 定義相關市場僅為德里，而應該是德里及首都區域才恰當；(2)Uber 車業低價且誘因大，可能是因新商業模式替代舊者所產生的效率改善，也可能是因反競爭行為所致，CCI 應該進一步調查。

南非計程車業 v. Uber (2015)

南非八家跳表計程車公司及 150 位駕駛，於 2015 年五月對 Uber 提出訴訟，謂其(1)採用掠奪訂價，企圖驅退競爭者；(2)規避管制條款而大量氾濫式

[152] United States District Court Northern District of California Case No. 15-cv-05163-JSW (N.D. Cal. Mar. 31, 2017)
[153] Said, C. (2016), Flywheel taxi sues Uber for antitrust violations. SFGATE, November 2.
[154] Meru Travel Solutions Private Limited v. Uber India Systems Private Limited, Case No. 96 of 2015. *See also,* Ghuman, P. (2017). Analysis of competition cases against Uber across the globe.

侵入市場；(3)誤導大眾認為它創造工作機會而致不公平競爭。Competition Commission of South Africa (CCSA)駁回此案，認為 Uber 行為並未違反競爭法。專家認為，控訴 Uber 採用掠奪訂價，必須要先證明 Uber 在界定的相關市場中是優勢地位廠商。這相關市場的界定很難[155]。

第二節 差別訂價

演算法可以在一些先決(特徵)變數下區分許多種類的不同消費者，然後給予不同區塊類型族群不同價格，甚至區塊可以細分至針對一(些)特殊個人，因此區塊訂價(或族群訂價)在訂價演算法中，時常被稱之為個人化價格(personalized price)，構成了經濟分析上另一個值得注意的結果。不過，美國 DOJ 與 FTC 都曾提及過，演算法差別訂價以既有相同法律架構分析即可。差別訂價未必涉及競爭法疑慮，但若廠商訂定差別價格時，也考慮了競爭對手的相關價格數據，則差別訂價影響競爭就有可能發生。在訂價演算法普及下，新型且複雜方法的差別訂價隨之出現，尤其進步到可以鎖定特殊消費族群。

例如在保險授信產業，價格已是普遍的設定於個人資料基礎上，在演算法普遍後更容易操作；這樣的訂價反應成本，可以使保險市場更有效率。然而，因為藉以評估服務成本的因素，其來源是消費者如種族、年齡、及性別等特徵，以此作為訂價是不合法的、差別待遇的、不公平的。曾被疑慮差別訂價的案例，例如美國抵押貸款人就曾被控訴其貸款措施廣泛的以種族為基礎[156]；而平台經濟的 Airbnb 則是利用了用戶的個人資料進行差別訂價[157]。最有名的，Amazon 推薦引擎會根據不同條件針對相關結果進行搜索排序，收集用戶購買與瀏覽習慣並與世界其他地區消費者進行比對；Facebook 利用圖像

[155] SA Breaking News (2016), Uber beats anti-competitive claims, October 21.
[156] Savage, C. (2012). Wells Fargo Will Settle Mortgage Bias Charges, The New York Times, July.
[157] Edelmann, B. and Luca, M. (2014), Digital discrimination: the case of Airbnb.com. Harvard Business School, Working Paper 14-054.

識別的先進技術，識別圖片或視頻中的物體或細節，並收集用戶的分布與興趣，為企業精準錨定潛在客戶。當然少不了 Google，網頁人氣排名的 PageRnak 演算法正是其營業模式的最核心部分，讓它從 2002 年營收不到 5 億美元，十年後暴增 125 倍。

訂價演算法幾乎可行使一級差別訂價

Diakopoulos (2014)指出，資料顯示 Home Depot、Orbitz、及 Staples 這些經銷商，就曾針對一網站用戶，依不同住區、瀏覽紀錄、是否是無線使用者等等特性，予以不同區塊化、而給予不同訂價。其運作模式，即是利用過去資料進行「價格與利潤」關聯預測，再以這個關聯與用戶位址及瀏覽紀錄進行配比，找出不同區塊用戶的不同最適化價格水準。於是，當演算法掌握住某一用戶的位址與瀏覽紀錄後，即可立即針對該個別用戶送出個人化訂價。

2012 年華爾街日報報導，線上辦公用品零售商 Staples，常依不同郵遞區號進行不同價格訂定(即依距離遠近訂價)，其結果，導致低所得地區卻有較高價格[158]。2014 年波士頓東北大學研究六家旅行業(Cheaptickets, Expedia, Hotels.com, Orbitz, Priceline, Travelocity)及非旅行業如 Home Depot 及 Macy's 等共十六個電商網站，發現旅行業最可能出現價格導流(price steering)現象，也就是網站常會讓較昂貴項目出現在某些特定客戶的搜尋結果表中的前列，刻意引導一些消費者流向高價產品[159]。而 Datta and Tschantz (2015)的研究則發現，被 Google 識別出為女性的用戶往往獲悉高薪工作廣告的機會較少[160]。一般而言，不論線上或線下，價格差異只要不是刻意依種族決定，是不違法的[161]。

---

158 Valentino-DeVries, J. and Singer-Vine, J. (2012), Websites vary prices, deals based on users' information. The Wall Street Journal, December 24.

159 Crocker, M. (2014), OTA pricing tactics show value of traditional travel agencies, November 11.

160 Datta, A. and Tschantz, M.C. (2015), Automated experiments on Ad privacy settings. Proceedings on Privacy Enhancing Technologies 2015 (1), 92-112.

161 Baracas, S. and Selbst, A.D. (2016), Big data's disparate impact. 104 California Law Review

又如，Princeton Review (線上 SAT 家教)的教材依不同地區用戶而有顯著價格差異[162]。在美國本土，一些地區(依郵遞區號)的訂價會低於另一些地區，而亞洲地區客戶則幾乎是非亞洲客戶的兩倍價格。The Princeton Review 的說法是，線上課程是 24 小時的一對一真人會話，學生與教師的所在時區不同，連線與經營之成本各有不同；且說，在紐約地區則因學生與教師都在同一時區，因此價格就都相同。其結果並未違法。The Princeton Review 指出，其價格是簡單的依地理區域決定，但 Uber 的差別訂價則是依電腦演算法決定。

演算法協助廠商進行價格差異化的工程，相當精密，針對細微區塊化的個人(或族群)，可以開出不同樣式的價格與折扣組合表單。依經濟理論而言，一廠商要能夠成功的價格差異化，必須具有某種程度的市場力，且必須防止可能的買者套利。在訂價演算法的運作中，其區塊化工程是依據消費者細微特徵與慣性進行開發，其所開發出來的區塊消費者，獨自構成一個市場、且可能是其他廠商並未開發到的區塊，因而投給該族群所偏好的產品、式樣、與價格，等同於是針對一個獨占型小市場一般，這也正是演算法對該區塊市場獨占力的來源。且因，個別區塊的偏好是不一致的，開列給 A 區塊的式樣價格組合，未必受到 B 區塊消費者的青睞，於是轉售在區塊消費者間並不會流行。

依經濟學理論，差別訂價有三種基本類型：(1)一級(或完美)差別訂價，每一消費者被訂以其消費各單位的願付價格 (2)二級差別訂價，依購買數量不同而訂定不同價格 (3)三級差別訂價，以不同特徵分類不同族群，依族群之願付價格訂價。

一級差別訂價，過去被視為理想型，不存在於真實。但隨著大數據的收集以及更強力更快速的演算法出現，廠商已可以把消費者區段成更微小的群

671.

[162] Angwin, J. and Larson, J. (2015), The Tiger mom tax: Asians are nearly twice as likely to get a higher price from Princeton Review. ProPublica, September 1.

體、甚至個人，於是，一級差別訂價已幾乎可及。根據 2014 年美國 FTC 報告指出，一個 data broker 擁有幾乎全美每一消費者的 3000 個特徵數據段(data segments)；據此特徵數據段所區塊出來的消費群，理論上必然很微小，甚至可以達到個人化裁製。對消費者進行一級差別訂價，其福利效應正負未定，在既有競爭法架構上並不違法；然而演算法促成的價格差異化，卻可能會導致某些區塊市場在廠商結合過程中被獨占化，因為，特殊化區塊市場等同於窄化了市場界定。於是，結合審查過程中，應針對訂價演算法商業的結合審查，特別予以檢視區塊化市場所受到的衝擊。

過去，因網路數位商業平台的出現，就地理區域而言，其市場界定被大大的放寬，早期一句諺語說「On the internet, nobody knows you are a dog.」，正是地理市場擴大的註腳。如今大數據與強力演算法的出現，技術上可以收集個別消費者的所有密切性枝微末節特徵、行為活動、與頻率，於是精密的訂價演算法可以細微區塊化出特殊偏好的小團，並針對性的給予個別化訂價，等於市場被窄化細化了。於是前述諺語變為「On the internet, everybody knows you are a dog.」

小消費市場因廠商合謀而致傷害仍屬違反競爭法

美國 2010 水平結合指導原則中，就價格差異這一項目作了具體指出：

> 「價格差異可能涉及識別個體然後決定給予不同價格，或者依觀察所得之特徵，給予不同類型群體不同類型價格」「當價格差異是合理可能時，執法者可以評估各分別不同類型消費群的競爭效應(competitive effect)」。「執法者通常獨立的評估受到結合影響的每一相關市場。假如結合可能在任一相關市場中產生反競爭效應，執法者通常也會挑戰該一結合。」

也就是說，指導原則並不以一市場消費者福利所得來抵消另一市場福利

損失。如果一錨定客群(targeted group of customers)因競爭減損而受害，其本身就足以構成阻止該結合交易案的充分理由。Judge Sullivan 在 FTC v. Staples 寫到：「反托拉斯法的存在就在於於保護競爭，儘管錨定族群只代表了整個市場中相對很小的一部分。」

當演算法訂價程式愈複雜，為了評估一潛在結合的競爭效應，執法者所需界定的相關市場就會愈窄 ；一個結合案在一個市場中不具反競爭效應，卻可能在一個更小的差別訂價市場(price-discrimination market)中顯著的減低了競爭。於是，在精密訂價演算法之下，每一區段化族群消費者可能只是一小族群，但其因競爭減損而受到的福利傷害，執法機關仍需予以關注。

第三節 結合審查

McSweeny and O'Dea (2017)於其文章設計了一個簡易例子[163]，說明當訂價演算法足以精密個人化訂價時，則兩廠的結合可能會導致某些小族群市場，可能一變而為高度壟斷。於是，競爭法機關在結合控制審查時不得不留意此一個人化訂價所可能衍生的變動。此處將以該文範例說明於后。

高度差別訂價下小市場因廠商合謀而受害的案例

表 5.1 呈現了該文的第一個範例，消費者具有車無車的特徵分類、而廠商則是網路或實體店面的特徵分類。市場上有六家廠商 ABCDEF，ABC 三家是網路商店、DEF 三家為實體商店；而消費者分成兩類，一類是占 90%比例的有車族、一類是占 10%比例的無車族。無車族購買某產品時，只能透過網路購買而直接送貨到住家，因為無車故無法(或很難)親到實體店購買並帶回；而有車族則可在六家中任一家購買。於是當 AB 兩家廠商進行結合，有車族

[163] McSweeny, T. and O'Dea, B. (2017), The implications of algorithmic pricing for coordinated effects analysis and price discrimination markets in antitrust enforcement. Antitrust 32 (1), 75-81.

可購買廠商從六家變五家，而無車族則從三家變兩家。後者的市場力變化甚大，從競爭法角度而言，已需給予結合控制上的關注。

表 5.1 依交通問題之特徵分類

	Firm	A	B	C	D	E	F
	Market Presence	online	online	online	Brick & Mortar	Brick & Mortar	Brick & Mortar
	Consumer Category						
Before Merger	With Car (90%)	●	●	●	●	●	●
	No Car (10%)	●	●	●			
After Merger	With Car (90%)	●		●	●	●	●
	No Car (10%)	●		●			

Note. A acquires B

表 5.2 則是以政治意識型態進行消費者與廠商特徵分類。市場上有六家廠商 ABCDEF，各有不同政治色彩標籤。ABEF 四家在政治上中立、無明顯色彩，C 廠是政治保守色彩的廠商、D 廠則為政治極自由派。假設依政治意識型態，消費者可分成三類，中間者占 80%、保守者占 10%、自由派者亦占 10%。進一步假設，自由(保守)派消費者不願跟保守(自由)派車商買、保守(自由)派車商也不樂意賣車給自由(保守)派消費者。因此，在市場中，政治中間派消費者可與六家廠商交易，保守派消費者則可與五家(ABDEF)交易，同時自由派消費者也可以五家(ABDEF)買賣。一旦 A 廠併了 B 廠後，中間派消費者可交易廠商由六家變五家、保守派消費者由五家變四家、自由派消費者亦由五家變四家。如此看來，五家變四家，或許並無太大的競爭法疑慮。

然而，如果把政治意識型態、有車無車、網路實體店等諸項特徵一併考量，則情形會變得非常極端。如表 5.3 所示，AB 兩廠是政治中間派的網路商、EF 是政治保守的實體店、C 是保守的網路商、而 D 則是自由的實體店。消費者分類上，依舊是有車族 90%、無車族 10%，政治中間、保守、自由各 80%、10%、10%。由表中，可以明顯看到，無車而自由派消費者(占 1%)在 AB 結

合後，其可交易廠由原先兩家變成一家獨占，這個範例足以提供競爭法機關在訂價演算法涉入的結合案審查上，予以更審慎的分析。

表 5.2 依政治傾向之特徵分類

	Firm	A	B	C	D	E	F
	Political Reputation	Political neutral	Political neutral	Very conservative	Very liberal	Political neutral	Political neutral
	Consumer Category						
Before Merger	Moderate (80%)	●	●	●	●	●	●
	Conservative (10%)	●	●	●		●	●
	Liberal (10%)	●	●		●	●	●
After Merger	Moderate (80%)	●		●	●	●	●
	Conservative (10%)	●		●		●	●
	Liberal (10%)	●			●	●	●

Note. A acquires B

表 5.3 依交通問題與政治傾向之特徵分類

	Firm	A	B	C	D	E	F
	Market Presence	online	online	online	Brick & Mortar	Brick & Mortar	Brick & Mortar
	Political Reputation	Political neutral	Political neutral	Very conservative	Very liberal	Political neutral	Political neutral
	Category	Consumer Category						
Before Merger	With Car (90%)	Moderate (80%)	●	●	●	●	●	●
		Conservative (10%)	●	●	●		●	●
		Liberal (10%)	●	●		●	●	●
	no Car (10%)	Moderate (80%)	●	●	●			
		Conservative (10%)	●	●	●			
		Liberal (10%)	●	●				
After Merger	With Car (90%)	Moderate (80%)	●		●	●	●	●
		Conservative (10%)	●		●		●	●
		Liberal (10%)	●			●	●	●
	no Car (10%)	Moderate (80%)	●		●			
		Conservative (10%)	●		●			
		Liberal (10%)	●					

Note. A acquires B.

訂價演算法對結合審查的新挑戰

在大數據及演算法之下，個別消費者之有車無車及政治傾向，可以很容易的被偵察出來，於是可以細微的依多個面向特徵進行消費族群區段，針對性的投以不同價格(個別化價格差異)，McSweeny and O'Dea (2017)稱此為「錨定價差市場(targeted price discrimination markets)」。這對執法者而言，會是一個相當難以解決的新課題。前述範例，足以提供我們預見與說明，演算法基底廠商於結合審查時的可能新挑戰與新疑慮：[164]。

首先，析離影響因子極為艱難。在廠商個別化訂價策略下，可能大多數消費者並不太受結合結果影響(例如表 5.3 中有車中間派之可交易由六家變五家占 72%)，於是很難說價格上漲是緣於結合。而且，事先結合審察時，執法者也沒有理由會去懷疑或意識到消費者政治觀點將會有關於競爭效應評估。

第二，受結合限制競爭的區塊市場可能很微小。在個別化訂價策略之下，因結合而引起競爭疑慮的區段市場，可能僅占總銷售的非常小比例，例如表 5.3 中之無車自由派可交易由兩家變一家占 1%。於是，欲分析或檢測如此小比例卻多元特徵區段化的市場，執法機關非有堅強訂價演算程式能力，無法追蹤與檢測；尤其，當特徵項目更多元化時，區段消費者愈多，區段市場愈細化，其於結合過程所受的到競爭減損之傷害不一；往往族群愈小受傷愈大，但執法者卻愈難以追蹤與檢測。

第三，執法者偵測區段市場遠比廠商創造難。對運用演算法的廠商而言，如此眾多細化的區段市場，可能只消幾個步驟就可以快速創造出來。執法者對一個結合案審查，過去可能只需分析一個相關產品市場的競爭效應，已是大費周章；現在則須面對廠商演算法快速創造出來的幾十個幾百個細化後區段市場，造成極大困難度。一來，市場太多，難有足夠人力物力的支援；二來，若無資訊技術能力與人員的強化與組織擴充，對這等細化市場將無從追

[164] 同前文 McSweeny, T. and O'Dea, B. (2017).

蹤脈絡與原理，亦將無法進行釐清或審查。競爭法機關只有與時俱進的掌握與熟練演算法運用，方有能力對涉及訂價演算法廠商的結合進行適當的審查。

第四，結構救濟可能派不上用場。當前競爭法架構，對於結合審查會一併提出的結構救濟(structural remedies)或行為救濟(behavioral remedies)，針對因訂價演算法所區塊出的錨定價差市場之競爭傷害，適用上仍需多經辨證。例如，訂價演算法涉入廠商與市場後，受競爭減損傷害的區塊化市場，其營運資產與總體間不可能會是間斷(discrete)可分割的，要求結合交易必須分割資產(以適當的處理掉競爭憂慮)，變得無能為力。不過，由行為救濟著手或許較為可行，例如與廠商協議，令有疑慮的價格差異區塊化市場之價格拴鏈(tether)於其它市場價格之上。

在結合案涉及精密訂價演算法時，競爭法執法者應該警惕小心的予以評審，並仔細檢查可能的錨定消費群是否受到傷害。

第四節 企圖獨占

企圖獨占化(attempeted monopolization)，是一廠商以反競爭行為企圖獲致獨占地位、而且當下已來到一個即將成功的概率。因此法院認為，企圖獨占化之訴訟必須證明被告三件事：第一，被告採取了掠奪或反競爭行為；第二，被告具獨占化的具體意圖(specific intent to monopolize)；第三，被告已達獨占地位的危險概率(a dangerous probability of achieving monopoly power)。

上述三項判斷，不因訂價演算法有無而有所改變；亦即，在此類爭項中，訂價演算法仍然只扮演著廠商遂行目的的工具；因其快速監看偵測與反應訂價能力，讓廠商於進行不法之時，可以更見所欲效果。於是，既有的競爭法標準架構已足以處理。

Philadelphia Taxi Association v. Uber (2016, 2017, 2018)

2016 年費城泊車機構(Philadelphia Parking Authority; PPA)與 75 家計程車業者提出訴訟，謂 Uber 違反了企圖獨占化(attempeted monopolization; Sherman Act 第 2 款)、相關契約(賓州法律)、及不公平競爭(賓州法律)。

於勞動法上，Uber 堅持其駕駛人並非僱員，而是獨立契約人。這樣的堅持，一來開啟了駕駛人之間僵固價格之疑慮(因為每一駕駛人為一經營個體)，同時也為其造成規避管制之不公平競爭優勢的獨占疑慮。獨占疑慮之起因，不單單只是其宣稱駕駛人不是僱員，更重要的是，其獨特新穎商業模式，完全落在傳統搭載服務供給者之管制規範定義外，在 2016 年 Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc.一案上展露無遺[165]。此案的原告認為 Uber 規避了管制而節省了許多成本、形成了反競爭優勢，但因無法證明反競爭傷害，而為賓州東區法院於 2017 年駁回；第三巡回法院支持此一決定，並於 2018 年確認原告控告 Uber 企圖獨占不成立[166]。

自 2005 年 3 月起，凡於費城經營計程車必須取得由費城泊車機關(Philadelphia Parking Authority; PPA)所授與之便利公眾證明及執照(標章)[167]，該執照具有作為融資購買新車或更新設備的擔保品價值。欲擁有經營執照必須符合許多相關規定標準，例如車子保險、駕駛人最低薪資保證、駕駛執照、流利英語、車輛年限與配備…等，並取得便利公眾證明。當 2005 年此規定實施時，此營業標章於擔保市場即有 6.5 萬元美金的價值；而在 2014 年，費城有 500 家業者、7000 駕駛人，共流通 1610 個營業標章之下，估計每一營業標章已達 54.5 萬美元之擔保價值。提出本案訴訟者為其中的 80 家業者、共

165 Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 218 F. Supp. 3d 389 (E.D. Pa. 2016); compare to Malden Transportation, Inc. v. Uber Technologies, Inc., 2017 U.S. Dist. LEXIS 213023 (D. Mass. 2017). Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 2017 WL 551593 (E.D. Pa. Mar. 20, 2017).

166 Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 2018 WL 1474373 (3rd Cir. Mar. 27, 2018).

167 依照規定，公共運輸路線與經營之開設，必須取得美國公用事業委員會(Public Utilities Commission)授與便利公眾(public convenience)證明。

擁有 240 塊營業標章。

Uber 於 2014 年 10 月開始於費城經營，沒有取得費城營業標章與公共運載證明，對於使用其 app 的出租車輛不具擁有權、對其營運不具法律義務責任、也沒有僱用駕駛人為其員工，其進入費城市場，既無向 PPA 繳任何費用、亦無遵守任何相關規範。原告認為，Uber 的經營是違法的，同時他因此而可以以極低成本營運。

2016 年 10 月賓州議會修法通過，允許在 PPA 管理下於賓州營運。於是 PPA 底下管制了兩個營運模式，一為傳統的營運標章計程車公司(medallion taxicab companies)，二為透過數位 apps 運行的運輸網公司(Transportation Network Companies; TNCs)，例如 Uber 等。TNCs 必須先取得營業執照、並遵守相關規定，包含對車輛與駕駛人的保險要求與安全標準，可以不必揭露駕駛人與車輛數目、也可以自行訂價。相對的，傳統標章計程車公司則遵守著既定的車資價格、人員最低薪資、以及設限的車輛與標章數目。在此法律通過之前，Uber 在費城兩年，共約 1700 駕駛人員與車輛，服務了約 70 萬位乘客、載過 100 萬旅次，其中則吸引了近約 1200 位標章計程車駕駛人改為 Uber 駕駛，有高達 15%標章因此被出租方收回。傳統標章計程車則大約減少了 30%搭載旅次、而致營收減少了約 30%，同時導致了一塊營業標章喊價，於 2016 年 11 月跌到了僅約 8 萬元美金。

PTA 與 75 家計程車業者，控訴 Uber 違反了企圖獨占化(attempeted monopolization; Sherman Act 第 2 款)、相關契約(賓州法律)、及不公平競爭(賓州法律)。

企圖獨占化的訴訟必須證明被告：(1)採取了掠奪或反競爭行為、(2)獨占化的具體意圖(specific intent to monopolize)、及(3)達成獨占力的危險概率(a dangerous probability of achieving monopoly power)。原告的主訴求亦圍繞於此，提出：(1)Uber 駕駛沒付費取得標章，就大量的進入費城計程車市場(taxicab market)，規避該受管制的規章而得以低成本營運、並誘離原本計程業駕駛人，

傷害了計程業市場之競爭。(2)Uber 既知相關管制規章卻刻意忽視或規避，藉此而排除了計程車市場中的競爭者。(3)Uber 具有達成獨占力量的危險性，再以其募資能力所建立的不公平競爭場域，破壞競爭者之經營，企圖成為唯一廠商。

在反競爭行為一項上的論述，原告認為 Uber 以無執照標章車輛氾濫式侵入費城計程車市場、不遵循管制規章要求、不支付成本取得執照標章、不保證駕駛人最低報酬、不購買該有的保險等等，足以使 Uber 在顯著相對低成本之下營運，以如此掠奪行為參進市場，快速的成就其在費城的強大據點。同時 Uber 亦以資金引誘(例如汽油補助)挖角其原標章駕駛人。法院則認為，就 Uber 整體行為來看，其之降低標章計程車競爭，並不構成反競爭行為而違反反托斯法。因為，氾濫式 Uber 車輛出現，儘管導致競爭者減少，也不是所謂的「反競爭」；恰恰相反的，它以更低價格、更多供給、更高技術叫車方法與支付方法而加速了競爭。不論價格是以如何方法訂定，只要不是掠奪，這樣的模式造成了低價並圖利了消費者，事實上「降價以促進商業經營時常是競爭的基本要素」，因此單單看到商業經營有損失，亦不能就此斷言是反競爭行為的結果。法官指出第二項，Uber 以低成本營運的能力，並不是反競爭；低成本可以是來自於經營上的經濟效率，就算是 Uber 亦可能因違反 PPA 而致成本減低，但若無確實反競爭行為的證據，則並不能說 Uber 這行為疑涉反托拉斯法。第三，雖然僱用競爭對手員工或許可能有反競爭疑慮，但必須該作用手段旨在驅逐競爭者，而非源於效率考慮；而觀察這些轉至 Uber 的員工，是繼續開車營業、而非閒置，故當視為出於 Uber 經營效率考量。於是，原告關於反競爭行為之指控，完全不被法院接受。原告藉由一連串敘述 Uber 進入市場方式，而後認為其傷害了商業經營及在執照標章上的投資，法院直接認為「沒有任何一項說明傷害競爭的效應」。

在獨占化具體意圖一項上，原告認為 Uber 明知而規避 PPA 管制，透露出其欲達獨占的具體企圖(specific intent to monopolize)。法院認為，具體企圖

必須建構於一些不具顯然效率意涵的行為之上，例如反競爭或排他競爭等行為。儘管 Uber 知道既有卻又選擇規避管制措施，但單這樣並不能說他顯露了獨占的明確意圖。同時，Uber 選擇獨立契約的駕駛人商業模式，也只是出於經營效率的考量，亦無涉及明確獨占企圖。

在達成獨占力量危險性與不公平競爭一項上，法院認為，危險性標準不僅複雜且當以事實證據為主，因此在因素分析時，除顯著市占率之外，當同時檢閱諸如反競爭行為、參進障礙、競爭強度、產業可能發展、消費者需求彈性等；而其中參進障礙包含了阻礙新廠參進競爭的管制要求、高資金成本、與技術障礙等。法院認為，原告主張 Uber 已驅退了許多競爭者，卻從無舉出反競爭行為的實證，也無提及 Uber 於該地區市場的市占率；主張 Uber 具有提高參進障礙的力量、並藉此傷害產業發展，卻都無事實舉證。原告主張一旦 Uber 成為支配性廠商，他將可以調高價格，而無智能手機的消費者將被剝奪於戶外叫車的能力；但法院認為基於原告對前述諸多指陳均無事實舉證，故此論點亦無法成立。原告敗訴。

若論某廠因規避管制而產生競爭優勢，則需該廠屬於所欲規避管制的範疇市場；反面來說，一個管制措施針對某一特定產業，但卻非一定適用於某一看似相同產出的經營模式，尤其一個富含破壞式技術創新的經營模式，其最終產品交易是運作於該獨特創新技術之上，往往很難被劃歸於原產業管制範疇。Uber 即屬此一類型。因此，Uber 雖相對於傳統計程車業具有競爭優勢，但並不足以證說此等優勢即是因反競爭而來[168]。

第五節 濫用市場地位

在平台經濟上，濫用市場地位的案例，以歐盟對 Google 獨惠自家比較購

[168] 更簡單的例子說明，例如，相對於其競爭者，某一公司因其組織具有許多課稅福利優勢，而具有了競爭優勢，但並不能據此而證說該公司違反了 Sherman Act 之企圖壟斷。

物網一例最為有名。惟此案涉及的是搜尋引擎頁面的演算方法，非本計畫所專注的訂價演算法議題，故本計畫於此將只把幾個相關案例(如下)作一梗概簡述介紹，而不正式列為本計畫詳述與探討之案例。

Google Maps 2007 年進入英國，打敗了既存廠商 StreetMap (建立於 1997)，英國法院認為這是因為 StreetMap 產品因缺乏投資致品質較差，並非是 Google 把自家 Google Maps 產品置於顯著位置；儘管在某些特殊區域，Google 措施容或具有反競爭效應，但法律不該阻礙創新，否則將傷害動態競爭過程 (dynamic competitive process)[169]。然而這判決與隨後 EC 的判決，剛好相反。

EC 從 2010 開始調查 Google 搜索引擎，起因於兩家搜索引擎的控訴(後來增加到 20 餘家)。EC 的調查，在於是否 Google 濫用其線上搜索的市場支配地位，降低競爭者的垂直搜尋服務(vertical search services)排序、優先安置自家產品的垂直搜尋服務結果，企圖驅逐市場上的競爭者。2015 年 4 月，EC 起訴 google 於一般網路搜索引擎服務(general search services)上濫用支配地位，於其搜尋結果頁面上，系統性的優惠自家比較購物產品。2016 年 7 月，EC 進一步補述其聲明，以更多證據與數據加強其認定，並仔細考慮 Google 所認為比較購物服務(comparison shopping services)應與其他商品購買平台(如 Amazon 及 eBay)一同考慮。2017 年 6 月 27 日，EC 做了最後判決，確認 google 濫用其一般性搜索引擎之支配力，非法的給予自家比較購物服務優勢，處罰 2.42 billion 歐元[170]。

German Bundeskartellamt v. Lufthansa (2018)

在柏林航空(Air Berlin)破產(2017 年 10 月 27 日)後，漢莎航空(Lufthansa, 亦稱德航)的演算法所訂定票價，在某些航線上出現了暴漲(25-30%)。德國聯

[169] Gibbs, S. (2016), UK's Streetmap loses anticompetitive search abuse case against Google. The Guardian, February 12.
[170] European Commission (2017), Commission decision of 27 June 2017 in Case 38606 - AT.39740 Google Search (Shopping).

邦卡特爾局(Bundeskartellamt)於是展開調查，借以評估對德航啟動濫權訂價(abusive pricing)的訴訟程序[171]。最終，卡特爾局並未起訴德航，因為研究結果發現：(1)即使德航增加航班頻率並飛行更大容量班機，市場上運輸載量仍然不足 20%。 (2)且由於 easyJet 快速的參進市場營運，價格高漲現象並未持久。(3)在柏林航空退出市場後，其容量主要是被 easyJet 所填補，而非被德航攫走[172]。

聯邦卡特爾局強調，演算法的運用並不使得企業免除競爭法責任，企業不能躲在其所運用的演算法背後。也就是意味著，當前演算法議題，仍都是依賴於人類的介入與干涉。

然而，當市場上一家競爭者破產(退出市場或相類似的市場結構改變)時，市場供給突然大幅減少，則訂價演算法面臨供不應求的實時市場，必然自動的訂出高昂價格。問題是，面臨此一特殊狀況，是該任由訂價演算法依原設計的實時供需訂出價格？或是人主體必須於此時介入更改訂價演算法、重新決定價格的參數？若是介入，則該在何種程度的突然改變之下介入？介入參數修正將以至於何種程度？歸根究底的，人類是否有義務監控及調整訂價演算法？這些問題，值得探討，尤其，當競爭對手退出而致剩餘廠商具有市場支配地位時，更顯得重要[173]。

第六節 不公平行為

Uber 於歐盟 (2017, 2018)

2014 年西班牙巴塞隆納計程車組織 Asociación Profesional Élite Taxi

[171] Bundeskartellamt (2018). Press Release of 29 May. Lufthansa tickets 25-30 per cent more expensive after Air Berlin insolvency–"Price increase does not justify initiation of abuse proceeding".
[172] 同前文 Bundeskartellamt (2018).
[173] 同前文 Picht, P.G. and Loderer, G.T. (2018).

(APET) 對 Uber 提出控訴，認為 Uber 未先通過政府管制條件即提供交通運送服務，違反西班牙競爭法；而如此作法，使 Uber 相對於其它計程車業者及駕駛人，得以具有反競爭優勢，其活動在西班牙競爭法規之下，已構成了不公平措施(unfair practices)。

Uber 的主要辯解，則一直認定自己並不是一個交通運輸服務者(transport service provider)，而是基於技術與創新商業模式的一個資訊社群服務者(information society service provider)，也就是一個平台或一個網路產業提供者，用以聯結獨立契約商(independent contractors 即駕駛人)與消費者，並由此而開創消費者更大的福利。

此案為西班牙法院暫行擱置，並提出於 Court of Justice for the European Union (ECJ)要求先行裁決(preliminary ruling)，確認 Uber 到底是交通運輸服務者或資訊社群服務者，或是兩者兼具，以為適用。

若是第一者，則歐盟法律是可以施以限制管制的，而若是第二者，歐盟法律則被禁止對其施以任何限制。事實上，在歐盟各國，Uber 的進入都面臨了傳統計程車業者的反抗，專家們認為，其商業模式也對競爭政策產生新式衝擊，例如在界定市場、在評估市場力、以及在評估其商業模式是否促進勾結或閉鎖之議題上。於是，歐盟競爭法院對 Uber 商業模式的最終認定，將連帶對上述競爭政策議題與評估做出正式定調。

最終 ECJ 於 2017 年 12 月確認，Uber 為一個交通運輸服務公司，並要求該公司於歐盟內必須如同一般計程車業者，遵守嚴格的管制規定及證照制度[174]。ECJ 認為，Uber 是一個利用資訊社群服務配對供需雙方的中介服務者，其最終在達成運載目的，其本質就是連結於運載服務；而且 Uber 也確實對本為駕駛人提供的服務項目具有重大介入，例如最高收費、向旅客收費、轉付費用於駕駛人、約定車輛品質與駕駛人行為，這些都是直接本質上連結於運

[174] Case C-434/15, Asociación Professional Élite Taxi v. Uber Systems Spain SL ("Uber Spain"). 亦請參閱 The Guardian/World/Europe (20 Dec 2017).

載業務上的，故該被視為一個運載服務公司。這是近幾年 Uber 持續於美國各州及他國地區勝訴之後的一個重要挫敗。2018 年 4 月，因應於 Uber 在法國的被訴案，ECJ 再次的做出相同決定[175]，法國也於 2019 年 1 月。ECJ 先行判決確定後，西班牙隨即對 Uber 與 Cabify 做管制要求，要求駕駛人必須具有執照；法國法院也於 2019 年認定 Ueber 對駕駛人具有控制力，Uber 是運載服務公司，當適用一般計程車管制法[176]。

Uber 於台灣 (2016)

台灣對於 Uber 的適法運用，是以其「虛偽不實或引人錯誤的表示或表徵」違反公交易法，給予處分。

依據台灣相關管制法規，經營汽車或電車運輸業者、計程車客運業、小客車租賃業等，都需依公路法向主管機關申請核準始得經營。Uber 集團規避相關管制，於網上直接招募個人司機、以自用車輛(白牌車)從事載客經營，也未經租車公司授權而私自與他租車公司司機合作、並直接收取報酬派遣調度車輛，此等行為已涉及未依公路法申請核准而經營汽車運輸業。惟此乃屬於相關管制主管機關經濟部職權。

Uber 國際控股公司於台灣所成立 100%子公司宇博數位公司(與經營 Uber APP 的荷商 Uber B.V 為不同法人)，為推廣 Uber APP 平台，自 104 年起，即於「Uber 司機資訊網」推廣訊息[177]，刋載推播徵募個人司機訊息廣告，謂「UberX 菁英條件：年滿 21 歲、持有普通駕照、車輛符合菁英條件、無犯罪或重大肇事紀錄」,「Uber 菁英所需文件：1.駕照 、2.行照、3.強制險、4.駕駛執照審查證明(肇事紀錄)、5.良民證」等；並謂「開自己的車、免費加入最夯共享平台、時間自由、每週多賺上萬」。

[175] ECJ, 10 April 2018, Case C-320/16, Uber France SAS v. Nabil Bensalem
[176] The Local (2019), French court reaches 'landmark decision' against Uber over drivers' rights, January 11.
[177] 公平交易委員會處分書，公處字第 105065 號。

本身即為未申請核準之行業、卻又公開推播徵募個人司機廣告，致使閱者誤認開自己的車、符合條件加入就可以合法提供服務，然卻與實際法令並不相符。宇博公司之於「Uber 司機資訊網」刊載此等內容廣告，無疑已涉及廣告不實之疑。

公平交易委員會於 105 年 6 月 15 日，裁決宇博違反公平法第 21 條第 1 項定「事業不得在商品或廣告上，或以其他使公眾得知之方法，對於與商品相關而足以影響交易決定之事項，為虛偽不實或引人錯誤之表示或表徵。」予以罰款 100 萬元。

所謂「虛偽不實」者，係指與事實不符的表示或表徵，其差異難為一般或相關大眾所察覺，而有引起錯誤認知或決定之虞者；所謂「引人錯誤」者，則係指不論是否與事實相符，凡表示或表徵，有引起一般或相關大眾錯誤認知或決定之虞者。事業倘於廣告或以其他使公眾得知之方法，就服務相關而足以影響交易決定之事項為虛偽不實或引人錯誤之表示者，即違反了第 21 條規定。

Uber 不服，再提行政訴訟抗罰，台北高等行政法院則於 105 年 11 月判決[178]，認定公平會裁罰有理。其判決書同時指出，該公司持續招募司機，除讓人誤認為合法之外，也由於增加司機加入的交易機會，將排擠其他計程客運業者的交易機會，致競爭同業蒙受損害，足以產生不公平競爭的效果。

第七節 本章結論

一廠商在增進自己利潤原則下，其訂價策略對競爭者產生不合理侵略，或因此而削弱整個市場的競爭狀態，這樣的單方訂價行為就會疑涉違反競爭法，尤其當一廠市占份額夠大時，其單方策略更易產生前述涉法後果。傳統上這些單方行為樣態，例如維持轉售價格、最優惠條款、掠奪訂價、差別訂

[178] 臺北高等行政法院，105 年度訴字第 1159 號。

價、意圖獨占等，在訂價演算法基底商業上，獲得更佳的施作環境。可以說，對於廠商而言，訂價演算法等同於是加強其洞察市場競爭與他廠訂價行為的神器，於是廠商足以快速了解市場狀態與競爭對手價格變動，然後快速調整自己價格以為因應。也因此，許多傳統反競爭的行為，在運用訂價演算法之後，仍然不改其反競爭、而且容易發生，但以既有競爭法架構仍是足以充分處理的。對廠商而言，神器在手，一不小心而誤蹈法網的機會變大，任何廠商對其所僱用的訂價演算法，應該謹慎留意，以免觸法。而偵辦實務上，了解訂價演算法必須成為執法者的基本素養。

例如 Asus、Denon & Marantz、Philips、Pioneer 四家家電製造商，被歐委會判決其線上零售產品，採用維持轉售價格，致傷害市場競爭而違法，此案演算法充當了對下游價格的監控。另外，Booking.com 等線上旅遊平台業者，對旅宿供應者訂定費率等同條款，足以讓市場價格維持於一個相對較高的地板，傷害市場競爭；在被歐委員進行調查後，表態自動撤除。Uber 在美國許多地方被提起控訴，其中理由都包含 Uber 虧本掠奪、企圖獨占、或濫用市場地位的宣稱，惟目前法院針對此一新興商業模式，仍未判決 Uber 違反競爭法。而個人化訂價亦進行消費者的細化區段，一個個特殊偏好的小族群構成一個小市場，雖然平時各小區段市場獲得了個人化偏好的餵養，但也引起了兩個問題，其一，個人化價格提高時，消費者將無以得知或比較他人被供給的價格；其二，在廠商結合時，某些小族群消費者可能會陷入被高度壟斷的風險。前者，目前實證與產業調查上，仍未發現已被商業運用，而後者，則增添了結合審查時的莫大困難，競爭機關必須留意這個可能性。

第六章 訂價演算法及競爭法執行

Saurwein et al. (2015)舉出了演算法選擇的七個風險類型，包括：濫用市場力、偏誤、審查、操控、隱私權、財產權、社會差異化。其中，市場力的濫用是直接關於競爭法，而訊息偏誤、市場操縱、侵犯財產權等，則可視為是間接的創造了市場參進阻礙，以及降低了創新意願[179]。

演算法可能被編制來促進反競爭活動。透過搜尋引擎操控搜尋結果，或以訂價演算法於網路商場上協同固定價格等等，都是屬於濫用市場力(abuse of market power)之類。透過線上用戶的偏好分析，採用訊息過濾器，降低了訊息多樣性，等同於偏誤了原來訊息。例如，搜尋引擎可以只提供線上讀者符合自身深信與偏好的新聞、產品推薦只推薦用戶先前有買過的同類型書本或電影、社群網路的更新只納入那些頻繁接觸者。透過程式自動審查(censorship)，控制或封鎖某些特定用戶可進接的內容、或被用來執行政府的某些司法管轄，或令其依商業或政治興趣而進行操控與選擇訊息，而不依相關性或品質。例如，在網路商場中開創多個帳號或重複多次交易，操控回饋分數以影響排序；或設計網路聯結來刻意偏誤搜尋引擎結果，讓某些特定網站排名高出。

另外，線上自動演算法，自用戶身上收集個人數據(有時還會與第三者分享)，引起數據保護與隱私的疑慮；例如，臉書於 2010 採用的「立即個人化(Instant Personalization) 」模型，允許伺服器提供者進取用戶們的 profile(刻畫)、收集用戶們位址資料，以做更佳的廣告錨定；自用戶收集、集成、安排、以及分享一些被智財權保護的訊息產品，也構成了財產權侵害問題。例如，新聞集成服務(news aggregator services)重新分派版權文章的一部分、無授權的音樂視頻串流網站。依個人訊息與特徵，演算法於決策過程會為其量身裁制，形成差異化結果(discriminatory outcomes)；例如，訂價演算法基於社會或群族

[179] Saurwein, F., Just, N. and Latzer, M. (2015), Governance of algorithms: options and limitations. info 17 (6), 35-49

特徵(例如址址)而進行差別訂價。

以本計畫之訂價演算法而言，前述問題中與競爭法相關的，其實也就是本計畫提及的第四章合謀及第五章非合作策略。

於第五章中，我們一再強調，對於廠商非合作策略所涉及的可能違法行為，基本上，都是傳統已具有的樣態、而在訂價演算法之下獲得更輕而易舉的執行力，競爭法之適用與執行並無疑義，惟執法人員必須進一步了解「訂價演算法」這一新型工具。

而第四章所論述的合謀樣態，在訂價演算法的協助下，可能超越了傳統「人為主體」的競爭法框架，不得不讓我們進一步思考各種可能策略及其變化形式。無疑的，隱性合謀、僵固價格、或個人化訂價，將是競爭法所直接面臨的最大挑戰。本章將持續探討這一問題。

第一節 競爭法的適用疑問

圖謀協同行為或企圖，若是直接顯然的通訊傳遞，肯定是違法的；然若完全借用競爭策略本身做為傳遞媒介，原則上，欲確認其為違法，則「必須舉出其意欲排除廠商獨立行為之證據」；因此，原告常被建議的方法，就是主張「某等安排是於各自獨立決行下，所不能獲致的結果」。

法院要求須有策略以外的額外因素證明

在目前的案例中，說服法官的論述，總必須顯示涉疑合謀廠商具有顯然通聯行為的證明(evidence of an overt act of communication)，而這類通聯行為總是具有一定的面向，例如它促成了多廠協同於一合謀狀態、或者促進了監視制約此一合謀狀態；這些面向並非競爭過程中的策略互動。儘管定義明確，然欲界定非法通聯仍是相當困難的[180]；除了顯然通聯之外，欲充分提出協議

[180] Kaplow, L. (2011), On the meaning of horizontal agreements in competition law. California

證據，相當的困難。目前法院對共謀判例，都是具有呈現確實協議的通訊證據。

依市場競爭原理而言，一廠商於競爭狀態下，絕無與競爭者通訊其訂價之需求；若有，則必然是意欲進行勾結。因此尋找這些資料文件或證人證詞作為證據，是最明確也最被法院採用的方法。

就經濟學分析而言，寡占廠商的決策行為，本質上都是非「獨立決行」，都是互依決策的。事實上，法院所指的「廠商獨立決行」應指「競爭狀態下的廠商單方決行」；若單方決行策略中，還運載著傳達給對手意欲邀約未來協同行動的意向訊息，這即構成法院所說「意欲排除廠商獨立決行」，但必須對此舉出明確的溝通證據，才能獲得法院肯認。一些判例中，雖並不見法庭作證或內部文件說明或通訊之存在，但法院或會要求至少「以合理推斷通訊存在」的證明，以作為區別獨立行動或協和行動的推論證據；這些推論證據往往必須證明出，廠商間的某些已現方法或動作，其實正是進行通訊所必須的[181]。也就是說，不論如何，必須直接舉證，「競爭者間具有創造或維持限制競爭相互理解的通聯行為」、或「存在一些他廠單獨決行時所無法一致達成的行動安排」。經濟分析證據亦常被用來做為旁證 (circumstantial evidence)。

額外訊息的例子，例如，1980 年代末，證據顯示航空公司隱性協議「公司可在其樞紐機場(hub)訂定高價」，他公司若在此處削價，則被攻擊公司即可在攻擊者的樞紐機場回敬以削價，並於電腦上對此訂價冠以 FU。此 FU 註記即是一個額外訊息，帶著通訊性質，而非競爭策略本身[182]。又如，美國 FCC (Federal Communications Commission)調查了 1994-98 的 16 個頻譜拍賣案，發現最終勝出標金超過 200 萬美元時，其它競標金最常出現的後三碼是 999。

Law Review 99 (3), 683-818.

[181] Page, W.H. (2007), Communication and concerted action. Loyola University Chicago Law Journal 38, 405-460.

[182] Viscusi, W. K., Harrington, Jr., J.E. and Vernon, J.M. (2005), Economics of Regulation and Antitrust, p.122.

調查發現，因為投標者故意以後三碼對應於頻譜基本交易區段(basic trading area)編碼(a BTA end code)，來讓其他競標者看到標金所代表的 BTA end codes；以如此方法，競標者幾乎沒有成本的解讀其他標金的真正目標，而與競爭對手達到了協同，沒有競爭[183]。

智能體合作下的人主體課責

在訂價演算法基底商業後，智能體(自動機代理人)所能取得的只是競爭之下的數據訊息，包含過去價格、銷售、與其它市場數據，於是智能體能據以決行的訊息，都屬於策略面(訂價)居多，智能體並不會也無法發布策略面以外的額外訊息(extraneous information)，以作為信號傳遞。於是，顯然通聯的證據，一般不會在智能體運作下出現。

在沒有額外訊息之下，智能體單憑著訂價策略本身，若可進化到彼此「相互理解」，而終致超競爭價格結果，則廠商(或人主體)是否還是一個可課責對象？

廠商經理人各自獨立選擇他中意的訂價演算自動機，他並不知道此一選擇會導向合謀狀態。就算最終經理人也知道，對手廠商經理人也是委由訂價演算自動機訂定，且就算最終智能體之間達成了「限制競爭的相互理解(mutual understanding to restrict competition)」，但人主體之間則是不存在此一「限制競爭之相互理解」的，這就是主張經理人無罪的說法。

然此一說法並無法立即也免除廠商責任。依據規定，公司對於其所僱員工負有相關法律責任，惟公司是否也需因其所僱智能體行為而負上法律責任？則無法適用。進一步想像，在智能體達致超競爭高價過程中，若無任何人為之「合意(meeting of minds)」或「有意識共同安排承諾(conscious commitment to a common scheme)」，則智能體真能自己做到達成超競爭高價嗎？

---

[183] U.S. v. Omnipoint Corp., In the U.S. District Court for the District of Columbia, Civil Action No.1:98CV02750, Competitive Impact Statement, November 10, 1998; pp. 6-7)

智能體真的具有「理解」能力嗎？

因此我們面臨到一個最核心的問題：訂價演算機真的可以自我具有「理解」這一回事嗎？可以自己做到超競爭高價結果嗎？

電腦編程幫助完成任務，但它並不懂人的語言。儘管訂價演算自動機可以彼此傳輸數據、並據以決行而甚至產生協同訂價，但並不意味著，彼此理解他們「正在協同以達競爭限制」。既不「理解」，則就不會「相互理解」，則就不構成競爭法合謀要件的「合意(meeting of minds)」，於是，廠商就沒有違法疑慮。

進一步推論，假設訂價自動演算機真的可以「理解正在協同以達競爭限制」，那麼要如何達到「相互理解」則又是一個更大的困難。相互理解，也就是說，甲演算機知道「乙基於認知甲會跟進而訂高價」，反之，乙亦是如此。電腦要具有此等心智歷程是相當困難的。

就算訂價演算自動機可以達到協議所需之「相互理解」，則欲以競爭法起訴之，則仍需進一步說服法院，訂價演算自動機真的可以像人類一樣的達到限制競爭協議。

準此而論，若缺乏一致行為的證據，則廠商單獨決行並採用訂價演算法服務，是不太可能承擔反競爭法律責任的，儘管經濟學分析中之相互依賴寡占問題，仍然如影隨形。例如，許多競爭廠商不知情的買用了相同的訂價軟體，這軟體採用了相同的演算法為廠商有效規劃訂價策略，結果趨向一致，但這些廠商們並不曾有過任何協議。

如何找尋智能體合作的證據

電腦編程是人類設計者的產物，假若設計者一開始即建構其演算機例如跟進對方價格的指令，我們即可說，此類型的人類設計者具有利用訂價演算機作為互通訊息工具的企圖，欲以此達致合謀而趨於超競爭價格水平；此時才可論斷為人主體違反了競爭法。然而，這類型指令可以非常細微、不動聲

色的被植建於整體編程設計中，競爭法執行機關或執行者，欲循傳統模式，從公司文件資料或人員作證中去掌握此等設計，變得困難，或許徒勞無功；又或者，欲從整體編程設計中去檢驗尋找出此一指令、或偵測內建函數與邏輯是否包含終至達成合謀的指令，這是一高度挑戰的任務。隨著技術進步，後者的檢驗模式或許會愈來愈被開發與倚重。

傳統促成隱性合謀的運作，不外乎兩個步驟(或關鍵)，其一策略外，即借助不屬於競爭策略變數的額外訊息進行溝通，其二策略內，即以策略完成一套兼含棍棒與蘿蔔的獎懲機制。訂價演算法自動機則可以只運用策略面，就一併完成這兩個關鍵。

一旦超競爭價格是起因於策略本身互動，完全不假外求，則除非真能依按電腦編程尋跡追索出其中暗藏的棍棒蘿蔔，否則只能視之為合法的意識平行行為。就算偵測或檢驗出可能暗藏的獎懲機制，也無法推定那是設計者或廠商有所意識到的、或是為其原始意圖，於是很難據此認定廠商違法。

獎懲機制是關鍵性因子

隱性合謀是彼此默契理解後的合意行為，惟以訂價演算執行此策略時，這一默契理解的產生過程，其實是彼此不斷策略訂定與回饋修正的市場競爭過程，可能沒有任何文件、言語、或非策略訊息於人員之間溝通傳遞，於是擴大了不法的明顯勾結與合法的平行意識行為間的灰色地帶。換句話說，訂價演算程式充分的讓廠商達到隱性協同(tacit coordination)，卻不須運作任何顯性合謀手段，其所依賴的就是持續的訂價策略試探，因此無法被確實直接觀測認定，而只能依賴於經濟分析作為間接觀測。然而法院過往案例中，經濟學分析實證很少成為法院認定有罪的主要證據，一般仍需其他額外因素證據。

經濟分析上，針對訂價演算程式合謀事例上，獎懲機制的有無，是一個判斷上的主要關鍵。歐委會競爭部長 Margrethe Vestager (2017)說「卡特爾都

面臨著成員開始欺騙的風險。若每一廠都訂高價，則你就可透過減價來攫取大量客戶，因此卡特爾的續存，依賴於他廠能夠多快觀察到這一削價、並以自己也低價來進行報復。能快速做到如此，就可確保他廠沒有太大誘因削價。麻煩的是，自動化訂價系統剛好可以很快的做好這事。」這其中，合謀果實是利得，低價報復則使果實失去，構成一套「獎懲機制」。

由競爭均衡走向合作勾結，一來須有廠商率先提價，二來必須對方肯定跟進。我方提價而偏離納許均衡，短期間收益必然減少，除非對方隨後不久也能跟著提價而達到長期合作狀態(合作利潤)，這必須取決於對方能夠會意我方提價是一種抑制競爭(或意欲勾結)的企圖與示意，而且還要能夠抗拒因和同我方抑制競爭(即跟著提價)時所須放棄的短期大利誘惑。基於理性假設，對方必然解讀「我方提價使自己當下利潤減少的策略」必是一種圖取較長期更大利潤的行為，必是示意著共同提價以「抑制競爭」的企圖。對方會意及此且和同提價，將獲取合作利潤，且我方將持續高價以維持於長期合作利潤；這是一種「獎勵」。若對方會意卻不理睬(即不和同提價)，將獲取當下短期大利(因低價之故)，卻坐看未來長期合作利潤機會被代之以持續競爭利潤(因我方隨之降回競爭價格)，這是「處罰」。暗藏這「獎懲機制」的策略互動，競爭廠商們方有機會從競爭均衡走上合作結果。當一個合作狀態出現，其能否維持的分析亦是如此。若對方繼續維持於此一狀態(即持續和同我之高價)，則繼續享受合作利潤，此為「獎勵」；但若對方偏離此一狀態(即不和同我之高價)，雖可獲短期大利益，但我將隨之而降回競爭價格致合作瓦解，長期合作利潤將被代以長期競爭利益，這是「處罰」。

這樣的獎懲機制，「跟進則有蘿蔔、不跟進則給棍棒」，迫(誘)使長期競爭者形成跟進誘因，於經濟分析上，已足證確實「排除了廠商之獨立決行」。在Monsanto Co. v. Spray-Rite Serv. (1984)一案中，法官就認定，被認為合意勾結的要件，是必須證明「該行為可能會排除了廠商的獨立決行」。然而，實際法例上，法官仍要求必須有足以「顯示競爭者並不獨立決行的證據」，往往是指

經濟分析之外的其它旁證(例如彼此交換訊息)。

「獎懲機制」的存在，正是隱性勾結形成的重要關鍵。在判斷兩廠或兩個演算法之間是否具有隱性勾結之合意行為時，重點當在於解讀「獎懲機制」是否存在。然而，實務中要去印證廠商間具有如此默契或協議，除了尋索文件或通聯等等紀錄以獲得明確證據之外，別無他途，因為目前法院並不接受單單經濟分析。

然而執法人員欲於訂價演算法商業競爭中採行經濟分析，面臨了更大的挑戰，因為由機器演算程式所完成的協同行為，執法人員該如何從此等機器結構中追跡尋索以判斷是否藏有獎懲機制設計？變得更為困難，然也是執法人員於訂價演算法商業中，所必須跨越的第一步。

第二節 人主體 v.智能體

傳統競爭法是發生於人類(human agent; HA;人主體)之間的互動關係，以圖 6.1 之例示來說，即為 a 關係。演算法普遍後，自動機代理人(automation agent, AA;智能體)也是一個具有自我運行的決行者，惟其所決行範疇則是來自於人主體的賦予，於是構成了僱傭模型(principal-agent model)；人主體為授權者、智能體為代理者，此即為圖一例示中的的 b 關係。一市場中多個廠商個別採用訂價演算法(或智能體)，則各廠訂價演算法之間形成互動、甚或互通「想法」，而構成圖 6.1 例示之 c 關係。在 b 關係與 c 關係確定後，亦即一個新「狀態(state)」的產生，智能體依其編程指令以及所處狀態而採取該有的決策行動，此即為圖 6.1 例示中之 d 關係。

各廠各行動組合構成一個市場競爭產出(outcome)，而以 e 於圖中標示此一產出，並進而影響消費者。智能體(自動演算機)的發展，令其對消費者偏好、地區、習性、購買、瀏覽紀錄、以及對市場他廠行動決策，都能快速偵測並據以成為該智能體下一回合決策之既有狀態(state)，此一迴圈表示於圖 6.1 的

f 關係。藉此迴饋，智能體不斷因應新局。所謂下一回合，其實可能只在踵息之間。

顯然 a 關係的強烈人主體角色

這一張示意圖，可以展現出演算法過程、與其在競爭法議題上的可能問題。首先，人主體若彼此間通信協商，各自編撰其智能體一個互相跟隨的高價格，此時的智能體所扮演的只不過是一個完成勾結的通訊工具(messenger)，意欲互通訊息者仍是人主體，若由此而達成超競爭價格(super-competitive price)，仍屬於人類行為所致，是人類的顯性勾結，這是屬於例示圖 6.1 中的 a 關系。*United States v. Topkins* (2015)即屬此例，英國 *Trod Ltd* 及 *GB eye Ltd* (2016)亦是。

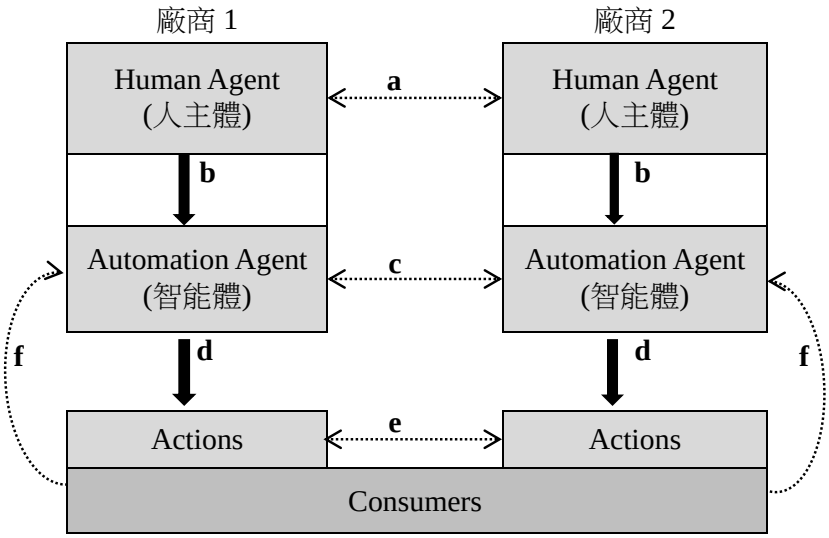

圖 6.1 機器演算法參與市場競爭之流程示意圖

假若人主體們使用相同演算法或數據庫來做為決策依據，就容易導致競爭者們對外部事件(例如成本或需求改變)都做相同反應，產生一致行為，構成平行演算法之一類，其一致行為產生之關鍵仍是 a 關係。甚且，假若競爭者

們知道或推論出彼此使用相同或相似的訂價演算法，則廠商們就更能夠預測對手對於價格變動的反應，產生類似於減低策略不確定性的訊息交換效應，這當然可以有效的幫助維持隱性共謀結果，關鍵因素仍然是 a 關係，而這模式即為 Ezrachi and Stucke (2016)所謂的「hub-and-spoke (軸輻架構)」。

以上的隱性合謀過程中，人主體具有吃重的角色，競爭法機關若懷疑這類型合謀，則往人主體間尋找顯性溝通證據，是一個確定有效的辦法。

具 c 關係的模糊人主體角色

兩個智能體之間的互通款曲，則是依賴著機器自動化演算的過程。假若個別人主體於其智能體中編撰了類似於「比照訂價(matching)」或「以牙還牙(tit-for-tat)」等運行法則(rule)，則該智能體以此類法則因應外部因素輸入後的反應行動，是明確可以預期的[184]。雖說人主體們並沒互通信息(無 a 關係)，但有可能智能體互相了解法則後達到了超競爭價格(c 關係)。這就進入了一個比較模糊的論爭區域。或許，我們可以說，此等訂價法則或有事先揭露或知會，則可視為一種「事先公告」模式，而以目前競爭法架構即可處理。如果訂價法則雖未事先揭露，而是由一方智能體於高頻策略互動後，發現另一方的既定訂價規則，於是採取相對應配合訂價，很容易的也可以共同達致超競爭價格，這類型即是 Ezrachi and Stucke 所提出的「可預期代理人」型式。

競爭機關對此類模型，仍在摸索。其中幾個問題於競爭法架構上的定位或問題，須先行釐清：

第一，智能體的互動探索

(1) 訂價演算機器之間的互動行為，是否屬競爭法架構所涵蓋範圍？

[184] 此即 Ezrachi and Stucke (2016)所謂的 predictable agent。

(2) 訂價演算機器之間因互動探索而致高價和同行為，是否屬於競爭法中所謂的隱性合謀？

(3) 實務上如何偵測此等機器間互動探索過程？

第二，人主體的編程與邏輯

(4) 人主體於此機器合謀結果上雖無涉入，但卻是源自於其對演算法所撰寫的編程與邏輯，此類人類行為是否是競爭法範圍？

(5) 如何偵測人主體所撰寫之編程與邏輯可能導致機器間未來形成合謀？

思考與釐清有助於透視問題本質，惟這問題涉及機器人故而難以理清，然本文仍於第七章執法者因應中作了一些建議；其中尤以歐盟作法最值得我們仿效。歐盟認為智能體是廠商所僱用的資產，如同僱員為其所用一般，於是僱員或僱用資產於行使公司事務所致之違法，雇主或廠商也必須因此負起法律責任。歐盟認為，一家企業於決定使用自動訂價演算機的那一刻起，就必須清楚知道，將為自動訂價演算機爾後所為負起所有責任。採用這樣的方法，是把訂價演算自動機的「行為」責任，完全令使用者負責；如此一來，前述五個待釐清問題，就可解決泰半。至於第(3)與第(5)，這是技術問題，唯有競爭法主管機關積極研發偵測方法，才能具有相對能量監理訂價演算法商業；於第七章，我們也作了相關於偵測的建議。

顯然 c 關係的微弱人主體角色

更進一步的，人主體各自編程製定演算法(或採用第三方演算法)，只給予個別智能體一個追求利潤最大化目標的編程指令，並無其他細目決策法則；但是，智能體們不斷接收到對方價格變動、不斷的以內部演算法試誤、不斷

的自我學習，為達成目標(最大利潤)而各自決行，卻在高頻互動學習過程後，也可能達到超競爭結果。這樣的深度自我學習機，其所達成的勾結，關鍵完全在 c 關係，沒有人為角色，已完全非目前競爭法所能框架。

歐委會競爭部長 Vestager 在演講中說到：「自動機所創造的挑戰是真實存在的。如果他們幫助廠商固定價格，他們就真實的使我們整個經濟體運作得更差… 至於競爭執法者，我們必須很清楚的表達，廠商們不能隱藏在電腦編程後面而規避了所有勾結的責任。」

當人工智能更高度發展，則人主體與智能體的聯結將更弱，訂價演算法即時自動反應與訂價能力，使廠商獲利增進之餘，卻使執法者對其在競爭法上責任擔負的判斷，更形疑惑。Ezrachi and Stucke (2016)認為，在訂價演算法涉入的市場競爭中，要界定一個不合法的基本模型，具有相當程度的挑戰性，因為這必須評估「獲益者是否事先即已預期或決定了該不法行為」(… it requires assessing whether any illegal action could have been anticipated or predetermined by the individuals who benefit from the algorithm.)。對這類行為的評估，應該包含，例如，仔細檢核演算法被編輯的指令？其可用的安全維護？獎勵結構如何？活動範疇為何？人為控制演算法活動至何程度？是否被創造來傷害消費者？接著再分析該課責對象，是設計訂價演算法者？使用演算法者？或得利於演算法的決策者？

第三節 判斷合謀的新課題

在沒有演算法涉入時，一些特殊市場結構，例如，競爭廠商數很少、透明度很大、或者參進障礙很高，則維持隱性勾結所需之特殊要件就很容易被達成、很難以被觀察。而當市場各廠異質性愈大時，隱性合謀就會愈形困難，例如成本、品質、市場規模、與品牌忠誠度等各方面，都會具有或大或小的差異；另外，若少數寡占大廠外存有多而小的廠商(fringe firms)們，其訂價能

力也將被制約著；而隱性勾結的超競爭利潤，必將吸引新廠參進並加劇市場競爭；同時，策略反應的遲滯性與因應突增需求的產能擴充無法彈性跟上，廠商儘管削價仍然可以增利(就算是對稱性廠商市場結構亦然)。

美國 2010 水平結指導準則中就曾特別指出，「對對手策略行動的確認與回應速度，是使市場變得更易造就協同行動的一個因素」。因為快速反應時間，將會大大降低了廠商挖走對手客戶時的預期短期報酬，使得削價利潤變得很少。European Commissioner for Competition, Margrethe Vestager (2017)也說到 ：「每一卡特爾都面臨著其成員開始欺騙的風險。如果每一廠都訂高價，你可以透過減價來攫取大量客戶，所以卡特爾的續存，依賴於他廠能夠多快觀察到這一低價、並以自己也低價來進行報復；若能快速如此做到，就可確保他廠沒有太大意願削價。麻煩的是，自動化訂價系統剛好可以很好的做好這事。」這就是訂價演算法帶來的新憂慮與新挑戰。

如同第三章第一節所言，在訂價演算法涉入市場後，市場特徵結構受到重大影響，隱性合謀條於寡占市場中變得更易達成，甚且可能推及至非寡占市場。

訂價演算法三功能增進合謀

在增進隱性合謀上，訂價演算法提供了三個面向的功能：第一，訂價演算法讓市場內各廠商彼此策略互動更為透明而穩定；第二，訂價演算法可於瞬時鎖定新競爭者施予針對性措施(exclusionary practices)，快速消滅參進威脅。第三，訂價演算法可以充當直接促進不競爭之有效工具，競爭者間不必透過顯性溝通互動。

訂價演算法收集與處理市場資料數據並快速回應對手行動的能力，恰如扮演廠商間的構通平台(intermediary)，更能夠精準偵測價格變動、消除非理性因素、降低錯誤決行而致瓦解勾結的機率，當然必定比人主體更勝任控管

合謀結構[185]。

訂價演算法使得現行許多競爭分析方法，出現難以適用的困境。許多競爭法分析多倚賴於價格觀測與衡量，檢視廠商是否具有訂定超競爭價格的能力或動機，這也是執法者於案例分析中的第一道門徑；例如 SSNIP 檢定市場界定、衡量一廠商市場力、或單方效果分析估計結合衝擊等等方法。這些檢定或分析方法的背後哲學，在於案涉行為前後的市場價格比較(或與假設性競爭價格比較)，但在訂價演算自動機代廠商決行後，其因應動態供需而以瞬息速度與高頻互動改變價格的能力，使得標準化的反競爭經濟分析模式，變得極難操作、且難以鎖定比較基準。目前的競爭法機關對此新型式挑戰，仍然大部分無解，卻可預見未來此類型案件必會非常頻繁。[186]

執法者須先行判斷智能體決行的分量

對於訂價演算法涉入的案例，欲適用既有競爭法規於反競爭協議或一致行為的判斷基準來評估訂價演算法所扮演的角色時，執法者首先須判別智能體促成該違法行為的分量。是幾乎自己獨立完成？抑或只是輔助或執行人主體意志想法的工具？

於是，執法人員必須具有訂價演算法相關技術與運作邏輯的了解，並且洞悉其如何促進或支撐了主要違法行為。例如，United States v. Topkins 一例，被告採用訂價演算法作為促成事前固定價格共謀的一個工具，其中的訂價演算法只是遵循與完成人類指令，於是，課責對象明確，就是人主體。

但當訂價演算程式與其他軟體愈行精密，協同行為可能沒有人主體顯性指令即可普遍出現，此類案例則已無法為既有競爭法架構所涵蓋，而需另謀解釋。寡占問題解析上的最大困難，在於其意識平行行為皆來自於不斷的市場策略互動與學習所致，其中若包藏有違法「合意企圖」，也甚難被觀測與析

[185] 參見前文 Mehra S.K. (2016b).
[186] 同前文 OECD (2017a), Box 11.

離。此等問題於傳統市場結構下，已是難解，更遑論於訂價演算法基底的市場結構中。Mehra(2016b)說「機器人賣家(robo-sellers)的崛起，使這工作更形困難。當前許多用以區分意識平行與顯性合謀的檢視方法，在機器人內函之下，用處已是不大的。典型用以臆斷人類精神狀態(presuppose Quintessentially human mental states)的「意圖(intent)」及「合意」，對處理計算機軟硬體是沒有用處的。[187]」

嚴格說，人主體決行概以「對自己是否有利」為思考主軸；於是當一廠商委託智能體全權決行時，此僱傭(principal-agent)模型下的廠商，將依舊秉持「是否真對自己有利」為核心來思考著授權智能體。指令或策略是人主體所擬定，而執行者則為智能體；雖由智能體完成合謀，但合謀的發源與企圖則始於人主體。透過既定的指令，簡單的策略例如「以牙還牙」訂價演算程式，就可促成並維持共謀結果。

人主體-智能體僱傭模式的弱點

不過，人主體-智能體間僱傭模式所達成的合謀結果，基本上具有很脆弱的本質，其強度遠不如人類間的僱傭模式；不確定性(即雜音 noise)是破壞力最強的一項。雜音時常的出現、且很容易出現於價格觀測或市場變動之中，智能體也都如數吸收並據以比對參照，成為決行所據的資料。因此，由智能體所促成的合謀結果，很容易波動不定、也就很容易被被推翻。

另一個破壞力則來自於人主體的心理狀態。在廠商合作價格下，人類永遠面對著一個最核心問題，就是，欺騙可以獲得暴利(短期)！因此人主體內心是否真的會安穩於讓訂價演算法帶往一個不攫取短期暴利的途徑上去？他會否把這樣一個人性短利的本質作為思考之一，而去選擇一個能夠解決這一問題的訂價演算法？又或者，有否可能人主體會在某些狀況下(例如抵擋不住短

[187] 同前文 Mehra, S.K. (2016b).

期暴利的誘惑)而改變訂價演算法指令？這些思維性問題，無一致性與邏輯性、也無相對解法，但卻是訂價演算法基底商業中，合謀成形或永續的一個重要影響因子。

第四節 訂價演算法可能違法樣態

綜合前述，我們將訂價演算法商業中，廠商可能利用訂價演算法達成合謀的樣態，逐一整理分述如下。

(一)仰賴人為合謀的監看型演算法

在合謀議題上，監控演算法被用於隨時監看所有廠商行動決策，確認所有廠商是否都訂價於合意水平，並隨時回報與採取相對因應措施。若並非所有廠商持續維持於合意價格，則將改訂競爭價格予以報復。其重點在於監看維護合謀狀態，至於合謀生成仍須仰賴其它機制或人為介入。針對這類訂價演算法的涉案疑慮，可以分成兩部分，一為人為、二為演算法所為。前者，如同當前競爭法架構之執法與調查，而後者演算法運作並不易調查，惟目前判例上，都是掌握人為違法而成案。若無法掌握人為部分的證據，則對演算法促成之勾結將無明顯證據足以提訴。第四章中的許多案例都屬於此類型。

(二)共用相同資料數據的訂價演算法

廠商共用相同來源資料數據的平行訂價演算法，則對外部事件(例如成本或需求改變)或對方廠商行動之策略反應，相似度將愈為提高，將時常出現平行行為。對各廠商而言，若其(購買)使用此類演算法是明知其將協助達成有利之一致訂價行為，則將涉及人為端的合謀，惟此類證據仍必須由公司人員或書面資料中去尋求。假若各廠購買使用此等演算法並無前述合謀意圖，則一

致行為出現時，是否違反競爭法疑慮，必須檢視其數據匯整模式。如果資料數據是由一群競爭廠商各自提供後整合一起，再共同提供予大家使用並隨時更新，則各廠據之所為的意識平行行為，就涉及明顯合謀，不待贅言。

如果數據資料匯整並非是各競爭廠商主動提供，而是某第三方廠商收集匯聚而成，然後再提供給廠商的訂價演算法運用，則第三方廠商所收集資料數據來源，將成為是否論為競爭廠商具合謀行為的證據。若其資料數據多為收集擷取自公開訊息與資料，則競爭廠商之共用訊息並無私密匯整，將無疑慮；但若其中部分仍是收集自各競爭者未公開訊息者，則仍然涉及共享營業秘密藉以聯合訂價之疑。

1990 年代初期的美國航空公司，每天將機票訂價訊息傳到 ATPC (Airline Tariff Publishing Company)，這公司集合所有業者送來訊息後，即時開放給各旅遊業者、電腦訂票系統業者、消費者、及航空業者自己。於是各家廠商利用相同的資料數據庫進行訂價決策，針對市場情況變化亦將為一致應對。這類型的平行演算法，漸趨一致的反應，終將導致高價格的出現。第三方提供演算法的協助，雖然確實提增下游各個廠商經營效率，促增競爭效應；但是另一方面，卻也促成各競爭廠商於反應動作上趨於協同，而有反競爭效用。雖有此疑慮，但因無人類進行勾結的行為顯現，並無法從明確證據上著手調查，只能依賴於法院對於「意圖證據(intent evidence)」的分析與收集。

(三)使用相同訂價演算法的廠商

當許多競爭廠商購買運用某一(類)訂價演算法時，例如 Amazon 提供其商場商家的訂價演算法，將使使用者的決策建基於相同演算邏輯與相同資料數據環境，各廠的訂價法則與趨勢必然一致，導致價格一致，也是一種平行行為。提供者並非市場競爭者一員，但因其提供的演算法聯結了市場競爭各廠，促進競爭者訂價趨勢一致，形成和同行為(構成軸輻模式)。在適用競爭法

上仍需依個案分析，重點仍然在於該第三方提供之演算法，其動機是在於協助串聯各競爭廠使之和同？抑或在於協助使用者更有效率的訂價？雖然涉及前者疑慮，但法院判斷上仍然需要有明顯證據證明確存此一動機。例如，Uber app 雖然遭受許多訴訟，但未有因此而被判決「協助競爭者和同行為」之違反。

(四)委託第三方之訂價演算法代為決行

與前一類型相似的是，當多家競爭廠商共同委託某第三方以其訂價演算法代為決行，則軸輻合作的問題就會浮現。基本上，當一廠商針對其上游(或下游)廠商，逐一進行聯絡互動以安排合謀，前者為軸心、後者為輻條，構成軸心與輻條的緊密一致行動的輻輳趨勢；其目的在於保護或提增發動者(軸心廠)市場份額、或者維護其利潤。其中牽涉了上下游(軸與輻)垂直安排，而且涉及輻輳廠之間的水平合意。在分析上必須確定：

- ●中介機構(軸心廠)研發該訂價演算法是否使用各客戶(輻輳廠)的過去資料數據？其訂價是否是最大化所有客戶總和利潤？
- ●若有一者是肯定的，則就可能涉及違反競爭法疑慮，然後進一步評量：受委任訂價演算法公司代客戶決行的相關市場比例有多大？

這個判斷，由發展階段就開始適用。一受委託訂價演算法公司在演算法發展階段(即訓練階段 training phase)，若並非使用公開訊息，而是使用自多個客戶(競爭者)的彙整數據，屬於各公司過去歷史資料、具競爭敏感性資料、或非公開的資訊交換，則第三方以此一訂價演算法為客戶決行，將涉及違反競爭法之疑慮；儘管該訂價演算法於應用階段(即 live phase)的推薦或訂價，其使用數據已經不再是來自客戶的彙整數據。基本上，演算法多為技術專門

公司所設計，作為訓練機器人的資料也當為該公司所收集與保存，於是競爭主管機關當可透過公權力要求檢視其所運用的數據資料。

另外，若受委任第三方訂價演算法公司，其演算法之目標函數是在於最大化其客戶總和利潤，則更是明顯違反競爭法。對受委任公司而言，此類型目標函數可行且易行，因為中介機構報酬常是依客戶銷售總額的比例計算抽成。

如果一個產業中有大部分廠商使用同一款訂價演算法，其軸輻結構將明顯的增進了提增價格的誘因與能力。與傳統案例相同，此類型軸輻結構之疑涉當前競爭法已無疑義。

(五)可預期的訂價演算機制

比較進階的訂價演算法，例如，競爭演算法知悉或推論出彼此使用相同或相似的訂價演算程式；如此一來，一方就更能夠預測另一方的可能反應，彼此更具能力解釋另一方訂價行為的背後邏輯或意圖。一來，達成訊息交換效應，二來，可能減低策略不確定性，極有利於促成與維持隱性共謀，三者，簡易跟進法則即可促成彼此同往高價水平。此類平行演算法，重點在於，一個訂價演算法的反應策略為另一個演算法所可以預期，於是容易形成訂價算法之間的和同行為而達致高價。

對此，就人主體而言，其在競爭法上僅有的苛責性只剩設計此類可預期邏輯編程。於是，在適用競爭法之前，得先釐清兩個問題：

- ●設計此類型編程的人類行為，是否是競爭法涵蓋範圍？是否違反競爭法？
- ●此類型編程於實務操作上如何可以被偵測與判斷出來？

而就智能體一端行為而言，其依據一已邏輯與編程運作，互動結果而構成高價和同行為，於適用競爭法之前，亦必先釐清兩個疑慮：

●此類型編程所達成之智能體間高價和同行為，是否是競爭法所謂之具意圖的合謀行為？

●於競爭法上又該如何舉證論述此等合謀已形成？

一些近期研究發現，在某些嚴格條件下，智能體彼此間合謀，不僅是可能的、而且是不可避免的。Salcedo (2016)的模擬證實，如果一智能體可以知道另一智能體的策略(比如透過機器學習)、且如果一智能體能夠進行跨時最佳化運算，則合謀終會出現。

然而，雖說其模擬得出如此結果，但該方法若運用於實務龐大串流數據與不確定性雜音之下，「解譯(decode)」與「跨時最佳化(dynamic optimization)」之運作將會面臨極大的挑戰。亦即，實務中，一智能體是否很容易解譯(decode)另一廠訂價演算法？又如何解讀？如何區別雜音？智能體是否可很容易的進行跨時最佳化決行？又如何跨時最佳化？這些問題，模擬可以解決，實務運用上則挑戰很大。

在適用競爭法的疑問上，歐盟的作法積極而且簡易，值得仿效。其作法，主張要求由設計端就開始管理、開始訓練其遵法競爭法的概念；並明白令廠商知悉，設計端不論是廠內部門或外部公司，既然都服務於廠商，或受僱專案委託、或受僱為員工，則因演算法所致違法情事，廠商都該負起法律責任。

(六)信號式的訂價演算機制

類似於可預期訂價演算法者，是信號訂價演算法。一廠訂價演算法刻意脫離競爭均衡而提出高價，藉以釋放其意欲邀約他廠共同提價的企圖，他廠

演算法於邏輯運算中解析出對方此看似不理性行為之企圖，且算出若應其邀約提價則可以獲取更大利益，於是跟進。其中所涉及競爭法的論述，與前一類型類似。基於對市場供需反應，一方廠商可以估計出自己的合理價格，也可以預期出大概的對方合理價格，因此程式設計上，可以編寫我方智能體於覺察對方訂價超越出此一合理範圍一段時期後，即視為一個詢問我方同行的訊號釋放。在執法人員執行檢驗時，是否有此程式編碼設計，是偵測重點。

前述可預期訂價演算法，亦可被用來作為訊息釋放的工具。因可預期程式是一種很容易被掌握到的訂價反應規則，有利於對方人主體偵悉後予以配合。一廠商若刻意採行這類型演算法，若事先公告當然就是釋放訊息的作為，若並沒有事先公告，其實也可能是廠商刻意採用來作為暗地裏釋放訊息的工具。

就人主體而言：設計此類型編程的人類行為，是否是競爭法涵蓋範圍？是否違反競爭法？此類型編程於實務操作上如何可以被偵測與判斷出來？就智能體一端行為而言：此類型編程所達成之機器間高價和同行為，是否是競爭法所謂之具意圖的合謀行為？於競爭法上又該如何舉證論述此等合謀已形成？

(七)自學型訂價演算法

至於學習型訂價演算法，人類單方設計其訂價程式，且只給予目標(例如達成利潤最大化)，其自身就能協助廠商往高利潤的合謀狀態形成。其合謀成形宛若黑盒子作業，人主體自身也已完全無法尋跡追蹤。該如何發覺與舉證此等合謀，更形艱難。

小結

廠商訂價委由訂價演算自動機執行，若最終智能體之間達成了「限制競

爭」的結果，顯然並不能代表人主體之間也存在著此一限制競爭之「相互理解」，因此負責採購此一演算法的經理人或可無罪，惟廠商則無法理所當然的立即也免除責任。公司對於其所僱員工負有相關法律責任，惟公司是否也需因其所僱智能體行為而負上法律責任？其實，智能體達致超競爭高價過程中，若無任何人為合意或有意識共同安排承諾，則智能體真能自己達成超競爭高價？這點目前只存在於學術模擬，而仍未見於實務。也就是說，以目前科技發展而言，智能體合謀的背後，必定有著人為引導。

最後，我們把前述違法樣態與思維邏輯，整理於表 6.1。

表 6.1 訂價演算法違法樣態與執法思維分類

違去樣態	樣態說明	執法思維與步驟
(一)仰賴人為合謀的監看型演算法	人為溝通合意，演算法監視以確保遵守	必須掌握人為端溝通合意的證據。
(二)共用相同資料數據的訂價演算法	競爭廠商間營業資料的互相分享	(1) 廠商於購買此演算法時，是否明知共用相同資料？若是，則是顯然的人為端合謀。 (2) 演算法所使用的匯整資料是否包含競爭公司的非公開資料？若是，則是合謀。 (3) 資料若為第三方所提供，該資料是否全部收集自公開訊息？若是，則非合謀。
(三)使用相同訂價演算法的廠商	相同訂價行為/相同資料，價格趨勢一致	(1) 第三方提供之訂價演算法，其動機是否在於協助串聯各競爭廠商使之和同？抑或在於協助使用者更有效率的訂價？ (2) 若有串聯動機之疑慮，則仍需有明顯證據證明確存此一動機。

(四)委託第三方之訂價演算法代為決行	軸輻合作的問題會浮現	(1) 第三方研發該訂價演算法是否使用各客戶的過去資料數據(包含機器學習的訓練階段)？若是，是違法。 (2) 第三方訂價演算法是否是最大化所有客戶總和利潤？若是則是以合作利潤為目標，故違法。 (3) 若有前述一者，則須進一步評量受委任訂價演算法公司，代客戶決行的相關市場比例有多大？
(五)可預期的訂價演算機制	容易洞悉訂價意圖、達成訊息交換、減低策略不確定性、易於與反應	(1) 人主體於競爭法上的苛責性如何？設計此類型演算法者是否違反競爭法？ (2) 此類型編程所達成之智能體間高價和同行為，是否是競爭法所謂之具意圖的合謀行為？ (3) 前一問若是，則須偵察與檢驗智能體是否內含此類型編程？這是確定是否人為促成合謀的證據。
(六)信號式的訂價演算機制	解譯對方脫離競爭均衡的高價，是否是意欲邀約同行的企圖？再行跟進。	(1) 智能體是否內含「訂價超越合理範圍一段時期」的編程？ (2) 智能體是否內含「察覺對手訂價超越合理範圍一段時後，即予以配合」的編程？ (3) 偵察與檢驗前二者，是確定是否合謀的證據。
(七)自學型訂價演算法	合謀成形宛若黑盒子作業。	人主體自身也已完全無法尋跡追蹤。該如何發覺與舉證此等合謀，更形艱難。

第五節 本章結論

本章針對訂價演算法於競爭法適用問題進行探討，鎖定當前實務與學術

上最為聚焦的合謀議題。人主體與智能體構成一個僱傭模型，涉案時執重執輕，受機器學習的先進與否所決定。比較低階的演算法，多數由人主體在合謀中扮演吃重角色，依既有法律標準架構，尋找人主體具體合謀證據，是可行辦法。但高階訂價演算法中，以智能體扮演合謀重角，此時欲尋找出具體證據顯然較難，於是對於編程偵測與檢驗，成為競爭機關必須盡速培養的能力。訂價演算法參與合謀的型式，有多種可能樣態，例如，仰賴人為合謀的監看型演算法、共用相同資料數據的訂價演算法、使用相同訂價演算法的廠商、委託第三方之訂價演算法代為決行、可預期的訂價演算機制、信號式的訂價演算機制、自學型訂價演算法。

傳統促成合謀的運作，不外乎兩個步驟(或關鍵)，其一，借助不屬於競爭策略變數的額外訊息進行溝通，其二，一套兼含棍棒與蘿蔔的獎懲機制設計。不過，訂價演算法自動機卻可只運用競爭策略變數一併完成這兩個關鍵。一旦超競爭價格是起因於策略本身互動，完全不假外求，則除非真能依按電腦編程尋跡追索出其中暗藏的棍棒蘿蔔，否則只能視之為合法的意識平行行為。就算偵測或檢驗出可能暗藏的獎懲機制，也無法推定那是設計者或廠商有所意識到的、或是本為其原始意圖，於是很難據此認定廠商違法。訂價演算程式足以讓廠商維持於超競爭價格與利潤，但可不藉用任何協議或溝通，擴大了不法的明顯勾結與合法的平行意識行為間的灰色地帶。例如，某些必須透過明顯通訊來達成的勾結，運用訂價演算程式之後，一個全新而自動機制被創造出來，藉此完成與執行共同政策並監視廠商彼此行為，這過程不須任何人為互動。換句話說，訂價演算程式充分的讓廠商隱性協同(tacit coordination)，而不須運作任何顯性合謀手段。

在自學演算法普及之前，訂價演算法所涉及的競爭法議題，基本上當前競爭法架構是足以應付的；當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。惟訂價演算法的普遍運用，使得勾結行為的確認，變得更為艱難，因此執法人員必須擁有更新的調查技術。在外部偵察未能達

到充分時，則兼利用寬恕政策及犯罪罰款，給予企業自我檢測與合作的誘因。

第七章 執法者的因應

毫無疑問，訂價演算法在數位經濟的競爭議題上，已經躍居所需面對的首位。多數的使用，在競爭上帶來了良性的發展與創新，但一部分的運用卻可能帶來社會傷害，各國競爭機關已都注意及此，並對此發展開始進行釐清、討論、與準備面對。在其中，歐盟採取了相對上最為強烈的偵辦態度。

第一節 各國態度

美國

2018 年 10 月 3 日，參議院反托拉斯競爭政策聽證會前，助理檢察總長 Makan Delrahim 說[188]：演算法運用所產生的反競爭效應，對美國與歐盟的執法人員都是一個掙扎中的重要議題；重要的是，美國反托拉斯執法人員認為，凡涉及演算法的勾結案，都應依傳統法律標準進行分析。美國司法部反托拉斯署副助理檢察總長(Barry Nigro)報告時特別指出：「當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。」

基本上，美國官員認為，現行反托拉斯法已提供必要工具來處理演算法促成的勾結，惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。FTC 前代理主席 Maureen Ohlhausen 則主張，既然偵測演算法勾結很難，則在外部偵察未能充分時，利用司法部寬恕政策及犯罪罰款，應該可以提供企業自我檢測與合作的誘因。

[188] DOJ (2019), Statement of Assistant Attorney General Makan Delrahim before the U.S. Senate subcommittee on Antitrust, Competition Policy and Consumer Rights, "Oversight of the Enforcement of the Antitrust Laws", September 17.

歐盟

歐委會(EC)對於演算法勾結則採取了較強烈的態度[189]，主席 Margrethe Vestager 說：演算法所進行的自動決策可能破壞民主，這並不是說執法人員必須去懷疑任何使用演算法的企業，但卻必須對於演算法帶來的挑戰保持警戒與處理能力[190]。Margrethe Vestager 提出「一設計就遵守(compliance by design)」途徑，認為企業能做的且必須做的，就是確保由設計端遵守反托拉斯法，也就是，演算法由設計端上就必須建立於不允許勾結；而且企業必須清楚，一旦決定使用自動系統，他們就必須為演算法所為結果負責任，所以他們最好必須了解該系統如何運作。

2017 年六月歐盟指出，依演算法如何被運用來決定其如何被看待[191]：

(1)如果企業透過任何溝通方法形成顯性勾結，並利用演算法來執行這個安排，這些企業當然違反了競爭法；其之違法是緣於溝通建構顯性勾結，而非在於執行策略。

(2)任何非法的線下行為策略，於線上施作也是依舊違法。企業必須確保其演算法不從事非法行為，例如，「釋放企圖訊息(signaling)」都是違法的，不論是發生於線下競爭者間的示意性溝通(signaled communication)，或者是發生於線上演算法間的編碼訊號(coded messages)。

(3)企業涉及非法競爭措施即受法律課責，並不能因是演算法自動行為所致而可免責。僱員、代理、或第三方，都是受一企業之指示或控制(direction or control)工作模式，而演算法也是處於這一企業的控制之下，故這企業必須為其僱用資產(訂價演算法)的行動負法律責任。

---

189 同前文. Autorité de la Concurrence and Bundeskartellamt (2016).

190 同前文 Vestager, M. (2017).

191 OECD (2017b), Directorate for financial and enterprise affairs competition committee, Algorithms and Collusion- note from the European Union, June 21-23. *See also*, Gosselin, S.S., Jones, A. and Martin, A. (2017), Are antitrust laws up to the task? A US/EU perspective on anti-competitive algorithm behavior, LEXOLOGY, August 10.

加拿大

競爭法當局認為，在技術持續增長之下，預期以技術進行反競爭協議或安排的可能性將會愈低，於是對於可能的演算法勾結等，既有的法律框架就足夠了。競爭機構認為： (1)大數據或許引進更效力與強力的方法，用來執行與管理卡特爾，但並不會因此而創生出新的行為模式；儘管牽涉到了更先進工具，但仍然植基於「協議」本身，也就是說，必須是企業間同意利用演算法來執行一個價格協議的。(2)儘管意識平行行為或默契勾結可能降低競爭，但此行為並不在違法卡特爾的範圍內，大數據並沒創造出新行為模式，而只是改變本來行為的程度，而且單方的監視與回應自競爭者收集而來的數據，是合法的，因此無需改變既有的法律框架。(3)在促進合謀的安排上，例如流通價格表列給對手、事先公告價格改變、採用相似的價格算法、參與包含競爭者的會議，都並非被禁止的。雖說如此，企業仍應保有警戒心，以確保其演算法運用不致於導致反競爭行為 。

英國

英國競爭與市場局(CMA)針對演算法勾結，增加採用了一些稍稍不同的衡量方法，但相較於傳統或公開形式之勾結，並無基本面上的不同[192]。原則上，儘管演算法被特別設計或使用來限制企業間競爭、或套取個別企業優勢地位，競爭法都適用於那些設計與採用演算法的個別企業。至於更為新穎如自學演算法，因未經確認勾結事項、也缺乏明確證明其出現的可能性及實質性，故不可鹵莽的對其採取排除性作為。CMA 自信的認為，「原則導向的 UK 競爭法架構(the principles-based UK competition law framework)」，具有充分彈性來納入演算法及其運用後的相關新穎競爭傷害。這樣的一個原則導向架構，可以取得更多訊息以便更佳理解一市場或一營運措施，然後再決定是否採用

[192] OECD (2017c), Directorate for financial and enterprise affairs competition committee, Algorithms and Collusion- note from the United Kingdom, May 30.

行動；可以對出現競爭或消費問題的市場，進行研究調查；也可以執行一系列民刑事消費保護法律、措施、與市場限制；同時可以採取禁止或補救預期可能導致的實質競爭減少的結合案。

2018 年 CMA 印行的全面經濟理論探討，結論發現[193]：(1)證據顯示，以演算法定價已經很普遍，尤其在線上平台。(2)雖然演算法已被用來進行個人裁訂的排序、廣告、及折價，但並無明顯證據顯示個人化訂價確實已被實施。(3)一些學界使用或參考用的模型指出，就算企業各自單方決定價格，但一些訂價演算法還是可能導致勾結結果的。然而，這些模型都是假設選擇訂價演算法是一個外生變數，因此，當勾結價格狀態出現，個別企業是否不會具誘因改採不同演算法(即背離合謀狀態)？例如削價，這些模型並未能給予解答。(4)演算法訂價較可能促成勾結的市場，通常是本來就已經很容易構成協同的市場，例如同質產品市場。

澳洲

澳洲目前採用「wait and see」策略對待演算法勾結的威脅[194]。2017 年 11 月澳洲競爭與消費委員會主席 Rod Sims 說，目前全球關於線上數據或訂價演算法的訟訴案例，都只是反應出現了「something more」，也就是全球並無真正演算法自學自動勾結的案例。

日本

日本於 2017 OECD Roundtables 中指出，數據匯集與利用可能促成企業間合謀，導致數位卡特爾，尤其當數家企業共享特定 AI 技術以決定最大利潤價格時，最終將使不同企業訂價趨於一致。若這類卡特爾顯著的限制競爭時，

---

193 同前文 Competition and Markets Authority (2018).

194 Sims, R. (2017), The ACCC's approach to colluding robots. Australian Competition and Consumer Commission, November 16. *See also*, Panichi, J., Seers, P. and Newman, M. (2017). Australia reckons it's ready to fight algorithmic collusion as world scrambles to review laws, MLEX, November 21.

將被以如同傳統卡特爾一般的予以處理[195]。

針對以上各國態度，我們整理成表 7.1，以利參閱。

表 7.1 各國基本態度

國家	基本態度
美國	(1) 現行反托拉斯法已提供必要工具來處理演算法促成的勾結，惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。 (2) 由於偵測演算法勾結很難，因此可以搭配寬恕政策及犯罪罰款，提供企業自我檢測與合作的誘因。
歐盟	(1) 對於演算法勾結則採取了較強烈的態度。 (2) 提出「一設計就遵守」途徑，課諸企業必須確保由設計端遵守反托拉斯法，且必須清楚一旦決定使用自動系統，就必須為演算法所為結果負責任。 (3) 僱員、代理、或第三方，都是受一企業之指示或控制工作模式，而演算法也是處於這一企業的控制之下，故這企業必須為其僱用資產(訂價演算法)的行動負法律責任。 (4) 任何非法的線下行為策略，於線上施作也是依舊違法。企業必須確保其演算法不從事非法行為
加拿大	(1) 對於可能的演算法勾結等，既有的法律框架就足夠了。 (2) 大數據或許引進更效力與強力的方法，但並不會因此而創生出新的行為模式，仍然是植基於企業企業間同意利用演算法來執行一個價格協議。 (3) 意識平行行為或默契勾，並不在違反卡特爾的範圍內；單方監視與回應自競爭者收集而來的數據，也是合法的，因此大數據並沒創造出新行為模式，而只是改變本來行為的程度，無需改變既有的法律框架。 (4) 促進合謀的安排，例如流通價格表列給對手、事先公告價格改變、採用相似的價格算法、參與包含競爭者的會議，都並非被禁止的。雖說如此，企業仍應保有警戒心，以確保其演算法運用不致於導致反競爭行為

[195] Japan Fair Trade Commission (2017). Report of study group on data and competition policy.

英國	(1) 儘管演算法被特別設計用來限制企業間競爭、或套取個別企業優勢地位，原則上，競爭法仍都適用。至於新穎的自學演算法，缺乏明確證明其出現的實質可能，故不可鹵莽的對其採取排除性作為。 (2) 目前仍無明顯證據顯示個人化訂價確實已被實施。 (3) 當勾結價格狀態出現，個別企業是否不會具誘因改採不同演算法(即背離合謀狀態)？學術研究或實際案例都仍未能給予解答。 (4) 演算法訂價較可能促成勾結的市場，通常是本來就已經很容易構成協同的市場。
澳洲	(1) 採用「wait and see」策略對待演算法勾結的威脅。 (2) 目前全球關於線上數據或訂價演算法的訟訴案例，都只是反應出現了「something more」而已。
日本	數據匯集利用與演算法可能促成企業間合謀，導致數位卡特爾，當若這類卡特爾顯著的限制競爭時，將被以如同傳統卡特爾一般的予以處理。

第二節 建議之因應策略

一如美國執法機關所秉持的態度，訂價演算法所涉及的競爭法議題，基本上當前競爭法架構足以應付，惟在調查與認定上，美國反托拉斯執法人員認為，凡涉及演算法的勾結案，都應依傳統法律標準進行分析。美國司法部反托拉斯署副助理檢察總長(Barry Nigro)報告時特別指出：「當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。」惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。由於偵測演算法勾結很難，因此可以搭配寬恕政策及犯罪罰款，提供企業自我檢測與合作的誘因。

因應訂價演算法所帶來的新型式競爭，綜合以上研究，本計畫整理並提出一些可行措施，供執法者予以及時留意與參考。

(一)區別人主體與智能體的角色

基於前一節的匯整論述可知，當前競爭法對於訂價演算法基底商業，執法上若可以掌握到廠商人主體通聯的證據、且於最終價格判斷為超競爭水平，則利用當前競爭法架構即可解決。但若無法掌握人主體顯然溝通證據，或者人主體於最終超競爭價格結果上僅扮演著小角色(甚或無角色)，則必須仰賴於對訂價演算法商業本身的偵測與試驗，同時得面對競爭法適用的爭議。

至於來自於智能體之間因互動探索而致高價和同行為，是否屬於競爭法中所謂的隱性合謀？雖然學習型演算法仍未完全運用於實務，而在其它類型演算法的程式設計上，已足以令演算法彼此間進行互動而致勾結。因此，執法者所需思考與調查的，不外乎是：

第一，是否具有人主體之間的顯性通聯證據？

第二，訂價演算機之編程是否可以找出「獎懲機制」的設計？

第三，若有，則在此編程設計上，人主體的知悉程度如何？

第四，若人主體事先不知其編程設計將實質形成獎懲機制，則討論智能體因此的合謀是否該適用競爭法？

第五，若人主體事先知悉其編程設計將實質形成獎懲機制，則以人主體作為適用競爭法對象。

事實上，偵測智能體之編程設計，仍是一大挑戰。

(二)發展測試與檢驗編程

在智能體的偵測上，一般化途徑有兩種類型，各取決於不同程度數據的有效性而定。第一，靜態檢定(static testing)，第二，動態檢定(dynamic testing)[196]。

[196] Harrington, Jr., J.E. (2018), Developing competition law for collusion by autonomous artificial agents. Journal of Competition Law & Economics 14 (3), 331–363.

靜態檢定方法

靜態檢定方法，是直接檢閱程式而不去執行。事實上，訂價演算法的合謀必然出現在優化模組上，因此只要針對其優化模組中的編程進行檢閱即可。

首先檢閱訂價演算法所運行的優化模組，其中是否包含有競爭者訂價的訊息？若無，則一定不會有合謀的疑慮；若有，則得進一步仔細審閱是否具有構成獎懲機制的編碼與選擇之對應。

然而若面臨到自學型演算法，則靜態檢定法就不易實施。深度學習機可以針對各個不同的可能訂價演算法，透過大量數據的試誤與實驗方式，於不同時點上被挖掘出更確實的評鑑績效值，於是不同訂價演算法在不同時點上績效排比會有變化，因此不同時點的最佳演算法並不一定固定。檢驗者欲於編程上尋跡追蹤，找出是否具有促成合謀之獎懲機制，非常之難，其實是不可得。事實上，其導致最終決策的特徵，是透過多重特徵的複雜計算而得，其編碼與抉擇之間的對應太過複雜，以致於無法理解、無法解釋、無法窺探，就像黑盒子一般。

深度學習領域中，還存在一個更困擾的問題，那就是，獎懲機制並不是構成合謀的必要條件。Cooper et al (2015)的研究發現，儘管其估計模組中未含對手價格資料，深度學習智能體也可以產生超競爭價格，這大大增添了檢驗上的困惑[197]。幸運的是，因為實務上，在每一時點對訂價法則進行評價的工作量非常龐大，深度學習型演算機於目前階段仍未能真正運作[198]。

不過，針對 *Q* 學習，靜態檢定或許可以稍稍派上用場。*Q* 學習會給予每一組「價格-市場條件(price-market condition)」組合一個價值(value)，在面對某一市場條件時，它會找出與其共構出最高價值的相對應價格；於是隨之產

[197] Cooper, W.L., Homen-de-Mello, T. and Kleywegt, A.J. (2015), Learning and pricing with models that do not explicitly incorporate competition. Operations Research 63, 86-103.

[198] 2015 年 Google 提出開放源演算法 TensorFlow 在全球獲得相當成功的商業價值，開源演算法市場於是成形，在這個開源體系中，企業可以從其資料庫中尋找合乎其數據與目的演算法模板，然後著手設計適合自我營業模式的演算法。

出績效、並更新「價格-市場條件」組合價值。一個訂價演算法會產生一組 *Q* 值，而智能體則在每一時點透過所有 *Q* 值進行學習。於是評估一個訂價演算法的特性，可透過其 *Q* 值的集合資料審閱，以判斷其是否具促成合謀功效而必須被禁止。實務上，所面臨到的問題，仍然是大數據之下，*Q* 值集合內容太過龐大，而不易審閱。

動態檢定方法

當靜態檢驗可能無法幫執法者進行有效評估訂價演算法時，可以考慮改採動態檢驗。這個方法比較像是模擬途徑，也就是，以大量的市場條件餵予該智能體，然後紀錄相對於各個市場條件輸入所產出的價格，從中觀察是否終於構成超競爭價格。

動態檢驗法有幾個個挑戰：第一，要得到擬真地步，我們必須餵以的輸入項(即市場條件)，可能需要非常大量。但在真實檢驗中，可能沒經費或無能力作到如此龐大，可能都只是作了其中的一部分而已。第二，智能體透過學習而可能隨時改變每一時點的訂價演算法，因此今天對其所做的測試檢驗，明天可能就不是它了；今年所用的資料，可能已是不同於去年的數據了[199]。第三，當檢驗出超競爭價格出現，但仍未知道是否具有獎懲機制時(尤其是學習型演算機)，能否遽下斷論？

(三)援引資訊技術與人才

不論前述檢驗或審閱，是多麼可行或多麼不可行，唯一可以肯定的是，在競爭法機構中，資訊專業是不可或缺的要角，而且隨著訂價演算法基底商業發展趨勢，愈發重要。為了執行漸增的分析與監控行動，競爭當局需要更多的資源(包含 know-how, tools, skilled staff, etc)，更多的人才與技術建置，甚

[199] 前述第一及第二點，請 Desai, D.R. and Kroll, J.A. (2018), Trust but verify: a guide to algorithms and the law. Harvard Journal of Law & Technology 31 (1), 1-64.

至與外部技術專家合作。

英國於 2014 年 12 月首先於「競爭與市場局(Competition and Market Authority, CMA)」的「卡特爾與犯罪群(Cartels and Criminal Group, CCG)」中聘任了首位「數位取證與情報(digital forensics and intelligence)」主任，負責發展 CMA 的數位取證與情報分析能力，並支援專案或計畫團隊，也徵募了許多相關的技術專家。其目的是要提升 CMA 對於數位證據的利用，提升對於結合、市場或管制產業的網路調查與運用，也將提升 CMA 推動競爭與消費者法律的能力[200]。透過這個資訊工程單位與專業人員的設置，提升網路調查取證、協助數位證據的取得與審察、引領自己部內科學取證能力。於是，在隨後的 CMA v. GB eye (2016)一案中，數位取證人員對 Trod 伺服器與安全數據輕易的取像，由此而確認 GB eye 所提呈的資料，終至於本案偵辦只用了不到 8 個月時間，相較往例大約的一年光陰，速度相當快。

美國發展亦復如此。FTC 因應行動裝置的興起，於 2010 年首設技術長(chief technologist)以協助擴展對此新趨勢的偵查能力；隨後網路隱私權受到嚴重挑戰，加上 2012 年面對其未能偵查起訴 Google 反競爭行為的許多能力質疑，終於在 2015 年三月於其消費者保護局(Bureau of Consumer Protection)內設立「技術研究與調查辦公室(BCP's Office of Technology Research and Investigation; OTRI)」[201]，聘任一位技術政策研究統籌人(Technology policy research coordinator)、許多具有 IT 背景的技術專家與電腦科學家、擴充其組織的內部專家與研究員，藉以發展全新的調查方法與偵測資訊技術[202]。

該統籌人任務在於負責監控 IT 發展趨勢、訂定 IT 研究日程、訓練檢查官與偵查員、鑑別新興技術所用之軟硬體設施。FTC 會指派研究員以提供技

[200] Aston, S. (2014), First director of digital forensics and intelligence appointed to CCG. Civil Service World, December 8.
[201] Peterson, A. (2015), The FTC beefs up technology investigations with new office. The Washington Post, March 23.
[202] Federal Trade Commission (2015), Press release of 23 March, BCP's Office of Technology Research and Investigation: The next generation in consumer protection.

術專業給檢察官及偵查員、鑑別與設計相關於消費者技術的研究、發展消費者保護新技術的研究。這辦公室的設立，緣於 FTC 認知，需要加強執法人員資源以跟上 IT 商業發展腳步。「這是 FTC 的自然演化。當技術更為複雜，而使所有事物與技術間起了正當或不正當使用的直接關聯，FTC 必須有能力針對組織行為對錯做出更佳判斷。」「若無清楚了解數據運用的基礎技術，FTC 將無能為力有效實現其目標；擁有更多技術專家人員，將使 FTC 能更佳評估是否廠商合理運用技術。」[203]

以台灣而言，最可行且最快速可推動的方式，應該是採用外部技術專家合作。歐盟 2017 年六月 27 日對 Google Search (shopping)判決之後，依法 Googel 必須於接受通知 90 天內停止案關行為，EC 為了能夠及時在如此短暫法定時間內執行監控 Google 確實遵守，特別透過其內部一個兩步驟快速採購法的規定，招標發包外部專業代為執行。其招標內容主旨有二，一者，建議關於監控 google 實現遵法的技術與經濟分析議題，二者，建議應付未來可能的聯合法庭無效訴訟及其它訴訟上，關於技術與經濟分析議題[204]。在組織擴充不易或人力調整緩慢的狀態下，採用委外發包方式，既可應付時間緊迫的要求，在監控上亦可靈活的隨時跟進市場技術發展腳步，不致落後。委託發包方式，亦可擴大至產業調查與產業資料及人才庫的建立，執法機關即可隨時觀測與掌握訂價演算法產業的趨勢與變動；面對議題時，亦可及時透過人才資料庫中，隨時諮詢或委託，可確實於法定緊迫時間中完成任務。

(四)採用演算法作為證據

競爭機關須著手建立並運用自有的演算法，進行偵測反競爭行為或提升結合潛在效應的經濟模型運算。執法中可要求廠商提供其演算法，藉以判定

[203] Higgins, J.K. (2015), FTC upgrades IT to protect consumer privacy data security. Ecommerce Times, April 8.
[204] European Commission (2017), Tender specifications COMP/2017/012.

廠商間的競爭態勢，是否視彼此為競爭者？是如何反應著對方的訂價改變？於結合審查時，還得就此審視參與者擁有的數據，若顯著數量是基於演算法所生，則執法者必須同時考慮該項交易中的非價格效應(non-price effect)，例如消費隱私權、品質、與創新等。

英國 CMA 建立一個技術團隊並宣稱，可以運用演算法來偵測卡特爾，並已經建立了一個卡特爾篩檢工具(cartel screening tool)，以幫助採購單位透過標單數據與內容篩檢出可能的卡特爾行為信號[205]。然而，比較標單具體內容以防止圍標而所萃取出的勾結特徵，只適合於競標場合，難以移作線上零售市場默契勾結的識別之用。

欲以演算法結果作為證據，最大的困難仍在於建立競爭機關資訊團隊的公信力，此證據才能取得法院信任。

(五)另闢結果導向途徑

數位世界增加了舉證矛盾(Paradox of Proof)，市場狀態使合作變得更加容易、同時使得證明明確協議變得更難，於是，危害變得更可能出現，而卻更難找到協議的證據推論。因此建議以「結果導向途徑(results-based approach)」，只要偵測到反競爭市場結果，儘管沒有證明出演算法設計的缺失、或主觀要素的出現(如知識或企圖)，當局就可以介入干預[206]。

(六)從設計端進行管理

對於所用的演算法，企業相關人員必須了解其目的、訊息追尋、與市場相關的各項功能，包含預測與決策能力；設計與熟悉演算法功能的員工們，必須了解哪些類型訊息具有競爭敏感性？而這類型訊息是否有透過演算法與

[205] 同前文 Competition and Markets Authority (2018).
[206] 同前文 Picht, P.G. and Loderer, G.T. (2018).

人分享？同時，法遵人員必須與這些人員密切合作。

對企業而言，任何員工、經理人、董事成員、或第三方，只要對於該企業的演算法具有任何一點控制或影響力(尤其是針對競爭敏感性訊息)，就必須適當的給予訓練，使其熟知競爭法所有的限制；也務必令其知悉且敏感到，當公司所採用的特定演算法或軟體平台，若同時也為競爭者使用中或即將使用時，其所可能產生對市場競爭的削弱或穩定作用。更謹慎的作法是，建議這些相關決策者，按時詳載採用這些工具之獨立且單方的決策過程；若是購買或評估使用第三方提供的軟體，則應禁止供應商透露相關銷售訊息(或其他敏感性訊息如對方如何運用這軟體)給自己或任何其它競爭廠商。

公司也可以進一步利用演算法來過濾與識別那些具觸犯競爭法風險高的個人，施予法遵訓練。也可利用演算法來監控內部活動，識別任何已達紅色警戒的行為，並立即予以消除，以發展健全的內部控制與治理程序。對於運行中的演算法，必須隨時監控並定期檢查與評估，以確保遵守法律。

一如歐洲競爭委員會主席 Margrethe Vestager 認為，企業能做且必須做的，就是確保由設計端遵守反托拉斯法，且必須清楚，一旦決定使用自動系統，就必須為演算法所為結果負責任，所以他們最好必須了解該系統如何運作。

(七)事先產業結構調查

面對訂價演算法的不可觀測性，一些傳統衡量方法或工具，對執法人員仍可持續有用，尤其當人類於勾結上扮演較重角色時，更可適用。

首先，市場調查與研究仍是不可免的基本手段。如果有跡象顯示市場運作不良，則執法者或許可以決定進行市場研究或產業調查，了解原因並尋找可能解法。若是涉及演算法基底的廠商，而且執法者已意識到，在該產業中訂價演算法扮演著重要角色，則應嚐試去確定這個產業的一些特徵：

是否已具有訂價演算法勾結相對容易發生的結構？

是否具有高度價格(或訂價)透明？

是否具有高度訂價可預測性？

是否是高頻交易的市場？

是否具有其它未被確認的結構特徵？

這可由市場研究(market studies)或產業詢查(sector inquiries)著手，藉以事先釐清該產業的市場特徵，有助於了解是否具有導致訂價演算法勾結的市場特徵。事實上，英國、冰島、及墨西哥這些國家，執法機關除了針對市場進行研究與查詢之外，還可進一步實施市場偵查(market investigation)，可以發布不具約束力的建議書、甚至提出結構或行為補救措施。

毫無疑問的，目前的線上零售業必是訂價演算法運用最為普遍的產業，其所累積的數據必然最豐富，若欲擇一著手，線上零售業時然是最佳的開始。

(八)事前結合控制審查

如果一錨定客群(targeted group of customers)因競爭減損而受害，其本身就足以構成阻止該結合交易的充分理由，一如 Judge Sullivan 在 FTC v. Staples 所提及：「反托拉斯法之存在正是在於於保護競爭，就算鎖定客群只占了整個涉及市場的很小一部分，亦然。」由於商業應用的演算法發展快速，愈來愈精密，可能產生許多細段化的族群消費者。然而在對結合審查時，執法人員必須偵測出可能很多的細段化客群市場，再逐一進行檢視各市場是否為錨定價差客群？是否受到結合傷害？這樣的工程相當浩大，於人力物力與技術上無法實行。於法上，再怎麼小的市場受到結合而傷害，執法機關都必須予以關注，但於實務上，在個人化價格惡化後，實在難以做到。慶幸的是，如英國產業調查所示：雖然演算法已被用來進行個人裁訂的排序、廣告、及折價，但並無明顯證據顯示個人化訂價確實已被實施。

(九)考慮先期補救措施

簡單利用一些監控、平行或信號式訂價演算法，都是可以有機會促成價格上的勾結行為，因此提早對高度可能產生訂價演算法勾結的產業與廠商進行警示，建立一個防止隱性勾結的先期補救措施。例如，歐美線上業者基於回應法院之要求，一旦他們(網主)被通知其網站上某些內容已涉及違法被訴時，則他們就必須應當立即予以下架該內容，即所謂「notice-and-take-down」流程。類似於這類型流程措施，若有廠商之訂價演算法已涉及違法而被初步偵測懷疑，則該廠商當被要求立即採用一些適當的回應行動。

雖也有一些聲音，建議引介或發展審核演算法機制，藉以確保被使用的訂價演算法編程，可以清楚的避開任何反競爭的疑慮。但是這將是不具效率的作法，因為，利益驅動的商業發展，總是無可避免的，其訂價演算法將永遠領先於審核檢視機制，後者終將無能為力檢視前者。而且，往往機制一經採用則是經年不變，而商業訂價演算法卻可能每週每月重編改令，規避機制審查相當容易。再者，訂價演算法的發展，委託主(人主體)的涉入愈來愈小，可能僅僅只是給予一個最大化公司利潤的指令，不涉及任何勾結編程，而代理者(智能體)的決行權則愈來愈大，不斷透過自我學習、且不斷更新作法，審核演算法的機制是無能為力去尋跡追蹤的。另外，商業訂價演算法亦可自網路上擷取公共訊息，成為決行的經驗與環境，造成動態訂價、時刻變動，都增添其高頻多變的過程。無法企及此等能力的審核檢視機制，將無濟於事。本計畫完全不讚同這樣的建議。

(十)或用顯失公平途徑

美國聯邦貿易法(FTC Act)第 5 條提到：「於商業營運中或企圖影響商業營運，使用不公平競爭手段(unfair methods of competition; UMC)、不公平或欺騙的行動安排，是違法的。」最高法院認為此條款延伸 Sherman Act 及其他反

托拉斯法規。長期來 FTC 以此權力處理了許多不同類型具反競爭效果的行為安排，包含廠商單向對競爭者傳遞「合謀邀約(invitations to collude)」、但無明顯「應約」證據的卡特爾或獨占企圖。於是，該條款被認為是可以被延伸運用至智能體間的合謀[207]。

FTC 第 5 條建構於廣泛性的基礎上，是「原則性的(principle-based)」而非「規定性的(rule-based)」；因國會並無製定詳細條目，也剛好提供 FTC 解決因應技術發展等實際問題的彈性空間。FTC 對此也一直沒有任何相關的明確定義或說明，直到 2015 年才終於對 UMC 做了一個簡易的指導原則：(1)委員會將遵行反托拉斯法的公共政策，亦即提升消費者福利；(2)委員會將依類似「合理原則」評估行動與措施，亦即，在考慮效率分析及商業理由後，會被委員會所挑戰的那些行動與措施，將必須是會或可能會導致傷害競爭或競爭過程者；(3)若 Sherman Act 或 Clayton Act 的執法已足以排除競爭傷害，則委員會不會對此行動或措施單獨以不公平競爭手段進行審視[208]。

由於現行法律標準，不合理的消費者傷害(unjustified consumer injury)是 FTC Act 最主要的關注點，FTC 也認為單由這點，即足可確認一措施是否具不公平性。於是，在指導原則下，FTC 檢驗一行為措施(例如演算法的運用)是否是不公平時，將依該措施所導致的消費者傷害是否符合三個要件：(1)是重大的 (2)是無法為該行為另於消費者或競爭帶來的利益所抵消的 (3)是消費者本身無法合理避開的[209]。可以說，凡一項措施或行為導致消費者重大傷害，或許並不涉及反托拉斯行為，但即可進入第 5 條不公平措施的檢視範圍圈了。

近十來年，FTC 利用第 5 條進行持續性的企業網路安全監管，並針對企業的錯誤資料安全與隱私陳述，依危及消費者個資而以第 5 條起訴者，超過

[207] 亦參見前文 Harrington, Jr., J.E. (2018).
[208] Federal Trade Commission (2015), Statement of enforcement principles regarding "Unfair Methods of Competition" Under Section 5 of the FTC Act, August 13.
[209] Federal Trade Commission (1980), FTC policy statement on unfairness. Appended to International Harvester Co., 104 F.T.C. 949, 1070 (1984).

60 個案子，這些被起訴者往往都未上法院，就談判尋求了和解[210]。唯一一個上法院請求撤銷該起訴的是 2012 年的 Wyndham Worldwide Corp.。該案中，FTC 的控訴指出，駭客曾於不同的三個時刻侵入 Wyndham 電腦網路，導致 60 萬消費者曝險、以及超過 1.06 千萬美元的錯誤收費，已相當程度的危害消費者[211]。一審法院駁回撤案提議，惟對於 FTC 是否於此案上有權限使用第 5 條，則允許上訴，而於上訴法院中判決 FTC 有權監管網路安全。案中 Wyndham 也主張，當企業本身亦是駭客攻擊的受害者時，它就不該被視為是不公平對待消費者；法院認為，當企業也是一犯罪行為的受害者時，並不能因此減低其對於「可預期的消費者傷害」的法律責任，或許第 1 次遭受攻擊是不可預期的，但隨後的第 2 次及第 3 次攻擊，則是屬於可預期的，其所造成的已是可預期消費者傷害。另外 Wyndham 亦提出，FTC 並未公告給予企業了解何種水平資料安全即會被視為是不公平方法交易措施；法院則認為，一企業一而再、再而三被駭，已說明該公司完全沒有防火牆與豈碼的安全裝置，而且 FTC 在許多的出版品或行政白皮書的宣傳，企業都該由此有所獲悉；而從這些宣傳品中，即可預期 Wyndham 並無法通過基本的成本效益分析。該案最終於 2015 年合解[212]。

於是基於「消費者受到重大傷害」的前提，則第 5 條也可運用於訂價演算法商業。近年美國的系列 Uber 案件中，例如 *Malden et al. v. Uber (2016), Desoto Cab v. Uber (2017)*及 *Philadelphia Taxi Association v. Uber (2016, 2017, 2018)*等，原告提訴通常包含獨占化、掠奪訂價、不公平競爭手段、以及違反相關管制法規等等多項理由，後都因舉證不足而敗訴。而在「不公平競爭手段」這一項上，或指稱 Uber 因規避管制而致優勢、或謂其低於成本經銷的不

[210] Denny, W.R. (2016), Cybersecurity as an unfair practice: FTC enforcement under Section 5 of the FTC Act, Business Law Today.
[211] Denny, W.R. (2016), Cybersecurity as an unfair practice: FTC enforcement under Section 5 of the FTC Act, Business Law Today.
[212] FTC v. Wyndham Worldwide Corp., 799 F. 3d 236 (3d Cir. 2015)

當、或稱獨占危險性加上募資能力將令競爭者大受其害，不一而足，但其實都是指涉 Uber 商業模式導致了消費者重大傷害；惟所有這些案件，原告卻都未能對此一重大傷害確實舉證，故不為法院所採信。南非計程車業者於 2015 年控訴 Uber，與美國案例類似，宣稱 Uber 以掠奪訂價企圖驅退競爭者、規避管制而氾濫入場、誤導大眾認為它創造工作機會，以致不公平競爭，亦為南非競爭機關駁回此案[213]。不過歐盟的結果，比較不同。西班牙巴塞隆納計程車組織 APET，於 2014 年控訴 Uber 未先通過政府管制條件即提供交通運輸服務，違反競爭法[214]，認為這使得 Uber 相對於其它計程車業者及駕駛人，具有了反競爭優勢，構成不公平行為；為此歐盟法院於 2017 年確認 Uber 乃交通運輸服務業者，當適用一般計程車管制法，於是不公平行為成立。另外，盧森堡競爭機構於 *Webtaxi (2018)*一案[215]，雖認為原告叫車 app 固定訂價模式違反競爭法，惟衡諸其所帶來的便利與空污減少，確實產生夠大的效率好處，而特別予以個別豁免。這些案例都清楚的顯示著，消費者福利是競爭法判斷中的一個核心。不論是採用怎樣的策略或措施，只要對消費者福利構成了重大傷害，則適用第 5 條「不公平競爭手段」的討論就可展開。

對於科技破壞式創新產業的崛起，自學訂價演算法所致合謀，不易識別釐清，偵辦上費時且困難，於是轉而分析「運用此一新科技的營利模式」，其所創造出來的市場動態性是否具有反競爭效果。首先，該營利模式是否導致消費者重大傷害；然後，確認該傷害是否無可合理避免；最後，分析該傷害是否無法為其它消費者利益或競爭利益所抵消。整個分析架構，不再針對各別行為策略，而是針對整個營利模式所進行的市場競爭衝擊分析；這或許是一個可用的途徑，尤其新科技的出世往往帶著一個不同的營利模式。Ezrachi

[213] SA Breaking News (2016), Uber beats anti-competitive claims, October 21.
[214] Case C-434/15, Asociación Professional Élite Taxi v. Uber Systems Spain SL ("Uber Spain"). 亦請參閱 The Guardian/World/Europe (20 Dec 2017).
[215] Ciannino, M. (2018), Webtaxi: the Luxembourg competition authority exempts an algorithmic price-fixing arrangement on efficiency grounds. CORE Blog, July 10.

and Stucke (2016)曾有相同的主張，認為：「解決智能體合謀問題，可以轉向於市場操作或不當手段(unfair practice)議題面向上；由原先聚焦廠商間存在的協議，轉而檢視因運用先進演算法而改造出一個有利於隱性合謀的既存市場條件(pre-existing market conditions)。在競爭法架構下，互相監看是合謀的必要條件，而我要檢視的則是，此一透過人工手段所創造的市場動態性，是否產生了反競爭的干預？」他們更進一步建議：「當執法機關可以提出證明，證明被告於運用演算法時，其動機在於獲得反競爭結果，或者已意識到其行為是自然而可能的產生反競爭後果，則第 5 條即可被適用於法辦訂價演算法合謀。」

「不公平競爭手段」即如我國「顯失公平行為」，規範於公平交易法第 25 條，其謂「除本法另有規定者外，事業亦不得為其他足以影響交易秩序之欺罔或顯失公平之行為」，亦或可提供一個參酌運用的方向。我國對於 Uber 的商業經營，公平交易委員會於避免介入經濟部相關職權之後，則以第 21 條「不實廣告」予以課罰 100 萬元[216]。公平會於該案指出，「本身即為未申請核準之行業、卻又公開推播徵募個人司機廣告，致使閱者誤認開自己的車、符合條件加入就可以合法提供服務，然卻與實際法令並不相符。宇博公司之於「Uber 司機資訊網」刊載此等內容廣告，無疑已涉及廣告不實之疑。」故裁決宇博違反公平法第 21 條第 1 項定「事業不得在商品或廣告上，或以其他使公眾得知之方法，對於與商品相關而足以影響交易決定之事項，為虛偽不實或引人錯誤之表示或表徵。」

Uber 不服，再提行政訴訟抗罰，台北高等行政法院則於 105 年 11 月判決，認定公平會裁罰有理。其判決書同時指出，該公司持續招募司機，除讓人誤認為合法之外，也由於增加司機加入的交易機會，將排擠其他計程客運業者的交易機會，致競爭同業蒙受損害，足以產生不公平競爭的效果。

[216] 臺北高等行政法院，105 年度訴字第 1159 號。

針對以上建議的因應策略，我們整理成表 7.2，以利參閱。

表 7.2 建議因應策略與執行方法

建議因應策略	執行步驟與方法
(一)區別人主體與智能體的角色	(1) 是否具有人主體之間的顯性通聯證據？ (2) 訂價演算機之編程是否可以找出「獎懲機制」的設計？ (3) 若有，則在此編程設計上，人主體的知悉程度如何？ (4) 若人主體事先不知其編程設計將實質形成獎懲機制，則討論智能體因此的合謀是否該適用競爭法？ (5) 若人主體事先知悉其編程設計將實質形成獎懲機制，則以人主體作為適用競爭法對象。
(二)發展測試與檢驗編程	靜態檢驗法： (1) 檢閱訂價演算法所運行的優化模組，其中是否包含有競爭者訂價的訊息？ (2) 若無，則一定不會有合謀的疑慮；若有，則得進一步仔細審閱是否具有構成獎懲機制的編碼與選擇之對應。 (留意的是，此法無法處理龐大資料或自學演算法) 動態檢驗法： 以大量的市場條件餵予該智能體，然後紀錄相對於各個市場條件輸入所產出的價格，從中觀察是否終於構成超競爭價格。 (留意的是，餵給的模擬資料永遠都會只是一部分，此刻檢驗結果不等於適用下一刻市場狀態。)
(三)援引資訊技術與人才	競爭當局需要更多的資源、更多資訊人才、與更多技術建置，甚至需與外部技術專家合作。尤其面對組織擴充不易，發包招標援引外部技術人才，容易實施且快速有效。

(四)採用演算法作為證據	(1) 建立與運用自有的訂價演算法,進行偵測反競爭行為或提升結合效應的經濟模型運算。 (2) 執法中要求廠商提供其演算法,藉以判定:是否視彼此為競爭者?是如何反應著對方的訂價改變? (3) 結合審查時,審視參與者擁有的數據,若顯著數量是基於演算法所生,則必須同時考慮該項交易中的非價格效應,例如消費隱私權、品質、與創新等。
(五)另闢結果導向途徑	只要偵測到反競爭的市場結果,則競爭機關即可介入干預。(儘管沒有證明出演算法邏輯設計、或主觀要素出現,如企圖)
(六)從設計端進行管理	(1) 要求企業,對於員工、經理人、董事成員、或第三方對該企業的演算法具有任何一點控制或影響力者,都必須施以競爭法規教育訓練。 (2) 務必令企業知悉且敏感到,當公司所採用的特定演算法或軟體平台,也同時為競爭者使用,其所可能產生的競爭法問題。 (3) 建議企業中相關決策者,按時詳載採用這些工具之獨立且單方的決策過程。 (4) 令企業知悉,購買或評估使用第三方提供的軟體,應禁止供應商透露相關銷售訊息給自己或任何其它競爭廠商。
(七)事先產業結構調查	對於訂價演算法基底商業,應事先調查產業特徵: (1) 是否已具有訂價演算法勾結相對容易發生的結構? (2) 是否具有高度價格(或訂價)透明? (3) 是否具有高度訂價可預測性? (4) 是否是高頻交易的市場? (5) 是否具有其它未被確認的結構特徵?
(八)事前結合控制審查	結合控制審查時,必須偵測出可能的細段化客群市場,再逐一進行檢視是否受到錨定價差?是否受到結合傷害?(此工程相當浩大,現實上難以實行。目前仍無明顯證據顯示個人化訂價確實已被實施。)
(九)考慮先期補救措施	若廠商之訂價演算法已涉及違法而被初步偵測懷疑,則該廠商當被要求立即採用一些適當的回應行動。

(十)或用顯失公平途徑	在偵測確實困難、也難以分析時，可依公平法第 25 條「。影響交易秩序之顯失公平行為」。一訂價演算法之運用構成上開行為，必須符合： (1) 導致消費者重大傷害 (2) 消費者無法合理規避該等行為 (3) 該傷害無法被該行為所致之消費者利益或競爭利益所抵消

第三節 本章結論

美國反托拉斯執法人員認為，凡涉及演算法的勾結案，都應依傳統法律標準進行分析。美國司法部反托拉斯署副助理檢察總長(Barry Nigro)報告時特別指出：「當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。」惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。由於偵測演算法勾結很難，因此可以搭配寬恕政策及犯罪罰款，提供企業自我檢測與合作的誘因。

最後一章，我們對競爭執法機關提出了一些建議。首先當務之急，應仿效國外競爭法機構，教育訓練執法人員對演算法邏輯的熟悉，並引進充分資訊人才，進行網路偵測、搜尋、監視、與比對，然後進一步發展測試與檢驗程式的定規模式，有計畫的採用演算法結果作為證據。

傳統上的產業結構調查仍然必須，對演算法普遍運用的產業，施予相關人員對訂價演算法適法學習與訓練，並對高度運用訂價演算法廠商提出警示。建立持續監視與偵測具高頻波動的單位，發展偵測編程中獎懲機制的偵察模式。也可以針對採用訂價演算的廠商，課以設計源頭管理之責，並宣導訂價演算法可能涉案樣態、以及寬恕政策及犯罪處罰，提供廠商自我檢測與合作的誘因。當然，結合審查時個人化訂價所產生細段化消費群，亦須發展出相對檢測或偵測能力，並輔以適當的補救措施；幸運的是，目前發展階段，真正的個人化訂價仍未實際商業運轉。

第八章 結論

歐盟競委員會主席 Margrethe Vestager (2017) 說到：「演算法自動決策的方法甚至可能侵蝕了我們的民主。近來，社交媒體已是新聞的重要來源… 於是社交媒體演算法的範疇內，創造了另一個實境(reality)，這是我們所擔憂的，因為它餵給人民一個接一個的故事，但卻是，都不是真的。」「自動機所創造的挑戰是真實存在的。如果他們幫助廠商固定價格，他們就真實的使我們整個經濟體運作得更差… 至於競爭執法者，我們必須很清楚的表達，廠商們不能隱藏在電腦編程後面而規避了所有勾結的責任。」「沒有人可以認為使用軟體為他們達成協議，就可免於固定價格的責任。」「卡特爾都面臨著成員開始欺騙的風險。若每一廠都訂高價，則你就可透過減價來攫取大量客戶，因此卡特爾的續存，依賴於他廠能夠多快觀察到這一削價、並以自己也低價來進行報復。能快速做到如此，就可確保他廠沒有太大誘因削價。麻煩的是，自動化訂價系統剛好可以很快的做好這事。」

以大數據為基礎的現代商業經營模式，自動的訂價演算法對交易者進行追踪、預測與影響，甚至協助交易者決行策略；具有快速收集競爭者數據，並於瞬息之間決策與執行反應。於是，企業經營與競爭成本大幅降低、市場呈現高度透明化，完全改變傳統的市場競爭結構。

訂價演算法的普遍，屬線上平台交易為最。證據顯示，Amazon 中的許多賣家已經開始使用自己的訂價演算法，Amazon (平台業者)自身也供給簡單訂價演算法，而第三方廠商也開始推出販售更精密的訂價演算法，甚至直接接受委託而為零售業者做電腦訂價事宜之決行。2018 年 2 月 5 日美股突然產生爆炸性下跌，被認為導因於多數金融公司使用機器演算法執行複雜交易指令所致，據估計，S&P 500 指數交易中，大約有 50%以上已是由機器演算法來完成決行。由於人類投資者一般對於殖利率上升至某一關鍵幅度時就會觸動拋售股票而轉進債市的概念，也都如實的編製進入機器演算法運行。於是，

所有機器演算法快速且同時的偵測出逼近觸發點，隨即不約而同的快速決定拋售股票與買進債券，導致股票市場容易呈現大起大落的現象。

機器演算法接收輸入項(input)並衡諸當前狀態(state)，瞬息間決定回應行動。在市場競爭中，人類的角色開始弱化。於是，競爭法之適用，必須因應的予以檢視。機器演算法該如何在競爭法中被看待？其所產生的競爭行為該如何被規範？更核心的，「無人不能自行」，訂價演算法與人類之間千絲萬縷的關係，在競爭法上該如何予以角色定位？這都是數位時代中，競爭法主管機關所必須面對的新課題。亦是本計畫所關注的對象。

本計畫第二章首先介紹訂價演算法的意義與表達及其演算基本邏輯，對於輸入、產出、與狀態等演算法的基本元素與運行，做了詳細說明，以利執法人員由此進入演算法的世界。目前學習型訂價演算法正開始發展，本章亦對於其四種分類進行詳細介紹，包括督導式學習、無督導式學習、半督導式學習、及強化式學習。事實上，無督導式學習的結果若被人類發現有誤而予以糾正，此時智能體即成為督導式學習。例如郵件演算法自動篩檢垃圾郵件，一旦我們發現錯誤而從垃圾桶中拉回該郵件，演算法隨即獲取該類型不是垃圾標籤的識別，亦是半督導式學習。在實際應用中，最為廣泛的，當屬強化式學習中的 Q 學習，於是我們以不透過電腦編程的模式，由一步一步手算過程中，一窺訂價演算法 Q 學習的運行邏輯，務必令執法人員完全熟識演算法的運作模式。關於與演算法高度相關的特徵工程與推薦系統，我們亦做了一些介紹。這是一個全面而簡易的運作邏輯盤點，基本上這是執法人員面對平台經濟，該具有的基本知識裝備。

第三章探討訂價演算法對市場結構及廠商行為所產生的可能改變、以及它可能被用為合謀工具的樣態。因為訂價演算法之運用，廠商數目與市場供需波動，已不太會衝擊合謀形成或維持；而另一方面則使得廠商參進變得容易、但立足障礙則變得更高，導致網路市場泡沫小廠眾多，而整個市場幾乎集中於少數具有巨大規模的廠商。其結果，導致了市場失靈。一方面，訂價

變動頻率變大且歧異性高，消費者不易察覺價格波動情形；二方面，網路市場強烈的外部性，使得廠商必須同時兼具規模效率與範疇效率，方足以穩定立足，加大了參進阻礙；而個人化裁製，則導致訊息、知識、或其它項目的推播偏頗與集中於消費者原本偏好或信任者。

然而，運用訂價演算法的廠商，效率是增加的，更精良的配置效率、更準確的估計環境(尤其是需求)、更有效與快速的尋找最佳化價格、更迅速的對市場變動進行價格調整、更細段化客戶特徵進行個人化訂價。這讓廠商在價格與利潤關係、以及價格與市場狀態關係的動態最適評比，獲得快速而有效率的訂定。訂價演算法也使異質化的可能性變大，創新與成本差異可以提供新廠參進的利基，同時也使隱性合謀變得相對不容易。

訂價演算法改變了市場環境，從而改變了合謀的可能條件。其之協助廠商合謀，依功能模式而言，OECD 將其分類為監控演算法、平行演算法、信號演算法、與自學演算法等四種；若依運算進化度分類，Ezrachi and Stucke 則將其分為信使、軸輻、可預期代理、與數位眼等四個類別。

訂價演算法改變了市場環境結構，從而改變了合謀出現的條件。第四章針對新型訂價演算法在合謀條件上的影響，作出一番分析。合謀是一種一致性行為，在當前法例上仍需具備人為溝通作為證據。然而寡占的決策互依性必然使得價格競爭的市場，呈現價格同向變動的趨勢，於是同時提價可能是競爭結構的必然，這使得與刻意一致行為的提價，常常不易互相區別開來，這即是所謂的寡占問題。若非結構必然的提價行動，必然是「有所企圖」的提價，在經濟分析中，我們已經發覺這個企圖正是企望對手了解我企圖而願意共同提價。企圖信號的發放，可以透過逐期價格策略的刻意變動、也可以藉以價格策略以外的資訊。前者，建立於「對手跟進提價則享長期高價的合作利潤、不跟進就只能有長期低價的競爭利潤」，亦即一個獎勵與處罰機制的制約；後者則建構於額外非策略變數的作為，釋放合作企圖，但仍需內建一獎懲機制，才能迫誘對手願意配合提價。

毫無疑問，獎懲機制是合謀的必要條件。然而，雖然透過經濟分析上，我們已經足以確認當前高價是緣於一套獎懲機制，或者已足以確認，除非競爭者透過一套獎懲機制策略，否則無以獲致目前超競爭價格局面；但如同前述，獎懲機制是競爭過程中不斷的系列策略行動，本身是策略變數，並無策略本身以外的任何訊息通聯，因此不屬於法院所欲之額外因素證明。因此，仍需尋找此套機制曾被形諸文字、面談、溝通或各形式洩露的實質因素，才能將其認證。目前訂價演算法涉及的合謀案例，仍都是以人為溝通協調為主角、再輔以訂價演算法的操作，例 Meyer v. Kalanick (2016)、U.S. v. Topkins (2016)、CMA v. GB eye (2016)、U.S. v. Aston (2015)等。更進一步的學習型演算法合謀，則仍只存在於學術研究中特定設定的模擬，並未實務運作過。

第五章專論訂價演算法非合作策略的涉法可能。一廠商在增進自己利潤原則下，其訂價策略對競爭者產生不合理侵略，或因此而削弱整個市場的競爭狀態，這樣的單方訂價行為就會疑涉違反競爭法，尤其當一廠市占份額夠大時，其單方策略更易產生前述涉法後果。傳統上這些單方行為樣態，例如維持轉售價格、最優惠條款、掠奪訂價、差別訂價、意圖獨占等，在訂價演算法基底商業上，獲得更佳的施作環境。可以說，對於廠商而言，訂價演算法等同於是加強其洞察市場競爭與他廠訂價行為的神器，於是廠商足以快速了解市場狀態與競爭對手價格變動，然後快速調整自己價格以為因應。也因此，許多傳統反競爭的行為，在運用訂價演算法之後，仍然不改其反競爭、而且容易發生，但以既有競爭法架構仍是足以充分處理的。對廠商而言，神器在手，一不小心而誤蹈法網的機會變大，任何廠商對其所僱用的訂價演算法，應該謹慎留意，以免觸法。而偵辦實務上，了解訂價演算法必須成為執法者的基本素養。

例如 Asus、Denon & Marantz、Philips、Pioneer 四家家電製造商，被歐委會判決其線上零售產品採用維持轉售價格，致傷害市場競爭而違法，此案演算法充當了對下游價格的監控。另外，Booking.com 等線上旅遊平台業者，對

旅宿供應者訂定費率等同條款，足以讓市場價格維持於一個相對較高的地板，傷害市場競爭；在被歐委員進行調查後，表態自動撤除。Uber 在美國許多地方被提起控訴，其中理由都包含 Uber 虧本掠奪、企圖獨占、或濫用市場地位的宣稱，惟目前法院針對此一新興商業模式，仍未判決 Uber 違反競爭法。而個人化訂價亦進行消費者的細化區段，一個個特殊偏好的小族群構成一個小市場，雖然平時各小區段市場獲得了個人化偏好的餵養，但也引起了兩個問題，其一，個人化價格提高時，消費者將無以得知或比較他人被供給的價格；其二，在廠商結合時，某些小族群消費者可能會陷入被高度壟斷的風險。前者，目前實證與產業調查上，仍未發現已被商業運用，而後者，則增添了結合審查時的莫大困難，競爭機關必須留意這個可能性。

第六章則針對訂價演算法於競爭法適用問題進行探討，鎖定當前最受聚焦的合謀議題。人主體與智能體構成一個僱傭模型，涉案時執重執輕，受機器學習的先進與否所決定。比較低階的演算法，多數由人主體在合謀中扮演吃重角色，依既有法律標準架構，尋找人主體具體合謀證據，是可行辦法。但高階訂價演算法中，以智能體扮演合謀重角，此時欲尋找出具體證據顯然較難，於是對於編程偵測與檢驗，成為競爭機關必須盡速培養的能力。訂價演算法參與合謀的型式，有多種可能樣態，例如，仰賴人為合謀的監看型演算法、共用相同資料數據的訂價演算法、使用相同訂價演算法的廠商、委託第三方之訂價演算法代為決行、可預期的訂價演算機制、信號式的訂價演算機制、自學型訂價演算法。

傳統促成合謀的運作，不外乎兩個步驟(或關鍵)，其一，借助不屬於競爭策略變數的額外訊息進行溝通，其二，一套兼含棍棒與蘿蔔的獎懲機制設計。不過，訂價演算法自動機卻可只運用競爭策略變數一併完成這兩個關鍵。一旦超競爭價格是起因於策略本身互動，完全不假外求，則除非真能依按電腦編程尋跡追索出其中暗藏的棍棒蘿蔔，否則只能視之為合法的意識平行行為。就算偵測或檢驗出可能暗藏的獎懲機制，也無法推定那是設計者或廠商有所

意識到的、或是本為其原始意圖，於是很難據此認定廠商違法。訂價演算程式足以讓廠商維持於超競爭價格與利潤，但可不藉用任何協議或溝通，擴大了不法的明顯勾結與合法的平行意識行為間的灰色地帶。例如，某些必須透過明顯通訊來達成的勾結，運用訂價演算程式之後，一個全新而自動機制被創造出來，藉此完成與執行共同政策並監視廠商彼此行為，這過程不須任何人為互動。換句話說，訂價演算程式充分的讓廠商隱性協同(tacit coordination)，而不須運作任何顯性合謀手段。

在自學演算法普及之前，訂價演算法所涉及的競爭法議題，基本上當前競爭法架構是足以應付的；當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。

最後，第七章，我們對於競爭法機關提出了建議。依美國反托拉斯執法人員之認為，凡涉及演算法的勾結案，都應依傳統法律標準進行分析。惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。首先當務之急，應仿效國外競爭法機構，教育訓練執法人員對演算法邏輯的熟悉，並引進充分資訊人才，進行網路偵測、搜尋、監視、與比對，然後進一步發展測試與檢驗程式的定規模式，有計畫的採用演算法結果作為證據。建立持續監視與偵測具高頻波動的單位，發展偵測編程中獎懲機制的偵察模式。也可以針對採用訂價演算的廠商，課以設計源頭管理之責，並宣導訂價演算法可能涉案樣態、以及寬恕政策及犯罪處罰，提供廠商自我檢測與合作的誘因。而更銳利的工具當是「結果導向」與「就源法遵」，前者只要看到訂價演算法商業市場出現超競爭水平價格，則執法者即可介入干涉演算法運作；後者則令使用演算法的廠商清楚，從一啟動購買或設計設階段時，就負起了該演算法未來可能衍生的所有競爭法問題。本文極力主張這兩個執法途徑。另外搭配公平法第 25 條「顯失公平」規範，凡一項措施或行為導致消費者重大傷害，儘管並未涉及反托拉斯，即可進入本條「顯失公平」的檢視範圍圈。

傳統上的產業結構調查仍然必須，對演算法普遍運用的產業，施予相關人員對訂價演算法適法學習與訓練，並對高度運用訂價演算法廠商提出警示。當然，結合審查時個人化訂價所產生細段化消費群，亦須發展出相對檢測或偵測能力，並輔以適當的補救措施；幸運的是，目前發展階段，真正的個人化訂價仍未實際商業運轉。

本計畫詳實且廣泛，期望這一議題的概念與作法，足以提供競爭法主管機關之參用。

附錄 馬可夫過程與貝爾曼方程

馬可夫決策的獎勵過程(Markov Reward Process)，其特色是，同一個當下狀態會有相同反應與報酬；其決策基礎是由四個項目所組成：有限狀態集(S)、狀態轉換機率分布(P)、獎勵函數(r)、及折現因子(γ)。狀態轉換機率分布是描寫由當下(t 期)狀態 s 更新至所有可能狀態 s'的一個矩陣，可以寫作：$P_{ss'} = P[S_{t+1} = s' \mid S_t = s]$。獎勵函數則是描寫當下($t$ 期)狀態形成後(s)、隨即產生的一個報酬(r_{t+1})，寫作：$r_s = \mathrm{E}[r_{t+1} \mid S_t = s\ ]$。當進入某個狀態，將隨即生成相應獎勵，在一般文獻的呈現上，都是以當下進入的狀態為 t 期、而隨即產生的獎勵為 t+1 期(故亦常以預期 E 形式表現)；但亦有一些經濟學者偏好把隨即產生的獎勵置於 t 期，例如於本文所呈現者。不論何者，只要敘述中保持著一致性，都無問題。

在計算依狀態而決定價值的長期預期價值時，我們常用貝爾曼方程式(Bellman Equation)來計算，其基本形式為：

t 期之長期預期價值(Vaule)
= 第 t+1 期之立即報酬(inmmediate reward)
+ 隨後期別狀態之預期折現長期價值(discounted value of successor state)

在計算長期價值時，假若未來每一期都是可事先觀測的，則一賽局之總所得即為每一期立即報酬之折現值總和，記作：$G_t = r_{t+1} + \delta r_{t+2} + \delta^2 r_{t+3} + \ldots$ 其中δ為折現因子。

馬可夫決策的特色是，價值只與當下 state 相關，於是，我們可以符號 $V(S_t)$ 來表示站在當下狀態所預測的未來長期利潤；因為每一期可觀測，故 $V(S_t)= G_t$。假若每一期 state 並非可事先觀測，於是形成不確定性，我們只能透過一些規則進行合理預期，因此當下預期的長期所得價值(折現)，可以記作：$V(S_t)$

$= \mathrm{E}[G_t \mid S_t] = \mathrm{E}[r_{t+1} + \delta r_{t+2} + \delta^2 r_{t+3} + \ldots \mid S_t]$ 。在文獻上，為了表示第 t 期已是出現的某一特定狀態 s，我們時常表達為 $S_t = s$，於是：

$$
\begin{aligned}
V(s) &= \mathrm{E}[G_t \mid S_t = s] \\
&= \mathrm{E}[r_{t+1} + \delta r_{t+2} + \delta^2 r_{t+3} + \ldots \mid S_t = s] \\
&= \mathrm{E}[r_{t+1} + \delta(r_{t+2} + \delta r_{t+3} + \delta^2 r_{t+4} + \ldots \mid S_t = s] \\
&= \mathrm{E}[r_{t+1} + \delta G_{t+1} \mid S_t = s] \\
&= \mathrm{E}[r_{t+1} + \delta \mathrm{E}(G_{t+1}) \mid S_t = s] \\
&= \mathrm{E}[r_{t+1} + \delta V(S_{t+1}) \mid S_t = s]
\end{aligned}
$$

由於相同的 state 則會選擇相同的行動、同時會產生相同的獎勵，因此當第 t 期 state 確定為 s 時，則預期總價值就可表達為 $V(s)$，而當時立時出現的獎勵 r_{t+1}，亦可記為 r_s，表徵此期 state 為 s。如果 S 為有限狀態集，而 s'則為其中的任一可能狀態，$s' \in S$。則前述數學最後一式亦可表達為：

$$V(s) = \mathrm{E}[r_{t+1} + \delta V(S_{t+1}) \mid S_t = s]] = r_s + \delta \sum_{s' \in S} P_{ss'} v(s')$$

其中，$P_{ss'}$代表由狀態 s 而於下一期更新為某一狀能 s'的轉換機率值(函數)，所以$\sum_{s' \in S} P_{ss'} v(s')$是一個機率權重期望值，而$\delta$是折現因子。

參考文獻

中文資料

公平交易委員會處分書，公處字第 105065 號。

陳和全(2011)，管理經濟與策略。指南出版社。

臺北高等行政法院，105 年度訴字第 1159 號。

Books & Articles

A.I. Wiki. A beginner's guide to deep reinforcement learning. https://skymind.ai/wiki/deep-reinforcement-learning

Agrawal, A. and Jaiswal, D. (2012). When machine learning meets AI and game theory. CS 229 Machine Learning Final Project. http://cs229.stanford.edu/proj2012/AgrawalJaiswal-WhenMachineLearningMeetsAIandGameTheory.pdf.

Alexander, C. (1979). The timeless way of building. Oxford University Press.

Angwin, J. and Larson, J. (2015). The Tiger mom tax: Asians are nearly twice as likely to get a higher price from Princeton Review. ProPublica, September 1. https://www.propublica.org/article/asians-nearly-twice-as-likely-to-get-higher-price-from-princeton-review

Autorité de la Concurrence and Bundeskartellamt (2016). Competition law and data. www.bundeskartellamt.de/SharedDocs/Publikation/DE/Berichte/Big%20Data%20Papier.pdf?__blob=publ.

Axelrod, R. (1984). The evolution of co-operation. Basic Books Inc., New York.

Ballard, D.I. and Naik, A.S. (2017). Algorithms, artificial intelligence, and joint conduct. CPI Antitrust Chronicle (May 201&), 1-6. https://www.competitionpolicyinternational.com/wp-content/uploads/2017/05/CPI-Ballard-Naik.pdf

Ban, G.Y. and Keskin, N.B. (2017). Personalized dynamic pricing with machine learning. ArXiv working paper, DOI:10.2139/ssrn.2972985.

Banicevic, A., Kohlmeier, G.Z.A., Pechersky, D. and Howlett, A. (2018). Algorithms challenges and Opportunities for Antitrust compliance. ABA-SAL Compliance and Ethics Committee Spotlight.

Baracas, S. and Selbst, A.D. (2016). Big data's disparate impact. 104 California Law Review 671. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2477899

Bulow, J, Geanakoplos, J. and Klemperer, K. (1985). Multimarket oligopoly: strategic substitutes and strategic complements. Journal of Political Economy 93, 488-511. https://www.jstor.org/stable/1832005

Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019a). Artificial intelligence, algorithmic pricing and collusion. SSRN working paper.

Calvano, E., Calzolari, G., Denicolò, V. and Pastorello, S. (2019b). Algorithmic pricing: what implications for competition policy? Review of Industrial Organization 55 (1), 155-171. https://doi.org/10.1007/s11151-019-09689-3

Camrer, C. and Ho, T-H. (1999). Expected-weighted attraction learning in normal form games. Econometrica 67 (4), 827-874.

Capobianco, A. and Gonzaga, P. (2017). Algorithms and competition: friends or foes? CPI Antitrust Chronicle (August), 1-5.

Chen, L., Mislove, A. and Wilson, C. (2016). An empirical analysis of algorithmic pricing on Amazon marketplace, in Proceedings of the 25th International Conference on World Wide Web, 1339-1349. www.ccs.neu.edu/home/amislove/publications/Amazon-WWW.pdf.

Competition and Markets Authority (2016). Online seller admits breaking competition law. Press release of GOV.UK (21 July). https://www.gov.uk/government/news/online-seller-admits-breaking-competition-law

Competition and Markets Authority (2018). Pricing algorithms: Economic working paper on the use of algorithms to facilitate collusion and personalized pricing.

Cooper, W.L., Homen-de-Mello, T. and Kleywegt, A.J. (2015). Learning and pricing with models that do not explicitly incorporate competition. Operations Research 63, 86-103.

Cormen, T.H., Leiserson, C.E., Rivest, R.L. and Stein, C. (2009). Introduction to Algorithms, 3rd ed..

Datta, A. and Tschantz, M.C. (2015). Automated experiments on Ad privacy settings. Proceedings on Privacy Enhancing Technologies 2015 (1), 92-112.

Den Boer, A.V. and Zwart, B. (2015). Dynamic pricing and learning with finite inventories. Operations Research 63(4), 965-978. https://doi.org/10.1287/opre.2015.1397

Deng, A. (2017). When machines learn to collude: lessons from a recent research

study on artificial intelligence. SSRN working paper.

Deng, A. (2018). An antitrust lawyer's guide to machine learning. Antitrust 33 (2), 82-87.

Denny, W.R. (2016). Cybersecurity as an unfair practice: FTC enforcement under Section 5 of the FTC Act. Business Law Today: June 2016 (ABA Groups).

Desai, D.R. and Kroll, J.A. (2018). Trust but verify: a guide to algorithms and the law. Harvard Journal of Law & Technology 31 (1), 1-64.

Diakopoulos, N. (2015). Algorithmic accountability. Digital Journalism 3 (3), 398-415. DOI: 10.1080/21670811.2014.976411

Diakopoulous, N. (2014). Algorithmic accountability reporting: on the investigation of black boxes. Tow Center for Digital Journalism: Columbia University.

DOJ (2019). Statement of Assistant Attorney General Makan Delrahim before the U.S. Senate subcommittee on Antitrust, Competition Policy and Consumer Rights, "Oversight of the Enforcement of the Antitrust Laws", September 17. https://www.justice.gov/opa/speech/statement-assistant-attorney-general-makan-delrahim-us-senate-subcommittee-antitrust

Edelmann, B. and Luca, M. (2014). Digital discrimination: the case of Airbnb.com. Harvard Business School, Working Paper 14-054.

European Commission (2016). Summary of decision of 7 July, relating to a proceeding under Article 101 of the Treaty on the Functioning of the European Union and Article 53 of the EEA Agreement (Case AT.39850-Container Shipping. https://eur-lex.europa.eu/legal-content/EN/TXT/PDF/?uri=CELEX:52016XC0906(01)&from=EN

European Commission (2017). European Commission (2017), Tender specifications COMP/2017/012. file:///D:/Admin/%E4%B8%8B%E8%BC%89/EN-Tender+specifications_002%20(2).pdf

Evans, D.H. (2018). Webtaxi: a wrong decision on "algorithmic pricing fixing". Competition Law & Economics, August 9. https://www.oncompetitionpolicy.com/2018/08/webtaxi-a-wrong-decision-on-algorithmic-price-fixing/

Ezrachi, A. and Stucke, M.E. (2016). Virtual competition: the promise and perils of the algorithm-driven economy. Harvard University Press.

Ezrachi, A. and Stucke, M.E. (2017a). Algorithmic collusion: problems and counter-measures. OECD Background Paper, roundtable on algorithms and collusion, DAF/COMP/WD (2017) 25.

Ezrachi, A. and Stucke, M.E. (2017b). Artificial intelligence and collusion: when computers inhibit competition. University of Illinois Review 2017, 1775-1810. https://illinoislawreview.org/wp-content/uploads/2017/10/Ezrachi-Stucke.pdf

Federal Trade Commission (2015). Statement of enforcement principles regarding "Unfair Methods of Competition" Under Section 5 of the FTC Act, August 13. https://www.ftc.gov/system/files/documents/public_statements/735201/150813section5enforcement.pdf

Federal Trade Commission (1980). FTC policy statement on unfairness. Appended to International Harvester Co., 104 F.T.C. 949, 1070 (1984). https://www.ftc.gov/public-statements/1980/12/ftc-policy-statement-unfairness

Gal, M.S. (2017a). Algorithmic-facilitated coordination: market and legal solutions. CPI Antitrust Chronicle (May 2017), 22-28.

Gal, M.S. (2017b). Algorithmic-facilitated Coordination. OECD background paper, roundtable on algorithms and collusion, DAF/COMP/WD (2017) 26.

Gal, M.S. and Elkin-Koren, N. (2017). Algorithmic consumers. Harvard Journal of Law & Technology 30 (2), 309-353.

Ghuman, P. (2017). Analysis of competition cases against Uber across the globe. CUTS International. http://www.cuts-ccier.org/pdf/Analysis_of_Competition_Cases_Against_Uber_Across_the_Globe.pdf

Gibbs, S. (2016). UK's Streetmap loses anticompetitive search abuse case against Google. The Guardian, February 12. https://www.theguardian.com/technology/2016/feb/12/streetmap-loses-google-anticompetitive-search-abuse-case

Gosselin, S.S., Jones, A. and Martin, A. (2017). Are antitrust laws up to the task? A US/EU perspective on anti-competitive algorithm behavior, LEXOLOGY, August 10. https://www.lexology.com/library/detail.aspx?g=8210db07-cff3-4e1d-85e2-28542b18ba0d

Green, E.J. and Porter, R.H. (1984). Noncooperative collusion under imperfect price information. Econometrica 52 (1), 87-100.

Hanaki, N., Sethi, R., Erev, I. and Peterhansl, A. (2005). Learning strategies. Journal of Economic Behavior & Organization 56 (4), 523-542.

Harrington, Jr., J.E. (2018). Developing competition law for collusion by autonomous artificial agents. Journal of Competition Law & Economics 14 (3), 331–363. https://doi.org/10.1093/joclec/nhy016

Hassan, S. (2006). Optimal timing of defections from price-setting cartels in volatile markets. Economic Modelling 23, 792–804.

Henderson, P., Crouch, S., Walters, R.J. and Q. Ni (2003). Comparison of some negotiation algorithms using a tournament-based approach. In J. G. Carbonell, J. Siekmann, R. Kowalczyk, J. P. Müller, H. Tianfield and R. Unland (Eds.), Agent Technologies, Infrastructures, Tools, and Applications for E-Services, Lecture Notes in Computer Science, Vol. 2592, Springer, Berlin, Heidelberg. https://eprints.soton.ac.uk/257426/

Hingston, P. and Kendall, G. (2004). Learning versus evolution in iterated prisoner's dilemma. In Proceedings of the Congress on Evolutionary Computation (CEC'04). http://www.cs.nott.ac.uk/~pszgxk/papers/cec2004ph.pdf.

Japan Fair Trade Commission (2017). Report of study group on data and competition policy. https://www.jftc.go.jp/en/pressreleases/yearly-2017/June/170606_files/170606-4.pdf

Javanmard, A. and Nazerzadeh H. (2016). Dynamic pricing in high-dimensions. Arxiv.org, Cornell University working paper.

Kaplow, L. (2011). On the meaning of horizontal agreements in competition law. California Law Review 99 (3), 683-818. https://www.jstor.org/stable/23014697?seq=1 - page_scan_tab_contents.

Khan, L.M. (2016). Amazon's Antitrust Paradox. The Yale Law Journal 126 (3), 710-805.

Klein, T. (2018). Assessing autonomous algorithmic collusion: Q-learning under short-run price commitments. Tinbergen Institute Discussion Paper, No. TI 2018-056/VII

Kreps, D. and Scheinkmam, J. (1983). Quantity pre-commitment and Bertrand competition yield Cournot outcomes. Bell Journal of Economics 14, 326-337.

Lam, A. (2018). What can TensorFlow really do? Some business applications. Oursky Blog (February 14). https://blog.oursky.com/2018/02/14/tensorflow-business-applications-ai-hong-kong/

Levitan, R. and Shubik, M. (1972). Price duopoly and capacity constraints. International Economic Review 3 (1), 111-122.

Love, J. (2015). Technology is out of your control and why you should celebrate. IT World Canada: www.itworldcanada.com/article/technology-is-out-of-your-control-and-why-you-should-celebrate/377563.

Lowrie, I. (2018). Algorithms and automation: an introduction. Cultural Anthropology 33 (3), 349-359.

https://journal.culanth.org/index.php/ca/article/view/ca33.3.01/84

Maskin, E. and Tirole, J. (1988). A theory of dynamic oligopoly II: price competition, kinked demand curves and Edgeworth cycles. Econometrica 56(3), 571-599

McSweeny, T. and O'Dea, B. (2017). The implications of algorithmic pricing for coordinated effects analysis and price discrimination markets in antitrust enforcement. Antitrust 32 (1), 75-81.

Mehra, S.K. (2016a). US v. Topkins: can price fixing be based on algorithms? Journal of European Competition Law & Practice 7 (7), 470–474.

Mehra, S.K. (2016b). Antitrust and the robo-seller: competition in the time of algorithms. Minnesota Law Review 100, 1323-1375. https://www.minnesotalawreview.org/wp-content/uploads/2016/04/Mehra_ONLINEPDF1.pdf

Ciannino, M. (2018). Webtaxi: the Luxembourg competition authority exempts an algorithmic price-fixing arrangement on efficiency grounds. CORE Blog, July 10. https://coreblog.lexxion.eu/webtaxi-the-luxembourg-competition-authority-exempts-an-algorithmic-price-fixing-arrangement-on-efficiency-grounds/

Mnemosyne Studio. Q-learning: step-by-step tutorial. http://mnemstudio.org/path-finding-q-learning-tutorial.htm

Nambiar, M., Simchi-Levi, D. and Wang, H. (2018). Dynamic learning and pricing with model misspecification. SSRN working paper.

OECD (2013). Policy roundtables: Ex officio cartel investigations and the use of screens to detect cartels. http://www.oecd.org/daf/competition/exofficio-cartel-investigation-2013.pdf

OECD (2015). Roundtable on competition enforcement in oligopolistic markets. https://one.oecd.org/document/DAF/COMP(2015)2/en/pdf.

OECD (2016). Big data: bringing competition policy to the digital era. https://one.oecd.org/document/DAF/COMP(2016)14/en/pdf.

OECD (2017a). Algorithms and collusion: competition policy in the digital age.

OECD (2017b). Directorate for financial and enterprise affairs competition committee, Algorithms and Collusion- note from the European Union, June 21-23. https://one.oecd.org/document/DAF/COMP/WD(2017)12/en/pdf

OECD (2017c). Directorate for financial and enterprise affairs competition committee, Algorithms and Collusion- note from the United Kingdom, May 30. https://one.oecd.org/document/DAF/COMP/WD(2017)19/en/pdf

Okuliar, A. and Kamenir, E. (2017). Pricing algorithms: conscious parallelism or

conscious commitment? CPI Competition Policy International (July 2017), https://www.competitionpolicyinternational.com/pricing-algorithms-conscious-parallelism-or-conscious-commitment/

Owen, T. (2015). The violence of algorithms: the crisis of the state in the digital age. DOI: 10.1093/acprof:oso/9780199363865.003.0008.

Page, W.H. (2007). Communication and concerted action. Loyola University Chicago Law Journal 38, 405-460.

Panichi, J., Seers, P. and Newman, M. (2017). Australia reckons it's ready to fight algorithmic collusion as world scrambles to review laws, MLEX, November 21. https://mlexmarketinsight.com/insights-center/editors-picks/antitrust/cross-jurisdiction/australia-reckons-its-ready-to-fight-algorithmic-collusion-as-world-scrambles-to-review-laws.

Passaro, N (2018). Uber has an antitrust litigation problem, not an antitrust problem. CPI Antitrust Chronicle, May: 38-42.

Picht, P.G. and Loderer, G.T. (2018). Framing algorithms-competition law and (other) regulatory tools. Max Planck Institute for Innovation and Competition Research Paper No. 18-24.

Qiang, S. and Bayati, M. (2016). Dynamic pricing with demand covariates. SSRN working paper.

Rotemberg, J.J. and Saloner, G. (1986). A supergame-theoretic model of price wars during booms. The American Economic Review 76 (3), 390-407.

Rubinstein, A. (1986). Finite automata play the repeated prisoner's dilemma. Journal of Economic Theory 39, 83-96.

Salcedo, B. (2016). Pricing algorithms and tacit collusion. Manuscript, Pennsylvania State University.

Sanadhya, A. Feature engineering: a closer look. Retention Science; https://www.retentionscience.com/blog/feature-engineering-a-closer-look-part-1-rs-labs/

Saurwein, F., Just, N. and Latzer, M. (2015). Governance of algorithms: options and limitations. info 17 (6), 35-49. https://ssrn.com/abstract=2710400.

Shakya, S., Kern, M., Owusu, G. and Chin, C.M. (2012). Neural network demand models and evolutionary optimizers for dynamic pricing. Knowledge-Based Systems 29, 44-53.

Sims, R. (2017). The ACCC's approach to colluding robots. Australian Competition and Consumer Commission, November 16. https://www.accc.gov.au/speech/the-accc's-approach-to-colluding-robots;

Stack Overflow. What's the difference between reinforcement learning, deep

learning, and deep reinforcement learning? https://stackoverflow.com/questions/50542818/whats-the-difference-between-reinforcement-learning-deep-learning-and-deep-re

Stone, B. (2013). The everything store: Jeff Bezos and the age of amazon. Amazon.com, 239-297.

Stucke, M.E. and Ezrachi, A. (2017). Two artificial neural networks meet in an online hub and change the future (of competition, market dynamics and society). Legal Studies Research Paper Series, the University of Tennessee.

Sunstein, C. (2009). Republic.com 2.0, PUP, Princeton, NJ.

Suslow, V.Y. (2001). Cartel contract duration: empirical evidence from international cartels. Working Paper, University of Michigan Business School.

Sutter, J. D. (2011). Amazon seller lists book at $23,698,655.93 – plus shipping. CNN, April 25. http://www.cnn.com/2011/TECH/web/04/25/amazon.price.algorithm/

Sutton, R.S. and Barto, A.G. (1998). Reinforcement learning: an introduction. MIT Press.

Thomas, K. (2018). Building a reinforcement learning A.I. for the iterated prisoner's dilemma using Soar cognitive architecture. Master Thesis, National and Kapodistrian University of Athens. https://pergamos.lib.uoa.gr/uoa/dl/frontend/file/lib/default/data/2778307/theFile

Vestager, M. (2017). Algorithms and competition, speech at the Bundeskartellamt 18th Conference on Competition, Berlin, March 16. https://ec.europa.eu/commission/commissioners/2014-2019/vestager/announcements/bundeskartellamt-18th-conference-competition-berlin-16-march-2017_en.

Viscusi, W. K., Harrington, Jr., J.E. and Vernon, J.M. (2005). Economics of Regulation and Antitrust, 4th Edition, Cambridge, Mass.: The MIT Press.

Waltman, L. and Kaymak, U. (2009). Q-learning agents in a Cournot oligopoly model. Journal of Economic Dynamics & Control 32, 3275-3293.

Whish, R. and Bailey, D. (2012). Competition law. Oxford university press. https://books.google.co.in/books?id=9QDhoLiRX-MC&printsec=frontcover&source=gbs_ge_summary_r&cad=0#v=onepage&q&f=false.

Wilson, R.A. and Keil, F.C. eds. (1999). The MIT Encyclopedia of the Cognitive Sciences (1999), MIT Press.

Cases

A White and Yellow Cab, Inc., No. 4:15-cv-05163, Doc. 114 at 14 (N.D. Cal. Mar. 5, 2018).

ACF Chemiefarma NV v Commission of the European Communities Case 41-69 (Judgment of the Court of 15 July 1970).

Aircraft Cheque Services et al. v. Verizon Wireless et al., No. 14-2301 (7th Cir. 2015).

Am. Tobacco Co. v. United States, 328 U.S. 781, 809–10 (1946), at 810.

American Tobacco Co. v. United States 328 U.S. 781, 809-10 (1946)

Ariekat v. Uber Technologies, Inc., CGC-17-557728 (Cal. Sup. Ct. Mar. 24, 2017).

Bayer AG v Commission of the European Communities (Judgment of the Court of First Instance of 26 October 2000).

Bundeskartellamt (2018). Press Release of 29 May. Lufthansa tickets 25-30 per cent more expensive after Air Berlin insolvency–"Price increase does not justify initiation of abuse proceeding". https://www.bundeskartellamt.de/SharedDocs/Meldung/EN/Pressemitteilungen/2018/29_05_2018_Lufthansa.html;jsessionid=1A8D22E0F52CCB06EEBABE068F36CB66.2_cid371?nn=3591568.

Case C-434/15, Asociación Profesional Élite Taxi v. Uber Systems Spain SL ("Uber Spain") ◦

Case T-41/96, Bayer AG v Commission, [2000] ECR II-3383, para 173.

Competition and Markets Authority (2016). Decision of Online sales of posters and frames, case 50223, 12 August 2016. https://assets.publishing.service.gov.uk/media/57ee7c2740f0b606dc000018/case-50223-final-non-confidential-infringement-decision.pdf

Competition Policy International (2015). France: Google wins court decision vs Evermaps, November 29. https://www.competitionpolicyinternational.com/france-google-wins-court-decision-vs-evermaps

Desoto Cab Company, Inc. v. Uber Technologies, Inc. et al., 2017 U.S. Dist. No.C 16-06385 WHA (January 10, 2017).

DOJ (2015). News of April 6: Former E-commerce executive charged with price fixing in the antitrust division's first online marketplace prosecution.https://www.justice.gov/opa/pr/former-e-commerce-executive-charged-price-fixing-antitrust-divisions-first-online-marketplace

DOJ (2016). News of August 11: Online retailer pleads guilty for fixing prices of wall posters: second defendant to plead guilty in ongoing investigation. https://www.justice.gov/opa/pr/online-retailer-pleads-guilty-fixing-prices-wall-posters

DOJ (2017). News of January 10: Three Former Traders for Major Banks Indicted in Foreign Currency Exchange Antitrust Conspiracy. https://www.justice.gov/opa/pr/three-former-traders-major-banks-indicted-foreign-currency-exchange-antitrust-conspiracy

ECJ, 10 April 2018, Case C-320/16, Uber France SAS v. Nabil Bensalem

ECJ, Case C-320/16, Uber France SAS v. Nabil Bensalem (10 April 2018).

ECJ, Case C-434/15, Asociación Profesional Élite Taxi v. Uber Systems Spain SL ("Uber Spain")

ECJ's Judgment in Case C-74/14, Eturas (on the scope of concerted practices and on technological collusion), January 26, 2016.

European Commission (2016). Press release of 16 February. Antitrust: Commission seeks feedback on commitments offered by container liner shipping companies. https://europa.eu/rapid/press-release_IP-16-317_en.htm

European Commission (2017). Commission decision of 27 June 2017 in Case 38606 - AT.39740 Google Search (Shopping).

European Commission (2018). Press release of July 24, Antitrust: Commission fines four consumer electronics manufacturers for fixing online resale prices. http://europa.eu/rapid/press-release_IP-18-4601_en.htm.

European Commission (2018). Statement by Commissioner Vestager on Commission decision to impose fines on four consumer electronics manufacturers for fixing online resale prices, July 24. https://europa.eu/newsroom/content/statement-commissioner-vestager-commission-decision-impose-fines-four-consumer-electronics_en; file:///D:/Admin/%E4%B8%8B%E8%BC%89/STATEMENT-18-4665_EN%20(1).pdf

Federal Trade Commission (2011). Letters and Statements: Amazon.com, Inc. / Quidsi, Inc., March 23. https://www.ftc.gov/enforcement/cases-proceedings/closing-letters/amazoncom-inc-quidsi-inc

Federal Trade Commission (2015). Press release of 23 March, BCP's Office of Technology Research and Investigation: The next generation in consumer protection. https://www.ftc.gov/news-events/blogs/business-blog/2015/03/bcps-office-technology-research-investigation-next.%202015?page=27

Friendly Cab Company, Inc. v. Uber Technologies, Inc., RG-17-858247 (Cal. Sup. Ct. April 27, 2017).

FTC v. Wyndham Worldwide Corp., 799 F. 3d 236 (3d Cir. 2015)

In Re High Fructose Corn Syrup Antitrust Litigation Appeal of A & W Bottling Inc. et al., United States Court of Appeals, Seventh Circuit, 295 F3d 651 (2002).

Interstate Circuit Inc v United States, 306 US 208, 810 (1939)

Malden Transportation, Inc. v. Uber Technologies, Inc., 2017 U.S. Dist. LEXIS 213023 (D. Mass. 2017).

Meru Travel Solutions Private Limited v. Uber India Systems Private Limited, Case No. 96 of 2015. http://www.cci.gov.in/sites/default/files/26(2)_96%20of%202015.pdf

Meyer v. Uber, No. 1:2015-cv-09796-JSR, Doc. 37 at 22-23 (S.D.N.Y. Mar. 31, 2016).

Miadeco Corp. v. Uber Technologies, Inc., No. 1:15-cv20356, Doc. 120 (S.D. Fla. Mar. 30, 2017)

Monsanto Co. v. Spray- Rite Serv. Corp., 465 U.S. 752, 768 (1984); In re Flat Glass, 385 F.3d at 357.

Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 218 F. Supp. 3d 389 (E.D. Pa. 2016)

Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 2017 WL 551593 (E.D. Pa. Mar. 20, 2017).

Philadelphia Taxi Association, Inc. v. Uber Technologies, Inc., 2018 WL 1474373 (3rd Cir. Mar. 27, 2018).

Securities and Exchange Commission (2014). Administrative Proceeding File No. 3-16199. In the Matter of Athena Capital Research, LLC.

Standard Oil Co. v. United States 221 U.S. 1 (1911)

Statement of Enforcement Principles Regarding "Unfair Methods of Competition Under Section 5 of the FTC Act" (August 13, 2015)

The Guardian/World/Europe (20 Dec 2017).

Toys "R" Us, Inc. v. FTC, 221 F.3d 928 (7th Cir. 2000).

U.S. v. Arline Tariff Publishing Company, Civil Action No. 92-2854 (1992).

U.S. v. Daniel William Aston et al, 2015 U.S. Dist. No. Case3:15-cr-00419-WHO (Aug 27, 2015). https://www.justice.gov/atr/file/840016/download

U.S. v. David Topkins, 2015 U.S. Dist. No. Case3:15-cr-00201-WHO (April 6, 2015)

U.S. v. Omnipoint Corp., In the U.S. District Court for the District of Columbia, Civil Action No.1:98CV02750, Competitive Impact Statement, November 10, 1998; pp. 6-7)

U.S. v. Omnipoint Corp., In the U.S. District Court for the District of Columbia, Civil Action No.1:98CV02750, Competitive Impact Statement, November 10, 1998; pp. 6-7)

United States District Court Northern District of California Case No. 15-cv-05163-JSW (N.D. Cal. Mar. 31, 2017)

United States v. Airline Tariff Publishing Co., 1994-2 Trade Cas. (CCH) ¶70,687 (D.D.C. Aug. 10, 1994).

United States v. Apple, Inc., 791 F.3d 290 (2d Cir. 2015)

United States v. Suntar Roofing, Inc., 897 F.2d 469, 474 (10th Cir. 1990)

News/Magazines

Aston, S. (2014). First director of digital forensics and intelligence appointed to CCG. Civil Service World, December 8. https://www.civilserviceworld.com/articles/news/first-director-digital-forensics-and-intelligence-appointed-ccg

BBC NEWS (2018). Did robot algorithms trigger market plunge? February 6. https://www.bbc.com/news/business-42959755

Campbell, L. (2013). Amazon to drop Marketplace price parity, The Bookseller, news of August 29. https://www.thebookseller.com/news/amazon-drop-marketplace-price-parity

CCN BUSINESS/Business (2018). Dow plunges 666 points -- worst day since Brexit, February 2. https://money.cnn.com/2018/02/02/investing/stock-market-today-dow/index.html

Crocker, M. (2014). OTA pricing tactics show value of traditional travel agencies, November 11. https://www.travelmarketreport.com/articles/OTA-Pricing-Tactics-Show-Value-of-Traditional-Travel-Agencies

Higgins, J.K. (2015). FTC upgrades IT to protect consumer privacy data security. Ecommerce Times, April 8. https://www.ecommercetimes.com/story/81916.html

Lawrance, S. and Linsner, M. (2017). Eturas-Any conclusions on platform collusion..? Kluwer Competition Law Blog, January 19.

http://competitionlawblog.kluwercompetitionlaw.com/2017/01/19/eturas-conclusions-platform-collusion/

Leber, J. (2016). Algorithmic pricing is creating an arms race on Amazon's marketplace, June 14. https://www.fastcompany.com/3060803/algorithmic-pricing-is-creating-an-arms-race-on-amazons-marketplace

May, K. (2015). Booking.com makes changes to rate parity clauses in Europe, Phocus Wire, news of April 21. https://www.phocuswire.com/Booking-com-makes-changes-to-rate-parity-clauses-in-Europe.

McDermid, R. (2016). Uber fares cover less than half of ride costs: new report says. San Francisco Business Times, December 2. https://www.bizjournals.com/sanjose/news/2016/12/02/uber-fares-cover-less-than-half-of-ride-costs-new.html?ana=twt

Mehta, N., Detroja, P. and Agashe, A. (2018). Amazon changes prices on its products about every 10 minutes—here's how and why they do it, August 10. https://www.businessinsider.com/amazon-price-changes-2018-8

Morris, D. (2018). DOJ Antitrust Division suffers another trial setback in forex-rigging case, Lexology, October 26. https://www.lexology.com/library/detail.aspx?g=2c488834-fa43-498a-b703-8c42aedb509b

Morris, H. (2018). Airlines are starting to price their seats based on your personal information – but is it legal? The Telegraph, February 27. https://www.telegraph.co.uk/travel/news/dynamic-fare-pricing-airline-ticket-personalisation/

OTAINSIGHT (2019). The decline of rate parity clauses and what this means for hotels, Blog of April 11. https://www.otainsight.com/resources/blog/the-decline-of-rate-parity-clauses-and-what-this-means-for-hotels

Peterson, A. (2015). The FTC beefs up technology investigations with new office. The Washington Post, March 23. https://www.washingtonpost.com/news/the-switch/wp/2015/03/23/the-ftc-beefs-up-technology-investigations-with-new-office/?noredirect=on&utm_term=.d19999e010ab

SA Breaking News (2016). Uber beats anti-competitive claims, October 21. https://www.sabreakingnews.co.za/2016/10/21/uber-beats-anti-competitive-claims/

Said, C. (2016). Flywheel taxi sues Uber for antitrust violations. SFGATE, November 2.https://www.sfgate.com/business/article/Flywheel-Taxi-sues-Uber-for-antitrust-violations-10488784.php

Savage, C. (2012). Wells Fargo will settle mortgage bias charges, The New York

Times, July.

Statement by Commissioner Vestager on Commission decision to impose fines on four consumer electronics manufacturers for fixing online resale prices, Brussels, 24 July 2018.

The Guardian/World/Europe (2017). Uber to face stricter EU regulation after ECJ rules it is transport firm, December 20. https://www.theguardian.com/technology/2017/dec/20/uber-european-court-of-justice-ruling-barcelona-taxi-drivers-ecj-eu

The Local (2019), French court reaches 'landmark decision' against Uber over drivers' rights, January 11. https://www.thelocal.fr/20190111/french-court-reaches-landmark-decision-against-uber-over-drivers-rights

The Register/Business/Policy (2016). EU court to determine how Uber's business should be defined, December 2. https://www.theregister.co.uk/2016/12/02/eu_court_to_determine_how_uber s_business_should_be_defined/

Tricker, M and Rogers, S. (2016). Online retailers should tread carefully after Trod. Digital Business Lawyer, October, 3. https://www.nortonrosefulbright.com/en/knowledge/publications/7e7bdcca/online-retailers-should-tread-carefully-after-trod

Valentino-DeVries, J. and Singer-Vine, J. (2012). Websites vary prices, deals based on users' information. The Wall Street Journal, December 24. https://www.wsj.com/articles/SB10001424127887323777204578189391813881534

摘　要

關鍵詞：訂價演算法、機器學習、寡占問題、額外因素證明、單方行為、合謀、獎懲機制

以大數據為基礎的現代商業經營模式，自動的訂價演算法對交易者進行追踪、預測與影響，甚至協助交易者決行策略；具有快速收集競爭者數據，並於瞬息之間決策與執行反應。於是，企業經營與競爭成本大幅降低、市場呈現高度透明化，完全改變傳統的市場競爭結構。

訂價演算法的普遍，屬線上平台交易為最。證據顯示，Amazon 中的許多賣家已經開始使用自己的訂價演算法，Amazon (平台業者)自身也供給簡單訂價演算法，而第三方廠商也開始推出販售更精密的訂價演算法，甚至直接接受委託而為零售業者做電腦訂價事宜之決行。機器演算法接收輸入項(input)並衡諸當前狀態(state)，瞬息間決定回應行動。在市場競爭中，人類的角色開始弱化。2018 年 2 月 5 日美股突然產生爆炸性下跌，被認為導因於多數金融公司使用機器演算法執行複雜交易指令所致，據估計，S&P 500 指數交易中，大約有 50%以上已是由機器演算法來完成決行。

於是，競爭法之適用，必須因應的予以檢視。機器演算法該如何在競爭法中被看待？其所產生的競爭行為該如何被規範？更核心的，「無人不能自行」，訂價演算法與人類之間千絲萬縷的關係，在競爭法上該如何予以角色定位？這都是數位時代中，競爭法主管機關所必須面對的新課題。亦是本計畫所關注的對象。

本計畫第二章首先介紹訂價演算法的意義與表達及其演算基本邏輯，對於輸入、產出、與狀態等演算法的基本元素與運行，做了詳細說明，以利執法人員由此進入演算法的世界。目前學習型訂價演算法正開始發展，一般可分為督導式學習、無督導式學習、半督導式學習、及強化式學習。在實際應

用中最為廣泛的，當屬強化式學習中的 Q 學習，於是我們以不透過電腦編程的模式，由一步步手算過程中，一窺訂價演算法 Q 學習的運行邏輯，務必令執法人員完全熟識演算法的運作模式。這是執法人員面對平台經濟，該具有的基本知識裝備。

第三章探討訂價演算法對市場結構及廠商行為所產生的可能改變、以及它可能被用為合謀工具的樣態。因為訂價演算法之運用，廠商數目與市場供需波動，已不太會衝擊合謀形成或維持；而另一方面則使得廠商參進變得容易、但立足障礙則變得更高，導致網路市場泡沫小廠眾多，而整個市場幾乎集中於少數具有巨大規模的廠商。然而，運用訂價演算法的廠商，效率是增加的，更精良的配置效率、更準確的估計環境(尤其是需求)、更有效與快速的尋找最佳化價格、更迅速的對市場變動進行價格調整、更細段化客戶特徵進行個人化訂價。這讓廠商在價格與利潤關係、以及價格與市場狀態關係的動態最適評比，獲得快速而有效率的訂定。訂價演算法也使異質化的可能性變大，創新與成本差異可以提供新廠參進的利基，同時也使隱性合謀變得相對不容易。

訂價演算法改變了市場環境，從而改變了合謀的可能條件。其之協助廠商合謀，依功能模式而言，OECD 將其分類為監控演算法、平行演算法、信號演算法、與自學演算法等四種；若依運算進化度分類，Ezrachi and Stucke 則將其分為信使、軸輻、可預期代理、與數位眼等四個類別。

第四章探討合謀條件的變化。訂價演算法改變了市場環境結構，從而改變了合謀出現的條件。合謀是一種一致性行為，在當前法例上仍需具備人為溝通作為證據。然而同時提價可能是競爭結構的必然，而與刻意一致行為的提價，常常不易互相區別開來，這即是所謂的寡占問題。毫無疑問，獎懲機制是合謀的必要條件。然而，雖然透過經濟分析上，我們已經足以確認當前高價是緣於一套獎懲機制，或者已足以確認，除非競爭者透過一套獎懲機制策略，否則無以獲致目前超競爭價格局面；但如同前述，獎懲機制是競爭過

程中不斷的系列策略行動，本身是策略變數，並無策略本身以外的任何訊息通聯，因此不屬於法院所欲之額外因素證明。因此，仍需尋找此套機制曾被形諸文字、面談、溝通或各形式洩露的實質因素，才能將其認證。目前訂價演算法涉及的合謀案例，仍都是以人為溝通協調為主角、再輔以訂價演算法的操作，例 Meyer v. Kalanick (2016)、U.S. v. Topkins (2016)、CMA v. GB eye (2016)、U.S. v. Aston (2015)等。更進一步的學習型演算法合謀，則仍只存在於學術研究中特定設定的模擬，並未實務運作過。

第五章專論訂價演算法非合作策略的涉法可能。一廠商在增進自己利潤原則下，其訂價策略對競爭者產生不合理侵略，或因此而削弱整個市場的競爭狀態，這樣的單方訂價行為就會疑涉違反競爭法，尤其當一廠市占份額夠大時，其單方策略更易產生前述涉法後果。傳統上這些單方行為樣態，例如維持轉售價格、最優惠條款、掠奪訂價、差別訂價、意圖獨占等，在訂價演算法基底商業上，獲得更佳的施作環境。任何廠商對其所僱用的訂價演算法，應該謹慎留意，以免觸法。而偵辦實務上，了解訂價演算法必須成為執法者的基本素養。

例如 Asus、Denon & Marantz、Philips、Pioneer 四家家電製造商，被歐委會判決其線上零售產品採用維持轉售價格，致傷害市場競爭而違法，此案演算法充當了對下游價格的監控。另外，Booking.com 等線上旅遊平台業者，對旅宿供應者訂定費率等同條款，足以讓市場價格維持於一個相對較高的地板，傷害市場競爭；在被歐委員進行調查後，表態自動撤除。Uber 在美國許多地方被提起控訴，其中理由都包含 Uber 虧本掠奪、企圖獨占、或濫用市場地位的宣稱，惟目前法院針對此一新興商業模式，仍未判決 Uber 違反競爭法。而個人化訂價亦進行消費者的細化區段，一個個特殊偏好的小族群構成一個小市場，在廠商結合時可能會陷入被高度壟斷的風險。

第六章則針對訂價演算法於競爭法適用問題進行探討，鎖定當前最受聚焦的合謀議題。人主體與智能體構成一個僱傭模型，涉案時執重執輕，受機

器學習的先進與否所決定。比較低階的演算法，多數由人主體在合謀中扮演吃重角色，依既有法律標準架構，尋找人主體具體合謀證據，是可行辦法。但高階訂價演算法中，以智能體扮演合謀重角，此時欲尋找出具體證據顯然較難，於是對於編程偵測與檢驗，成為競爭機關必須盡速培養的能力。訂價演算法參與合謀的型式，有多種可能樣態，例如，仰賴人為合謀的監看型演算法、共用相同資料數據的訂價演算法、使用相同訂價演算法的廠商、委託第三方之訂價演算法代為決行、可預期的訂價演算機制、信號式的訂價演算機制、自學型訂價演算法。

傳統促成合謀的運作，不外乎兩個步驟(或關鍵)，其一，借助不屬於競爭策略變數的額外訊息進行溝通，其二，一套兼含棍棒與蘿蔔的獎懲機制設計。不過，訂價演算法自動機卻可只運用競爭策略變數一併完成這兩個關鍵。一旦超競爭價格是起因於策略本身互動，完全不假外求，則除非真能依按電腦編程尋跡追索出其中暗藏的棍棒蘿蔔，否則只能視之為合法的意識平行行為。就算偵測或檢驗出可能暗藏的獎懲機制，也無法推定那是設計者或廠商有所意識到的、或是本為其原始意圖，於是很難據此認定廠商違法。訂價演算程式足以讓廠商維持於超競爭價格與利潤，但可不藉用任何協議或溝通，擴大了不法的明顯勾結與合法的平行意識行為間的灰色地帶。

在自學演算法普及之前，訂價演算法所涉及的競爭法議題，基本上當前競爭法架構是足以應付的；當分析行為是否構成勾結時，分析者必須拿掉演算法牽涉其中的這一事實。

最後，第七章，我們對於競爭法機關提出了建議。依美國反托拉斯執法人員之認為，凡涉及演算法的勾結案，都應依傳統法律標準進行分析。惟不可忽視的，演算法的運用確實使得確認勾結行為時變得更為艱難，因此執法人員需要具有更新的調查技術。

首先當務之急，應仿效國外競爭法機構，教育訓練執法人員對演算法邏輯的熟悉，並引進充分資訊人才，進行網路偵測、搜尋、監視、與比對，然

後進一步發展測試與檢驗程式的定規模式，有計畫的採用演算法結果作為證據。建立持續監視與偵測具高頻波動的單位，發展偵測編程中獎懲機制的偵察模式。也可以針對採用訂價演算的廠商，課以設計源頭管理之責，並宣導訂價演算法可能涉案樣態、以及寬恕政策及犯罪處罰，提供廠商自我檢測與合作的誘因。

傳統上的產業結構調查仍然必須，對演算法普遍運用的產業，施予相關人員對訂價演算法適法學習與訓練，並對高度運用訂價演算法廠商提出警示。當然，結合審查時個人化訂價所產生細段化消費群，亦須發展出相對檢測或偵測能力，並輔以適當的補救措施；幸運的是，目前發展階段，真正的個人化訂價仍未實際商業運轉。

ABSTRACT

Key Words：Pricing algorithm, machine learning, oligopoly problem, plus factors, unilateral practice, tacit collusion, reward and punishment mechanism

Pricing algorithms are very common, especially for online platform trading. Evidence shows that many sellers in Amazon have already used their own pricing algorithms, while Amazon itself (or other platform operators) provides some simple pricing rules for sellers. In response to this trend, some third-party vendors have also begun to sell more sophisticated pricing algorithms to retailers, and even directly accept commissions to make retail pricing for retailers. Therefore, the application of the competition law must be examined in response to it. How should machine algorithms be viewed in competition law? How should the competitive behavior generated by it be regulated? More importantly, how can the pricing algorithms and human beings be inextricably linked, and how should they be positioned in the competition law? These are all new issues that the competition authorities must face in the digital era.

The machine algorithm receives the input, values the current state, and determines the response action in an instant. Thus, in the market competition, the roles of human beings began to be weakened. On February 5, 2018, US stocks suddenly experienced a sharp drop in profits, which was thought to be caused by most financial companies due to their using machine algorithms to execute complex trading orders. It is estimated that more than 50% of S&P 500 index transactions have been determined by machine learning algorithms.

This project first introduces the basic logic, the classification, the advantages,

and the functions of algorithms, and how they assist manufacturers for efficient operations. It is the basic knowledge and equipment that law enforcement personnel face in the platform economy. The pricing algorithm quickly assists manufacturers in price-and-profit correlation estimation and in price-and-market-condition adjustment. With the help of pricing algorithms, manufacturers are more efficient in dynamic markets,

The third chapter of this study continues to explore the impact of pricing algorithms to the market structure, firms' behaviors, and the possible use as a collusion tool. Because of the pricing algorithm, the number of firms and the fluctuations of market supply and demand become less likely to impact the formation or maintenance of collusion. On the other hand, pricing algorithms make a firm's entry easier but harder to succeed, leading to numerous bubble firms with a very small number of large-scale firms. However, the possibility of heterogeneity has increased, providing a niche for new entrants and making collusion relatively difficult. Moreover, the pricing algorithm-based firms increase their efficiency: better allocation, more accurate estimation (especially demand), more efficient and faster search for optimal prices, more rapid price changes to the market change, and subtle segmented users for personalized pricing. This allows firms to quickly and efficiently estimate the relations between their price and profit, as well as the dynamic relations between their price and the market state.

Of course, the pricing algorithm changed the market environment and thus changed the possible conditions for collusion. According to the OECD classification, there are four types of pricing algorithms that facilitate collusion, namely, monitoring algorithms, parallel algorithms, signal algorithms, and self-learning algorithms. According to Ezrachi and Stucke, it is classified into four types:

the messenger, the hub-and-spoke, the predictive agent, and the digital eye.

Collusions are concerted practices, which still need for human communication as an evidence in current legislation. However, the interdependence of oligopolistic firms will inevitably make the firms behave the same trending of prices in competition market. Therefore, the both price increases are the inevitable result of competition structure, which makes the deliberate concerted practices often difficult to be distinguished. This is the so-called oligopoly problem.

Although the economic analysis may be sufficient to confirm that the current high price is due to a set of reward and punishment mechanism, or it is enough to confirm, unless the competitors adopt a set of reward and punishment mechanism strategy, they will not be able to obtain supercompetitive prices; there is still not enough to convict a case because the reward and punishment mechanism itself is a series of strategic actions, not any other plus factors. It is still necessary to find additional factors that are written, interviewed, communicated or leaked in various forms. At present, the collusion cases involved in the pricing algorithm are all based on the coordination of human communication and supplemented by the pricing algorithm, such as Meyer v. Kalanick (2016), US v. Topkins (2016), CMA v. GB eye (2016), US v. Aston (2015), etc.

The pricing algorithms can, of course, be used to carry out other anti-competitive behaviors, which is discussed in Chapter 5 of this project. For example, four home appliance manufacturers, Asus, Denon & Marantz, Philips, and Pioneer, were judged by the European Commission to maintain the resale price of online retail products, and the rates of the online travel platform operators such as Booking.com were investigated by the European Commission. Uber has been sued in many parts of the United States, including the claims that Uber is looting at a

loss, attempting to monopolize, or abusing market positions.

The sixth chapter discusses the application of the competition law to the pricing algorithms. The human agent and the automation agent actually constitute a principal-agent model. With a lower advanced algorithm, human agents in the model play a heavy role in collusion, which can be reviewed by the existing legal standard framework. However, with a higher advanced algorithm, it is difficult to find specific evidence for being colluding between firms. Therefore, the ability to program detection and inspection becomes important for the competition authority. We conclude many possible ways in which the pricing algorithms participates in the type of collusion; for example, a monitoring algorithm that relies on human practices, a pricing algorithm that shares the same data, a manufacturer that uses the same pricing algorithm as others, and a third party with price algorithms to make decision for firms, a predictable pricing algorithm, a signaling pricing algorithm, and a self-learning pricing algorithm.

In fact, before the popularization of self-learning algorithms, the issues involved in the pricing algorithm are sufficiently regulated with the current competition law framework. When analyzing whether a behavior constitutes collusion, we have to take away the fact that the algorithm is involved. However, the widespread use of pricing algorithms makes the identification of collusion behavior more difficult, so law enforcement officials must have updated survey techniques. When the external detection fails, we can also use the Leniency Policy and the crime penalty to create incentive for firms to self-detect and cooperate.

In the final chapter of this project, we made some suggestions for competition law enforcement agencies. First of all, learning from the foreign competition law institutions, educate and train law enforcers to be familiar with the logic of

algorithms. Then, recruit sufficient information talents, conduct network detection, search, surveillance, and comparison, develop a scale of test and inspection programs, and prepare well results of the algorithmic detection as evidence. At the same time, conduct the industrial survey and the training of relevant personnel about how the competition laws works on pricing algorithms. Establish a continuous monitoring and detection unit for price fluctuations, and develop a test mode for detecting reward and punishment mechanisms in programming. Further, encourage the manufacturers who adopt pricing algorithms to comply the competition laws at the design stage of the software.