

國立臺灣大學管理學院商學研究所

博士論文

Graduate Institute of Business Administration

College of Management

National Taiwan University

Doctoral Dissertation



整合機器學習與啟發式技術建構顧客洞察分析架構之

量化研究

Quantitative Research on Integrating Machine Learning and Heuristic

Techniques to Construct a Customer Insight Analysis Framework

王子騫

Tzu-Chien Wang

指導教授：郭瑞祥 博士

Ruey-Shan Guo, Ph.D.

指導教授：陳家麟 博士

Chialin Chen, Ph.D.

中華民國113年6月

June, 2024





國立臺灣大學博士學位論文
口試委員會審定書

整合機器學習與啟發式技術建構顧客洞察分析架構之
量化研究

Quantitative Research on Integrating Machine Learning and
Heuristic Techniques to Construct a Customer Insight Analysis
Framework

本論文係王子騫君（學號：d08741009）在國立臺灣大學
商學研究所完成之博士學位論文，於民國 113 年 6 月 17 日承
下列考試委員審查通過及口試及格，特此證明。

口試委員：

| | |
|-----|------------|
| 郭瑞祥 | 陳家麟 (指導教授) |
| 鄭至甫 | 郭人介 |
| 王克軒 | 孔令儀 |

系所所長：



謝辭



感謝郭老師與陳老師五年的指導，幫助我順利完成研究，也在研究之餘指導我人生方向，提高我的眼界，幫助我建立新的思維和價值觀。感謝兩位指導老師及人生導師。

感謝口試委員們的專業點評，使我能完善我的博士論文。

感謝王志軒委員的指導，作為研究室的學長及交大工業工程與機器學習大師，幫我確立核心研究與聚焦主題，使我受益良多。您是我的榜樣，畢業後希望能多向您學習。

感謝郭人介委員的指導，委員看出我論文方法論的不足，提供諸多建議使我能完善我的博士論文，並感謝委員提供許多未來學術方向的建議，很高興認識您。

感謝鄭至甫委員的指導，協助我釐順邏輯論述，使文章更具說服力。委員的氣質和談吐也令我非常欣賞，非常感謝您的幫助。

感謝孔令傑委員的指導，委員一針見血的點評，雖然一開始有些驚訝，但根據您的建議，整理了整個研究脈絡和貢獻，使整個研究更加清晰，也非常感謝委員臨時被邀請來審查。

也感謝博士期間認識的學長、學姊、同學、學弟、學妹。學術的路上，有時真是一言難盡，但回過頭看，沒有當時的經歷，也沒有現在的成果。回憶起來是難能可貴，即使未來不會有聯繫，但這些事蹟都會存在博士就學的記憶之中。也祝福大家未來都能更好，僅此感謝。

王子騫 敬上

2024/6/28

中文摘要



本研究針對顧客旅程管理、最佳化顧客購買週期三階段規劃、「顧客-通路-產品」理論與變數探討、精準行銷模式建構、顧客終身價值評估、多通路價值最佳化、精準研發模式建構、產品（工業）效用評估及產品規格推薦等實證研究，提出了一個「整合性機器學習與啟發式演算法最佳化技術」的顧客洞察分析系統。該系統以企業真實工作場景和數據為基礎，針對金融業和有終端消費性產品之製造業進行電子商務場域驗證的實證研究。本研究強調的是實務應用，而非方法論的突破，透過應用過往文獻中顧客旅程（Customer Journey）和新產品開發流程（New Product Development）的理論觀點，提出一個整合性分析框架，驗證兩個研究案例，並補足文獻中處理動態數據和最佳化企業資源配置分析方法之缺口。

第一項研究的驗證結果顯示，通過整合分析台灣金融保險行業的多種電子商務顧客數據，將顧客旅程購買週期三階段的動態分析納入現有的顧客價值估計模型，分析各種類型之線上通路的顧客通路互動、點擊行為數據，確實可以最佳化顧客終身價值，同時降低企業的整體轉換成本，並可更深入地了解顧客群體、購買行為、通路接觸點等對電子商務轉換的影響。研究框架涵蓋了各種技術，如集群分析、機器學習、深度學習、整數規劃與二進制差分進化法，目標變數包括點擊、立即購買、轉換收益與顧客終身價值。資料量約為 140 萬次流量訪問、110 萬用戶和 56,000 筆商務交易的通路互動、點擊、轉換等分析數據。

第二項研究的驗證結果顯示，通過整合自然語言處理技術中的潛在狄利克雷分配主題分析及梯度提升決策樹技術，可以準確地預測亞馬遜消費者評分。並透過與製造公司合作，提出了一個數據驅動的產品服務系統，通過引入品質機能展開程序，根據研發流程自動產生顧客需求與功能重要性排序、顧客需求與產品功能對應之主題特徵矩陣，以及最佳化產品規格推薦，使企業能夠即時識別關鍵研發規格，快速展開新產品開發規劃，藉以支持顧客驅動製造（C2M）商業模式。研究資料量包括從 2021 年 1 月到 2022 年 8 月的 76 個產品類別中 3,492,632 條

產品評論觀察記錄，以及來自亞馬遜運營商的銷售數據。研究整合了結構化和半結構化數據，並使用 LDA 和 LightGBM 模型進行分析。為了確保模型的準確性，建立了六項評估指標，並在製造應用中進行了概念驗證（POC）。

藉由所提供的多通路顧客價值最佳化解決方案與最佳化產品規格推薦解決方案，分別解決了金控公司數位行銷部門常見的營運管理問題（如顧客價值預測、會員經營管理、行銷通路自動配置、通路資源管理準則）以及製造公司研發部門常見的產品研發問題（如顧客需求分析、產品功能模組設計、新產品規格推薦、產品研發管理準則），對企業在系統化管理顧客購買週期、最佳化顧客旅程管理及產品創新與敏捷開發方面皆有實質性的幫助。機器學習預測和啟發式最佳化技術的整合，提高了動態數據分析和強化企業資源分配的能力。同時，顧客洞察分析系統的分析框架為企業系統提供了數值數據、非結構化分析和自動化分析能力。這為管理科學方法在電子商務研究領域的實務運用提供了參考，該數據分析框架適用於產業中的電子商務部門。

關鍵字：數據驅動商業模式、顧客旅程三階段購買週期、機器學習、最佳化分析、自然語意分析

ABSTRACT

GRADUATE INSTITUTE OF BUSINESS ADMINISTRATION COLLEGE OF
MANAGEMENT

NATIONAL TAIWAN UNIVERSITY



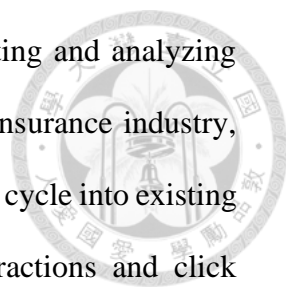
NAME : Tzu-Chien Wang

June, 2024

ADVISER : Dr. Ruey-Shan Guo, Ph.D. ; Dr.Chialin Chen , Ph.D.

Quantitative Research on Integrating Machine Learning and Heuristic Techniques to
Construct a Customer Insight Analysis Framework

This study focuses on customer journey management, three-stage planning for optimizing the customer purchase cycle, the exploration of the "customer-channel-product" theory and variables, the construction of precision marketing models, customer lifetime value assessment, multi-channel value optimization, precision R&D models, product (industrial) utility evaluation, and product specification recommendations. It proposes a customer insights analysis system that integrates machine learning and heuristic optimization techniques. Based on real-world enterprise scenarios and data, this system is validated through empirical research in the e-commerce domains of the financial industry and manufacturing industries with end-consumer products. This research emphasizes practical applications rather than methodological breakthroughs by applying theoretical perspectives from previous literature on customer journey and new product development processes. It proposes an integrated analytical framework, verifies two research cases, and addresses gaps in the literature concerning dynamic data handling and enterprise resource optimization analysis methods.



The validation results of the first study show that by integrating and analyzing various e-commerce customer data from the Taiwanese financial insurance industry, incorporating dynamic analysis of the three-stage customer purchase cycle into existing customer value estimation models, and analyzing customer interactions and click behavior data across various online channels, customer lifetime value can indeed be optimized while reducing overall conversion costs for enterprises. Additionally, it provides deeper insights into customer groups, purchase behavior, and the impact of channel touchpoints on e-commerce conversion. The research framework encompasses various techniques such as cluster analysis, machine learning, deep learning, integer programming, and binary differential evolution, targeting variables including clicks, immediate purchases, conversion revenue, and customer lifetime value. The dataset includes approximately 1.4 million traffic visits, 1.1 million users, and 56,000 business transaction interactions, clicks, and conversion data.


The validation results of the second study demonstrate that by integrating Latent Dirichlet Allocation (LDA) topic analysis from natural language processing technology with gradient boosting decision tree techniques, Amazon consumer ratings can be accurately predicted. By collaborating with manufacturing companies, a data-driven product-service system is proposed. This system, through the introduction of the Quality Function Deployment (QFD) process, automatically generates customer needs and function importance rankings, customer needs and product function correspondence topic feature matrices, and optimized product specification recommendations. This enables enterprises to promptly identify key R&D specifications and quickly initiate new product development planning, thereby supporting customer-driven manufacturing (C2M) business models. The research data includes 3,492,632 product review observation records from 76 product categories

spanning from January 2021 to August 2022, along with sales data from Amazon operators. The study integrates structured and semi-structured data and employs LDA and LightGBM models for analysis. To ensure model accuracy, six evaluation metrics were established, and a proof of concept (POC) was conducted in manufacturing applications.

By providing multi-channel customer value optimization solutions and optimized product specification recommendation solutions, the study addresses common operational management issues in the digital marketing departments of financial holding companies (such as customer value prediction, member management, marketing channel auto-configuration, and channel resource management guidelines) and common product development issues in manufacturing R&D departments (such as customer needs analysis, product function module design, new product specification recommendations, and product R&D management guidelines). This has substantial benefits for enterprises in the systematic management of customer purchase cycles, optimized customer journey management, and product innovation and agile development. The integration of machine learning prediction and heuristic optimization techniques enhances dynamic data analysis and strengthens enterprise resource allocation capabilities. Simultaneously, the analytical framework for customer insights systems provides numerical data, unstructured analysis, and automated analytical capabilities for enterprise systems. This offers a reference for the practical application of management science methods in the field of e-commerce research, and the data analysis framework is applicable to e-commerce departments in various industries.


Keywords: Data-Driven Business Models, Customer purchase journey, Machine learning, Optimization analysis, Natural language processing

目次



| | |
|------------------------------|----------|
| 口試委員會審定書..... | I |
| 謝辭..... | II |
| 中文摘要..... | III |
| 英文摘要..... | V |
| 目次..... | VIII |
| 表次..... | XI |
| 圖次..... | XIII |
| 第一章 緒論..... | 1 |
| 第一節 研究背景..... | 1 |
| 第二節 研究動機..... | 1 |
| 第三節 研究目的..... | 3 |
| 第四節 論文結構..... | 4 |
| 第二章 文獻探討..... | 6 |
| 第一節 顧客旅程研究..... | 6 |
| 第二節 顧客購買週期三階段模式..... | 10 |
| 第三節 顧客通路/目標顧客/產品屬性架構之研究..... | 16 |
| 第四節 多維度轉換問題之解決方法..... | 21 |
| 第五節 預測問題之解決方法..... | 26 |

| | | |
|-----|--------------------------|----|
| 第六節 | 最佳化問題之解決方法 | 35 |
| 第七節 | 文獻回顧小結 | 40 |
| 第三章 | 研究架構 | 42 |
| 第一節 | 顧客購買週期三階段理論化模型 | 43 |
| 第二節 | 顧客購買週期三階段分析架構與說明 | 44 |
| 第三節 | 研究一分析模式建構與說明 | 50 |
| 第四節 | 研究二分析模式建構與說明 | 58 |
| 第四章 | 研究一：多通路顧客價值最佳化求解 | 64 |
| 第一節 | 研究案例說明 | 65 |
| 第二節 | 多通路顧客價值分析模式之集群分析 | 70 |
| 第三節 | 多通路顧客價值分析模式之機器學習分析 | 72 |
| 第四節 | 多通路顧客價值分析模式之最佳化模式計算 | 75 |
| 第五節 | 多通路顧客價值分析模式之大型規劃求解 | 79 |
| 第六節 | 通路資源配置法則 | 81 |
| 第五章 | 研究二：最佳化產品規格推薦求解 | 83 |
| 第一節 | 研究案例說明 | 83 |
| 第二節 | 最佳化產品規格分析模式之主題分析 | 87 |
| 第三節 | 最佳化產品規格分析模式之機器學習分析 | 90 |
| 第四節 | 最佳化產品規格分析模式之最佳化模式計算 | 93 |



| | |
|------------------------------|-----|
| 第五節 最佳化產品規格分析模式之系統推薦架構 | 95 |
| 第六節 產品研發 2X2 矩陣 | 97 |
| 第六章 研究結論與建議 | 100 |
| 第一節 研究結論與貢獻 | 100 |
| 第二節 管理意涵 | 101 |
| 第三節 研究限制與未來方向 | 103 |
| 參考文獻 | 104 |




表次



| | | |
|-----|-------------------------|----|
| 表1 | 顧客旅程文獻結論與模型設計建議..... | 9 |
| 表2 | 八個線上通路類別與研究公司媒體整理..... | 17 |
| 表3 | 電子商務顧客研究相關變數..... | 18 |
| 表4 | 產品屬性特徵變數..... | 18 |
| 表5 | 代表性文獻及本研究提出方案說明彙整表..... | 41 |
| 表6 | 研究一建模方法優劣勢比較..... | 53 |
| 表7 | 參數符號說明..... | 54 |
| 表8 | 量化模式建構說明..... | 56 |
| 表9 | 研究二推薦方法優劣勢比較..... | 61 |
| 表10 | 參數符號說明..... | 63 |
| 表11 | 顧客變數表..... | 67 |
| 表12 | 顧客接觸點資料示意表..... | 68 |
| 表13 | 顧客資料示意表..... | 69 |
| 表14 | 分群結果1..... | 70 |
| 表15 | 分群結果2..... | 70 |
| 表16 | 預測模式最佳參數表..... | 73 |
| 表17 | 預測模式模型檢定..... | 74 |
| 表18 | 目標轉換價值矩陣..... | 75 |
| 表19 | 最佳化模型參數值設定區間..... | 76 |
| 表20 | 最佳化模型分析結果..... | 77 |
| 表21 | 人工規劃與最佳化模型比較..... | 78 |
| 表22 | 啟發式演算分析結果..... | 80 |
| 表23 | 產品類別部分資料示意表..... | 86 |
| 表24 | 產品評論部分資料示意表..... | 86 |

| | |
|---------------------------|----|
| 表25 主題模型參數 | 87 |
| 表26 主題分析結果 | 89 |
| 表27 主題特徵矩陣 | 90 |
| 表28 模型參數最佳候選值結果 | 90 |
| 表29 預測模式模型檢定 | 91 |
| 表30 預測模式穩健度檢定 | 91 |
| 表31 顧客需求與產品功能排序 | 92 |
| 表32 最佳化模型參數設定區間 | 93 |
| 表33 最佳化推薦產品規格及產品效用值 | 94 |
| 表34 2X2產品研發矩陣 | 98 |




圖次



| | | |
|-----|---------------------------|----|
| 圖1 | 顧客旅程架構圖 | 8 |
| 圖2 | 品質機能展開架構 | 14 |
| 圖3 | 通路/顧客/產品三角結構圖 | 20 |
| 圖4 | LDA結構圖 | 25 |
| 圖5 | LSTM結構圖 | 28 |
| 圖6 | 使用者路徑資料結構示意圖 | 29 |
| 圖7 | CNN結構圖 | 30 |
| 圖8 | CNN整合模式結構圖 | 31 |
| 圖9 | CNN推薦模式訓練流程示意圖 | 32 |
| 圖10 | 整體式決策樹獨立建模示意圖 | 33 |
| 圖11 | 整體式決策樹相依建模示意圖 | 34 |
| 圖12 | 顧客購買週期三階段理論化模型圖 | 42 |
| 圖13 | 本研究購買流程結構圖 | 43 |
| 圖14 | 隱含狄利克雷分布主題分析建模流程圖 | 45 |
| 圖15 | 深度學習與集成機器學習方法的建模流程圖 | 46 |
| 圖16 | 啟發式架構分析流程圖 | 47 |
| 圖17 | 本研究分析架構圖 | 48 |
| 圖18 | 研究一分析流程圖 | 50 |
| 圖19 | 整合模式資料結構示意圖 | 52 |
| 圖20 | 研究一多通路顧客價值最佳化數學模型 | 57 |
| 圖21 | 研究二分析流程圖 | 58 |
| 圖22 | 研究二QFD最佳化產品規格推薦架構圖 | 60 |
| 圖23 | 作業痛點與本研究提出之解決方案 | 66 |
| 圖24 | 方案前後效益比較 | 81 |

| | |
|------------------------------|-----|
| 圖25 通路資源配置之管理準則 | 81 |
| 圖26 消費市場數據推動新產品研發之營運模式 | 84 |
| 圖27 AI-QFD架構..... | 96 |
| 圖28 最佳集群數與視覺化圖 | 114 |
| 圖29 最佳主題數圖 | 114 |



第一章 緒論

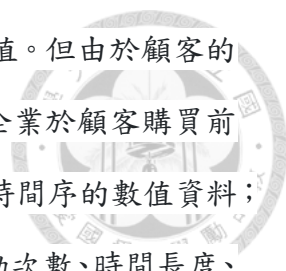
第一節 研究背景



顧客洞察的概念逐漸受到學術與產業界的重視，越來越多的企業開始導入顧客洞察系統，分析顧客資料以作為企業決策的依據。其中便有企業透過建立雲端運算環境來支援企業決策，並制定相關資料治理政策，發展電子商務營運模式。例如：中國電子商務公司京東發展 C2M（顧客對工廠）商業服務模式，運用分析消費數據瞭解終端痛點，實現更聰明的生產排程與彈性供貨。而美國網路零售公司亞馬遜憑藉整合顧客評論、銷售數據與推薦演算法發展 D2C（直接面對消費者）商業服務模式。國內新創公司沛星則運用人工智慧技術分析顧客資料理解購買意圖、為其打造自動化行銷系統，進而發展 SaaS（軟體即服務）商業服務模式。從上述案例成功要素之探討，除了顧客資料累積之重要性，還必需藉由制訂高效的資料處理機制與先進顧客分析演算法之建構，及確立數據驅動商業服務機制，企業方能在現今的數位時代中維持競爭優勢（Jimenez, Lim, Cheok and Ng, 2018; Liu, Soroka, Han, Jian, and Tang, 2020 ;Mak and Max Shen, 2021）。而臺灣過去缺乏數據加值的營運模式近年來已呈現趨緩之勢，相對地，新興的電子商務應用人工智慧加值的產業則逐年成長，為其制訂一個企業決策最佳化的指導框架，有其必要性與急迫性。因此，本研究期望透過建構跨產業標準化顧客分析流程以及分析執行框架，以企業問題求解及真實資料進行核心模型建構，並在最後進行整體模式的驗證，確保提出模式的可行性和可用性。藉此加強產業的電子商務數據營運模式、強化企業經營管理能力與加速企業決策速度。

第二節 研究動機

考量到當前的企業資源必需有效且能被充分利用，企業數位部門必需務實地思考如何在有限的公司資源情況下，提升其顧客經營效率，並規劃更符合市場需求的新商品及建立更多樣的顧客接觸通路，以此推薦給企業目標顧客。而從顧客分析文獻中，文獻的顧客分析方法自 2005 年開始演化至今，雖然已可以利用顧



客輪廓與購買資料來發展顧客分析模型，並推估出顧客終身價值。但由於顧客的購買行為於購買階段的不同，造成分析方法無法有效被執行；企業於顧客購買前利用電商瀏覽紀錄所調查的通路來源資料，屬於蘊含顧客接觸時間序的數值資料；在顧客購買階段的交易互動資料收集，還包括顧客購買期間互動次數、時間長度、以及購買金額等動態數據；在顧客購買完成之後，顧客後續的商品回饋、意見評論資料則屬非結構化的文字數據，致使分析方法無法有效執行。而有關原有顧客分析方法對購買三階段（購買前、購買時、購買後）的執行效率，以及影響各階段轉換成效的重要關鍵因素，隨著金融業線上服務的增加，該些顧客資料與相關變數正在迅速積累，卻遲遲尚無適當的方法加以應用；以國內金融業龍頭公司為研究案例，其資料庫主要包含結構化資料，如顧客輪廓、人口統計變項與顧客交易狀態等。其他資料則主要以半結構化與非結構化形式存儲。半結構化資料包括顧客瀏覽紀錄、點擊紀錄、商品瀏覽日誌與社群媒體足跡等，而非結構化資料則包括商品評論、服務意見回饋、社群媒體評論與聊天機器人互動紀錄等平台資料。因此，如何整合顧客各階段之購買資料，並設計方法來充分了解影響各顧客階段之關鍵購買因素及其經營效率，以供企業決策單位作為精進計畫執行與資源配置之參考。

綜觀現有文獻有關顧客購買分析之研究，似乎大多是從顧客單一購買階段的視角來估算其購買行為的轉換價值，及較少文獻探討最佳化顧客管理策略。此外，在探討影響轉換價值的購買因素部分，文獻也大多只是針對企業的顧客資料庫尋找出影響購買行為的相關因素而已，並未針對時間序與動態因素間之關係進行深入探討，更遑論建立分析框架去執行自動化決策支援系統。至於執行的演算方法部分，過去文獻最常用的統計或經濟推估為主的方法，基於假設以擬與特定的概率模型進行推論運算，雖然能依據顧客的歷史交易資料有效地計算出顧客終身價值，但當資料違背統計假設時，常會有估算偏誤之情形，如必須滿足自變數間共線性、避免殘差項存在自我相關及資料要符合特定分配等統計假設；傳統線性規

劃方法的最佳化方案求解，則會有執行時間過長、甚至無法求解之困難。並且，若以此量化模式執行各購買轉換價值的評估，仍需要不足以解決複雜的時間序列問題，尤其是顧客與企業互動的時間序數值資料呈現出非線性、複雜、固有噪音與非平穩的特徵，且估計過程必須具備要足夠數量之歷史數據來估計參數及隨機特性的處理能力。

而前述的不同購買階段資料結構處理之執行問題，則可運用先進的演算法機制來快速進行獨特編碼與進行維度轉換，包括電商顧客行為在不同通路的序列動作資料處理、文字評論資料的上下文序列處理、及這兩類資料的關鍵特徵標註等問題，以不同機器學習演算技術作為顧客管理系統之運算引擎，進行顧客終身價值預測、通路最佳化規畫，以及新產品開發推薦，並建立模型性能指標根據測試資料與回饋資料篩選演演算法以發展最適分析模式，在此架構下以模型性能指標評估採行當前最適用的模型演演算法及最佳架構，屆時，將自適化處理顧客數據、重新構建或校正更新模型，實現企業決策支援自動化。

第三節 研究目的

考慮到數位競爭的激烈程度以及先前文獻中的理論缺口，本研究專注於三階段購買流程的差異，並打算提出一個整合購買三階段分析流程及其最佳化分析模型。基於該分析模型，本研究將透過先進的機器學習技術與方法論建構一個系統分析框架，進一步分析台灣產業的電子商務資料，以進行理論之實證研究。

本研究的目的說明如下：

一、彙整顧客旅程、購買階段分析，以及相關研究文獻，如顧客需求、用戶行為、顧客分群、接觸通路規劃、銷售策略、產品開發等。找出影響顧客的各個購買階段之關鍵因素，並進行購買價值轉換與最佳化資源配置分析。

二、根據分析方法延伸購買三階段流程，以此發展最佳化顧客洞察分析架構，並開發與整合多目標混合整數規劃模型、啟發式演演算法、機器學習演演算法、非結構化資料處理之系統分析框架。以此處理與轉換不同屬性的資料結構，了解在

不同資料限制下的最佳化決策方式。並確保本研究整合架構是否較具準確性、穩健性與可解釋性，以使該分析框架能夠在產業界實地運用。

三、本研究為實證研究，涵蓋兩個概念驗證（Proof of Concept）案例，以研究案例公司所提供的真實數據為例：第一個研究案例將整合購前通路路徑與購買階段顧客終身價值的最佳化分析，而第二個研究案例則將根據購後產品需求轉至產品規格進行最佳化產品推薦。案例企業透過引入本研究理論化模型與分析架構，整合到企業的管理系統中，發展成該專屬的顧客管理系統的支援決策模式，藉此案例公司增加電子商務資料的分析能力，即時提供管理者營運的最適化決策。以期透過理論與實務結合的研究方式，為案例公司與相關領域的發展注入結構化的指導方針，協助企業建立數據驅動的商業模式。

第四節 論文結構

本研究共分為六部分，內容包括緒論、文獻探討、研究架構、個案背景描述、分析結果、結論與建議，各部分內容分述如下：

1. 緒論：

說明本研究的研究背景與研究動機、研究目的、研究範圍、研究限制與論文結構。

2. 文獻探討：

本研究文獻探討共分兩個部分，第一部分為理論的探討，主要為顧客旅程研究探討，包括探討學術界與產業界在顧客旅程管理的重要性，以及彙整購買前、購買時、購買後模式的研究之文獻比較與理論缺口表格，透過了解現有顧客研究發展現況，探討顧客通路、目標顧客、產品屬性三者之間的研究脈絡，並據此提出一的三角架構探討，作為本研究發展最佳化顧客洞察理論化模型的參考依據。第二部分為方法論的探討，主要有三種方法，分別為維度轉換方法、數值預測方法、最佳化分析方法之介紹及探討，以提出合適的分析框架，為後續實證與分析之運用，進而延伸成企業

的決策應用系統架構。

3. 研究架構：

提出理論化模型與分析框架，說明方法比較與兩個實證研究所使用的分析技術、行銷漏斗相關理論，並將研究案例一及研究案例二關係畫出來後分別說明。

4. 研究一：多通路顧客價值最佳化求解：

研究案例一描述本研究案例一公司背景、作業流程與分析資料，以本研究提出的分析框架進行實際驗證，其中包含介紹驗證資料、敘述性統計、分析模式目標變數設定說明、顧客終身價值計算公式、最佳化模型數學定義與物理涵義，以及其分析模式。最後進行結果說明與理論建議，其中包括目標轉換值預測結果、漏斗目標轉換結果前後比較、評估預測模型準確度與穩健度、最佳化通路規劃求解、評估最佳化模型性能、大型通路規畫求解、通路資源配置法則。

5. 研究二：最佳化產品規格推薦求解：

研究案例二描述本研究案例二公司背景、作業流程與分析資料，以本研究提出的分析框架進行實際驗證，其中包含介紹驗證資料、敘述性統計、分析模式目標變數設定說明、資料預處理、自然語意分析、品質機能展開架構，以及推薦系統方法比較。最後進行結果說明與理論建議，其中包括顧客產品需求及重要性排序、產品評分預測結果、評估預測模型準確度與穩健度、產品需求與產品規格特徵矩陣、最佳化產品規格推薦、2X2 研發矩陣。

6. 研究結論與建議

將本研究的兩個研究議題之研究結果進行討論與歸納研究發現、研究建議、研究貢獻、管理意涵。

第二章 文獻探討

在文獻探討部分，首先探討文獻理論，主要針對顧客旅程相關模式、顧客購買週期三階段模式、顧客通路/目標顧客/產品屬性架構、顧客購買三階段模式指標，接著，從方法論角度探討現有方法不足之處，主要探討本研究問題之各式解決方法介紹、維度轉換問題之解決方法、數值預測問題之解決方法、最佳化問題之解決方法等相關議題文獻進行彙整，期望藉由文獻的回顧，深入整理顧客旅程相關議題面對的問題、以及思考如何根據該些問題採用最適方法或整合方法，以建構最適分析模式，提出解決方案及標準化分析框架進行求解，進而對學術研究及產業界提出貢獻。

第一節 顧客旅程研究

顧客旅程 (customer journey) 的觀念源於許多學派，一些學者從服務營運、行銷科學、顧客體驗與顧客關係管理等角度進行了探討。比如在服務營運領域中，學者將顧客旅程視為服務主導邏輯 (Service-Dominant Logic, 簡稱S-DL) 概念之延伸，強調以顧客為中心，記錄顧客在購買前、購買時、購買後的每個階段與企業互動的方式與情感體驗 (Akaka and Vargo, 2014; Crosier and Handford, 2012)。學者認為，顧客正在積極地尋找一種能夠滿足他們的期望與顧客體驗的服務 (Oh, Yoo, and Lee, 2019)。因此顧客旅程被定義為顧客購買商品與服務時被服務提供商明確服務過程 (Whittle and Foster, 1991)，而該系列的體驗過程則可被企業用為衡量顧客滿意度之參考 (Edvardsson, Gustafsson, and Roos, 2005)，企業可以透過從顧客與服務提供者的互動中蒐集每階段的服務體驗資訊 (Folstad and Kvale., 2018)。

以行銷科學的觀點，可以把以上顧客與服務提供者互動的過程與模式進行定義，顧客旅程是顧客與企業在購買週期內的互動，所形成的一個多個接觸點 (touchpoints) 的服務體驗旅程 (Lemon and Verhoef, 2016)；接觸點是指消費者與企業接觸的所有途徑，通常會依據消費者在顧客旅程的時序上改變。每個接觸



點在顧客旅程中的影響程度與重要性都不盡相同，整個顧客旅程的接觸點也可涵蓋部分上游供應商、下游的品牌、銷售與服務提供者之參與。而企業為了實現以顧客為中心的經營管理，通常在營運成本有限的情況下，針對特定高價值顧客制定個人化的通路策略，並深入挖掘該顧客群體的痛點與需求，以提供符合其需求的服務與產品，建立高效且具有成本效益之行銷政策(Lamrhari, El Ghazi, Oubrich, and El Faker, 2022)。因此，數位化工具便扮演重要執行腳色，研究表明科技創新技術將顯著提升了管理與增強顧客體驗的效率 (Pöppel, Finsterwalder, and Laycock, 2018)。行銷科學領域學者便重點關注顧客行為、顧客旅程以及服務體驗與顧客忠誠度的研究，並試圖建構電子商務決策系統，提高顧客轉換率與整體業務的營運績效。此些研究包括顧客旅程分析，其中涉及分析顧客購買前階段的通路接觸點與購買階段的購買行為。其主要流程包括分析與顧客的首次接觸、根據顧客需求規劃個人化產品服務、在顧客產生興趣後即進行購買轉換、最終引導顧客進行購買，形成顧客忠誠迴路，以有效管理顧客購買流程(Edelman and Singer, 2015)。另一方面，服務體驗分析則針對購買後階段的產品回饋進行分析，並推薦產品(或服務)設計參數，最終提出服務設計或產品強化的建議(Liu, Soroka, Han, Jian, and Tang, 2020)。此外，其他研究主題還包括消費行為分析、服務體驗、產品開發流程與顧客接觸點分析等，旨在盡可能增強顧客旅程管理，進而達到強化顧客服務體驗的效果(Lemon and Verhoef, 2016)。

Lemon and Verhoef (2016) 將顧客體驗以服務管理與行銷管理之相關模式進行關聯、回顧及探討，進一步將顧客購買週期的行為分成三個階段，分為購買前、購買時及購買後三個階段進行探討。如圖一，在「購買前」(pre-purchase) 階段，顧客與服務廠商進行互動，此時消費者確認購買通路、搜尋相關品牌資訊，以及評估哪一個品牌最符合其需求。接著，在「購買時」(purchase) 階段，消費者與服務提供商互動，包括選擇產品、詢問價格、選擇交貨方式等。最後，在「購買後」(post-purchase) 階段，消費者使用產品並提供回饋，可能還會推薦產品給他

人 (Lemon and Verhoef, 2016)。

若從顧客關係管理與企業實務的角度探討，過去企業為了衡量與顧客互動的服務體驗，通常會在顧客完成體驗之後，透過讓顧客填寫問卷的方式（例如：用餐完畢）來詢問顧客滿意度，進而依據成效回饋改進服務流程之設計。然而，以其模式執行的流程，單一時間點的問卷填寫，無法真正測得服務流程的完整顧客體驗。近十年，企業以建置顧客關係管理 (Customer relationship management, 簡稱CRM) 資料庫的方式來持續獲取顧客交易資料 (Jayachandran, Sharma, Kaufman, and Raman, 2005; Mithas, Krishnan, and Fornell, 2005; Reinartz, Krafft, and Hoyer, 2004)，並透過導入動態顧客畫像、行為分群技術來瞭解顧客行為、受眾特徵及目標轉換成效，然而，購買前、購買時、購買後並非是一個完全線性過程，顧客旅程路徑通常會隨著各種因素的影響而呈現不同的顧客購買週期 (Grewal and Roggeveen, 2020)。因此，傳統的顧客關係管理方法仍無法有效衡量整個顧客旅程之服務體驗。

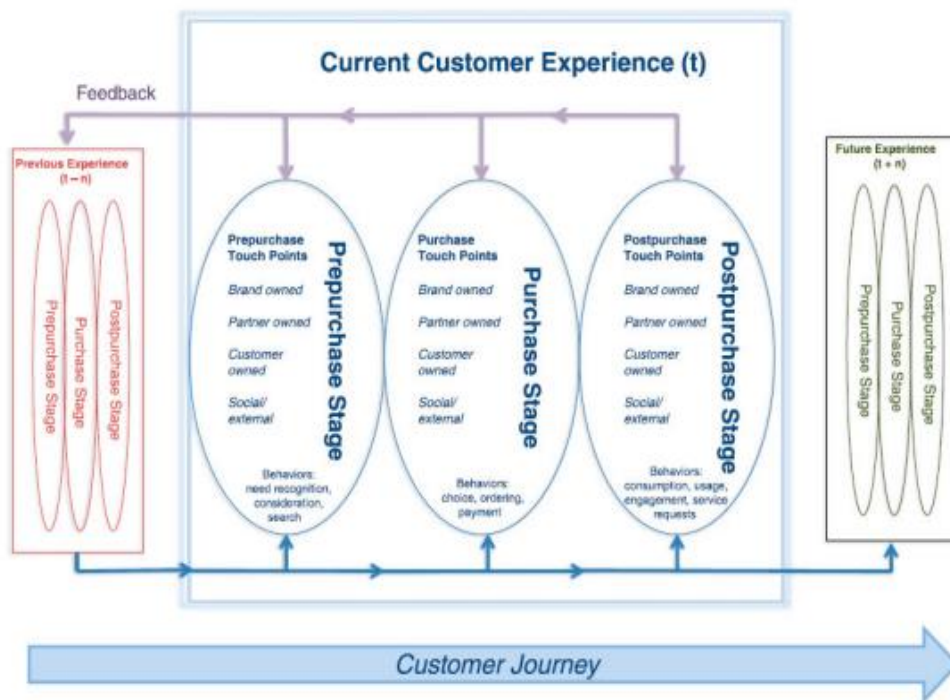


圖1 顧客旅程架構圖 (Copyright 2016 Lemon and Verhoef)

對經營管理者而言，顧客旅程是顧客購買關鍵變數的集合，管理者需要更進一步了解這些決策變數對各消費階段的執行效率及對顧客的目標轉換之實質性影響。Edelman (2015)便指出顧客旅程是個不斷更動、迭代的動態過程，企業必須從此些複雜的旅程中，識別關鍵通路以動態地分配相應的資源，管理與創造經濟效益。Grewal 與 Roggeveen 也提出企業建立顧客旅程管理 (customer journey management, 簡稱 CJM) 機制的重要性，以確保管理者能有效地管理線上顧客在整個購物旅程中的體驗 (Grewal and Roggeveen, 2020)。因此，如何適切最佳化顧客旅程以建構一個管理人員專屬的決策支援系統 (decision support systems)，遂成為重要研究議題之一。

表1 顧客旅程文獻結論與模型設計建議

| 學者 | 研究議題與模型設計總結 |
|--|---|
| Lemon and Verhoef (2016) | 建構顧客行為分析模型時，需要加入顧客偏好通路之分析變數顧客。在購買階段之跨通路行為會交互影響成交機率，需要在方法選定時，考慮可處理資料相依關係之分析技術。顧客接觸點與顧客偏好通路蘊含時間序影響，需要在方法選定時，考慮可處理時間序關係之分析技術 |
| Anderl, Becker, Von Wangenheim, and Schumann (2016). | 作者運用高階馬可夫鏈啟發式技術評估顧客管道的使用路徑，並建立管道次序選用決策架構。品牌方或代營運方在進行最佳化通路規劃時，需要考慮最初接觸通路和最後轉換通路的影響，藉以評估歸因通路有效性，並安排顧客被通路觸及之次序 |
| Heuchert (2019) | 作者提出顧客旅程規劃之方法論，運用顧客旅程地圖及顧客決策層級衡量每一階段顧客決策下的體驗品質。 |
| Berendes, Bartelheimer, Betzing, and Beverungen (2018) | 作者開發高階顧客旅程模型視覺化顧客線上線下通路的接觸順序、使用者行為，結構化繪製和預測使用管道之次序，透過此評估模式供企業管理顧客旅程狀況及環境的系統。 |
| Koch, Lindenbeck, and Olbrich (2023) | 運用動態馬可夫鏈程序法衡量顧客通路接觸順序之廣告效果，分析 45,694 個顧客旅程資料，用以衡量特定管道的歸因準確性及決定管道次序，以提供廣告商更有效的行銷通路預算安排。 |

Lemon and Verhoef(2016)在顧客旅程之顧客體驗過程研究中，以圖一提供的顧客旅程架構圖的服務體驗之衡量觀點，建置了一個顧客購買週期三階段動態體驗蒐集的概念化模式，使管理者能考慮各購買階段服務體驗回饋進行方案之設計與修正。其中，顧客購買週期的三階段中，接觸點是決定顧客是否進入下一個階段的關鍵因素。作者為顧客購買週期各自的階段之分析結論進行彙整，對企業管理者進行建議，其主要著重於理解接觸點的類型與識別顧客的偏好接觸點及影響成交的關鍵通路行為，顧客在不同購買階段會有不同的偏好通路，建議管理者應藉由分析顧客行為特徵，以此在細分出不同的特定多通路，換言之，在建構顧客行為分析模型時，需要加入顧客偏好通路之分析變數。其他如顧客在購買階段之跨通路行為會交互影響成交機率，需要在方法選定時，考慮可處理顧客資料的相依性、次序性關係之分析技術，進而衡量特定管道的歸因準確性及決定管道次序，以提供品牌商或代營運商更有效的行銷通路安排與預算分配。從顧客旅程文獻整理的結論與模型設計建議，如表1。

第二節 顧客購買週期三階段模式

在探討完顧客旅程研究與顧客行為分析模式的建構要素之後，本研究彙整文獻所提及的顧客購買週期三階段模式，根據「購買前」(pre-purchase)、「購買時」(purchase)與「購買後」(post-purchase)三個階段進行分析流程的邏輯梳理；

首先，購買前階段包含品牌商、服務提供商(有時由品牌商自己負責)、顧客與用戶等，相關流程如向品牌商提供產品(或服務)、由服務提供商規劃管道與顧客進行接觸、由主動媒體或自有媒體觸及終端顧客(或用戶)、有效為其介紹品牌、產品、服務。

再來，購買時階段則包含服務提供商、銷售單位、會員經營管理等，一般品牌會為顧客制定其標準購買流程，如線上行銷的會員登入頁面、購物車頁面、立即購買按鈕、購買頁面、結帳頁面、成交頁面等相關標準化流程，方便顧客順利成交。

最後，購買後階段包含服務中心、營運規劃、顧客關係管理單位等，主要流程為調查顧客意見回饋、產品回饋、市場調研等，會將顧客反饋資訊提供給相關單位進行內部營運改善之參考。

過去大多的研究，將購買前、購買時與購買後模型的規劃單獨設計，但實際上顧客購買週期三階段的網路架構具有較強的攸關性、彼此相互影響，各別單獨的顧客購買分析模式所獲取的顧客洞察，僅為顧客旅程的片面知識，且整體規劃僅達到次最佳化的求解結果，為了避免陷入局部解求解而影響企業決策，顧客購買週期三階段模式必須整合規劃設計。

本節將分別對顧客購買週期三個階段的概念化模式以及考量分析方法的實際分析模式(或系統)進行探討。

一、顧客購買前之通路選擇導向分析模型

一般消費者購買決策行為，是指消費者為了滿足某種需求，再一定購買動機下所表現出的一系列購買與決策行為 (Peter et al., 2005)。而購買前，消費者通常從各種線上線下管道收集資訊，例如：媒體廣告、口碑資訊(word-of-mouth)、第三方或零售商提供的商品資訊，再進行購買 (Peterson and Merino, 2003)。近年由於電子商務興起，多數學者延續了購買導向、網路行為分析、消費者購前搜尋 (Pre-purchase search) 一派的研究觀點，Barwitz and Maas (2018) 認為消費者偏好的線上購買管道之選擇為影響購買意圖的主要觸發因子。而分析模式若以混合多變量方法與啟發式方法建立分析模型，主要目標是根據顧客動線的影響，進行顧客旅程規劃最佳化求解。例如，Hense and Hübner (2022) 提出了一個整合全通路管道的最佳化模型，考慮到空間彈性、商品隨機性、跨通路選擇與替代通路配置等因素，旨在實現零售商利潤最大化、單位成本最小化、權重最大化以及產品需求與通路匹配。他們運用啟發式演算法在小型規劃案例中取得了接近最佳的結果。Jiang 等人 (2018) 的研究指出，整個行銷通路規劃應該涵蓋從目標市場細分到消費者端通路銷售的策略最佳化。為了實現整體最佳化的營運管理目標，他

們將顧客分群、接觸通路規劃與銷售策略等流程納入最佳化模型中。他們的研究模型分析結果顯示，理論分析與數值分析指出所提出的模型皆優於傳統的線上推廣策略（Fader, Hardie, and Lee, 2005; Larson, Bradlow, and Fader, 2005; Hübner, Hense, and Dethlefs, 2022; Jiang, Liu, Shang, Yildirim, and Zhang, 2018）。

以下則針對近期的多變量方法與啟發式方法之電子商務通路分析模式進行探討。

Anderl, Becker, Von Wangenheim, and Schumann (2016) 發展高階馬可夫啟發式演算技術進行四個不同產業的顧客點擊數據分析，同時考量到路徑與管道間的最佳化模式，並建構一個歸因模型協助第一線人員瞭解開發顧客的最初管道，並繪製成顧客旅程地圖，藉以協助管理者針對購買前顧客規劃最適化網路行銷策略。

Anderl, Schumann, and Kunz (2016) 所規劃的混合全通路的顧客旅程模式，針對零售商大型通路點擊數據進行分析，瞭解消費者潛在購買決策過程之規則，協助零售商跨管道選擇的配置設定，運用通路風險比例模型進行各通路資源配置的求解。Neslin (2022) 則為了解決全通路架構下顧客橫跨線上線下通路行為問題，建構混合型分析框架，並進行實證求解，確定十個顧客購買前全通路策略的決策變數。

二、顧客購買時之顧客價值導向分析模型

過去有關顧客購買時分析的實證研究主要集中在購買行為分析與顧客價值評估等研究主題，其中，購買行為分析與顧客價值評估方面的研究，最具代表性的模型為 Fader 等人（2005）提出的一混合貝氏概念的 RFM（最近一次交易時間、交易頻率與交易金額）模型。該模型結合經典 Pareto/NBD 模型，用於估計顧客的存活時間與購買次數，同時採用了 Gamma/Gamma 模型來估計平均每次購買金額，以應對顧客交易狀態隨時間變化的情況。Fader 等人（2005）還提出了 Beta-Geometric/NBD 模型，有效解決了 Pareto/NBD 模型難以計算的問題。該模型根據每位顧客的歷史交易資料來預測未來的購買次數，並評估顧客的異質性，進而計算個別顧客的活躍機率。此些模型成功結合了貝氏統計估算方法與 RFM

模型，預測了顧客的終身價值，並構建 RFM 與顧客生命周期價值 (CLV) 之間的數學函數關係結構。從上述文獻探討，結合第一階段顧客購買前之通路選擇導向分析模型的結論，以及購買行為分析與顧客價值基本模型之探討，本研究發現，若要有效提升行業顧客端的營運效率，分析架構應先涵蓋顧客購買前通路規劃與購買時行為評估資訊。然後根據評估顧客多通路下的目標價值轉換以進行多目標模式求解，如此才能使整體營運達到最佳效果。

而除前述量化顧客價值評估模式之外，另有機器學習建模技術，其建模方式則是依據現有資料找出各預測變數與準則變數間的關係模式，之後再運用此模式進行預測工作。相對於統計推估與自迴歸分析方法在購買轉換之應用而言，通常，機器學習預測模式並無傳統量化方法建構模式需要滿足許多假設條件的要求，也不需要複雜的參數估計，就能夠廣泛地處理數據中非線性與線性的問題，亦有較大的運用空間，在建構處理非線性問題預測求解方面亦展現優越能力。

以下則針對近期的機器學習與深度學習方法之電子商務購買分析模式進行探討。

Chen, Guitart, del Río, and Perriñez (2018) 在購買階段顧客價值分析上，同時考量顧客動作、購買金額與互動時間性，建構顧客終身價值分析模型，一生在電玩應用程式上的總花費金額，及計算每一位顧客的終身價值。作者首先運用混合卷積神經網路方法建構購買階段顧客價值分析模式；接著運用卷積神經結構直接處理原始顧客序列數據，包含個別參與者的互動歷程、顧客數據的特徵提取，建構出特徵處理與運算預測機制，最後將該模型效能，與傳統的Pareto/NBD等參數估計模式進行比較，準確度與計算效率皆較基準模型表現好，證明了深度學習方法在顧客價值評估與序列數據特徵提取之優勢。

Bauer and Jannach (2021) 提出以混合多種機器學習技術之顧客價值預測模式，建構自動化預測架構，以利企業掌握顧客購買週期性行為。此篇研究針對大型電子商務公司的真實數據、線上零售產業的公開數據等，運用具有增強時間卷積的序列循環神經網路技術求解。此模式疊加梯度提升機(Gradient Boosting

Machine) 進一步提高顧客終身價值預測準確性，以此強化深度學習方法在顧客價值預測準確度，以及運用商業智慧更好地理解購買階段顧客洞察。

三、顧客購買時之產品需求導向分析模型

查閱目前評估顧客購買回饋之產品滿意度與服務品質方法的文獻：評估方法主要基於顧客滿意度量表調查、問卷調查以及評估服務體驗狀況的NPS(Net Promoter Score)法，產業近年則較採用分析產品需求(或服務品質)的方法，主要為質化訪談、SERVQUAL法、QFD法 (quality function development, 簡稱QFD)、TRIZ (Theory of Inventive Problem Solving, 簡稱TRIZ)法等。儘管有眾多分析方法，但實際上在企業與顧客互動的過程中，最關鍵的環節就是如何能即時地收集顧客回饋，以協助研發部門或企劃部門進行產品與服務的設計，例如：消費者口碑(Chang, Jeng, and Hamid, 2013)。產業的研發流程通常參考QDF法，其流程是將顧客回饋轉換為產品(或服務)需求，再根據產品需求與產品規格的關聯性，進行產品設計規格的推薦，形成符合顧客需求、具品質功能的產品模組。

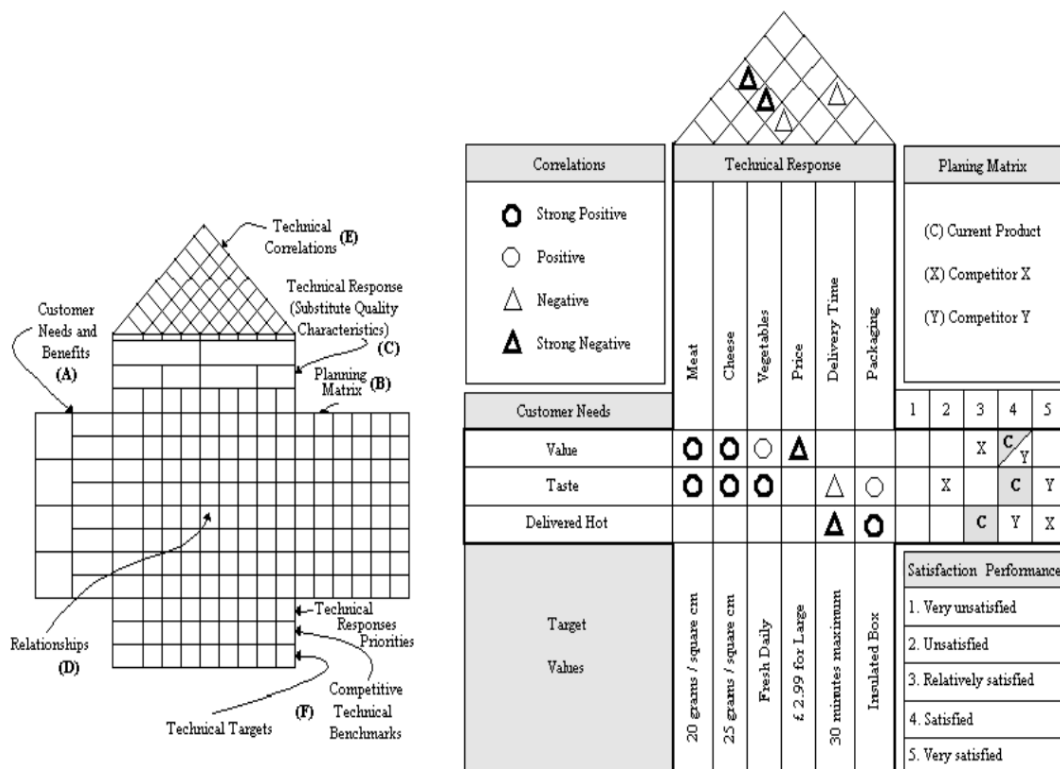
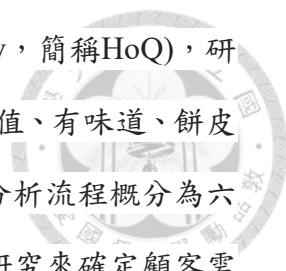


圖2 品質機能展開架構 (Copyright 2012 Jaiswal, E. S.)



Jaiswal (2012)運用QFD法建立產品品質屋 (House of Quality, 簡稱HoQ), 研發人員從產品類的產品品質屋看出顧客對速食產品需求為有價值、有味道、餅皮要辣, 之後依據這些顧客需求, 將生產參數進行相關性分析。分析流程概分為六個部分進行, 如圖一: A 部分包含顧客需求與期望, 透過質化研究來確定顧客需求; B 部分包含對 A 部分顧客需求進行優先性排序; C 部分包含設計與開發之產品參數描述, 一般由 A 部分顧客需求變數主導產品功能開發; D 部分包含對 A 部分與 C 部分每個元素之間關係強度判斷; E 部分則包含 C 部分相關性分析; 最後 F 部分包括 C 部分設計目標優先級。分析結果發現必須要研製低價、多肉、多奶酪的新產品來符合新市場需求。近期則有學者運用整體式TRIZ、QFD法及服務設計工具服務藍圖法的產品開發方式, 並將該套研發流程整合到企業子系統中, 進而推出基於服務的整合性解決方案(Wang, Lee, and Trappey, 2017)。除了整合企業管理系統之外, 為了解決企業多條生產線(或服務流程)設計與生產模組之開發, 學者也根據強化QFD分析流程, 根據不同階段分析目標建立執行模型。

Kuo, and Cheng (2022)則採用以亞馬遜顧客評論內容為基底之機器學習推薦系統, 進行個人化電子商務產品推薦。相較於過去採用二元(購買/非購買)或主觀加權方法分析顧客偏好, 該研究透過分析顧客交易數據預測顧客重複購買行為。此外, 他們還整合了反饋調節器, 進一步分析顧客交易後的隱式資訊, 以提高電子商務推薦系統的準確度。經過驗證, 該研究提出的個人化推薦新模式顯示出比傳統推薦演算法更高的準確度。

Wang and Chen (2012)考量製造業決策過程的複雜性, 建構一個三階段產品設計最佳化選擇模式, 包含產品模組組合評估、顧客意見分析、技術配置與選擇等。第一階段, 以模糊德爾菲法收集終端顧客需求, 並進行分析。第二階段, 以品質功能展開方法架構整合模糊德爾菲法進行技術評估與重要性排序, 建構產品規格建議模式。第三階段, 以混合整數規劃線性模式, 在供應商製造資源及預算有限的情況下進行產品最佳化求解。

第三節 顧客通路/目標顧客/產品屬性架構之研究

本節會先概述行銷路通定義、電子商務背景及其特徵，包含顧客通路、目標顧客與產品屬性，依據本研究場景定義為通路特徵變數、顧客特徵變數與產品屬性特徵變數，進一步針對三個特徵變數分別建構本研究的執行模式，與三構面的關聯結構。

在通路變數裡會分別介紹通路類型的分類依據以及媒體廣告形式的相關文獻探討；而在顧客特徵變數裡，則會介紹常見顧客行為以及顧客變數及線上線下用戶的類型；另外，在產品屬性特徵變數裡，則會分別探討顧客端及開發端之產品相關變數。

一、通路特徵變數

美國行銷協會(American Marketing Association, AMA)認為，行銷通路是由公司內部組織、公司外部代理商、經銷商所構成的組織，其目的是在於讓商品、服務能夠在市場上販售或傳遞大眾其所要宣傳的訊息；Kotler (1994) 定義為透過各種中間機構的操作來將產品傳遞給消費者，此一系列的過程，皆可稱為行銷通路；而隨著電子商務的快速發展，Kotler and Keller (2015)則認為行銷通路是一組互相依賴的組織，主要強調在產品到顧客手上，中間一系列的轉換過程。而線上虛擬通路是透過網際網路來完成交易的通路或媒介。而電子商務便是透過該通路完成電子化交易的過程，主要為所有權移轉的相關商務行為。綜合以上文獻定義，在本研究電子商務案例中之行銷通路定義應為品牌商的自有媒體、服務提供商的媒體廣告、第三方平台來源等，以各種不同的媒介，傳達訊息或服務給消費者，使得消費者對該產品產生購買意圖，也使得消費者對該企業及品牌產生正面的態度。

本研究參考相關文獻，將線上通路分為八種，分別是：付費搜尋廣告、展示型廣告、自然流量、自然搜尋、自有媒體、第三方平台、直接流量、其他，付費搜尋廣告與展示型廣告能主動以文字或圖像的方式來傳遞廣告訊息給目標顧客，而自然流量、自然搜尋、直接流量則多為顧客自主點擊線上連結進到企業網站。

而當企業發展自有媒體或與第三方平台合作，訊息傳遞的方式則有了一個新的形態，如聯盟行銷、交叉行銷或結合網路寫手文字、圖像與影片，使顧客能夠多元的體驗與互動方式，也因此，企業通常要從中去決定較高效益的通路，將自家的產品與品牌資訊以此作為媒介傳遞給顧客。當電子商務出現及數位行銷的快速發展，本研究與研究一驗證公司進行深度訪談，將現有媒體依據八個線上通路類別進行分類。以下將八個線上通路類別與研究公司媒體的進行整理，如表 2 所示。

表2 八個線上通路類別與研究公司媒體整理

| 線上通路類別 | 研究公司媒體說明 |
|------------|---|
| 1. 付費搜尋廣告 | 此通路為公司在付費搜尋引擎上的廣告投放。在特定搜尋期間，付費搜尋廣告會突出顯示在搜尋結果中。如：Google 關鍵字廣告、Yahoo 關鍵字廣告等 |
| 2. 展示型廣告 | 與 Google 上的純文字連結廣告不同，展示型廣告包含各種元素，例如文字、標誌、圖像等。較能傳達企業的整體品牌形象。如：GDN 廣告、GSM 廣告、Bridgewell 廣告、Google 影音廣告等 |
| 3. 關鍵字自然搜尋 | 使用者搜尋特定的關鍵字，搜尋結果中會出現相關網站供使用者點擊。如：Organic Search、SEO 排名等 |
| 4. 自然搜尋 | 此管道與關鍵字自然搜尋都涉及搜尋結果的點擊。但差別在於點擊的內容是否為公司付費廣告（分類為 4）或非付費廣告（分類為 3）。 |
| 5. 自有媒體 | 此通路包括透過電子郵件、簡訊以及由公司管理的 Facebook、Twitter 或 Instagram 等社群媒體平台進行溝通。如：FB 粉絲團、會員權益信、金控網站等 |
| 6. 第三方平台 | 交叉銷售是指當現有顧客在官網瀏覽產品 A 時，向他們展示並銷售另一種產品（產品 B）的做法。這是交叉銷售或聯盟行銷的一種形式，企業與部落客或個人之間建立夥伴關係。合作網站或部落格幫助廣告或行銷產品、分享利潤、促進商品銷售或清單收集，類似於今天的「贊助行銷」。 |
| 7. 直接流量 | 此管道由對網站非常熟悉的訪客組成。通常，這些會員透過將網站新增為收藏夾或直接輸入網站地址來存取網站，而無需搜尋或透過任何連結。 |
| 8. 其他 | 註：為了最大限度地減少錯誤，本研究中未考慮第 8 類「其他」。它涉及使用 Google Analytics 分析的各種廣告策略與方法，以對無法明確分類的資料來源進行分類。 |

二、電子商務顧客特徵變數

電子商務是指任何通過電子連接通道，進行產品或服務交易的經濟活動。其應用領域包括旅遊服務、金融交易或各種產品銷售和客戶服務等。而電子商務的興起主要為資訊科技的快速發展；藉由數位科技的突破，企業始能快速的在線上平台進行各種內部業務，以及買方與供應商之間的商業交易（Wigand,1997）。以下為文獻中常見的電子商務顧客研究相關變數

表3 電子商務顧客研究相關變數

| 顧客特徵模型 | 研究學者 |
|-------------|---|
| 1. RFM模型 | Birant (2011). |
| 2. 購買階段分析 | Sun, Adamopoulos, Ghose, and Luo (2022) |
| 3. 線上廣告分析 | De Haan, Wiesel, and Pauwels (2016) |
| 4. 購買漏斗指標分析 | De Haan, Wiesel, and Pauwels (2016) |
| 5. 網站行為分析 | Huang, Shen, Chiang, and Lin (2007) |
| 6. 顧客流失分析 | He, Shi, Wan, and Zhao (2014) |
| 7. 評價滿意度 | Bui, Jeng, and Lin (2015) |

三、產品屬性特徵變數

表4 產品屬性特徵變數

| 產品特徵變數 | 研究學者 |
|----------|--|
| 1. 產品價格 | Dodds, W. B., Monroe, K. B., and Grewal, D. (1991) |
| 2. 產品品牌 | Richardson, P. S. and Dick, A. S. (1994) |
| 3. 產品耐用性 | Rao, A. R. and Monroe, K. B. (1988) |
| 4. 產品品質 | Lee, M. and Lou, J. (1996) |
| 5. 產品保固 | Purohit, D. and Srivastava, J. (2001) |
| 6. 產品廣告 | Boulding, W. and Kirmani, A. (1993) |
| 7. 產品相容性 | Katz, M. L. and Shapiro, C. (1986) |

四、通路/顧客/產品三角結構圖

通路/顧客/產品屬性等構面的運用，通常透過設計產品服務系統(Product-Service System, 簡稱PSS)來傳遞資訊，並提供用戶價值。Machchhar, Toller, Bertoni, Bertoni (2022) 認為數據驅動的產品服務系統之設計，主要挑戰是確定執行系統要收集哪些類型的運營資料、這些資料的數據流如何設計、其分析數據目標為何、以及能夠替用戶實現哪些商業價值等四項。其他學者多持相似看法。然而若考慮通路/顧客/產品屬性等構面的關聯性，會發現許多值得關注之處。一般來說，顧客與通路的關係包括通路決策過程、顧客購買管道、接觸管道資訊(單或雙向)、互動品質等變數，影響企業的顧客生命週期 (Valentini, Montaguti, Neslin, 2011)。因此，產品服務系統之通路與顧客的設計，應根據通路性質、管道接觸程度去計算顧客影響性，透過整合顧客購買通路資訊來計算顧客終身價值，並設計顧客通路偏好與社群影響等資料流收集機制。而相較於線下通路資訊收集機制建立，線上通路資訊因顧客高度參與電子商務數位服務、企業高度接觸顧客，故據此設計能有較高的效率蒐集完整顧客資訊。並且還須考慮目標客群屬性，以及其通路選擇、互動行為、顧客生理與心理的期望等資訊，以協助企業替終端顧客設計個人化服務。若進一步加入顧客與產品關聯性，以設計服務接觸三角(Service Encounter Triad)架構，透過方法目的鏈(Means-End Chain)屬性-結果-價值之關係鏈結(Attribute-Consequence-Value, 簡稱AVC)。若囊括顧客、通路與產品構面，則改為顧客屬性-通路結果-產品價值之關係鏈結來表達(Gutman, 1982)。

首先「屬性 (Attribute)」可概分為具體屬性與抽象屬性，前者為具體且可觀察的特性，後者是無形且主觀的認知。而本研究顧客之具體屬性為顧客基本輪廓，如：性別、年齡、使用裝置、使用瀏覽器、年收入等，抽象屬性則是服務或產品期待，為顧客生理與心理的期望。其次，「結果 (Consequence)」則是進入選擇通路、接觸通路或購買流程直接或間接導致的決策結果，也就是體驗後的行動反應。Colicev, Kumar, and O'Connor (2019)認為購買流程通常包含幾個階段，從認知階

段的意識和興趣開始，到考慮階段的評估和比較，以及最後的購買意圖階段的購買和轉換，每個階段的目標是將潛在顧客引導到下一個階段，最終實現購買行為；Colicev, Kumar, and O'Connor (2019)並指出顧客生成內容(user generated content , 簡稱UGC)與企業生成內容(firm generated content , 簡稱FGC)對不同購買階段的重要性。因此該三角架構資料流的蒐集需考慮顧客回饋、企業文案變數，像是顧客點擊內容文案、產品內容，或是顧客對產品或服務的意見反饋等，影響通路選擇、功能需求相關資訊。至於「價值 (Value)」則是顧客透過產品體驗所回饋的評價，過去文獻採用價值鏈結將體驗價值分為終極價值與工具價值。終極價值(terminal value) 的抽象層級較高，指偏好的最終狀態，在本研究的產品價值可舉例為：非常滿意、身心舒暢、社會認同、舒適生活等，較為服務體驗導向的價值生成，工具價值(instrumental value)則是為了達到目標採取的行為模式，包括：產品功能好用、產品規格性能、性價比高等，較為產品功能導向功效端的價值生成。構面協作與因果鏈結關係對於企業決策之制定至關重要，本研究根據上述文獻探討，整合顧客屬性、通路結果、產品價值三角之之關係鏈結如圖3。

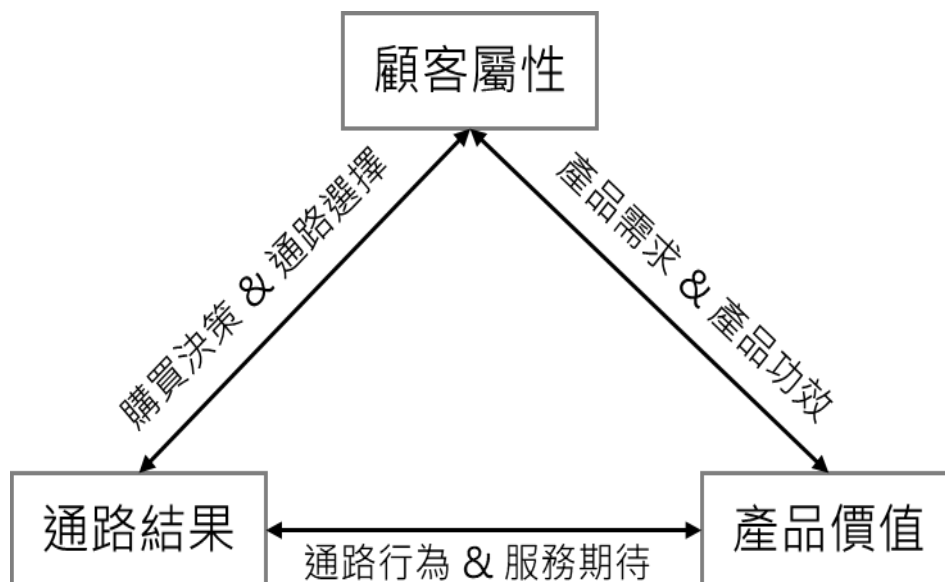


圖3 通路/顧客/產品三角結構圖
(本研究整理)

第四節 多維度轉換問題之解決方法



為了整合顧客購買週期涉及的多變量分析、高維度特徵提取、以及有效識別顧客資料中的隱藏結構交互影響，本節針對機器學習應用與管理科學領域的建模研究進行調查，瞭解現階段文獻處理顧客洞察研究的方法問題，以及可能的解決方式。

一、顧客多維度轉換問題與方法求解

顧客多維度轉換問題之處理，通常包含大量的顧客多變量資料之處理、並從轉換後的維度資料中提取最具代表性/解釋性的特徵。例如：Abbasimehr and Shabani (2021)將顧客所有的特徵與行為資料進行分群，並透過建構集群演算法來識別相似的顧客群體，包含高價值成長型顧客、中價值成長型顧客、易流失顧客、流失顧客的集群，以及顧客隨時間的動態行為之即時評估，運用資料點組合方式清楚地知道各群體內的相似性、群體間的差異性。Tabianan, Velu, and Ravi (2022)則透過建立顧客行為與產品關聯性的運算指標，將顧客購買歷史資料與不同產品類別進行整合運算，進而供應商訂製高利潤市場及低利潤市場產品計畫、交叉銷售策略等策略。Wijaya (2022)則將該技術用於顧客與產品之間的協同過濾篩選，對顧客與產品矩陣進行評分與計算，達到較精準的產品推薦。而隨著電商平台累積的用戶意見評論，Tarnowska and Ras (2021)將自然語意分析顧客對產品或服務的評論及反饋，並據此建構一個用於改善顧客忠誠度之推薦系統，藉以評估用戶服務滿意度。而主題建模與機器學習技術的結合已被證明在提取文本特徵、以及具有顯著提高預測模型準確度之成效。

二、顧客多維度轉換問題與模型設計

Cha, Kim, and Lee (2009)運用維尺度分析找出刺激顧客關鍵變數，對顧客資料進行多維縮放，進而在產品生命週期成熟階段進行行銷組合調整。Arthur, Harris, and Annan (2012)應用主成分分析萃取影響顧客流失的關鍵因素。Suguna, Devi, and Mathew (2019)則結合主成分分析與機器學習方法進行顧客分群，根據

集群的顧客行為進行產品設計。

隨著電商顧客資料、商品/服務反饋資料的累積，以及顧客動態資料的分析運用之趨勢，時間序資料(半結構化資料)、文字資料(非結構化資料)的運算也成為顧客購買分析研究的重要議題之一，顧客購買行為因素考量，顧客與公司之間交易與互動的時間性、顧客評論中的隱藏需求等相關變數亦需要被納入顧客購買分析模式中。根據文獻探討，在前述顧客多維度轉換量化模式之外，另有其他維度轉換方法。例如：K組平均法分群與自組織映射集群法、潛在狄利可雷分配法等技術；以下依據近期K組平均法分群與自組織映射集群法、潛在狄利可雷分配法等技術建構顧客分析之研究進行說明和介紹。

二、K 組平均法與自組織映射集群法

所謂的集群分析(Cluster Analysis) 是一種定量研究分析問題的多元統計方法。它主要是被用來觀察資料屬性間的相似性，在設定同一群內資料變異最小及不同群間資料變異最大的目標下，將相似性較高的樣本資料歸為同一群。而集群分析的應用主要集中於高維度資料的問題，由於此類資料無法以二維或三維散佈圖的方式呈現，因此無法以肉眼的方式分辨資料的分群結果。通常，集群分析方法中計算樣本間親疏程度的指標有兩個：(1)距離：指兩個事物距離多遠的測量，通常將每一個樣本看成 m 維（變數的個數）空間中的一個點，在這 m 維空間定義點與點之間距離，距離較近的點歸為同一類，距離較遠的點歸入不同類。(2)相似係數：指兩個事物相似性的測量，性質越近的樣本，它們之間的相似係數越接近於 1（或 -1），而彼此無關的樣本，它們之間的相似係數越接近於零。在進行集群處理時，將比較相似的樣本歸為一類，不相似的樣本歸為不同的類。

而群集演算法的選擇：根據相似係數，群集演算法會將資料做分群，使得群內差異小，而各族群間差異大。不同的演算法可能會有不同的分群結果，常用演算法有階層式集群分析法(Hierarchical clustering)及非層級式集群分析法(如 K-means、SOM)等。以下分別介紹 K 組平均法與自組織映射集群法。

K組平均法(K-Means)，又稱為Forgy's Algorithm，是 J.B.MacQueen 於1967年所提出的分群演算法。其主要目的是要在大量、高維度的資料點中找出具有代表性的資料點，這些資料點被稱為群集中心(Cluster Centers)，然後再根據這些群集中心，藉著反覆疊代運算，逐次降低一個誤差目標函數的值，直到目標函數不再變化，達到最後結果。各執行步驟及所使用方法的說明則整理如下：

步驟一：將n筆資料 $\{x_1, x_2, \dots, x_n\}$ 隨機分配成K個初始群集。

步驟二：計算樣本到初始群集中心值的距離(採用歐氏距離法)，其中距離接近的樣本，即把此資料分配於該群集，然後再重新計算各群集之平均值。分配不同 $X_i, i=1, 2, \dots, n$ 到 C_j 分群， $j \in \{1, 2, \dots, K\}$ ，計算方式如下：

$$\|X_i - Z_j\| < \|X_i - Z_p\| \quad (1)$$

其中， X_i ：每一筆不同資料。 Z_j ：初始群集j之平均值 $j \in \{1, 2, \dots, K\}$ Z_p ：初始群集p之平均值， $p \in \{1, 2, \dots, K\}$ ， $p \neq j$ ，若相等則重新求解。

步驟三：以新計算之群集中心為基準，重覆步驟2之分群過程，直到各資料不需再被分配到其他群集為止。計算新分群的平均值 $Z_1^*, Z_2^*, \dots, Z_k^*$ 方式如下：

$$Z_i^* = \frac{1}{n_i} \sum_{x_j \in c_j} x_j \quad (2)$$

其中， Z_i^* ：新分群之平均值， $i=1, 2, \dots, k$ 。 n_i, c_j ：各分群中之資料筆數。

步驟四：若 $Z_i^* = Z_i$ ， $i=1, 2, \dots, K$ ，即停止，否則繼續重複步驟二。

實際顧客資料中，含有數值變數與類別變數；若執行類別變數的集群分析，則採用類別資料分群法 K-Mode 進行分群。K-Mode 採用漢明距離，並根據類別變數進行編碼，分為 1 和 0。兩個點之間的距離定義為：

$$d(x_j, C_j) = \sum_{k=1}^m \phi(x_{1k}, x_{2k}), \text{ where}$$

$$\phi(x_{1j}, x_{2j}) = \begin{cases} 1, & \text{if } x_{1j} = x_{2j} \\ 0, & \text{if } x_{1j} \neq x_{2j} \end{cases} \quad (3)$$

除了前述透過中心點的距離分群法，另外一個有以數據點投影進行維度轉換的神經網路方法，自組織對映（SOM）或自組織特徵對映（SOFM）是一種使用非監督式學習來產生訓練樣本至輸入空間、低維度（通常是二維）離散化之類神經網路。其主要功能是發掘出在龐大資料庫中資料高維度特徵及序列間彼此之關聯性。該分群模式以輸入資料中模糊集相似性進行訓練，將其映射到二維網絡拓撲的網格點，通過計算每個圖中輸入樣本的累積數量，以推斷輸入樣本的分佈、可視化訓練數據，幫助實驗者了解在網絡拓撲中的資訊分布。輸出層中的神經元被排列成一維與二維矩陣，為特徵投影創造出有意義的序列。

三、潛在狄利克雷分配法

潛在狄利克雷分配法（Latent Dirichlet allocation，簡稱LDA）是一種無監督的主題建模演算法，能夠從文檔語料庫中生成新主題探究文檔中的詞彙分布以發現潛在變數（Latent variable）的主題結構；其採用“詞袋”方法將文檔概念化為詞彙頻率向量，將其作為各種詞彙群的合併。從文檔語料中提取主題，創建特定主題的詞彙庫，以吉布斯採樣（Gibbs sampling）反復歸因詞彙以推斷文檔中的潛在主題，並為每個文檔生成潛在主題分佈、被理論化為一個獨特主題分布、按此分布依序分配關鍵詞彙；此些詞彙集群中的每一個對應於一個不同的主題，文檔主題的提取獨立於詞彙的順序與相互關係。其流程為：（1）從文檔中的主題陣列中選擇一個主題；（2）從與主題相關的詞彙列表中選擇一個詞彙；（3）重複此過程，直到文檔中的所有詞彙都被考慮到。假設 i 表示文檔編號， K 表示主題數量， Z_{ij} 表示文檔 i 中不同主題中詞彙 j 出現的頻率（ Z_{ij} 遵循多項式分佈）， θ_i 表示文檔 i 中每個 k 個主題發生的概率（具有超參數 α 的狄利克雷分佈作為先驗分佈）， W_{ij} 表示文檔 i 中第 n 個詞彙（遵循多項式分佈）， Φ_k 表示主題 k 內每個詞彙出現的概率（具有超參數 β 的狄利克雷分佈作為先驗分佈）。LDA結構圖如下圖所示。

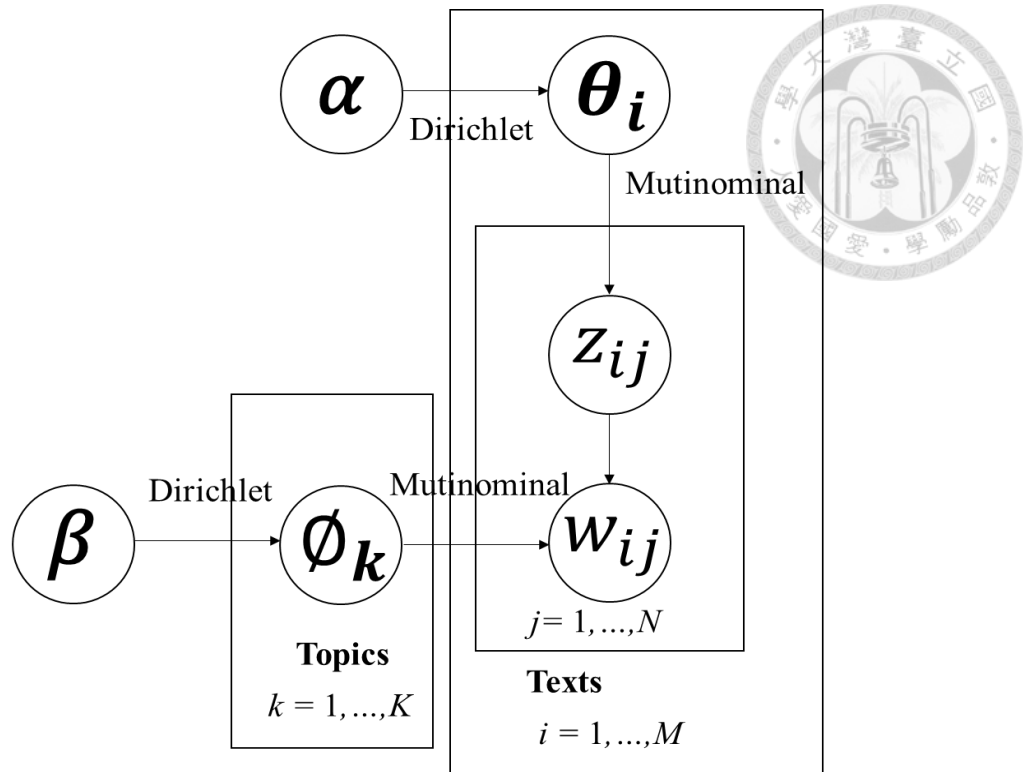


圖4 LDA結構圖
(本研究整理)

假設給定先驗參數 α 與 β ，主題分佈概率 θ_i 、主題集合 Z_{ij} 與詞集合 W_{ij} 的聯合分佈可以表示為：

$$P(\theta_i, W_{ij}, Z_{ij}, \phi_k | \alpha, \beta) = P(\theta | \alpha) \prod_{n=1}^N P(Z_{ij} | \theta) P(W_{ij} | Z_{ij}, \beta) \quad (4)$$

要操作LDA主題模型，還需要計算潛在變數的後驗分佈：

$$P(\theta_i, Z_{ij} | W_{ij}, \alpha, \beta) = \frac{P(\theta_i, W_{ij}, Z_{ij} | \alpha, \beta)}{P(W_{ij} | \alpha, \beta)} \quad (5)$$

- $N(i) \sim \text{Poisson}(\lambda)$ 選擇一個主題分佈 $\theta(i) \sim \text{Dirichlet}(\phi)$
- 選擇一個主題 $Z_{ij} = \text{Multinomial}(\theta(i))$
- 選擇一個詞 $W_{ij} = \text{Multinomial}(\phi, z_{ij})$

透過變分貝葉斯推斷與EM演算法(Expectation maximization algorithm)獲得LDA模型的文檔分佈、主題分佈與單詞分佈，再運用吉布斯採樣法進行抽樣。其遵循馬爾可夫鏈蒙特卡羅 (MCMC) 原則，條件機率如下：

$$P(x_1, y_1) P(y_2 | x_1) = P(x_1, y_2) P(y_1 | x_1) \quad (6)$$

應用於高維空間時，此方法可用於迭代解決LDA模型的後驗分佈。為了計算 $p(w|\alpha, \beta)$ ，在每次迭代中，可以固定所有其他變量並抽樣一個潛在變量，進而獲得後驗分佈。

與分群方法K均值法相比，潛在狄利可雷分配法允許每篇文檔包含多個主題，每個主題有不同權重。若將潛在狄利可雷分配法主題分析與主成分分析和多維尺度相比，多維尺度主要處理非結構化數據，通過發現評論中主題結構及語意關聯性；而主成分分析和多維尺度分析則適用於結構化數值數據，透過特徵值分解協方差矩陣將數據進行投影。

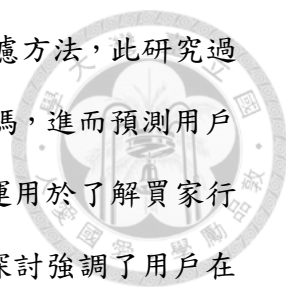
第五節 預測問題之解決方法

一、顧客數值預測問題與方法求解

面對複雜的電子商務運作流程，僅單一模型的維度轉換運算是無法完整呈現真實顧客的階段購買行為。本研究欲整合機器學習演算算法建立顧客購買行為預測模式，自動化產生顧客購買階段動作預測、目標轉換價值預測，提供給第一線決策人員參考，並將產生的數值作為後續最佳化模型運算之輸入參數，進行企業實地應用的最佳模式。

二、顧客數值預測方法介紹

近年來深度學習的方法也延伸到電商用戶行為分析中，透過分析消費者的歷史行為去預測未來的購買行為或點擊行為是近年最熱門的應用之一。例如，Zhang(2014)等學者利用了循環神經網路模型來預測搜尋引擎廣告的點擊機率，他們發現用戶前一次點擊廣告的停留時間與下一次點擊廣告的機率有相關性，因此學者視每個用戶的廣告瀏覽歷史為一個序列，將每個行為的順序依賴關係嵌入到循環的網路結構中進行預測，同時將分析結果與羅吉斯迴歸分析(Logistic regression)比較，結果發現循環神經網路模型的準確度達 88.9%，高於羅吉斯迴歸分析的準確度(87.48%)。而 Robin and Hugues (2016) 認為協同過濾系統是一個序列預測問題，因此欲將循環神經網路模型應用於電影推薦上，在此研究中學者



使用了 Movielens 和 Netflix 的數據集，不同於過去的協同過濾方法，此研究過程中考慮了時間的屬性，學者將用戶所評價的電影進行序列編碼，進而預測用戶未來會觀看哪一部電影。而 Zhang (2018)提出將深度學習網路運用於了解買家行為與觀看產品類別變化之時間動態序列上有著優良效果。文獻探討強調了用戶在各種通路上的線上行為對其影響的重要性，這受到接觸點、通路順序、顧客行為與媒體預算分配等因素的影響。執行多通路顧客數據分析涉及時間序列問題求解，通常資料需要按照序列擺放，並考慮隨時間變化觀察點之間的序列關係。

Kao, Chiu, Wang, and Ko, (2021) 結合集群分析技術與深度學習神經網絡技術提出電子商務用戶行為預測模型。此篇研究使用線上用戶瀏覽資料與網站停留時間，首先使用自組織映射 (SOM) 技術建構顧客分群模式，接著，依據顧客線上行為進行分群，再依據每一個集群去建構長短期記憶 (LSTM) 模預測用戶網站停留時間，研究結果顯示，序列型神經網路演算法較傳統機器學習演算法預測準確，其中以採用集群預測的模式又較未分群的模式準確。該研究不僅提供廣告商提高線上用戶網站停留時間，並幫助他們建構最佳預測模式；而相關實證研究亦指出以整合SOM-LSTM的序列處理模式特別顯著 (Kao, Chiu, Wang, and Ko, 2021; Niu, 2021)。因此，深度學習不只可以改善傳統神經網路無法解決的時序性問題，藉由整合集群分析(Clustering)和長短期記憶 (Long Short-Term Memory)的模式，將可動態分群與分析線上客戶的歷史序列，進而預測是否成交。

除了上述長短期記憶建模技術之外，也有許多學者提出卷積神經網路技術建模，並應用於顧客資料特徵處理上，進行推薦系統引擎之開發；例如：Covington, Adams, and Sargin (2016) 與 Zhang, Zheng, and Min (2018) 運用卷積神經網路經過多層過濾推薦系統訓練資料的特徵，相較於過去須要倚賴人工處理的特徵變數，該些研究提出的模式可直接從數據中提取潛在因子作為特徵變數。研究結果顯示，將其架構運用在電子商務買家行為與觀看產品類別之時間變化，在處理時間序列資料上具有顯著效果，改善傳統電商推薦系統無法解決的動態序列問題。



因此，本研究為應對電子商務序列性等挑戰，將目前文獻中序列演算法進行調查，分別為整體式預測模式技術、長短期記憶(LSTM)與卷積神經網絡(CNN)整合模式等技術。以下分別對三種技術進行介紹與比較。

一、長短期記憶分析

時間序列模型已發展多年，其中自回歸滑動平均模型已證實有高度易用性，然而此模型常被批評僅能處理線性的資料關係。而學者為了改善非線性處理能力，進而提出自回歸外生性模型，以數學模型呈現： $y_t = F(y_{t-1}, y_{t-2}, y_{t-3}, \dots, u_t, u_{t-1}, u_{t-2}, u_{t-3}) + \varepsilon_t$ ，其中 y_t 是欲預測值， $(y_{t-1}, y_{t-2}, y_{t-3})$ 為是 y 過去資料， u 是會影響 y 結果的序列。該模式可考慮影響該時間序列的外生性序列。而遞歸神經網路(Recurrent Neuron Network, 簡稱為 RNN) 則是用於處理時序性資料的神經網路模型，而 RNN 因容易出現梯度消失、梯度爆炸等問題，較不擅長處理時間序列資料中的長期依存關係。長短期記憶(LSTM) 是一種專門設計用於處理序列數據的循環神經網路 (RNN)。LSTM 透過記憶單元(memory cell)延長序列中記憶單元的長期資訊，改善梯度消失問題；而此記憶單元僅存在於 LSTM 層，不會將長期記憶資訊傳遞到神經網路的其他層內 (Hochreiter and Schmidhuber, 1997)。

在電子商務數據的情境下，本研究可將 LSTM 神經網路的結構應用在使用者點擊資料上。LSTM 內層含有輸出閘門、遺忘閘門、記憶單元、輸入閘門，閘門用來控制資料的傳輸量，其值由 Sigmoid 函數決定的 0 到 1 之間的實數，代表閘的開啟與關閉。圖中 C_t, C_{t-1} 表示用戶登錄時間 $t, t-1$ 時的記憶單元， h_t, h_{t-1} 表示時間 $t, t-1$ 時的隱藏狀態，隱藏狀態和記憶單元不同，會輸出到下一層， X_t 為時間 t 時的輸入資料。其模型訓練資料收集，則要收集使用者在多通路的接觸順序，將每一次的新造訪視為一次階段，紀錄每個階段直到使用者購買，或是直到收資料的日期。

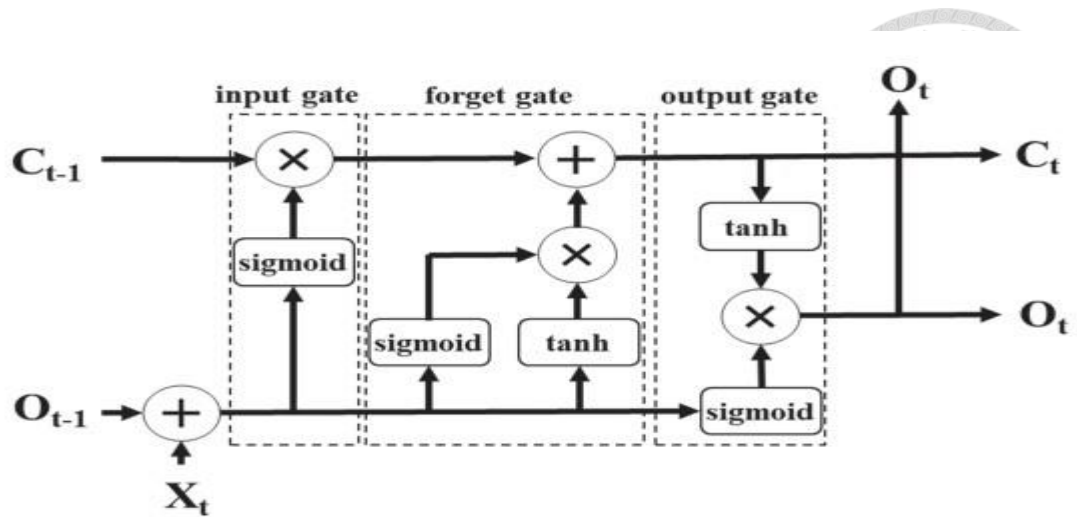


圖 5 LSTM 結構圖

(本研究整理)

序列顧客數據都會透過 Forget gate 和激勵函數決定權重和輸出值，在每一層中，來自先前神經元的數據會以合理的時間步 (time_steps) 進行收斂和調整成最適權重。該長短期循環神經網絡架構能夠藉由先前分析的顧客數據，來更準確地預測顧客行為的變化趨勢。訓練資料結構示意如下

D = 使用者歷史資料, d_n = 每位使用者的點擊路徑資料,

d_{n_1} = 利用二元編碼的路徑向量; n : 使用者總個數, t : 時間長度, p : 管道路徑

$D = \{d_1, d_2, \dots, d_n\}$, $D \in \mathbb{R}^{n \times t \times p}$; $d_n = \{d_{n_1}, d_{n_2}, \dots, d_{n_t}\}$, $d_n \in \mathbb{R}^{t \times p}$

$d_{n_1} = \{p_1, p_1, \dots, p_p\}$, $p_1 = 0, 1$

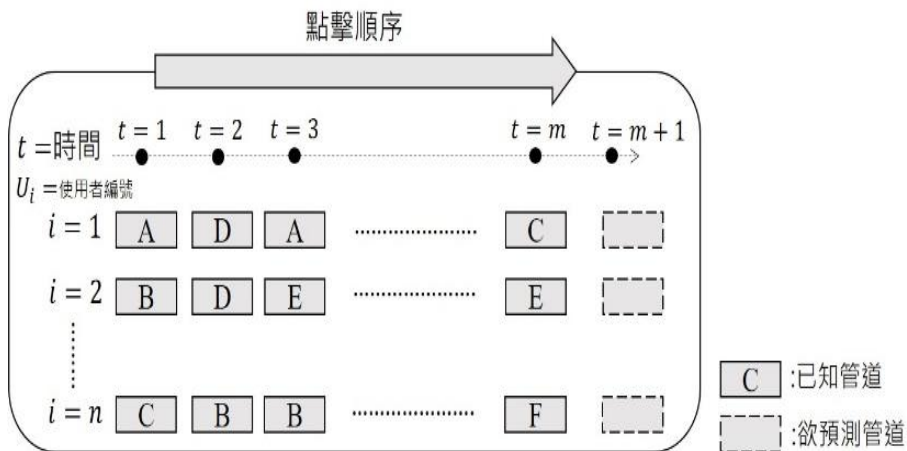


圖 6 使用者路徑資料結構示意圖

(本研究整理)

二、卷積神經網路

卷積神經網路則另一種用於圖像辨識及語音等二維數據的深度學習方法，其主要功能是從輸入的龐大資料中發掘出某些資料項目間彼此之相互關聯特徵，其核心結構包括卷積層、池化層與全連接層等，如圖6結構圖。其分析流程為將輸入數據分成多個區域，稱之為卷積，然後透過卷積層提取圖像的局部特徵，接著利用池化層降低特徵圖的維度，同時保留關鍵特徵，最後透過全連接層將所有提取的特徵映射到輸出層。相較於傳統的神經網路，卷積神經網路在圖像處理和語音識別等分析任務上有較高準確度。該架構運用反向傳遞方法以最佳化每個卷積單元的參數。並在同一特徵圖中共享每個神經元的權重，界以連接到上一層的局部神經元；共享權重和局部連接的架構能夠有效減少訓練時產生的模型過度配適之風險。

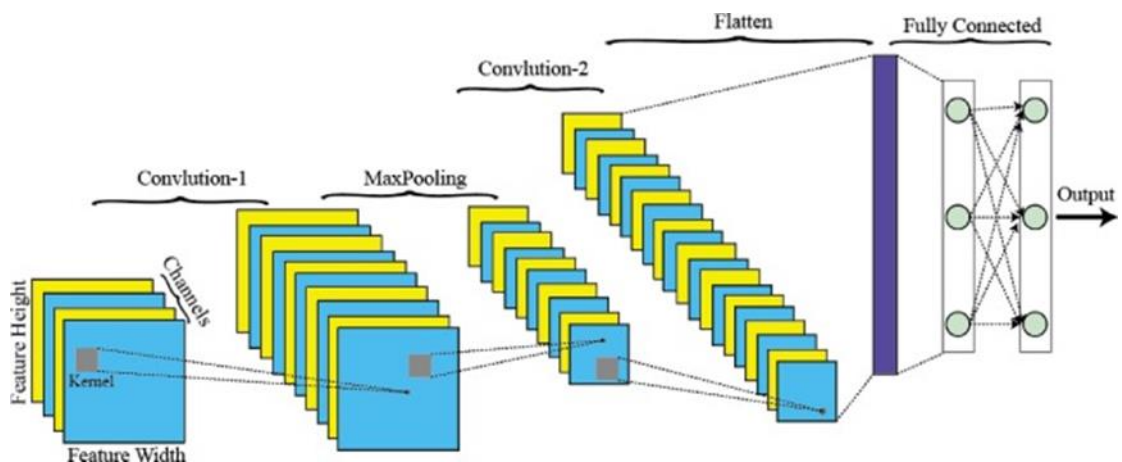


圖 7 CNN 結構圖

(Copyright 2021 Han, Lim, Long, Burgstaller, and Poonet)

而在電子商務數據領域，Ko, Hsu, Cheng, Jheng, and Luo (2019) 從企業管理系統中取出顧客的交易日誌，並透過卷積神經網路建構顧客保留模型，預測顧客重複購買行為，預測準確率達84%。其分析過程顯示，CNN核心結構可以透過局部內核(local kernel)過濾資料特徵，有效捕捉顧客行為的關鍵特徵或多個特徵的組合。而為了解決循環神經網路之長期依賴性問題，過去文獻中已有許多討論如何整合卷積特徵提取的優勢之分析方法論提出，例如：Habbat, Anoun, and

Hassouni (2022)結合多層卷積、GRU (Gated Recurrent Unit)進行顧客情感分析建模，該整合模型在三個法國社群資料集皆較單獨深度學習模型獲得較高的準確度；Jain, Saravanan, and Pamula (2021)則整合LSTM與CNN技術建構顧客情緒分析模型，對航空社群資料進行模型準確度檢定，研究結果顯示，不論是準確度、精確度、召回率、F1 測量該整合模型，皆表現較傳統機器學習模式出色。從上述的方法與研究能部份說明或解釋，CNN整合循環神經網路演算法(如：LSTM, GRU)的分析建模，能有效處理具有隱藏關聯特徵、時間依賴性的電子商務顧客數據，但他們卻有著一個顯著的共同缺點：資料來源多為文字資料或序列資料等非結構化數據；而根據這樣受限資料得出的分析結果，容易產生偏誤結果、導致模型穩健度較低。為了解決這樣的困境，本研究在前述研究維度轉換與預測方法，降低資料和變數維度，並提供更多分析變數與參數，藉以強化顧客洞察瞭解，並針對第二階段分析模式，透過整合不同先進演算法找出最佳預測模式。以下根據實際的購買行為資料，進行深度學習建模，並尋找出顧客對於不同通路及不同購買行為之分析模式建構，以提供高效處理高維度序列特徵的訓練資料結構。




圖8 CNN整合模式結構圖
(本研究整理)

若以本研究多通路分析議題進行建模，數據可按點擊日期排序，每個用戶的數據，包括瀏覽行為、設備類型、瀏覽器類型、RFM分割、接觸通路、分類、產品資訊、首頁、會員資訊與文案內容等，都被納入重要的分析特徵。根據第1st至第rth個用戶的行為，依此類推，創建一個相應大小為 $r * (A_l + 2)$ 的像素圖像。然後將該圖像輸入到第一個卷積層中，運用激勵函數進行非線性轉換，接著透

過池化層計算特徵圖、減少特徵圖的尺寸、減少模型的參數量和計算量，並重覆以上動作以確保模式能夠保留最重要的特徵資訊。藉由正則化技術防止過度擬合及LSTM層(或GRU層)捕捉資料長期依賴關係。最後運用激勵函數進行購買行為預測，由完全連接層進行輸出，並透過最佳化器和損失函數疊代訓練、強化模型的性能和準確度。整合模型架構如圖8所示。

若以本研究產品推薦議題進行建模，建立基於全局內核和局部內核的推薦系統引擎；以演算法運算內核從訓練數據中提取局部產品特徵，再以卷積神經網路架構從訓練數據中提取全局產品特徵，以特徵矩陣為主的分析系統，所採用的技術主要由產業定義的產品關鍵詞，再由詞之間的關聯程度形成產品關鍵特徵，以進行市場需求分析，使用戶得以進行初步的產品規劃。以下簡述支援向量回歸內核訓練原理：訓練流程如圖9所示。

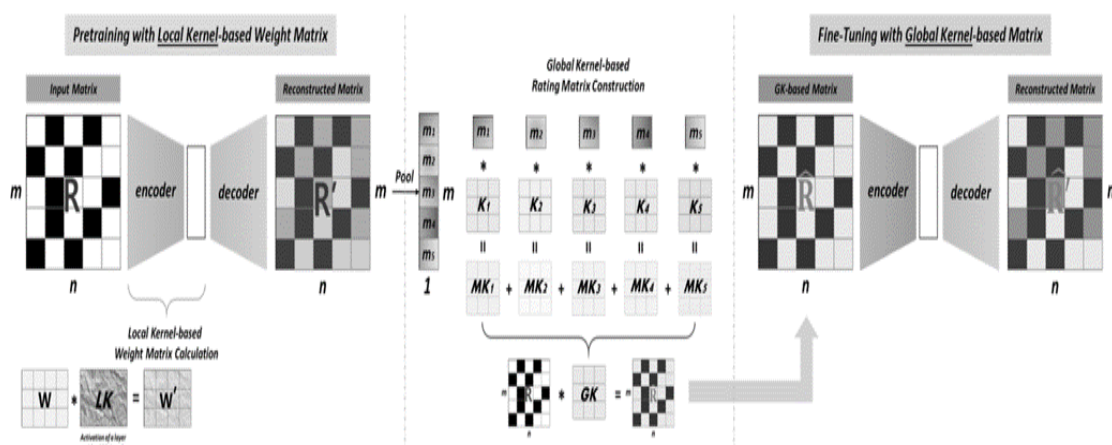


圖9 CNN推薦模式訓練流程示意圖

(Copyright 2021 Han, Lim, Long, Burgstaller, and Poon)

然而，需注意的是，使用全局內核通常有較高的運算資源要求，模型分析模式建構較為困難，且訓練與推論時間較長；本研究考慮到企業系統的實地應用，採用成本較低、效率較佳的局部內核運算進行分析模式建構。

三、整體式預測模式技術

整體式預測模式是一種常見的整體學習方法(ensemble learning method)。整體式學習方法其主要概念是透過多次執行基礎學習演算法以建立多個基礎模型，

並將每個基礎模型預測結果整理成較一致性之輸出決策，其結果會較傳統單一模型預測結果具更佳之績效表現。欲建構整體式學習系統其每個基礎模型必須具有足夠的準確度及基礎模型間必須具有多樣性，即每個基礎模型必須展現出不同之特性，才能發揮整體式學習之功效。常見的隨機森林及 XGBoost(eXtreme Gradient Boosting) 方式建模。隨機選取樣本資料則是指隨機森林中樹的產生是利用 Breiman 於 1996 年所提出的拔靴法(bagging, bootstrap aggregating)進行資料重複抽樣，是採用均勻亂數的方式從 N 筆資料中選出 N 個子訓練集樣本，每次都從原始訓練資料集中隨機選取子訓練集所用的資料，每次所選到的資料會放回訓練資料集中，故有些資料會重複被選取。而這些決策樹模型的平均值即為整體式預測模式的最終預測值。整體而言，抽樣結束後約有 $1/3$ 的訓練資料沒有被選到，這些資料被稱為袋外資料(Out-Of-Bag data, OOB data)，可用來評估此棵迴歸樹的優劣及對輸入因子進行重要性評估。隨機選取輸入因子係指隨機森林中每棵樹所考量的輸入因子，由使用者給定 m 值(m 值需小於 M 值)，採均勻亂數的方式從 M 個輸入因子中選出 m 個輸入因子出來，選出來的輸入因子不再放回樣本內，故為不重複選取。為了增進訓練效率以及維持決策樹模型的獨立性，在訓練決策樹模型的過程中，每次分支僅會使用部分的資料，因此可以平行地訓練多個決策樹模型，且有效率地處理大量的高維數據。此外由於隨機森林演算法會聚合數個獨立的決策樹模型進行預測，因此可減低雜訊與異常值的影響，進而提升整體模型的準確率。

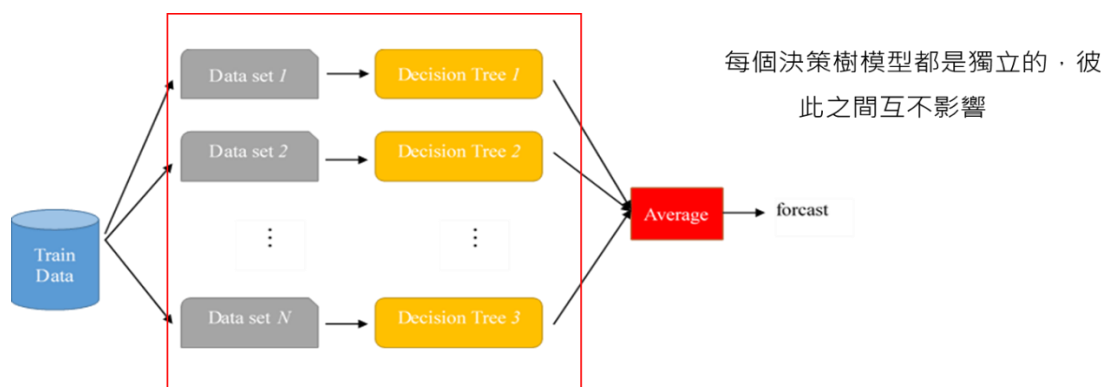


圖10 整體式決策樹獨立建模示意圖
(本研究整理)



在隨機森林模型中，每棵樹的預測都源自於多棵樹的平均預測。假設存在 T 棵樹，每棵樹的預測表示為 $f_{tree}(x)$ ，隨機森林模型的總體預測表示為：

$$f_{forest}(x) = (\sum_{t=1}^T f_{tree}(x))/T \quad (6)$$

在高階隨機森林模型領域，廣義隨機森林的概念引入了多種擴展技術。一個關鍵的創新是權重 w_t 的結合，或每個預測樹，代表每個樹對整體預測的貢獻。此外，此模型利用指標 $Improvement(t, feature)$ 來衡量特徵重要性。此測量是透過觀察所有樹的分割點處每個特徵的重要性以及用於分割的特徵的頻率而得出的。廣義隨機森林的預測公式結構如下：

$$f_{Generalized\ Random\ Forest}(x) = (\sum_{t=1}^T w_t \times f_{tree}(x))/T \quad (7)$$

$$f_{tree}(x) = \sum_{spilits\ on\ feature} Improvement(t, feature) \quad (8)$$

梯度提升決策樹 (GBDT) 模型 (示意圖如圖 10) 則是一種梯度提升框架，在許多應用皆取得良好成效的整體學習演算法。相對於在隨機森林中各個決策樹模型互相獨立，GBDT 中的決策樹模型則是彼此依賴。GBDT 採用迭代的學習，每一次學習都會著重學習上次的錯誤，也就是所謂的殘差 (residuals)，定義為真實值與上次模型預測值之間的差值。最後這些模型的加總即為最終預測值。

決策樹模型之間可能存在依賴或相互影響

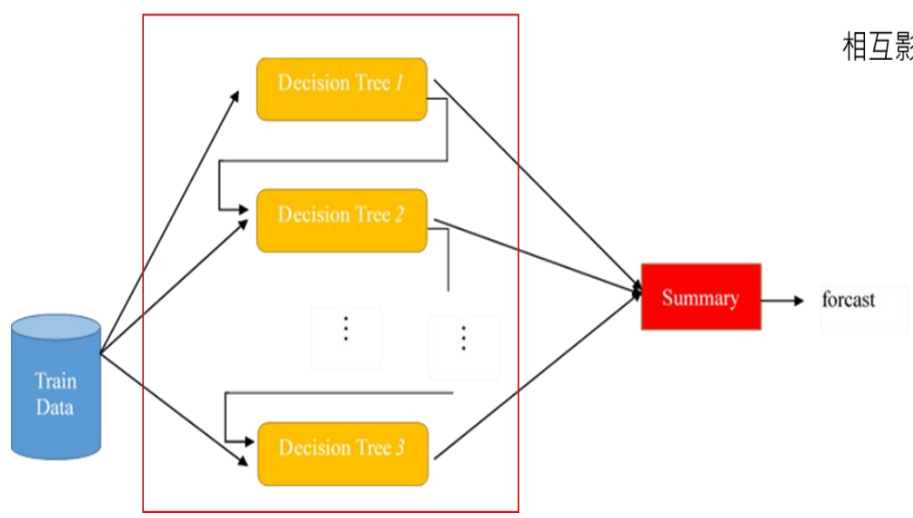


圖11 整體式決策樹相依建模示意圖 (本研究整理)



以下是 LightGBM 目標函數、損失函數與正則化項的介紹。

目標函數： LightGBM 的目標函數結合了損失函數與正則化項，可以表示為：

$$Objective(f) = \sum_{\{i=1\}^{\{n\}}} L(y_i, f(x_i)) + \sum_{\{k=1\}^{\{K\}}} \Omega(f_k) \quad (9)$$

其中， y_i 代表第 i -th 個樣本的真實標籤， $f(x_i)$ 代表模型對第 i 個樣本的預測，而 f_k 代表整體式模型中的第 k -th 棵樹。函數 L 表示損失函數， Ω 表示正則化項。

損失函數：損失函數的選擇取決於具體的任務。對於回歸問題，常見的選項包括：

$$\text{Mean Squared Error (MSE): } L(y, \hat{y}) = (y - \hat{y})^2 \quad (10)$$

$$\text{Mean Absolute Error (MAE): } L(y, \hat{y}) = |y - \hat{y}| \quad (11)$$

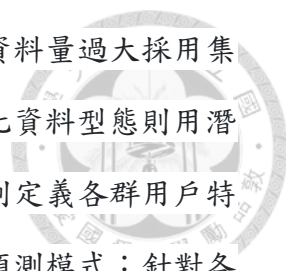
正則化項： LightGBM 支持各種正則化方法，例如 $L1$ 正則化 (Lasso) 與 $L2$ 正則化 (Ridge)。正則化項 Ω 的具體形式取決於所選擇的正則化方法，並添加到目標函數中以防止過擬合。

在經過整體式機器學習演算法，雖然可提高不錯的成效並且抓取一些傳統線性方法不能抓取的的非線性關聯，但如上述深度學習建模技術相似，較難以判斷模型具體訓練方式以及具體解釋推薦結果，乃至於產出結果在現實中很難直接被決策者使用。因此通常會計算整體式預測關鍵變數每個特徵的解釋性，將模型預測的結果了解成每個特徵因子的貢獻來衡量該特徵因子對預測的貢獻度，透過表格來表達特徵因子規格刻度對結果有正向或負向的影響，視覺化的長度越長也表達對推薦的結果影響也越大，就表示會對該預測越重要的特徵因子規格刻度。透過這樣的模型所參考的數據特徵可以讓決策者瞭解管理意涵，跟所謂的經驗法則有所銜接。

第六節 最佳化問題之解決方法

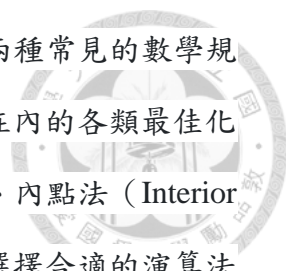
一、最佳化問題與方法求解

根據上述文獻回顧，大致可擬定本研究的核心執行流程，包含三部分：第一



是應用維度轉換方法，將顧客資料分別針對進行降維處理，當資料量過大採用集群分析處理，而變數維度過多則採用主成分分析，若是非結構化資料型態則用潛在狄利克雷分配法，並依據轉換後聚合結果根據三角結構圖分別定義各群用戶特性，如：顧客屬性/通路行為/產品偏好特性等。第二則是建構預測模式：針對各群用戶特性，分類與預測出「顧客在不同通路與管道順序下的行為模式與購買決策，或是顧客需求對不同產品功能的滿意度偏好」，並據此計算顧客終身價值或產品價值。最後，本研究需利用這些分群結果或參數資訊作為最佳化決策依據，將企業限制條件與決策資料整合，以建構最佳化分析模式探討電子商務企業乃至產品開發、產品計畫、產品行銷、顧客經營等問題求解及其企業資源分配。

確定性方法採用傳統數學規劃模式求解，在可行解空間中收斂至全域最佳解。Chen and Homem-de-Mello (2010) 提出整數數學規劃模型以解決顧客偏好選擇之收益管理問題(Revenue Management Problem)，該模型的目的為最大化航空公司的收益，其目標式為出發目的地組合、座位分配與顧客偏好順序等，因目標式含非線性函數與機率性，因此其解可能為該區域的最佳解而非全域最佳解。此外，許多相關研究使用了大量的 0-1 變數定義順序和分配位置，因此當組合越多時，該模式的求解效率越低。Sağlam, Salman, Sayın, and Türkay (2006)則提出混合整數規劃模型解決電子商務活躍用戶分群問題，該文獻提出之模型能使用較少的 0-1 變數求解，並用啟發式演算架構進行顧客分群，較傳統整數規劃或K平均法分群更有效率。Wübben, and Wangenheim (2008) 為了提升學界和產業模型易用性，運用啟發式演算法執行Pareto/NBD模型與BG/NBD模型進行隨機顧客分群，並比較預測顧客群在未來購買力的分析性能，結果表示基本啟發式演算法優於隨機模型。Jasin, and Kumar (2012)則針對確定型啟發式最佳化求解問題進行模型改進研究，文獻中指出將顧客收益管理進行最佳化建模的方法包含啟發式演算法、控制進化策略流程、確定性方法等。



GAMS (General Algebraic Modeling System) 和LINGO是兩種常見的數學規劃軟體，其內建了多種最佳化演算法，用於求解包括整數規劃在內的各類最佳化問題。其中常用的求解方法包括線性規劃 (Simplex Method)、內點法 (Interior Point Method)、分枝定界法和割平面法等。這些軟體能自動選擇合適的演算法來處理具體的問題，並提供詳細的求解過程和結果。

上述數學軟體在求解整數規劃問題 (Integer Programming, IP) 時，經常遇到 NP-hard問題。在實際應用中，特別是面對大規模問題時，求解整數規劃問題的難度顯著增加 (Papadimitriou, 1981)。元啟發式演算法 (Metaheuristic Algorithms) 能夠在有限資源條件下，合理的計算時間內找到可行解。例如，分枝定界法通過構建解的搜索樹，逐步縮小可能的解空間，直到找到最佳解；模擬退火則基於物理退火過程，通過控制“溫度”逐步逼近全局最優解 (Kirkpatrick, Gelatt, Vecchi, 1983)；螞蟻算法則模仿螞蟻尋路過程，通過信息素的積累與揮發找到最優路徑 (Dorigo, Maniezzo, Colorni, 1996)。這些啟發式演算法因其靈活性及適應性，在解決大型、複雜的整數規劃問題上取得了顯著成效，成為應用型研究的熱點方向。

二、啟發式演算架構求解

面對具有多個方程式、變數維度高、非線性等特點的問題時，相關問題的運算相當困難。在運算的最佳化上，啟發式演算法提供相對簡單的數學操作來解決此類的問題。在面對顧客行為序列處理問題，Dixon, and Thompson (2016)提出複雜度低且有效率的啟發式演算法來解決事件效用序列問題，透過最佳化調度順序特徵以最大限度提高顧客體驗，運用事件效用時間序列衡量顧客感知。在顧客價值最佳化中，Marmol, Goyal, Copado-Mendez, Panadero, and Juan (2021) 使用有偏隨機演算法選取設施選址，在行銷資源有限下，來進行顧客終身價值最佳化。AboElHamd, Shamma, and Saleh (2020)則介紹過往文獻中顧客終身價值最佳化動態啟發式建模的方法，例如：馬可夫決策過程、近似動態規劃與強化學習。

Mzoughia, and Limam (2015) 進一步提出一個總體的馬可夫鏈修改模型來解決顧客終身價值問題，其效能優於Pareto/NBD模型與BG/NBD模型，藉以預測顧客信用卡交易獲益利潤。許多學者也提出使用啟發式演算法並結合產品設計求解 Kohli, and Krishnamurti (1987)提出的啟發式演演算法，採用產品效用、需求函數、個人偏好等解決多屬性產品組合問題，在192個模擬問題求解，計算時間與近似最佳解優於其他基準方法。Lee, and Kim (1993) 最佳化公司中短期生產與行銷計劃之利潤最大化，整合需求端模型與供給端模型配合幾何規劃技術與邊際分析求解，比較完全整合與部分整合在求解上的差異，提供現實企業規畫之決策方案。Dobson, and Kalish (1993) 使用貪婪式啟發式演算法並結合選址數學規則。Nair, Thakur, and Wen (1995) 修改了搜尋啟發式演算法進行產品線重新設計問題求解。Jiao, Zhang, and Wang (2007) 提出產品組合規劃法則結合基因演演算法求解，其求解過程加入組合數量與產品屬性的機制。因此在執行大型問題時，常因為求解複雜性與硬體運算空間不足等問題，運用確定性整數規劃進行求解會耗費過長時間，例如：顧客集群數、顧客通路組合變數數量過多，導致維度過高模型無法執行或執行過久之問題。因此，本研究提出一種混合二進制編碼的差分進化啟發式演算法，以進行動態最佳化問題求解，運用搜索個體資訊從組中選出最具代表性的個體，避免在高維度問題求解收斂失敗。差分進化啟發式演算法步驟描述如下：

步驟 1. 初始化人口：

首先，設置一個參數值，並隨機生成一個初始目標向量，其值為 0 或 1，如方程 (12) 所示：


$$x_{j,i,0} = x_{j,min} + rand_{i,j}[0,1] \cdot (x_{j,max} - x_{j,min}), i = 1, 2, \dots, N_p \quad (12)$$

N_p ：人口規模

G ：最大疊代次數

$x_{j,min}$ ：最小搜索範圍

$x_{j,max}$ ：最大搜索範圍



步驟 2. 變異：

二進制差分進化法有許多變異策略，DE/rand/1 隨機從矩陣中選擇三個目標向量，即 $X_{r1,G}$ ， $X_{r2,G}$ ， $X_{r3,G}$ ，並將它們組合成一個組合向量 $V_{i,G+1}$ ，通過變異權重因子進行傳遞。方程（13）如下所示：

$$V_{i,G+1} = X_{r1,G} + F(X_{r2,G} - X_{r3,G}) \quad (13)$$

其中 F 是變異權重因子；r1、r2、r3 是隨機選擇的目標向量。

步驟 3. 交叉：

從方程（14）與選定的目標向量 $X_{i,G}$ 組合生成一個組合向量， $U_{i,G}$ 的過程為，設置參數值 Cr ，選擇另一個隨機值。如果隨機值小於 Cr ，則將新的一維向量放入 $V_{i,G+1}$ ，反之亦然，在值大於 Cr 時用 $X_{i,G}$ 替換。變量 nj 將成為範圍在 $[0,1]$ 之間的隨機實數。此步驟的主要目的是確保至少有一個值維度將通過變異過程，以使新向量 $U_{i,G}$ 與相應的目標向量 $X_{i,G}$ 不同。

$$U_{ji,G+1} = \begin{cases} V_{ji,G+1}, & \text{if } rand_j(0,1) \leq Cr \text{ or } j = nj \\ X_{ji,G}, & \text{otherwise} \end{cases} \quad (14)$$

其中 Cr 是 $[0,1]$ 之間的實數交叉率， $rand_j(0,1)$ 是 $[0,1]$ 範圍內的隨機實數。

步驟 4. 選擇：

透過計算適應值來進行選擇。若測試向量的適應值優於目標向量，則替換。為強化適應函數與本命題之專屬學域 (Domain) 意涵連結，本研究可根據企業部門對限制條件的評比，計算限制條件或限制式與適應函數之間的關係程度，作為目標函數的懲罰因子 (Penalty Term)。包括確定企業部門必須遵守的硬限制條件，主要為企業部門應遵守的企業規範。軟限制條件則為不一定要遵守，通常為管理者希望盡可能達成的條件。適應函數（或懲罰函數）計算出的適應值，會與目標函數計算的總績效值一致。並在疊代訓練時，適應函數為了收斂到最佳解，將直接淘汰不遵從限制條件的解向量。以常見的二元條件式確保軟限制條件，遵從限制條件式適應函數扣除 0，若不遵從限制條件式適應函數扣除一較大的數值；而

求解模型為避免適應函數被扣除極大值，則會強迫遵從限制條件。適應值函數如下方程 (15)

$$Fitness = Y \times penalty_{(1)} + penalty_{(2)} \quad (15)$$

最大化適應值需要模型遵守限制條件，使優良解向量被保留、消除任何不符合標準的解向量。終止條件規定，當適應值在幾代中沒有改善時，可能會達到最佳狀態，並且進化過程可能會停止。

第七節 文獻回顧小節

伴隨著企業加速數位化轉型、電子商務數據運用、人工智慧技術發展等議題持續受到關切，顧客洞察分析技術、電子商務系統整合應用的研究也持續受到學術界與實務界的重視，相關研究文獻發表仍具熱度。根據上述探討，本研究欲延伸既有方法論文獻，嘗試整合規劃顧客旅程購買三階段分析模式，提取顧客關鍵特徵並預測通路購買流程決策與目標轉換價值，運用啟發式演算法執行最佳化多通路顧客價值與產品價值，藉此進行企業內部的有效營運與最佳化企業決策規劃。本節彙整管理科學領域、電子商務分析應用為主題的文獻，包含顧客旅程研究、購買階段分析研究、顧客價值分析研究、產品創新研究、顧客評論分析研究、產品規格分析研究等議題，研究方法以量化研究為主。本研究檢視前述相關研究文獻，將文獻中顧客屬性-通路結果-產品價值關聯關鍵因素之研究結論，以一篇理論性代表性文獻、一篇模型建構代表性文獻，以及本研究提出方案作為說明，彙整說明如表5。

而綜觀產業轉型複雜性與多元化，與上述各項議題相互交雜，單一模型建構較難完全回應真實世界的複雜問題，本研究打算運用整合分析模式的規劃與設計，進行標準分析模式的建構與求解，以提供管理者更具多元及彈性的決策資訊。因應顧客旅程管理系統發展的重要性，本研究提出以顧客旅程的購買週期三階段的理論化框架進行模型設計，以整合多維度轉換方法、數值預測方法、最佳化方法進行模型建置，並藉由整合先進的機器學習、啟發式演演算法技術進行模型訓練。

表5 代表性文獻及本研究提出方案說明彙整表

| 關聯構面 | 作者、年份 | 研究名稱 | 通路影響顧客關鍵因素 |
|-----------|---|---|--|
| 顧客屬性-通路結果 | De Keyser, Schepers, and Konuş (2015) | Multichannel customer segmentation: Does the after-sales channel matter? A replication and extension | 研究指出，消費市場根據顧客使用的接觸管道和購買通路進行分群，透過購買通路的行為了解顧客群體的產品/服務需求。對於提供符合顧客需求的产品或服務之計畫制定至關重要。 |
| | Kuo, Alfareza, and Nguyen (2023) | Applying particle swarm optimization algorithm-based collaborative filtering recommender system considering rating and review | 研究建議的集群模型之較佳建構方式為，整合啟發式技術的集群方法對於目標消費者分群的實驗結果，其具有較顯著的準確性和穩健性。 |
| 顧客屬性-產品價值 | Wang, and Chin (2017) | Integrating affective features with engineering features to seek the optimal product varieties with respect to the niche segments | 該研究指出，顧客對產品情緒感知、以及產品功能與工程特徵是最直接影響新產品成功開發之關鍵因素，也是實現產品差異化的主要關鍵 |
| | Wang and Chen (2012) | Using quality function deployment for collaborative product design and optimal selection of module mix | 研究提出產品創新QFD推薦架構，第一階段運用模糊德爾菲法進行顧客需求識別，第二階段透過模糊決策實驗室分析法找出技術屬性加權，第三階段執行整數規劃最佳化產品模組組合。 |
| 本研究提出方案 | 本研究運用機器學習與啟發式技術建立智慧推薦架構，顧客需求識別改採用潛在狄利可雷分配法與整體式決策樹找出購買因素排序，需求轉規格則運用主題特徵矩陣，最後運用啟發式方法最佳化上述流程生成參數，進行產品規格推薦。 | | |

第三章 研究架構



本章節主要說明本研究的研究範疇、顧客購買週期三階段理論化模型、顧客購買週期三階段分析架構、研究一與研究二的分析模式等說明。首先說明本研究架構範圍，及可運用的流程與產業，接著建立顧客購買週期三階段理論化模型，再來說明此分析架構的運作機制，在此架構下，考量資料處理流程、資料分析流程、數學模型、演算方法、系統流程等相關程序之執行框架，再來分別說明研究一與研究二的分析模式建構，以及該模式用到的方法與技術。本研究所提出的顧客購買週期三階段理論化模型如圖12所示。

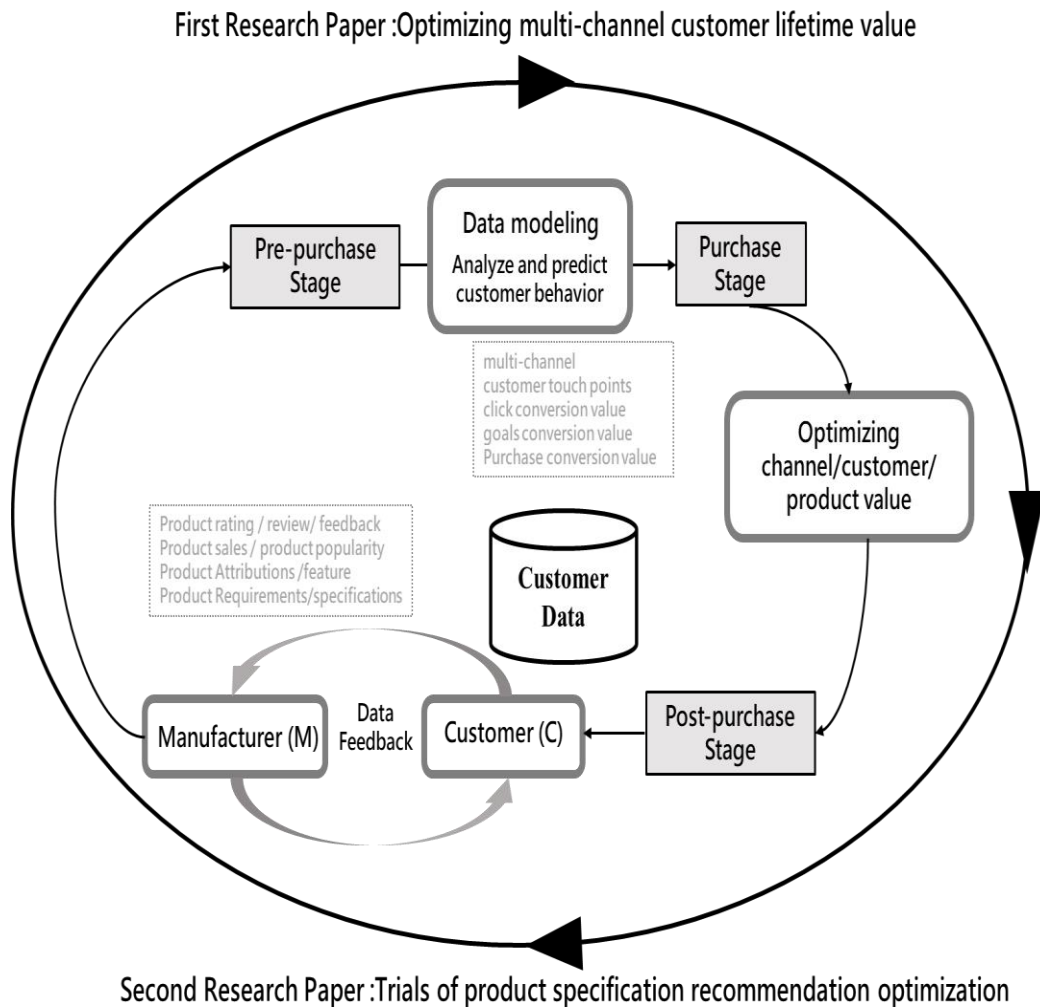


圖 12 顧客購買週期三階段理論化模型

(本研究整理)

第一節 顧客購買週期三階段理論化模型

分析架構的定義為一可再利用的半完成應用系統 (semi-complete-application)，可用於產生客製化的應用系統 (custom applications)，並加以運用在特定的商業單元或特定領域的應用系統上。而分析架構可被描述為不同的物件 (objects)及物件間如何互動，可以組成完整的系統或單獨的子系統。而近年隨著數位技術的商業化應用，多數學者認為架構是以抽象類別、具體類別與其他相關服務所整體式，其設計樣式 (design patterns) 僅要定義出解決用戶需求的功能模組、各模組的執行流程，以及使用者介面 (user interfaces)，即可以稱之為分析架構或應用系統。本研究以顧客購買週期三階段中的三個主題 (購買前、購買時、購買後) 為基礎，建立了顧客購買週期三階段理論化模型。為驗證此流程，進行了兩項實證研究。第一項研究整合了購買前階段的顧客接觸點與購買時階段的目標轉換數據，以跨多個管道最佳化顧客終身價值。第二項研究則分析購買後階段的產品回饋數據，進行消費者需求分析與需求規格分析，最後提出產品規格最佳化的建議。

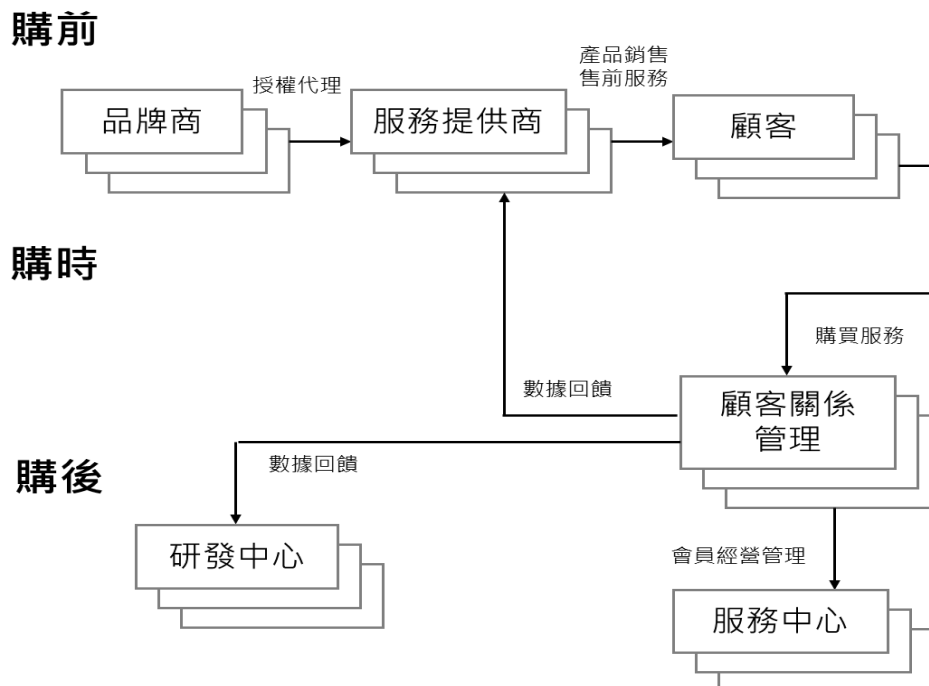


圖13 本研究購買流程結構圖
(本研究整理)

本研究之顧客購買週期三階段分析架構使用範疇，購買前階段包含品牌商、服務提供商、顧客等；購買時階段包含服務提供商、產品銷售、購買服務、會員經營管理等；購買後階段包含服務中心、營運規劃、顧客關係管理單位等(如圖12所示)。在此三階段分析架構下，本研究分別以兩個研究探討分析架構有效性。第一項研究探討在購買前階段與購買時階段，由品牌商利用自有媒體向顧客推撥品牌資訊、產品資訊，另由服務提供商用多媒體平台向顧客投放廣告曝光，依據分析上述這些管道互動與顧客購買行為數據，進而預測顧客不同管道下的轉換行為與目標轉換價值，進而最佳化多管道顧客點擊、顧客點擊立即購買(購物籃)、顧客成交的投入資源，提升整體顧客終身價值，以此來建立一可重複計算顧客購前購時轉換價值與整體價值分析最佳化的應用系統。第二項研究則為在顧客購買後階段、企業產品研發部門新產品開發之探討，首先蒐集顧客交易後回饋數據，透過分析購買後商品(或服務)回饋資訊，再由產品規格與其產品價值(產品功能與消費需求匹配度)最大化，進而推薦符合顧客消費需求的新產品開發規格，以此建立數據驅動研發機制，協助有終端產品的製造商快速開發新產品。

本研究基本假設說明如下：

- (1)僅考量單一時期下的量化模式規劃與架構
- (2)品牌商、服務提供商、顧客關係管理單位、研發中心等皆有單位資源限制
- (3)每一次與顧客互動皆會產生一條數據紀錄，在本研究定義為工作階段
- (4)購買服務階段將顧客動作概分為網頁點擊、點擊立即購買、實際購買三動作
- (5)本研究僅提供最佳化模型求解之整體目標轉換價值，顧客終身價值或產品生命週期價值等準則計算，則由企業單位自行進行。其他新產品銷售數據、相關單位成本則從真實數據提取，作為模型參數、正常運行。

第二節 顧客購買週期三階段分析架構與說明

本節介紹本研究運用隱含狄利克雷分布主題模型(見圖14)、深度學習與整體式機器學習方法建模(見圖15)、二進制差分進化分析(見圖16)等技術的建模流程。

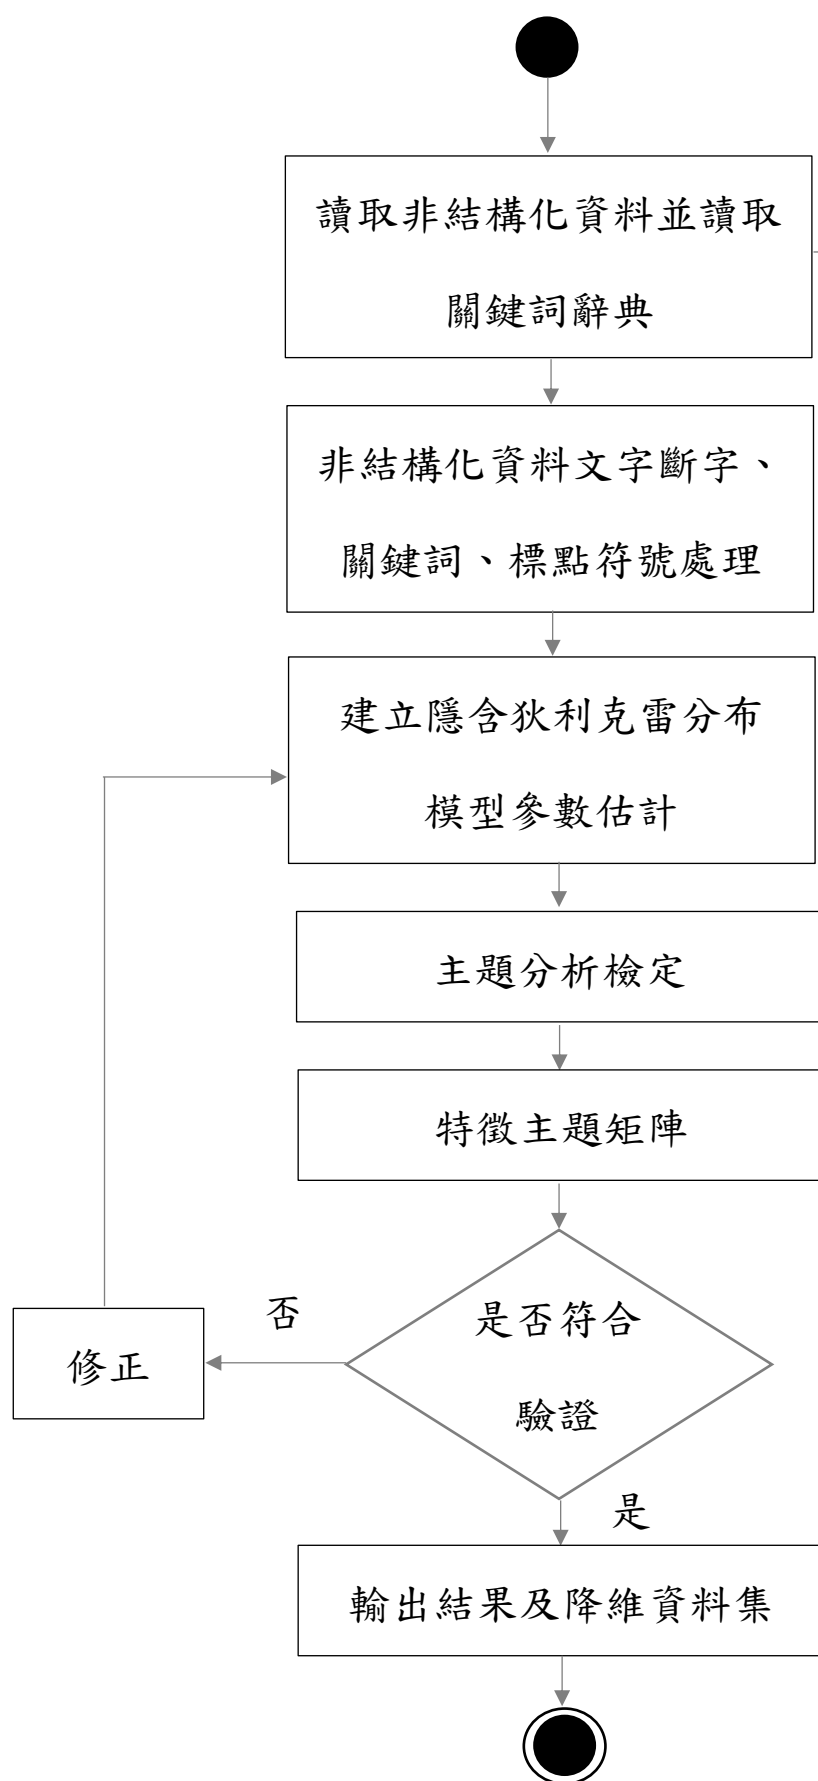


圖14 隱含狄利克雷分布主題模型分析的建模流程圖
(本研究整理)

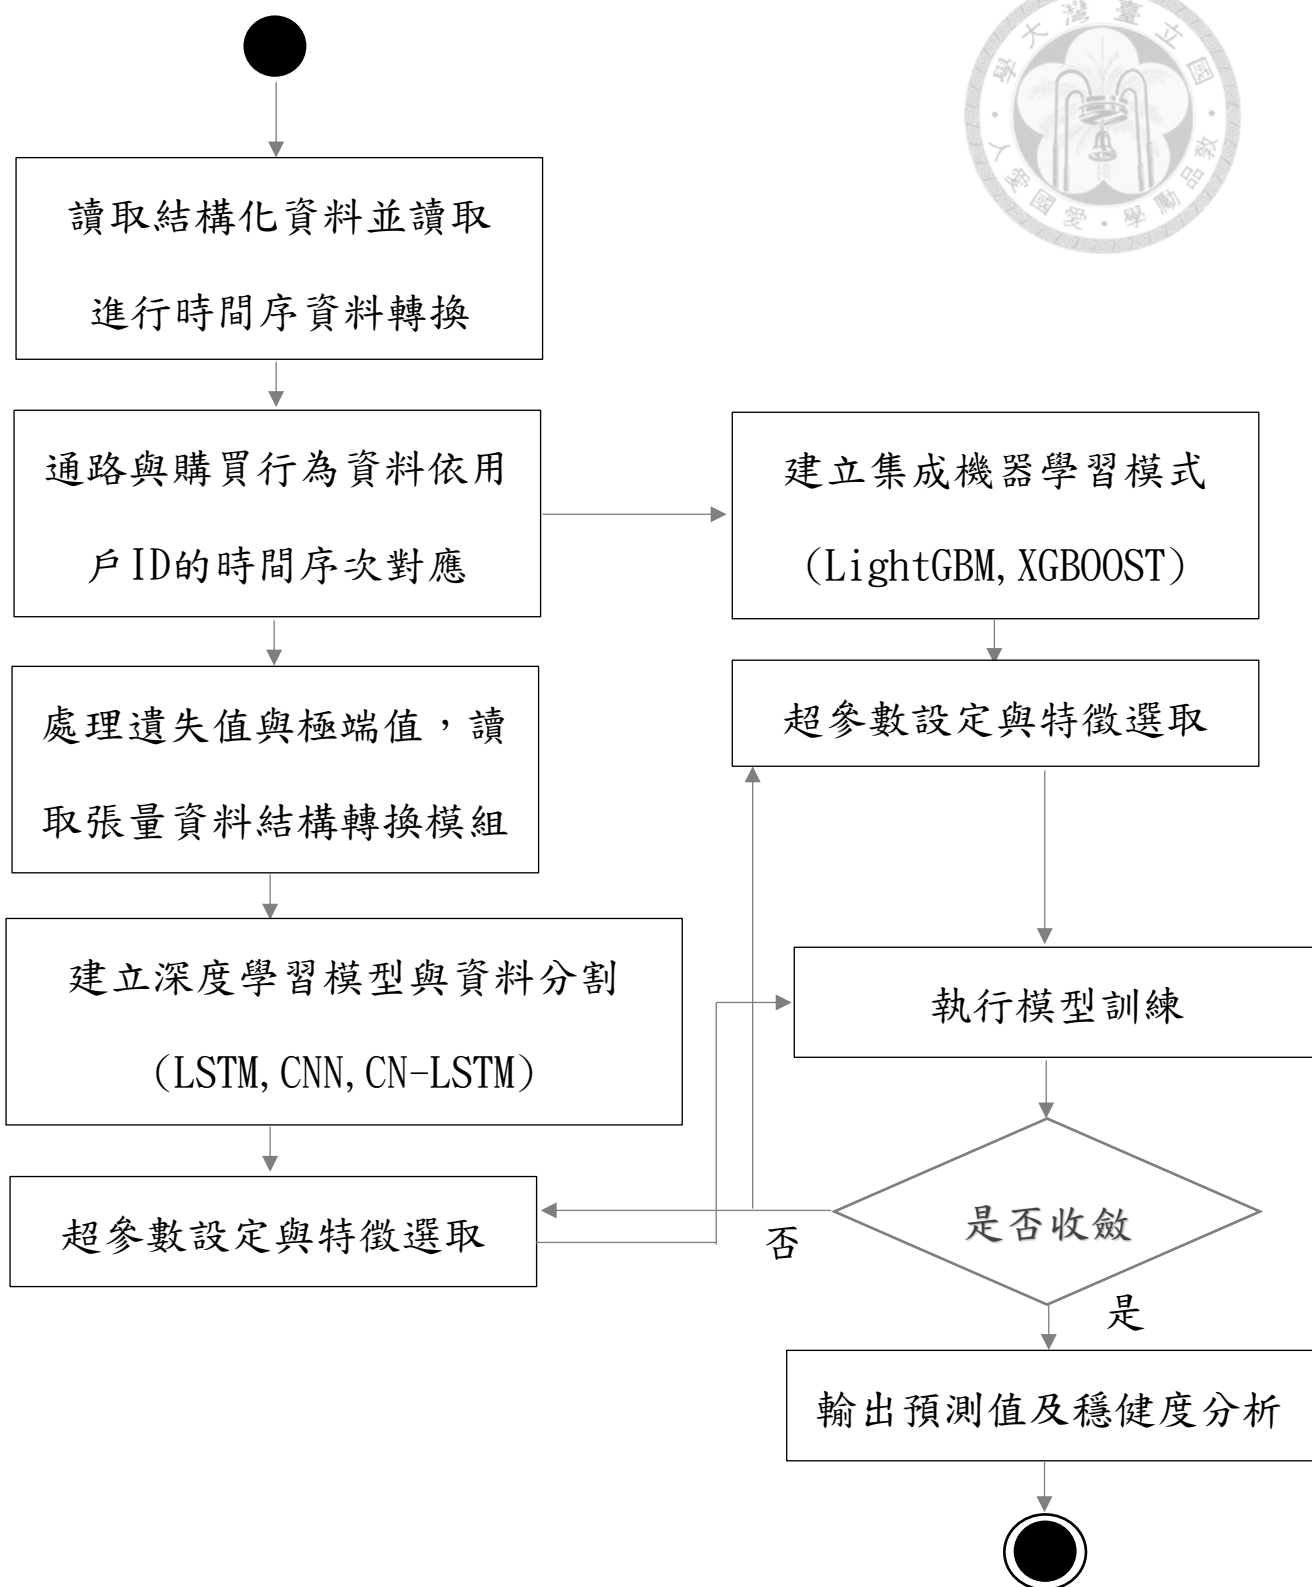


圖15 深度學習與集成機器學習方法的建模流程圖
(本研究整理)

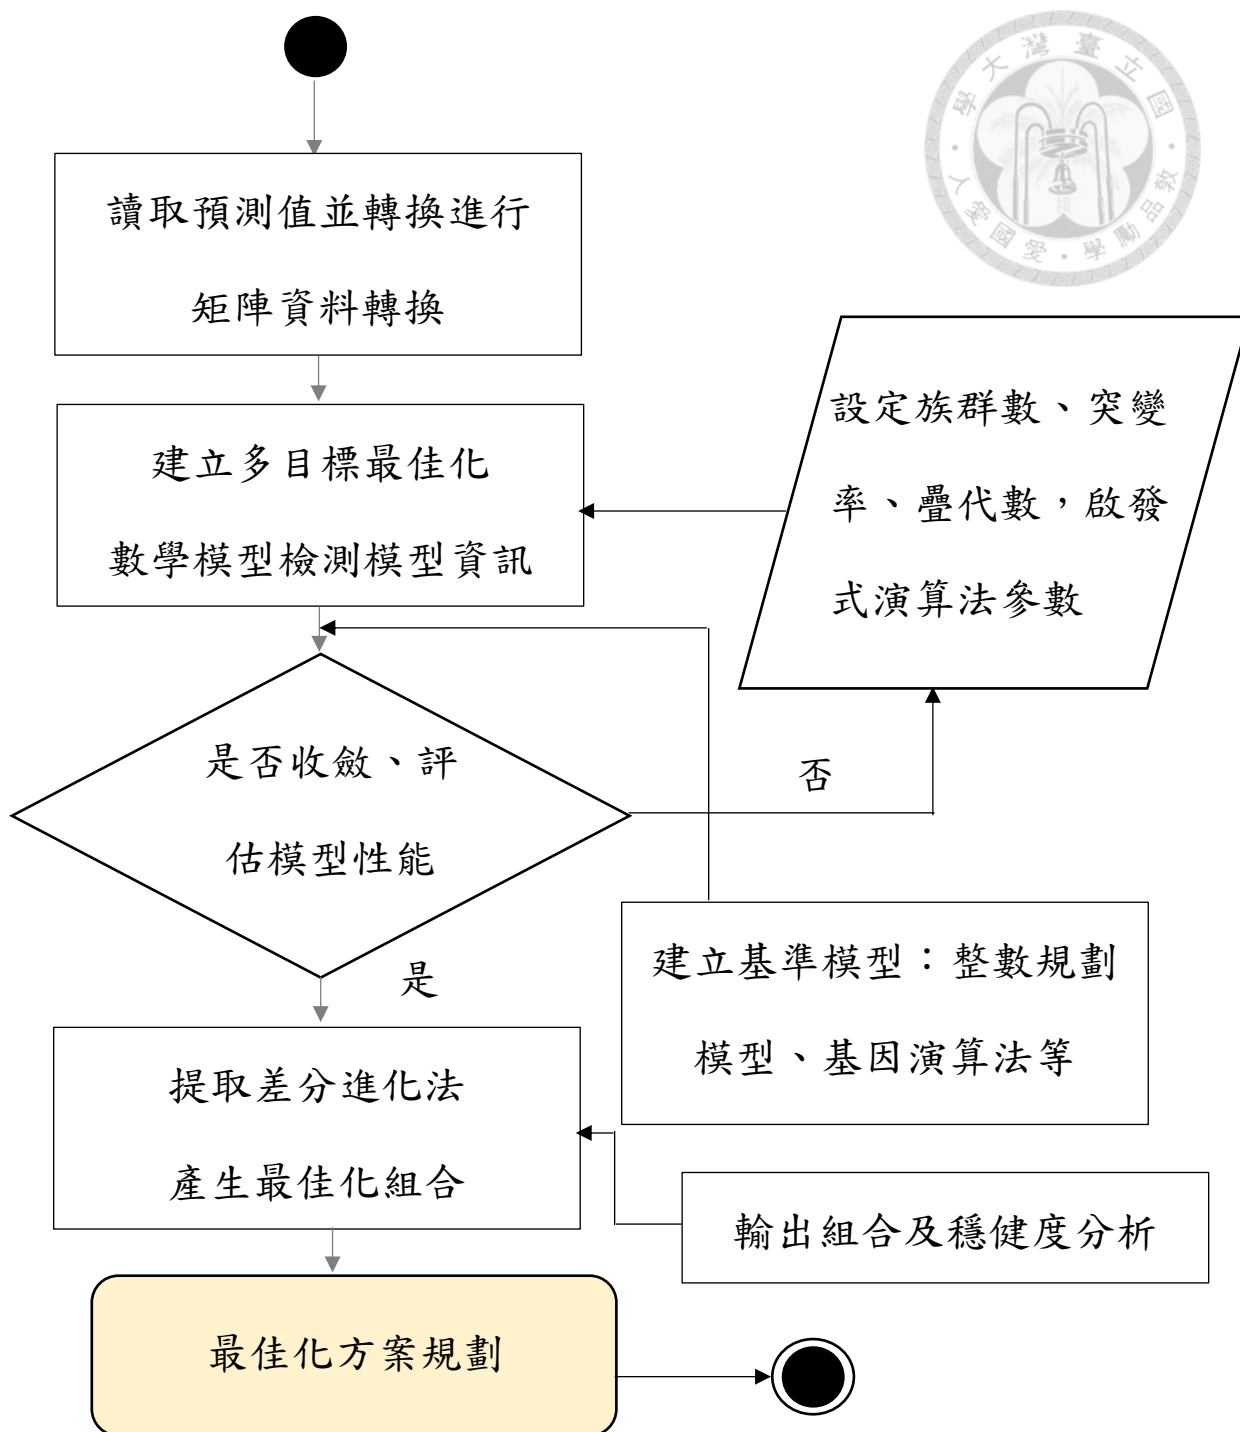


圖16 啟發式架構分析流程圖
(本研究整理)

針對本研究所提出之演算模式，用於結合並執行分析模型，再依據演算模式與分析模型建置相應的資料處理流程，處理企業產品、顧客與通路之電子商務資料，進而建構可重複使用之系統分析架構。本研究分析架構圖如圖17所示。詳細的執行方式與流程將於下面說明：

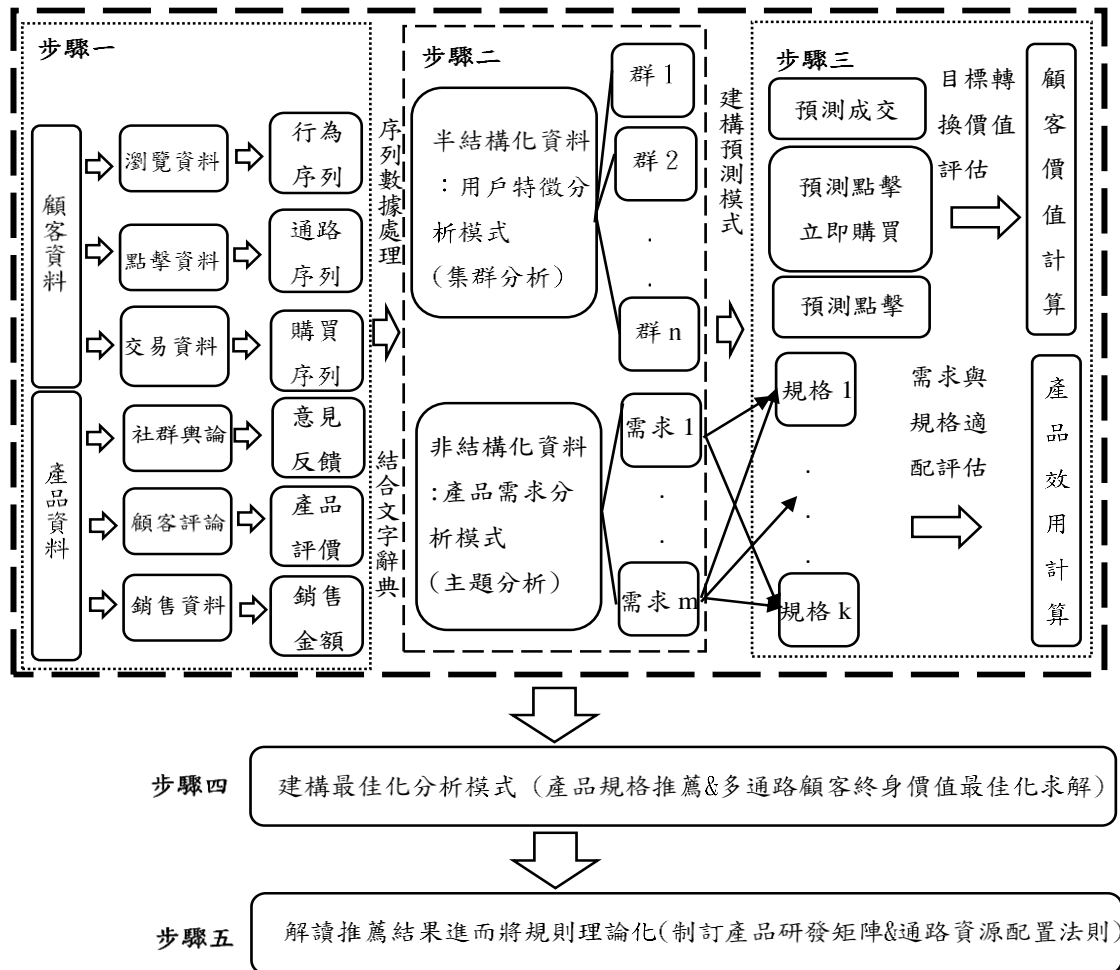


圖17 本研究分析架構圖
(資料來源：本研究整理)

步驟一：本研究根據電子商務常見資料類型制定資料處理流程，本研究從顧客資料與產品資料之前處理出發，顧客資料集包含：瀏覽資料(後轉換成行為序列)、點擊資料(後轉換成通路序列)、交易資料(後轉換成購買序列)；顧客資料集多為時間序列數據，需經過序列處理再進行模型建構。產品資料集包含：社群輿論(後轉換成意見反饋)、顧客評論(後轉換成產品評價)、銷售資料(後轉換成銷售金額)。

顧客資料集則多為文字數據，需與領域專家討論建立關鍵詞辭典，透過文字探勘方法處理文字數據，方能進行分析模式之建立。最後，依據前面的參考文獻，查找電子商務顧客變數與產品變數後，據此確定分析變數與分類線上管道。

步驟二：資料維度轉換主要分為兩個部分，第一部分為半結構化資料之分群建模，其原因為顧客資料多屬序列型、半結構化數據形式，本研究為了讓維度轉換時能保留顧客部分序列特徵，本研究採用自組織映射(SOM)技術建構顧客分群模式，將顧客分成不同集群，不同群體反映出不同購買行為或者其他特徵，而相同的群體則具有相似購買模式，且各群體將保留群中每個顧客序列特徵。另一部分，當遇到非結構化文字型資料時，則運用自然語意理解與隱含狄利克雷分布主題分析技術將文字評論資料轉換成關鍵主題，關鍵主題將包含顧客需求排序以及偏好的產品功能，並將收集的商品資料進行合併，以整合需求端偏好資料與供應端商品資料於後續進行模型分析；

步驟三：預測模式建構分為兩部分，第一部分為顧客購買動作之預測模式，首先是將合併後的顧客資料與分析變數進行分類模型之建構，目標變數分為預測成交、預測點擊立即購買、預測點擊以及跳離四種購買動作類別，目的是運用序列型演算法技術預測所有電子商務顧客在不同通路序列下之購買行為，以進行目標轉換價值之評估，最後根據所有顧客的動作序列之價值計算，獲得當前企業顧客終身價值資訊，作為後續最佳化模型輸入之重要矩陣參數。第二個部分則依據主題模型生成的主題構面，並整合產品類規格資料建構產品需求預測模式，透過整體式演算法將產品需求與產品規格進行整合分析，分析出產品需求對應不同產品規格的最佳評分，以找到符合顧客需求且評分(或滿意度)較高之規格組合，並據此估計顧客對產品之效用值，將預測值及實際值整理成後續模型分析之輸入參數。

步驟四：建構最佳化分析模式，將前述的實際資料與預測的參數資料，轉換成數學矩陣形式，根據企業資源限制下進行最佳化求解。本研究題目有二，第一為對多通路顧客終身價值進行最佳化求解，因考量到數位行銷部門的部門內規與標準

作業流程，本研究據此進行數學模型之建構，並以多目標函數方式表達不同購買動作之轉換價值，並用啟發式架構分析進行最佳化求解，產生所有通路之行銷策略給第一線產品經理使用。第二個研究題目為最佳化產品規格推薦，該題目亦根據產品研發部門鎖定產品類進行最佳化模型建構，將前述生成之顧客需求、產品功能與產品規格資料，運用品質機能展開架構進行整合，藉由啟發式架構分析進行產品效用(或產品價值)最佳化求解，推薦所有匹配顧客消費需求之規格組合，提供給產品研發人員參考。

步驟五：將分析結果提供給第一線決策人員使用，得到反饋後，將規則梳理後轉換為管理法則，進而成為企業標準作業流程的行動準則之一，本研究分別探討產品研發法則、通路資源配置法則。

第四節 研究一分析模式建構與說明

在上述分析架構下，企業面對了解產業數位化轉型及消費行為快速變化，如何在兼顧企業資源、顧客體驗、通路配置等面向有效經營會員，在此顧客旅程管理下，最佳化相關資源配置以達到企業營利最大化。本節將說明研究一之分析模式建構流程，圖18為研究一分析流程圖，以下為研究一分析流程說明：

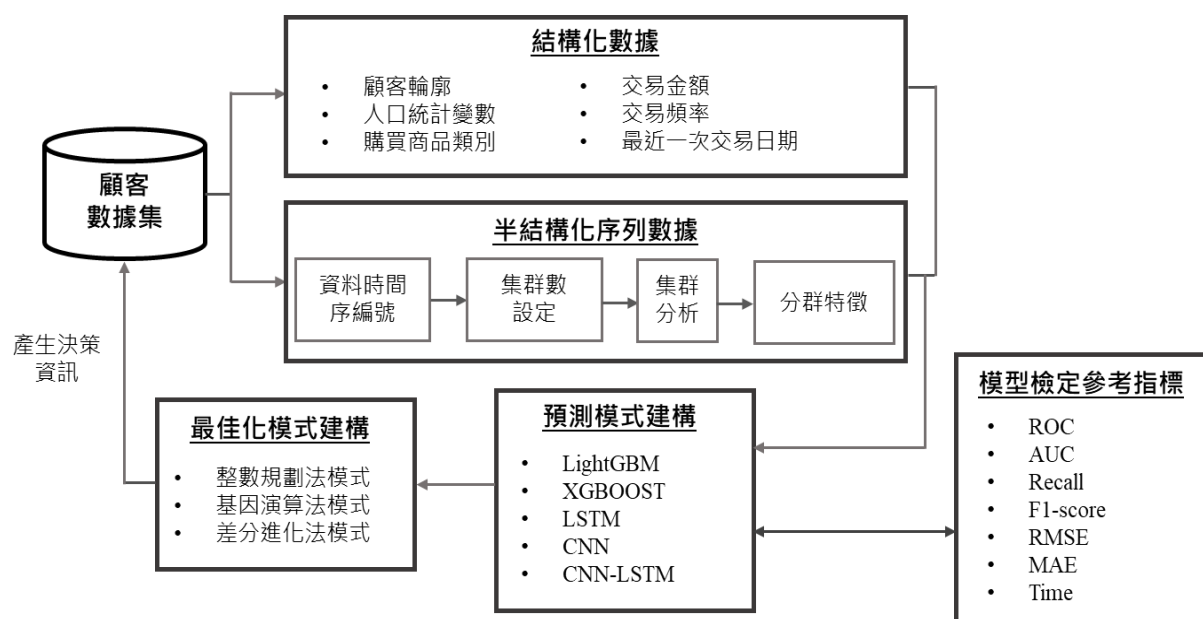


圖18 研究一分析流程圖
(本研究整理)

一、研究一分析流程說明

研究案例一驗證對象為臺灣某金控公司數位行銷部門，驗證資料由該部門的數據應用科提供，以作為本研究所提出分析架構與分析模式展示與應用。研究一分析流程主要為，從顧客數據集中獲取顧客相關資訊的結構化數據，包括從品牌公司資料庫獲得的顧客輪廓與人口統變資訊、交易資料中的購買商品類別、交易金額、交易頻率與最近一次交易日期(可參考 RFM 模型)。半結構化序列數據則為顧客線上資料，包括瀏覽資料、點擊資料、訂單交易資料，其中顧客接觸的管道通路、購買商品、商品文案、行銷文案、網頁行為、使用裝置等皆是以序列型態呈現。在第一階段，本研究根據資料時間點對該些類別資料進行編號，以保留類別資料的順序性，包含數據編號、數據合併與數據轉換。數據合併涉及對顧客線上數據與線下交易數據進行排序與合併；在數據轉換中，識別通路與管道數據，將各種來源/媒介資訊(例如，Google 廣告、原生廣告、不同的網站來源、跨平台行銷)根據分類本研究八種管道分類形式以二進制與順序格式表達。接著採用自組織映射(SOM)基於顧客基本輪廓、線上購買行為與其序列性進行用戶特徵分群模型之建構，對每個用戶的行為變量(A_{il})進行集群分析，將用戶分組成多個集群(Z_{ik})，並最小化殘差平方、確定目標群體(k)的最佳分群數量，分析不同購買階段的用戶特徵奠定基礎，提供顧客經營管理部門分群策略之參考。第二階段，運用不同預測模型技術處理用戶的序列數據，以預測顧客後續購買行為，例如點擊按鈕(AC_3)、點擊購買按鈕(AC_2)或實際購買(AC_1)；根據不同購買行為估計目標轉換價值數值，如交易收入(R_{ij})、點擊購買按鈕的轉換值(CL_{ij})與點擊按鈕的轉換值(S_{ij})。並以常見的模型檢定指標進行模型檢定。第三階段，運用不同啟發式演算法最佳化多通路顧客終身價值，透過文獻回顧與訪談確定模型限制條件，並將產生的通路規畫方案回饋至資料庫中，整合至企業管理系統，提供給第一線人員使用。如圖 19 所示。資料源可從網站收集用戶線上通路的行動序列資料，按照網站互動時間、工作階段進行排序，每一次顧客與網站的互動

被定義為一個工作階段，而該工作階段會根據顧客事件順序進行數據紀錄，這些資訊將作為線上通路行為與互動序列的分析基礎，用以預測顧客的後續購買行為與目標轉換價值。

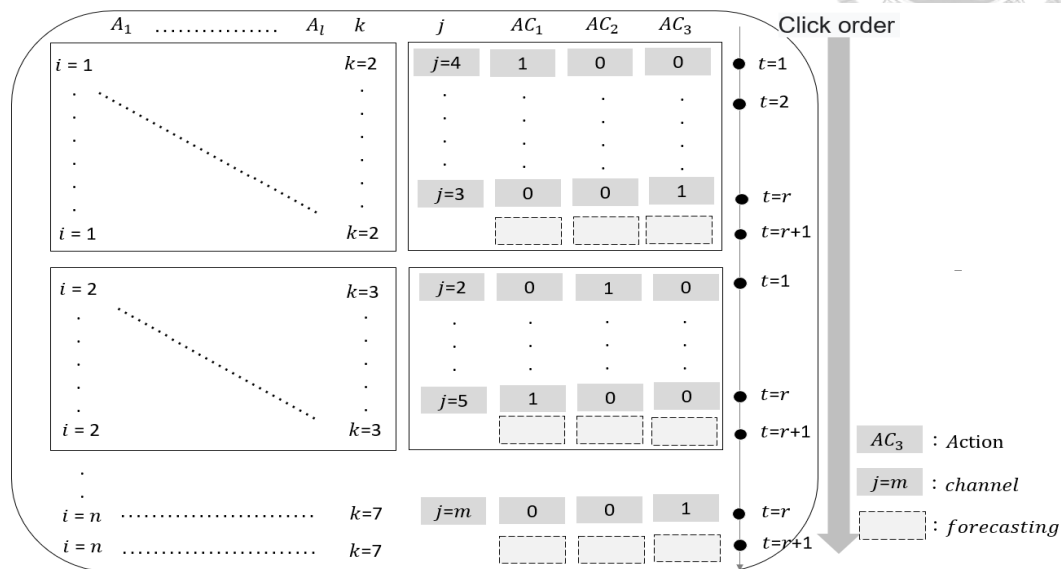


圖19 整合模式資料結構示意圖

二、預測模式建構及建模方法比較

本章節首先建構電子商務之顧客目標轉換價值預測模式，並將該預測模式分為兩階段，第一階段為目標顧客集群探討，參數以用戶欲行銷集群數為設定值；第二階段則建構機器學習預測模式之輸入因子探討參數之敏感度及最佳參數。為提供一個完整應用於即時預測的目標轉換預測模式，本研究遂使用序列型演算法建構各通路轉換預測模式，處理前1~2通路類別，以便提供通路轉換預測進行1~3通路類別下購買行為預測。過去的研究常以一般線性模式的分析方法來探討通路效益，但這樣的分析方法，往往忽略通路序列特徵，意即「通路接觸順序」與「購買行為特徵」可能有交互作用的效果存在，使得資料結構產生不穩定性與異質性，導致線性模式的係數估計結果產生偏誤，並降低解釋能力。以序列演算模式中的循環神經網絡機制、門控循環單元（Gated Recurrent Unit, GRU），或考慮到時間相依性、將序列數據轉換為固定大小的特徵向量進行梯度提升樹建模，根據不同類型顧客的行銷通路，分別建構預測模型，除了能夠探討在不同顧客類型在各通路特徵變數對於收視戶的廣告收視時間之影響，也能了解由於購買行為特徵使得

通路特徵變數對於購買轉換影響的變化程度。



表6 研究一建模方法優劣勢比較

| 預測模式 | 建模分析方法 | 優勢 | 劣勢 |
|------------|----------------------------|---|--|
| 顧客購買動作預測模式 | 深度學習預測模式：循環神經網絡機制、門控循環單元機制 | 運用多層神經網路提升模型訓練複雜度，擅長運用維度轉換方式，處理序列型數據，模型預測較強，具嚴謹數學推論。 | 倚賴人工選擇參數，需不斷測試方能找出最佳測，且試訓練時間較長，模型穩健度較差，深度神經網路架構複雜性太高，導致黑盒情況、難以解釋模型，商業運用能力較差。 |
| | 整體式學習預測模式 | 模型巨量平行處理能力與推論能力較強，具容錯能力、能過濾雜訊特性，較能適應不同分布資料，且無須設立許多假設條件就能進行求解，模型穩健度高。 | 倚賴人工選擇參數，需不斷測試方能找出最佳測，亦會因為整體學習模型複雜度太高，導致黑盒情況、及訓練時間過長之問題 |
| | 本研究提出整合型最佳預測模式 | 本研究將分析方法模組化，同時包括多個子模組，可隨時運用集群方法或主題分析法支援資料與變數降維，亦可根據輸入資料分布與特性選擇最適分析模組，迴避參數試驗與訓練時間過長問題。 | 實際運行時，因涉及許多模組與資料流程的建立，系統設計較為複雜，需倚賴大型資料庫或雲端資料庫雲算方能容納該複雜系統架構。較適合大型公司，如控股公司，中小型公司較無資源採用該模式。 |

本研究輸入變數為顧客各通路四個時刻之線上行為、購買行動及顧客基本輪廓，為更加了解顧客購買動作預測模式，並使預測模式更加精準，本研究遂探討不同序列演算機制對顧客購買動作預測模式之建構影響，分別以幾種演算機制進

行預測與目前模式做為比較，顧客購買動作預測模型反應變數 (Response Variable) 為點擊按鈕 (AC_3)、點擊購買按鈕 (AC_2)、實際購買 (AC_1) 以及跳離，再根據所有顧客各階段的購買動作，依據研究案例公司的目標轉換價值公式進行估算，計算所有顧客終身價值。解釋變數：性別、年齡、顧客集群、購買商品、工作階段來源/媒介(顧客接觸通路)、瀏覽網站內容(顧客接觸商品內容)、廣告活動(顧客接觸行銷活動)、廣告內容(顧客接觸行銷文案)、裝置類別(顧客使用裝置)、瀏覽器類別(顧客使用瀏覽器)、使用者類別、交易金額、最近一次購買日期、交易頻率、工作階段數、工作階段日期、工作階段時間、網站數等變數。鑒於這些分析方法會因為每次餵入的資料分布與特性不同，可能導致模型性能優劣情勢互換；如上所述，本研究探討不同序列演算機制模型建構與目前模式比較，並以指標評估模型效能，即時選擇效能最佳的分析方法，進而精準地預測顧客購買行為。表6根據文獻方法討論不同建構方法的優劣勢。

三、最佳化多通路顧客價值量化模型

本研究依據顧客旅程購買前與購買時流程與運作機制，建立確定型多通路顧客價值最佳化混合整數線性規劃模式，本節主要說明參數符號、模式建構內涵等。

表7 參數符號說明

| 參數符號 | 數值區間 | 中文涵義 |
|--------|--|-------------------------|
| i | $i=1$ (第一位顧客), 2 (第二位顧客)…… n (第 n 顧客, 根據資料顧客數決定) | 顧客編號集合 |
| j | $j =1$ (通路1), 2 (通路2)…… m (通路 m , 根據資料通路數決定) | 通路編號集合 |
| t | $t =1, 2, 3$ …… r (工作階段 m , 根據顧客的工作階段平均數決定) | 工作階段編號, 用於識別序列次序 |
| k | $k =1$ (集群1), 2 (集群2)…… k (通路 k , 根據設定集群數決定) | 顧客集群集合 |
| AC | $AC =AC_1$ (網頁點擊), AC_2 (點擊立即購買), AC_3 (實際購買) | 顧客購買動作集合 |
| AC_1 | 1 or 0 | 如果顧客點擊網頁為1, 否則為0, 為二元數據 |

| | | |
|-----------|--------------------------------------|---|
| AC_2 | 1 or 0 | 如果顧客點擊立即購買為1，否則為0，為二元數據 |
| AC_3 | 1 or 0 | 如果顧客實際購買為1，否則為0，為二元數據 |
| S_{ij} | 數值數據，由公司提供資料與預測模式估計產生，根據公司決定目標轉換價值區間 | 顧客 <i>i</i> 透過通路 <i>j</i> 點擊網頁之目標轉換價值 |
| CL_{ij} | 數值數據，由公司提供資料與預測模式估計產生，根據公司決定目標轉換價值區間 | 顧客 <i>i</i> 透過通路 <i>j</i> 點擊立即購買之目標轉換價值 |
| R_{ij} | 數值數據，由公司提供資料與預測模式估計產生，根據公司決定目標轉換價值區間 | 顧客 <i>i</i> 透過通路 <i>j</i> 實際購買轉換之目標轉換價值 |
| A_{il} | 1 or 0 | 用於分群的變數，顧客 <i>i</i> 具有變數特徵 <i>l</i> 為1，否則為0，為二元數據 |
| Z_{ik} | 1 or 0 | 顧客 <i>i</i> 屬於集群 <i>k</i> 為1，否則為0，為二元數據 |
| N_k | 數值數據，根據公司管理者決定最低觸及目標 | 觸及最大需求人數 |
| C_{1j} | 為數值數據，根據代營運商競價決定的達成目標之轉換成本 | 透過通路 <i>j</i> 達成網頁點擊目標之轉換成本 |
| C_{2j} | 為數值數據，根據代營運商競價決定的達成目標之轉換成本 | 透過通路 <i>j</i> 達成立即購買點擊目標之轉換成本 |
| C_{3j} | 為數值數據，根據代營運商競價決定的達成目標之轉換成本 | 透過通路 <i>j</i> 達成實際購買目標之轉換成本 |
| D_j | 為計數數據，根據公司管理者決定通路運行日 | 通路 <i>j</i> 運行日期 |
| d_j | 為計數數據，根據公司管理者決定通路運行天數 | 通路 <i>j</i> 最大運行天數 |
| E | 為數值數據，根據公司管理者決定獲客整體預算 | 單位預估獲客成本之總預算 |
| X_{ij} | 1 or 0 | 通路 <i>j</i> 觸及顧客 <i>i</i> 為1，否則為0，為決策變數與二元數據 |
| Y | 為數值數據，根據公司數位行銷部門討論出顧客終身價值估算公司進行計算 | 最大化單位之多通路顧客目標轉換價值，為目標函數 |

表8 量化模式建構說明

| 數學式 | 中文涵義 | 讀取資料 |
|--|--|---|
| $\begin{aligned} \text{Max } Y = & \sum_i \sum_j R_{ij} X_{ij} \\ & + \sum_i \sum_j CL_{ij} X_{ij} \\ & + \sum_i \sum_j S_{ij} X_{ij} \end{aligned}$ | <p>為該量化模式之目標函數，最大化所有顧客的購買動作目標轉換價值</p> | <p>$R_{ij} X_{ij}$：所有顧客在不同通路的實際購買轉換價值的參數資料 $CL_{ij} X_{ij}$：所有顧客在不同通路的點擊立即購買轉換價值的參數資料 $S_{ij} X_{ij}$：所有顧客在不同通路的點擊網頁轉換價值的參數資料</p> |
| $\sum_j D_j X_{ij} \leq d_j$ <p style="text-align: center;">$i = 1, 2, \dots, n$</p> | <p>顧客被觸及與通路資源限制，顧客盡可能不要被通路長時間觸及，導致顧客流失，以及資源重複觸及情況。</p> | <p>d_j：每個通路合約的運行時間資料 D_j：每個通路決定的運行時間資料</p> |
| $\sum_j C_{1j} X_{ij} + \sum_j C_{2j} X_{ij} + \sum_j C_{3j} X_{ij} \leq E$ <p style="text-align: center;">$i = 1, 2, \dots, n$</p> | <p>盡可能有效分配所有通路目標轉換成本</p> | <p>$C_{1j} X_{ij}$：所有顧客透過不同通路達成網頁點擊目標之轉換成本的參數資料 $C_{2j} X_{ij}$：所有顧客透過不同通路達成立即購買點擊目標之轉換成本的參數資料 $C_{3j} X_{ij}$：所有顧客透過不同通路達成實際購買目標之轉換成本的參數資料 E：獲客總成本，由管理者設定</p> |
| $\sum_i Z_{ik} X_{ij} \leq N_k$ <p style="text-align: center;">$k = 1, 2, \dots, k;$ $j = 1, 2, \dots, m$</p> | <p>目標受眾限制；每一位顧客所屬各自集群與變數特徵，每群集群內所有人員不能超過各自觸及最大需求人數</p> | <p>$Z_{ik} X_{ij}$：所有集群被不同通路觸及人數的參數資料 N_k：觸及最大需求人數，由管理者設定</p> |
| $\sum_i X_{ij} < 5$ <p style="text-align: center;">$j = 1, 2, \dots, m$</p> | <p>每人數最多被通路觸及5次</p> | <p style="text-align: center;">-</p> |

在本研究量化模式架構下，包含有顧客點擊網頁目標轉換價值指標、顧客點擊立即購買目標轉換價值指標與顧客實際購買轉換目標轉換價值指標等三個目標函式，並尋求獲客成本、通路運行時間、顧客集群、顧客行為等相關限制情況下最佳通路資源配置決策。在顧客購買動作目標函式的建構方面，本研究根據購買階段將顧客動作概分為網頁點擊、點擊立即購買、實際購買三動作，所提出之三個重要購買動作參數-點擊網頁之目標轉換價值、點擊立即購買之目標轉換價值與實際購買轉換之目標轉換價值，作為評判顧客各購買流程需要採用的最佳通路決策。管理者期望能透過此量化模式有效識別高價值用戶的行為特徵、所有顧客被觸及通路之規劃設定、評估所有通路的目標轉換價值，進行整體獲客成本之運籌帷幄及布局會員經營管理。

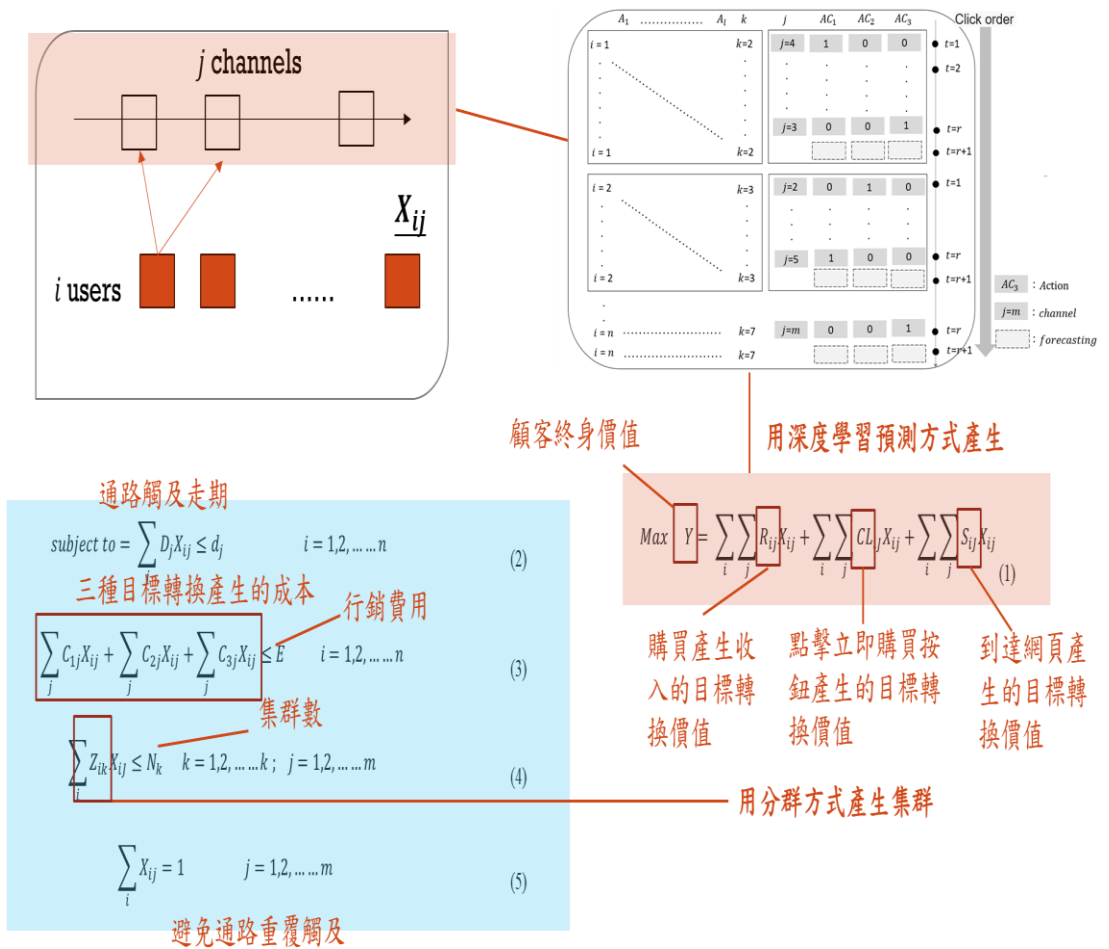


圖20 研究一多通路顧客價值最佳化數學模型
(本研究整理)

第五節 研究二分析模式建構與說明

在整體分析架構下，研究二囊括製造業之QFD法、以及上述提供之演算模式、分析架構以執行實際產品開發之研發參數推薦。本節將說明研究二之分析模式建構流程，圖20為研究二分析流程圖，以下為研究二分析流程說明：

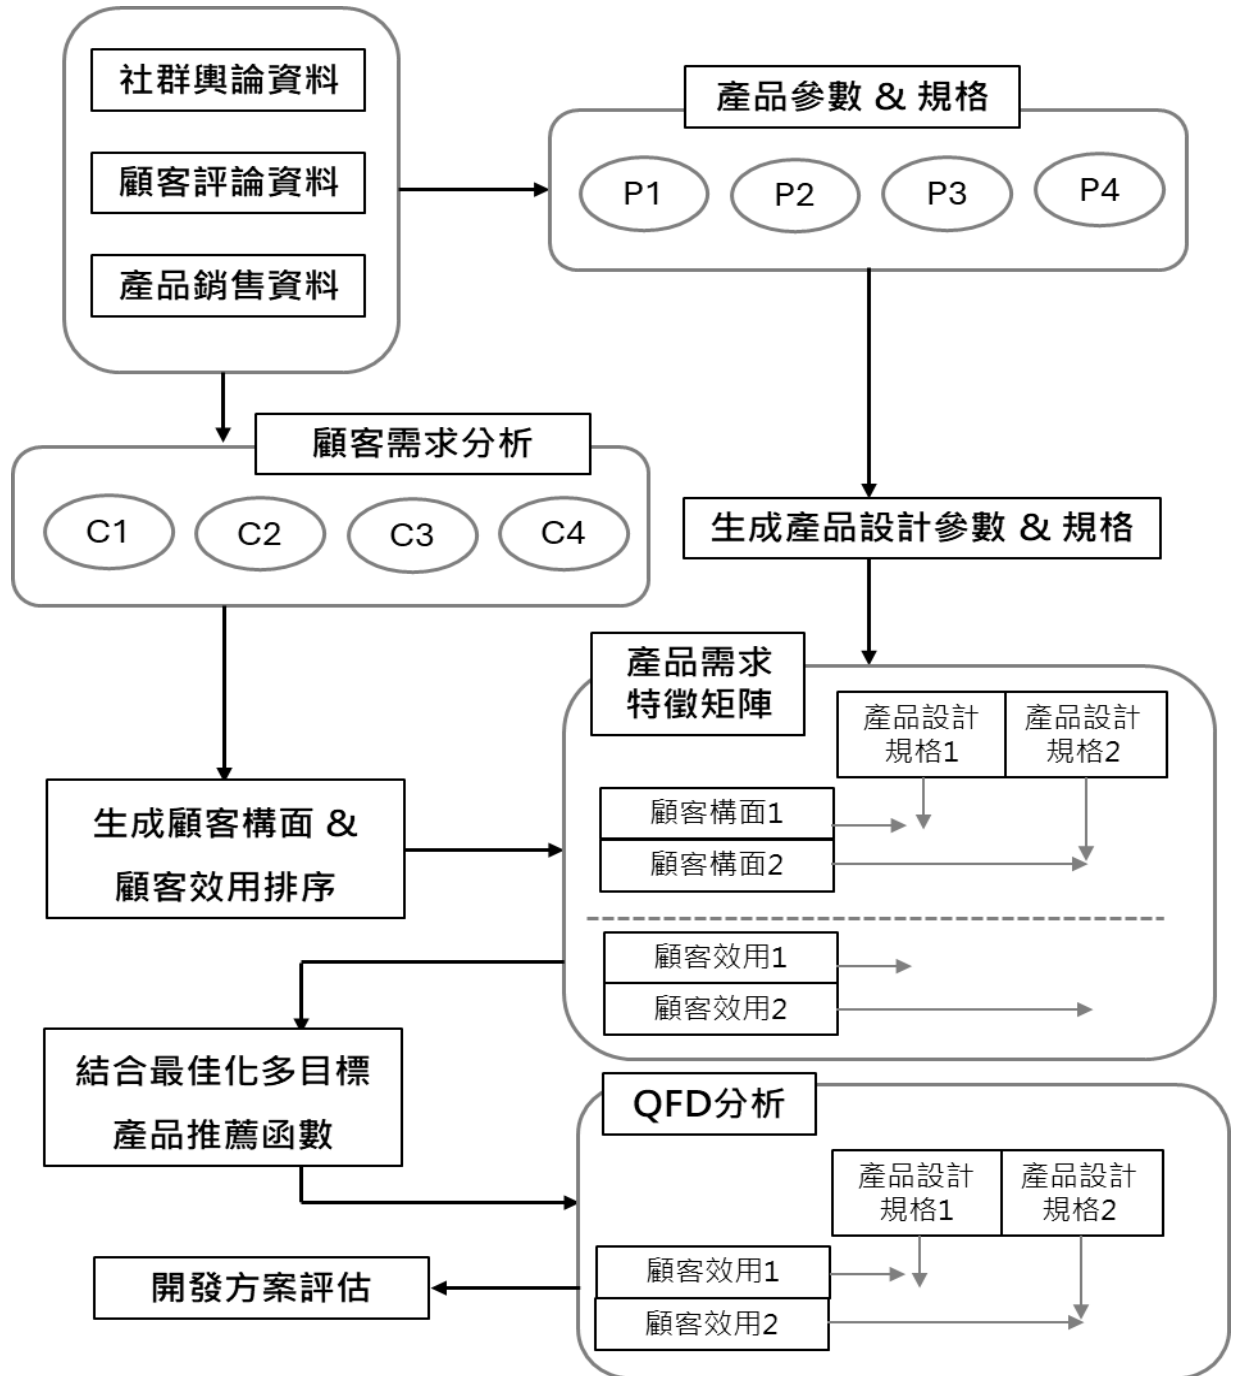


圖21 研究二分析流程圖
(本研究整理)

一、研究二分析流程說明

本研究運用上述介紹演算技術進行產品需求分析、產品規格分析、產品規格最佳化推薦，分析電子商務的產品評論及產品資訊，如產品規格、銷售數據以及使用者對這些產品評價與評論，並藉由數據分析後建立預測模型，以協助製造商了解產品使用者會在意哪些需求和規格，並且分析這些需求與規格間的關係，最後再依啟發式演算法推薦產品規格，產生產品推薦清單。該分析流程有四個執行步驟，包括建置數據處理流程、建構顧客需求分析、需求轉規格分析、最佳化產品規格推薦之開發方案評估階段。首先，數據處理流程為收集研究案例公司之目標製造產品的社群輿論資料、顧客評論資料、產品銷售資料等資訊，主要來自大型電子商務平台(例如：亞馬遜電子商務平台)，產品評分數據根據李克特量表分為1到5分。本研究資料處理流程，提取轉換載入(extract, transform, load, 簡稱為ETL)模式是要針對製造業，建立並提供整體產業都適用的市場端數據分析架構，藉以建構產業在研發端產品開發數據庫的基礎。主要為建立目標市場數據集、建立數據源串流、建立結構化與非結構化數據處理規則、建立數據倉儲、建立結構化查詢資料庫(SQL)。再確認欲建置的數據來源之後，進一步協助建置API串流獲取亞馬遜產品評論數據與評價數據，資料格式主要為非結構化，將蒐集到的產品評論數據與為結構化數據主要有三步驟，將API蒐集到原始數據以json檔格式開啟，透過資料清洗的程式碼，將非結構化與半結構化資料json檔轉換成結構化資料csv檔，將需要的變數逐欄覆寫成可分析的產品評論數據，清洗後產品評論數據整合導入數據至目標市場數據集中，定期從API讀取數據(取出)，按照上述步驟將取出的資料進行轉換、清理，及處理一些容錯或有問題的資料，並統一異質的資料格式(轉換)，最後再將轉換完的資料匯入雲端數據庫中(載入)使後續製造產業能夠具備豐沛的數據。接著結合自然語意處理技術流程將評論根據顧客需求-產品規格-產品評價的關聯鏈結，並透過設定截取得到價值階梯圖萃取最關鍵資訊之鏈結作為相關性分析階段參數。再透過隱含狄利克雷分布分析建構顧客需

求(主題)與產品規格(主題內關鍵詞)，主題數選擇為，透過文獻回顧產品關鍵變數，找出影響顧客對產品效用或產品感知的關鍵變數，再與案例公司的產品經理與管理者進行深入訪談，確定關鍵產品規格分類、特定產品認證、其他技術考慮因素、以及主流消費者產品期望等。最後確定最佳的主題數量，該過程涉及許多商業分析以解釋不同主題結果，並與產品經理討論反饋，評估所得主題有效性。本研究運用主題分析產生的資料與特徵矩陣，合併商家提供的產品規格資訊，作為整體式學習預測模式之輸入變數，進行顧客評分的分析與預測，找出不同顧客需求下所有的產品規格之顧客滿意評分，並與其他基準模型比較，如比較梯度增強決策樹、卷積神經網絡、長短期記憶等技術，將輸出結果作為最佳化模型之參數輸入。

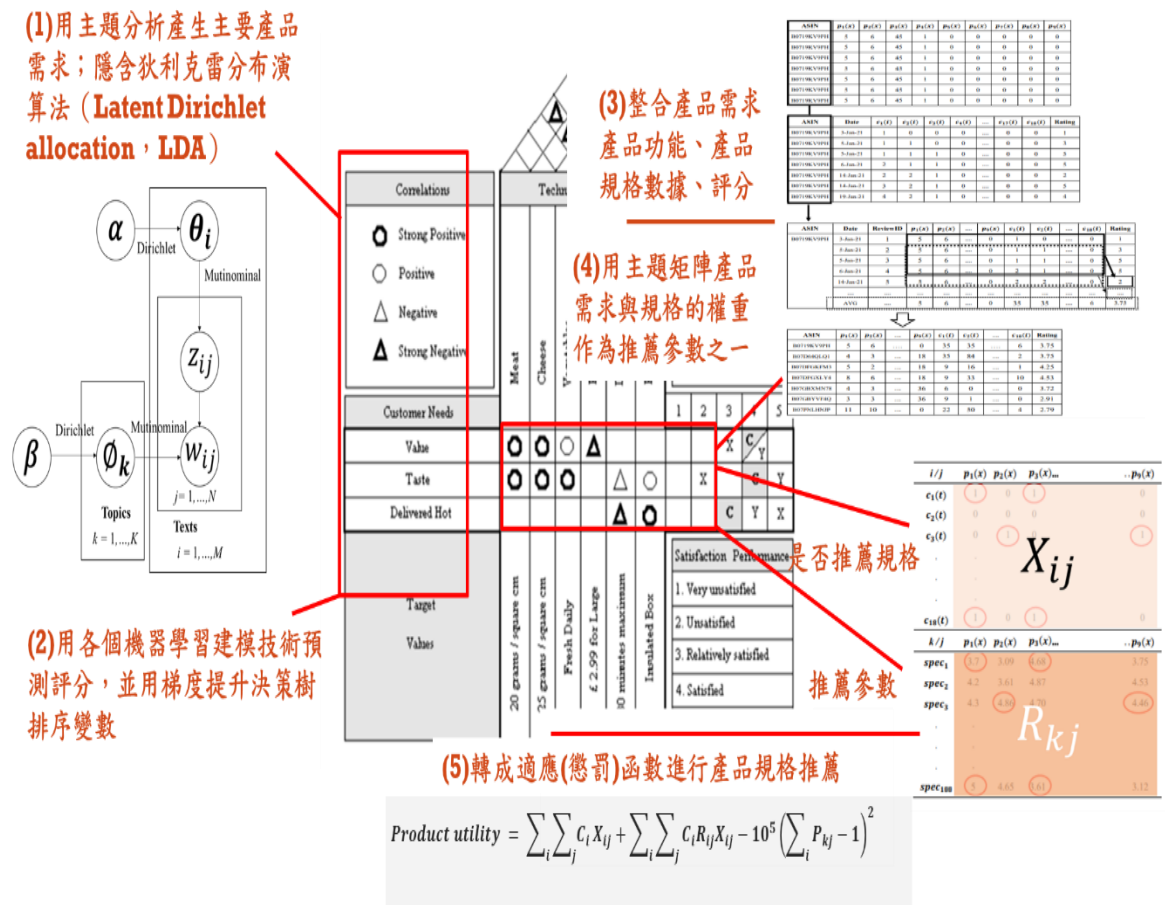


圖22 研究二 QFD最佳化產品規格推薦架構圖 (本研究整理)

二、推薦模式建構及建模方法比較



表9 研究二推薦方法優劣勢比較

| 推薦模式 | 推薦分析方法 | 優勢 | 劣勢 |
|-------------|--|--|--|
| 最佳化產品規格推薦模式 | 基於使用者的推薦方式、基於產品的推薦方式：主要利用排序方式、相關性分析方式、矩陣模糊評分方式 | 推薦分析結果容易瞭解，且建構的模式容易再使用，有效整合資料庫變數，執行速度較快。 | 分析方式多為敘述統計方法，依賴人工分析。而人工決斷易存有分析者偏見而影響決策。單一構面的推薦方式較顯粗糙，難以做到個人化推薦。 |
| | 混合用戶偏好、產品內容、產品類別等任兩者的協同過濾推薦：關聯規則分類方式推薦、集群分析推薦 | 分析用戶及產品元素之間的相似性，有助於綜合評估顧客偏好與產品需求，進行較為精準的推薦，並可清楚比較推薦達成情況。 | 主要採用企業歷史資料進行推薦，而企業數據通常有資料稀疏性問題。並且當有新用戶或新產品加入，系統將遭遇冷啟動問題、無法執行推薦。 |
| | 本研究提出人工智慧方法輔助品質機能展開 | 能處理非結構化文字數據，並作為特徵分析，建構顧客需求與產品功能、產品規格之關係鏈結，補足企業無結構化數據處理機制，迴避新產品或新用戶啟動問題，根據顧客需求、需求與規格關聯性、產品效用進行最佳化產品規格推薦，解決研發模組組合問題。 | 實際運行時，因涉及許多模組與資料流程的建立，系統設計較為複雜，需倚賴大型資料庫或雲端資料庫雲算方能容納該複雜系統架構。較適合大型公司，如控股公司，中小型公司較無資源採用該模式。 |

本章節根據研究二分析流程建構電子商務之最佳化產品規格推薦機制，首先探討過往文獻中的推薦方法，根據表格比較結果，如表9所列推薦方法優劣勢比較，可看出本研究提出模式有幾個好處，茲整理如下：(1) 相較於單獨推薦模式與整合兩者之協同過濾推薦模式，人工智慧方法輔助品質機能展開模式整合大量

非結構化顧客需求評論的資料，與研發產品規格資料，以主題分析與機器學習方式進行資料探勘，找出有因果意義的關係或鏈結；運算後除了可以得到顧客特徵重要性排序，亦可快速推薦符合該些顧客需求的產品研發規格；(2) 過往文獻中的推薦方法，會面臨無法人工偏誤、個人化推薦、資料稀疏性、冷啟動等問題。人工智慧方法輔助品質機能展開模式先運用主題分析處理非結構化文字數據，作為特徵分析，建構顧客需求與產品功能、產品規格之關係鏈結，補足企業無結構化數據處理機制。第二階段則用機器學習技術整合產品需求與產品規格建立預測機制，迴避新產品或新用戶啟動問題；第三階段在不存在硬計算公式的產品價值評估公司，可以運用最佳化方法執行由企業場景建構之產品推薦數學模型，根據顧客需求、需求與規格關聯性、產品效用進行最佳化產品規格推薦，解決研發模組組合問題。本研究輸入變數為顧客在不同平台的產品評論、產品評價及商家端的產品內容(產品功能、產品規格)與產品銷售金額，為更加了解顧客對產品需求與偏好規格，透過主題分析生成主題，了解不同產品需求下的顧客偏好功能和規格，並分別以不同演算機制建構顧客需求對不同產品規格之產品滿意度與其影響，反應變數產品評分，往後分別以給定的需求進行新產品規格推薦。最後再根據顧客需求排序、顧客需求與產品規格的關聯性、產品規格效用進行估算。解釋變數由第五章研究二主題分析結果詳述。

三、最佳化產品規格推薦量化模型

本研究依據顧客旅程購買後流程與運作機制，建立確定最佳化產品規格推薦之啟發式運算模式；本研究依文獻整理，以及與專家訪談後對各項作業流程的了解，初步建構數學產品規格推薦之適應函數，將上述數學模式轉換為適應函數，以製造業產品開發過程相符的數學計算。顧客需求與產品規格之間的關係作為決策變量 (X_{ij})、顧客需求與產品規格評分 (R_{ij})、顧客需求與產品規格之相關程度 (C_{ij}) 以及每個產品功能對應的產品規格 (P_{kj})，每個產品功能需要與一個產品規格配對，透過懲罰函數加入軟限制式盡可能遵守限制條件，依照上述流程進

行最佳化分析，以進行研發單位最佳化不同規格組合與資源配置。藉由分析成果，依據預測之終端用戶對產品評價進行最佳化產品規格推薦，進行規格組合與資源配置估算，並找出最佳產品研發法則。

本節主要說明參數符號、模式建構內涵等。



表10 參數符號說明

| 參數符號 | 中文涵義 | 讀取資料 |
|---|--|---|
| i | $i=1$ (第一個顧客需求), 2 (第二個顧客需求) $\cdots n$ (第 n 個顧客需求, 根據分析結果顧客需求數決定) | 顧客需求編號集合 |
| j | $j =1$ (產品規格1), 2 (產品規格2) $\cdots m$ (產品規格 m , 根據產品規格數決定) | 產品規格編號集合 |
| k | $k =1$ (產品功能1), 2 (產品功能2) $\cdots k$ (產品功能 k , 根據設定產品功能數決定) | 產品功能集合 |
| C_{ij} | 數值數據, 為主題特徵矩陣, 根據顧客產品需求與產品設計特徵配適值的矩陣 | 顧客需求 i 與產品規格 j 配適值 |
| R_{ij} | 數值數據, 為產品需求對應產品規格之評分, 結合真實評分與預測評分的矩陣 | 顧客需求 i 與產品規格 j 評分值 |
| P_{kj} | 數值數據, 為產品功能與產品規格的對應值 | 用於對應功能與規格, 功能 k 具有規格 j |
| X_{ij} | 1 or 0 | 顧客需求 i 匹配產品規格 j 為1, 否則為0, 為決策變數與二元數據 |
| $\begin{aligned} & \text{Max Product utility} \\ & = \sum_i \sum_j C_{ij} X_{ij} \\ & + \sum_i \sum_j R_{ij} X_{ij} \\ & - 10^5 \left(\sum_i P_{kj} - 1 \right)^2 \end{aligned}$ | 最大化產品效用價值, 並確保每個產品功能對應一個產品規格, 產品參數矩陣示意如下圖21: | $C_{ij} X_{ij}$: 所有顧客需求與產品規格特徵值參數資料 $R_{ij} X_{ij}$: 有顧客需求與產品規格評分參數資料 P_{kj} : 所有產品功能與產品規格的對應資料 |

藉由建構產品需求與產品規格分析與預測模式，以識別出產品需求與產品規格之配適程度。相較於以往製造業人工判斷研發規格，或透過研討會收集產品資訊。該模式能以自動化方式進行產品分析，尋找出隱藏具價值的產品特徵，有助於增進製造業領域的產品研發決策。


第四章 研究一：多通路顧客價值最佳化求解

因應數位化轉型、電子商務等議題的持續升溫，企業對於數位行銷管理有效運用行銷資源、數據分析技術，更是近幾年企業經營關切之重要課題。本研究期望透過多通路顧客價值最佳化模式的建立，提供企業在資源有限下進行最佳化決策運用。為了評估本研究數量模式可行性，將以實際個案與實際企業資料，進行後續的概念性驗證分析。本研究係以國內一間大型金控的數位發展部數據為例，透過與高階管理者與第一線決策者的訪談，了解該公司的運營管理模式與數位行銷流程，包含從顧客分析、商品提案與開發、行銷通路開發、行銷計畫、測試驗證、數據收集工具、數據分析與回饋等。

再藉由Google Tag Management(GTM)與Google Analytics(GA)工具進行為期兩年半的顧客線上數據收集，採用壽險商品類顧客數據、年金險商品類顧客數據、旅平險商品類顧客數據及意外險商品類顧客數據進行分析，相關欄位如：用戶類型資料、瀏覽次數、來源/媒介、到達網站資料、使用裝置瀏覽器等。另整合公司會員可識別化資料，透過串接交易資料庫，取得顧客基本資料與歷史資料，如顧客年齡、性別、居住地、投保保費、投保險種、投保保額、投保時間等資訊，以利後續根據交易模型及活躍度分析計算每一位顧客終身價值，並將其與顧客購買行為與購買通路進行整合分析，設定後續預測模型的目標變數。

在完成相關資料收集與整合之後，於本章節根據不同階段分析結果進行說明與探討，第一階段建立分群模式，運用R軟體建立訓練模型，執行SOM演算法進行集群分析；第二階段建立預測模式，運用Python建立訓練模型，執行不同序列型演算法執行預測，檢定指標測試不同模式準確度及穩健度，建立最佳預測模式。

第三階段轉換成最佳化模式，輸入情境參數資料，運用LINGO與GAMS軟體執行整數規劃運算、R軟體執行啟發式演算運算。將最佳化結果輸入顧客關係管理系統，設定目標客群行銷通路進行接觸，即時追蹤與計算所有顧客之通路轉換價值與總價值，並提出通路配置之管理法則與綜合討論。



第一節 研究案例說明

為了驗證本研究所提出多通路顧客價值最佳化量化模型的可行性，本研究以國內一間金控公司之數位發展部門的數位行銷工作流程與真實數據作為研究案例，依據該部門數位行銷運作架構與流程，建立本研究量化分析模式之訓練模型數據及最佳化模型之相關參數。該公司近年提供電子商務網路投保服務流程，並打算建立線上顧客關係管理機制，希望有效追蹤與管理顧客。經與部門管理者深入訪談，管理者提出三個主要的顧客分析需求，第一為，將顧客依據購買行為分群，根據不同集群顧客建立不同層級的會員管理機制；第二為，促進所有顧客不同購買階段目標之達成轉換率，並進行可持續性的有效監督；第三為，希望能夠最佳化部門資源調度與行銷預算分配，並建立通路資源配置準則強化部門運營。以下詳述部門作業痛點與本研究解決方案，彙整如圖22。

首先，在目標顧客經營階段，公司部門產品經理較常採用方式是，按照資料庫顧客購買金額高低，再將所有顧客概分為VIP顧客群、主力顧客群、小資顧客群三類，定期撈取該些顧客名單發送行銷郵件，與其互動。然而，該方式僅對有購買金額紀錄的顧客進行互動，導致資料庫仍有75%以上顧客未被觸及，進而累積大量未經營之沉睡顧客，未有效進行顧客經營。而本研究根據所有顧客的購買行為進行集群分析建模，透過模型分群並產生分群特徵與分群規則，其分出原有VIP顧客群、主力顧客群、小資顧客群之外，還為其產生更多的行為特徵，協助產品經理了解顧客輪廓與顧客行為，幫助其對目標族群採取更有效的經營，此外，還另外產生潛在顧客群、靜止顧客群、瞌睡顧客群、流失顧客等四群顧客群。產品經理更為這四種群體的顧客制定會員經營計畫，使其回購產品，本研究提出方

式協助部門有效運用所有顧客資料，並進行更精準地顧客經營。

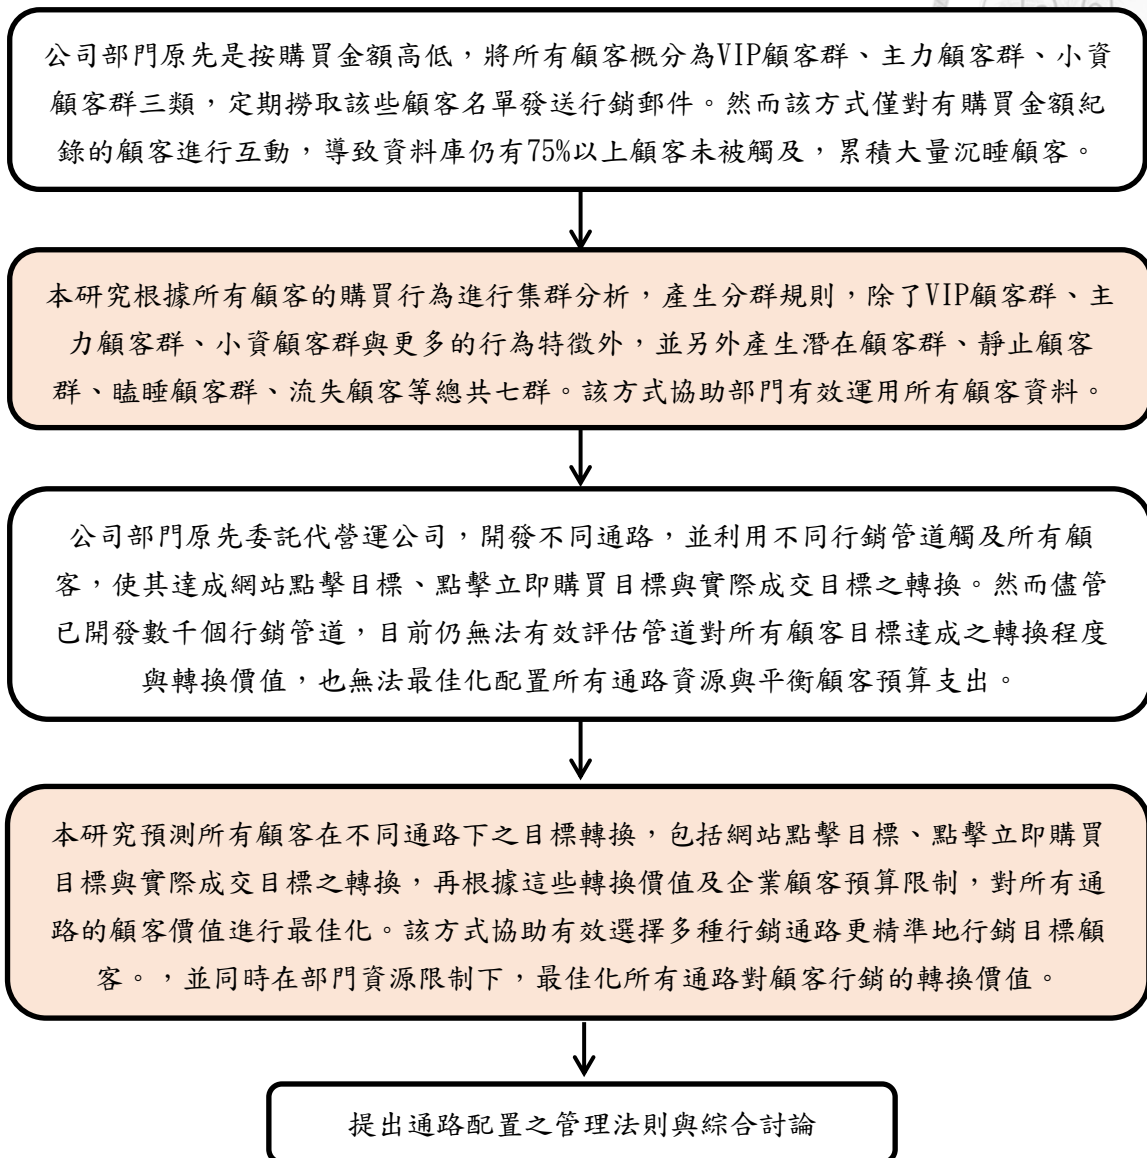


圖23 作業痛點與本研究提出之解決方案
(本研究整理)

其次，在行銷階段，公司部門通常委託代營運商(或稱廣告商)進行行銷通路的開發，並利用不同行銷管道觸及所有顧客，使其達成網站點擊目標、點擊立即購買目標與實際成交目標之轉換。然而儘管已開發數千個行銷管道，目前仍無法有效評估管道對所有顧客目標達成之轉換程度與轉換價值，也無法最佳化配置所

有通路資源與平衡顧客預算支出。本研究預測所有顧客在不同通路序列下之目標轉換，包括不同通路的網站點擊目標、點擊立即購買目標與實際成交目標之轉換，再根據這些轉換價值及企業顧客預算限制，對所有通路的顧客價值進行最佳化，本研究提出方式協助產品經理有效選擇多種行銷通路更精準地行銷目標顧客，並同時在部門資源限制下，最佳化所有通路對顧客行銷的轉換價值。

最後，以企業經營的角度，管理者希望據以上新流程建立新的部門管理準則。因此本研究探討預測分析與最佳化規劃之分析規則，進而發展成通路配置之管理法則，以此協助管理者有效達到更有效的管理。

本研究以應用程式界面(Application Programming interface, 簡稱API)對接方式，收集執行量化分析模式之顧客資料與相關參數資料，本研究先在金控官方網頁、商品網頁、內容網頁等到達網頁運用Google Tag Management 埋下追蹤程式碼，再啟用Google Analytics 來監控網站、線上用戶行為、購買交易等紀錄。資料擷取時間為該公司業績最好的期間，2020年3月至2020年11月，資料集包含180,760筆用戶記錄，共有793個來源/媒介，根據文獻的行銷管道分類，彙整為七種行銷通路；每個用戶都有單獨UserID，用於資料串接。使用變數為，性別、年齡、購買商品、工作階段來源/媒介(顧客接觸通路)、瀏覽網站內容(顧客接觸商品內容)、廣告活動(顧客接觸行銷活動)、廣告內容(顧客接觸行銷文案)、裝置類別(顧客使用裝置)、瀏覽器類別(顧客使用瀏覽器)、使用者類別、交易金額、最近一次購買日期、交易頻率、工作階段數、工作階段日期、工作階段時間、網站數、顧客購買動作等變數，如表11顧客變數表；模型產生參數為顧客所屬集群、顧客達成目標轉換價值之矩陣、顧客通路最適化配對之矩陣。

(1)顧客變數表：

表11 顧客變數表

| 變數特徵 | 描述 |
|------|------|
| 性別 | 顧客性別 |

| | |
|------------|---------------------------|
| 年齡 | 顧客年齡層 |
| 地區 | 顧客所在地區 |
| 網站數 | 訪客瀏覽頁數 |
| 購買商品 | 投保商品 |
| 工作階段來源/媒介 | 顧客接觸通路，獲得流量的來源與媒介 |
| 瀏覽網站內容 | 顧客接觸商品內容，訪客一進入網站所看到的頁面 |
| 廣告活動 | 顧客接觸行銷活動，通常是產品經理舉辦產品活動 |
| 廣告內容 | 顧客接觸行銷文案，每則廣告行銷內容 |
| 瀏覽器類別 | 顧客使用瀏覽器，網站訪客使用的瀏覽器 |
| 裝置類別 | 裝置類型：平板、手機、桌機 |
| 使用者類別 | 新訪客(第一次)或回訪客 |
| 交易金額 | 總保費 |
| 最近一次購買日期 | 從上一次購買到下一次購買的相隔天數 |
| 交易頻率 | 交易次數 |
| 工作階段數 | 單一訪客各工作階段發生的次序。 |
| 交易前所需天數 | 從通路推薦到購買的相隔天數 |
| 工作階段時間 | 每一次停留時間 |
| 工作階段時間長 | 工作階段的時間長度，以秒為單位 |
| 距上次工作階段的天數 | 從一個工作階段關閉到另一個工作階段開啟所經過的天數 |
| 顧客購買動作 | 點擊網頁、點擊立即購買、實際購買 |
| 目標轉換價值 | 完成某一顧客購買動作的轉換價值 |

(2)顧客接觸點及通路部分資料示意表：

表12 顧客接觸點資料示意表

| 用戶 ID | 通路 | 來源/媒介 | 到達網頁 | 購買動作 | 目標轉換價值 |
|------------------------|-------|---------------------------|------|--------|--------|
| 1587443807754.olejysi7 | 付費搜尋 | google/cpc | 商品網頁 | 點擊網頁 | 949 |
| 1587443807754.olejysi7 | 自有媒體 | fuboneip/banner | 首頁 | 點擊立即購買 | 3985 |
| 1587443807754.olejysi7 | 第三方平台 | shop.hsbc.com.tw/referral | 首頁 | 實際購買 | 10000 |

| 來源/媒介 | 通路 | 曝光 | 點擊 | 單次點擊成本 | 交易轉換率 | 收益 |
|----------|-------|---------|------|--------|-------|------|
| Adara | 第三方平台 | 422902 | 982 | 120.58 | 0.42 | 3772 |
| Facebook | 自有媒體 | 518336 | 5928 | 16.91 | 0.19 | 2470 |
| GDN | 展示型廣告 | 5948651 | 7764 | 8.44 | 0.01 | 1288 |

(4)顧客資料部分示意表：

表13 顧客資料示意表

| 用戶 ID | 性別 | 最近一次購買時間 | 購買頻率 | 購買金額 | 工作階段時間長度 |
|------------------------|----|----------|------|------|----------|
| 1587443807754.olejysi7 | 1 | 43439 | 1 | 779 | 1701 |
| 1584696454073.yx1ajfnt | 1 | 43419 | 1 | 615 | 140 |
| 1584684955336.odv2og9 | 1 | 43209 | 1 | 303 | 2251 |

第二節 多通路顧客價值分析模式之集群分析

本研究使用進行集群分析，將類似購買行為及通路習慣的用戶分成一群，並定義出不同用戶集群之行為特性，並針對不同群組下之顧客了解其購買行為差異(例如：習慣採用哪些行銷通路進行商品購買，偏好哪些內容或商品資訊，會有較高的網站停留時間或網頁瀏覽數)。相關的分群結果整理如表14、表15所示，其中，根據占比結果，本研究發現，部門過去以購買金額高低篩選出的三大主力顧客群「VIP顧客群」、「主力顧客群」、「小資族群」，對應本次分群結果應為第五群、

第三群、第七群，佔整體百分比約為75%，確實如先前討論未被觸及的顧客站比數。

表14 分群結果1

| 編號 | 佔整體資料的百分比 | 資料筆數 |
|------|-----------|-------|
| 集群-1 | 25.87% | 2,089 |
| 集群-2 | 11.32% | 914 |
| 集群-3 | 9.61% | 776 |
| 集群-4 | 18.25% | 1,474 |
| 集群-5 | 3.69% | 298 |
| 集群-6 | 21.59% | 1,744 |
| 集群-7 | 9.67% | 781 |

表15 分群結果2

| | 集群 1 | 集群 2 | 集群 3 | 集群 4 | 集群 5 | 集群 6 | 集群 7 |
|----------|--------|---------|---------|---------|---------|---------|---------|
| 最近一次購買時間 | 33.28 | 1.31 | 52.01 | 27.76 | 32.87 | 40.14 | 24.25 |
| 交易頻率 | 0.64 | 0.70 | 1.27 | 0.83 | 0.72 | 0.87 | 0.94 |
| 交易金額 | 947.36 | 2532.60 | 3158.19 | 6799.02 | 9334.24 | 1777.86 | 4946.58 |
| 自有媒體通路 | 1.08 | 1.55 | 3.49 | 3.09 | 3.19 | 1.09 | 1.27 |
| 展示型廣告通路 | 0.00 | 0.18 | 0.13 | 0.15 | 0.27 | 0.01 | 0.02 |
| 自然搜尋通路 | 1.48 | 1.54 | 2.48 | 2.60 | 2.87 | 1.32 | 1.41 |
| 付費搜尋廣告通路 | 4.61 | 4.61 | 8.14 | 5.78 | 2.99 | 5.18 | 5.93 |
| 關鍵字自然搜尋 | 0.25 | 0.67 | 1.19 | 0.76 | 0.74 | 0.58 | 1.26 |
| 第三方平台通路 | 0.20 | 0.28 | 1.52 | 1.69 | 0.26 | 0.09 | 0.23 |
| 直接流量 | 1.14 | 1.20 | 2.52 | 0.73 | 1.34 | 1.78 | 1.52 |
| 首頁 | 0.22 | 0.04 | 0.41 | 0.22 | 0.24 | 0.21 | 0.14 |
| 商品網頁 | 0.76 | 0.17 | 1.22 | 0.96 | 0.81 | 0.92 | 1.03 |
| 產品活動頁 | 0.01 | 0.01 | 0.16 | 0.14 | 0.12 | 0.03 | 0.06 |
| 內容情境頁 | 0.00 | 0.00 | 0.07 | 0.03 | 0.01 | 0.02 | 0.03 |
| 會員經營資訊 | 0.05 | 0.04 | 0.41 | 0.26 | 0.17 | 0.13 | 0.20 |
| 網站數 | 1.04 | 0.26 | 2.27 | 1.61 | 1.36 | 1.32 | 1.48 |
| 工作階段數 | 1.05 | 1.01 | 2.33 | 1.73 | 1.42 | 1.27 | 1.38 |
| 工作階段時間長 | 964 | 954 | 761 | 817 | 867 | 825 | 795 |

本研究將詳細分析結果，依各群用戶的特性差異進行經營策略建議，茲整理如下：



一、第一群的購買行為

本研究將第一群用戶定義為「靜止顧客群」，該群的顧客由於交易頻率與距上次工作階段的天數較低，也沒有特定偏好看什麼類型的內容資訊，也多是從自然來源來訪，雖然該群中包含了2,089筆顧客資料，但在網站瀏覽數與工作階段時間總長度皆偏短，第一群用戶與企業端的互動明顯較少，對企業也較無關鍵性的價值。

二、第二群的購買行為

本研究定義第二群為「流失顧客群」，其交易與互動資訊顯示出：交易頻率及網站訪問量最少，集群中最近一次購買時間、交易頻率、網站數與工作階段數均為最低，表示該群顧客以呈現流失狀態。管理者應針對該族群制定留存計畫，建議可以採用該族群較習慣的行銷通路、裝置與瀏覽資訊，如該族群偏好透過付費搜尋廣告通路進站與企業互動、較常使用桌機與Firefox、Edge，對商品資訊較為關注，產品經理必需專注於外部廣告與自有媒體曝光重新吸引。而產品活動頁、內容頁、會員經營資訊則呈現較高的跳離率，應減少觸及該內容。

三、第三群的購買行為

本研究定義第三群為「小資族群」，他們偏好固定回訪公司主頁、瀏覽活動資訊及會員服務相關資訊，時段集中在深夜。其有較高的購買頻率，購買間隔時間也較短，也是集群中瀏覽頁面數與訪問次數最多的。該族群較習慣的行銷通路較為分散，多透過自有媒體通路、付費搜尋廣告通路、自然搜尋通路與企業互動。整體而言，該族群被認為是「企業忠誠客戶」。與產品經理討論該集群經營策略後，建議未來透過電子郵件或簡訊主動聯繫該集群，積極溝通、定期提供最新會員權益資訊，被動方式則可在首頁與關鍵字導流頁面上提供產品活動資訊。

四、第四群的購買行為

本研究將第四群定義為「潛在顧客群」，儘管該群體的交易頻率及購買間隔時間較為平均，但該集群平均購買金額在七個群體中排名第二，且瀏覽活動資訊、會員服務資訊與內容情境資訊的時間相對較高，表示該族群不排斥企業主動向他們

傳遞相關資訊。該族群較常採用第三方平台通路、付費搜尋廣告通路及自有媒體通路導進。因此部門需特別強調經營跨平台合作通路，培養集群顧客忠誠度。

五、第五群的購買行為

本研究將第二群定義為「VIP顧客群」，該族群具有最高的交易金額，他們偏好從展示型廣告通路、自有媒體通路，較不常使用付費搜尋廣告通路，反而自然搜尋通路，並對商品功能介紹較為關注，而不偏向活動折扣，與產品經理討論該集群經營策略後，建議未來透過展示型廣告通路或簡訊主動提供最新產品資訊，並將通路到達頁面，改為商品介紹頁面直接曝光族群偏好資訊。

六、第六群的購買行為

本研究將第一群用戶定義為「瞌睡顧客群」，該群顧客特徵類似集群一「靜止顧客群」，最近一次購買時間、交易頻率、交易金額略高於靜止顧客群，網站數、工作階段數、直接流量也高於靜止顧客群，顯示該族群忠誠度還是較靜止戶高，屬於暫時沉睡的顧客集群，與產品經理討論該集群經營策略後，建議未來針對該族群加大付費搜尋廣告流量，並提供更多會員權益及商品消息，週期性發放點數或折扣券。

七、第七群的購買行為

本研究將第七群定義為「主力顧客群」，該族群具有較高交易金額、交易頻率、最近一次購買時間，是公司的主力顧客，較常使用付費搜尋廣告通路、關鍵字自然搜尋與直接流量，與其他關鍵目標群集一樣（「小資族群」、「VIP顧客群」），對於商品網頁與會員權益資訊較為關注，並有較高的網站互動率。與產品經理討論該集群經營策略後，綜合上述關鍵目標群集，建議未來產品經理應設計會員經營機制，針對關鍵目標群集設立會員階級，會員策略可包含週期性發送點數、發放票券，吸引會員回購；並在新商品推出的時候，透過電子郵件或簡訊等方式直接送電子折抵券、電子兌換券給會員。

第三節 多通路顧客價值分析模式之機器學習分析

(1)預測模型參數設定：

本節需測試不同關鍵參數以強化模型預測之準確性及其訓練效率，超參數包括：(1)最大神經元數(2)神經層或決策樹節點中的最大樣本數(3)學習率及(4)神經層總數或構建樹之總數；最大神經元數係指每一層中神經元的數量，通常設定在 50 至 200 之間會有較佳的預測表現；而決策樹整體學習模式中，每個節點的最大樣本數會影響樹的結構，通常設定在 10 至 50 之間是較佳範圍；學習率則設定在 0.001 至 0.01 之間會取得較佳平衡；神經層總數則為 2 至 5 層之間、樹總數較佳範圍為 50 至 150 之間。本研究彙整參數最佳候選值結果，如表 16。

表 16 預測模式最佳參數表

| 模型名稱 | 參數名稱 | 參數值 |
|----------|---|-------------------------------|
| CNN | Padding | { same, 2 } |
| | Pool size | |
| LSTM | Activation | { relu,0.3,20,100,0.001,100 } |
| | Dropout rate | |
| | Timesteps | |
| | Hidden nodes | |
| | Learning rate | |
| | Number of iteration | |
| XGBoost | Maximum number of leaves per tree | { 20,10,0.1,100 } |
| | leaves per tree | |
| | Minimum number of samples per leaf node | |
| | Learning rate | |
| 隨機森林 | Total number of trees constructed | { 8,32,1 } |
| | Number of decision tree | |
| | Number of decision tree | |
| | Maximum depth of tree | |
| | Minimum number of sample per leaf node | |
| LightGBM | Maximum number of leaf tree | { 20,10,0.2,100 } |
| | Maximum number of sample leaf node | |
| | Learning rate | |
| | Total number of trees constructed | |

(2)預測模型準確度與穩健度檢定：

LightGBM 模型在不同訓練資料百分比下皆表現優異；以 ROC 與 AUC 得分為例，當訓練資料百分比為 70%時，LightGBM 之 ROC 與 AUC 分別為 0.72 和 0.72，在 80%及 90%的訓練資料下，其 ROC 與 AUC 分別達到 0.73 和 0.73，以及 0.76 和 0.76，高於其他模型，當訓練資料百分比為 90%時，LightGBM 的 F1-score 和 Recall-score 分別為 0.69 和 0.72，高於其他模型。當 70%訓練資料為例，LightGBM 的執行時間為 28.01 秒，而其他模型的執行時間則在 31.88 秒到 36.74 秒之間。LightGBM 模型在預測顧客購買動作方面的性能優越。此些結果突顯了所提出的模型在採用時減少預測值與實際值之間差異的能力。

表17 預測模式模型檢定

| 訓練資料百分比% | 模型名稱 | ROC | AUC | F1-score | Recall-score | Execution time |
|----------|----------|------|------|----------|--------------|----------------|
| 70 | LSTM | 0.68 | 0.68 | 0.66 | 0.68 | 32.6 |
| | CNN | 0.7 | 0.7 | 0.65 | 0.68 | 36.74 |
| | CNN-LSTM | 0.69 | 0.69 | 0.66 | 0.67 | 31.88 |
| | XGBOOST | 0.71 | 0.71 | 0.64 | 0.67 | 36.23 |
| | LightGBM | 0.72 | 0.72 | 0.64 | 0.68 | 28.01 |
| 80 | LSTM | 0.69 | 0.69 | 0.67 | 0.69 | 32.6 |
| | CNN | 0.71 | 0.71 | 0.66 | 0.69 | 36.74 |
| | CNN-LSTM | 0.7 | 0.7 | 0.67 | 0.68 | 31.88 |
| | XGBOOST | 0.72 | 0.72 | 0.65 | 0.68 | 36.23 |
| | LightGBM | 0.73 | 0.73 | 0.65 | 0.69 | 28.01 |
| 90 | LSTM | 0.71 | 0.71 | 0.68 | 0.71 | 32.6 |
| | CNN | 0.72 | 0.72 | 0.67 | 0.7 | 36.74 |
| | CNN-LSTM | 0.73 | 0.73 | 0.69 | 0.71 | 31.88 |
| | XGBOOST | 0.74 | 0.74 | 0.68 | 0.71 | 36.23 |
| | LightGBM | 0.76 | 0.76 | 0.69 | 0.72 | 28.01 |

(3)顧客目標轉換價值估算：

因保險公司在實務上，需考量需多因素，因此顧客轉換價值/顧客終身價值計算較為複雜。本研究簡化計算流程，僅保留核心計算部分。本研究估算顧客目標轉換價值過程，以案例公司情況，若排除保險專業成本精算，正常情況下，平均收益約為3,297臺幣，平均利潤率約為5%，實際完成交易之轉換率約為6%，轉換

價值約為10臺幣(3296 x 5% x 6%)；然而將行銷通路因素列入考慮範圍，如個案公司表示憑再行銷，每位顧客通常可帶來額外 50% 的潛在收益，則轉換價值可達到15臺幣(10 x 150%)。若再考慮顧客壽命，預估平均一位顧客長期可以提供大約1萬的收益，則顧客當前終身價值為45臺幣(15 + 10000 x 5% x 6%)，最後考慮購買階段潛在價值，點擊採用權重為顧客點擊至立即購買之轉換率約為20%，顧客每次點擊網頁達成之轉換價值約為10(45 x 0.2)；立即購買採用權重為顧客點擊立即購買至實際購買之轉換率約為10%，則顧客每次點擊立即購買達成之轉換價值約為50(45 x 110%)；因該部門年度目標為保額最大化，因此實際購買採用保險額度加權300%，則顧客每次實際購買達成之轉換價值約為180(45 x 400%)。

表18 目標轉換價值矩陣 (以實際購買轉換價值為例)

| 通路 顧客 | 自有媒體 通路 | 展示型廣 告通路 | 自然搜 尋通路 | 付費搜尋 廣告通路 | 關鍵字自 然搜尋 | 第三方平 台通路 | 直接 流量 |
|------------|------------|-------------|------------|--------------|-------------|-------------|----------|
| 顧客1 | 665.07 | 359.046 | 590.44 | 600.4425 | 450.47 | 490.22 | 484.55 |
| 顧客2 | 430.94 | 311.74 | 392.16 | 537.40 | 339.32 | 477.74 | 257.28 |
| 顧客3 | 530.07 | 355.83 | 392.01 | 344.66 | 360.99 | 289.88 | 322.70 |
| . | | | | . | | | |
| . | | | | . | | | |
| . | | | | . | | | |
| . | | | | . | | | |
| 顧客 8076 | 181.62 | 170.26 | 220.07 | 203.38 | 264.50 | 191.52 | 208.6 |

第四節 多通路顧客價值分析模式之最佳化分析

(1)最佳化模型參數設定：

本研究欲解決核心問題是在各種行銷通路之間進行資源的最佳配置。本研究為管理者建構最佳化資源配置量化分析模式，幫助他們制定最佳化多通路顧客終身價值之策略，藉由顧客三種購買行為實際購買、點擊購買按鈕、網頁點擊及其產生之目標轉換值；其值為預測模型所產生之目標轉換價值矩陣，其他關鍵參數，包括當前部門編列的獲取顧客預算 (E)、每個目標轉換所支付的通路費用

(C_{1j}, C_{2j}, C_{3j}) 以及每個通路接觸顧客之時間 (D_i)。一般來說，公司與代營運商 (或廣告商) 通常有簽訂協定，每次獲客或達成目標轉換所支付之成本相對穩定，

表 20 為本研究最佳化模型參數設定區間：

表19 最佳化模型參數值設定區間

| 參數符號 | 數值區間 | 中文涵義 |
|-----------|---|---|
| i | $i = 1$ (第一位顧客), 2 (第二位顧客) ... 8076 (第8076顧客) | 共8076名顧客，案例一先抽100名顧客進行求解 |
| j | $j = 1$ (自有媒體通路), 2 (展示型廣告通路), 3 (自然搜尋通路), 4 (付費搜尋廣告通路), 5 (關鍵字自然搜尋), 6 (第三方平台通路), 7 (直接流量) | 共七種行銷通路 |
| t | $t = 1, 2, 3 \dots 5$ | 平均工作階段約為5 |
| k | $k = 1$ (靜止顧客群), 2 (流失顧客群), 3 (小資族群), 4 (潛在顧客群), 5 (VIP顧客群), 6 (瞌睡顧客群), 7 (主力顧客群) | 共七群 |
| AC | $AC = AC_1$ (網頁點擊), AC_2 (點擊立即購買), AC_3 (實際購買) | 顧客購買動作 |
| S_{ij} | 0-30 | 顧客 <i>i</i> 透過通路 <i>j</i> 點擊網頁之目標轉換價值 |
| CL_{ij} | 0-200 | 顧客 <i>i</i> 透過通路 <i>j</i> 點擊立即購買之目標轉換價值 |
| R_{ij} | 180-1000 | 顧客 <i>i</i> 透過通路 <i>j</i> 實際購買轉換之目標轉換價值 |
| N_k | 3000 | 觸及最大需求人數 |
| C_{1j} | 0-50 | 透過通路 <i>j</i> 達成網頁點擊目標之轉換成本 |
| C_{2j} | 50-100 | 透過通路 <i>j</i> 達成立即購買點擊目標之轉換成本 |
| C_{3j} | 0-500 | 透過通路 <i>j</i> 達成實際購買目標之轉換成本 |
| d_j | 180 | 通路 <i>j</i> 最大接觸天數 |

(2)最佳化模型分析結果：

本研究透過整數規畫法分析多通路最佳化量化模型，以 100 名顧客與七種行銷通路進行規畫求解，採用 GAMS 與 LINGO 之混合整數線性規畫模式執行最佳化求解。分析結果顯示，在相同情境下，比較 LINGO 與 GAMS 模式之求解結果，LINGO 求解較好。而運用啟發式演算法二進制差分演算模式迭代訓練結果顯示，在目標轉換值與計算時間方面，該模型可較接近最佳解。整理如表 20。

表20 最佳化模型分析結果

| 模型 \ 指標 | CLV | Execution time (sec.) |
|----------|-------|-----------------------|
| LINGO | 35559 | 55 |
| GAMS | 34822 | 25 |
| 二進制差分進化法 | 32036 | 55 |

如表 21 人工規畫與最佳化模型比較，以過去部門人工規畫方式求解，僅考量到購買轉換之求解結果為 17,418，最佳化求解則提高到 26,778，較人工規畫模式增加了 54%，成本降低了 139%，換言之，在相同情境下，僅考慮購買轉換之整數規畫量化模式執行通路資源配置會優於人工規畫模式。若進一步比較僅考慮購買轉換以及實際購買、點擊購買按鈕、網頁點擊之整數規畫模式通路配置，我們發現僅考慮實際購買之最佳化模型，為了達到最大的購買目標價值轉換效率，會將通路主要配置在 VIP 顧客群 (Z_{i5}) 與小資族群 (Z_{i3})，以致所有的通路組合皆集中在這些高價值群體中；而在執行考量實際購買、點擊購買按鈕、網頁點擊三者之最佳化模型，為了達到整體目標價值轉換效率最大化： $(\sum_i^n \sum_j^m R_{ij} X_{ij} + \sum_i^n \sum_j^m CL_{ij} X_{ij} + \sum_i^n \sum_j^m S_{ij} X_{ij})$ ，則會適當安排 VIP 顧客群 (Z_{i5}) 與小資族群 (Z_{i3}) 之通路轉換，再配置其他高價值轉換群體，換言之，該模式會優先考慮高價值集群通路配對後，再接著考慮更多購買行為之集群與通路之組合，以最大化整體目標轉換價值。

表21 人工規畫與最佳化模型比較

| 模型 | 行銷通路 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | Total | Cost | CLV |
|------------------------|--------------------|----|----|----|----|----|----|----|-------|------|-------|
| 人工調整 | (Z _{i5}) | 9 | 2 | 5 | 2 | 5 | 1 | 1 | 25 | 9830 | 17418 |
| | (Z _{i3}) | 7 | 0 | 0 | 12 | 6 | 0 | 0 | 25 | | |
| | (Z _{i4}) | 15 | 0 | 3 | 6 | 0 | 1 | 0 | 25 | | |
| | (Z _{i2}) | 17 | 0 | 3 | 3 | 1 | 0 | 1 | 25 | | |
| | Total | 48 | 2 | 11 | 23 | 12 | 2 | 2 | 100 | | |
| 僅關注實際成交 | (Z _{i5}) | 5 | 0 | 1 | 1 | 4 | 0 | 14 | 25 | 4110 | 26778 |
| | (Z _{i3}) | 4 | 0 | 1 | 0 | 1 | 3 | 16 | 25 | | |
| | (Z _{i4}) | 0 | 1 | 1 | 0 | 9 | 2 | 12 | 25 | | |
| | (Z _{i2}) | 0 | 3 | 0 | 0 | 1 | 6 | 15 | 25 | | |
| | Total | 9 | 4 | 3 | 1 | 15 | 11 | 57 | 100 | | |
| 購買、點擊 購買按鈕、網頁 點擊 | (Z _{i5}) | 5 | 0 | 1 | 1 | 4 | 0 | 14 | 25 | 7408 | 35559 |
| | (Z _{i3}) | 6 | 0 | 0 | 0 | 1 | 3 | 15 | 25 | | |
| | (Z _{i4}) | 2 | 10 | 0 | 0 | 1 | 0 | 12 | 25 | | |
| | (Z _{i2}) | 0 | 3 | 0 | 0 | 1 | 6 | 15 | 25 | | |
| | Total | 13 | 13 | 1 | 1 | 7 | 9 | 56 | 100 | | |

| 轉換指標 | 人工調整 | 最佳化模式 | 差值 |
|------------|-------|-------|-------|
| 點擊網頁轉換價值 | 4007 | 13722 | 9715 |
| 點擊立即購買轉換價值 | 5526 | 13794 | 12509 |
| 實際購買轉換價值 | 7885 | 8043 | 158 |
| 總價值 | 17418 | 35559 | 18141 |
| 點擊網頁轉換成本 | 1023 | 1649 | 626 |
| 點擊立即購買轉換成本 | 3858 | 2629 | -1229 |
| 實際購買轉換成本 | 4949 | 3130 | -1819 |
| 總成本 | 9830 | 7408 | -2422 |

(3)最佳化分析小結：

本研究根據購買動作建立一個多目標方程式，以針對購買過程中不同階段的用戶群進行目標設定。除了最大化現有顧客的價值($\sum_i^n \sum_j^m R_{ij}X_{ij}$)外，公司還應該專注於與對其產品感興趣並處於考慮階段的消費者建立聯繫。根據本研究分析結果，多目標模型可以識別能夠增加顧客價值的購買行動類型(例如， AC_1 , AC_2 , AC_3)。根據重要性水平，公司可以將資源分配到導致更高轉換率並最大化不同顧客群體的顧客終身價值通路。換句話說，該模型根據顧客的購買意向或“購買意願”優先考慮顧客，以增加目標轉換。表 22 顯示了該推論之驗證結果，並顯示直接流量轉換是使用最廣泛的通路，其次是自有媒體通路(NO.1)與展示型廣告通路(NO.2)。在確定了這一點之後，模型會進一步將合適的顧客群進行配對，如潛在顧客群(Z_{i4})，藉此實現最大化的目標轉換，而比較人工調整與最佳化模式目標轉換價值及轉換成本，可以發現，最佳化模式總價值較人工調整模式高 18,141，其中點擊立即購買價值與點網頁轉換價值皆遠高於人工調整模式，顯示該最佳化模式較強調提升點擊網頁與立即購買產生之轉換價值；最佳化模式成本也較人工調整低，主要為採用行銷通路單次轉換成本較低。

第五節 多通路顧客價值分析模式之大型規劃求解

(1)大型規劃問題最佳化求解：

在本節中，由於透過整數規劃方法解決多通路規畫問題，會遇到高維問題無法求解之困難（LINGO 系統顯示：“The model generator ran out of memory”），本研究使用了整數規劃模型與二進制差分演算模式進行大型通路規劃最佳化求解問題，亦有助於驗證啟發式方法在解決具有複雜限制的高維問題時，是否較整數規劃法更具可執行性。本研究也採用幾種常見的啟發式演算法—二進制粒子群優化法進行比較。本研究透過啟發式演算模式執行多通路大型問題求解，以 8076 名顧客與七種行銷通路進行規劃求解，採用參數為：(1)將每代人口設定為 50；(2)設定 $p=\max\{0.05,\min\{0.15,10/n\}\}$ ，以確保不會陷入局部解而過早收斂，以及

有效搜尋全域解；(3)終止標準被設定為 5000 次疊代內最佳適應性之提高不能超過 0.1%，當滿足條件則停止搜尋。目前編列獲客成本 (E) 為 4000000，表 23 總結了不同模型執行案例之模擬分析結果。如表 23 所示，啟發式演算法皆能夠順利求解大型規劃問題，二進制差分進化模型則可以在 49,877 秒內解決 56,532 個組合 (8076x7 維度)。

表22 啟發式演算分析結果

| 模型 | 維度 (顧客X通路) | 執行 時間 | 成本 | Fitness(Y) | $\frac{\text{Fitness}(Y)}{\text{Cost}}$ |
|-----------|---------------|----------|---------|---------------|---|
| 人工調整 | 1000x7 | 1 | 88896 | 345724 | 3.89 |
| 人工調整 | 4000x7 | 8 | 426701 | 1119199 | 2.62 |
| 人工調整 | 8000x7 | - | - | - | - |
| 人工調整 | 8076x7 | - | 1598640 | 1588665 | 0.99 |
| 二進制粒子群優化法 | 8000x7 | 49278 | 3499570 | -197742481306 | 0.71 |
| 二進制差分進化法 | 8000x7 | 49877 | 3356298 | -183834253645 | 1.26 |

啟發式演算法的二進制差分進化法模型的應用也比二進制粒子群優化法模型得到了更好的效果，提高了7%，成本降低了4%。二進制差分進化被懲罰的次數比二進制粒子群優化法少了 1391 次，顯示二進制差分進化法在高維度求解較不容易陷入局部解。為了比較二進制差分進化模型和人工規劃之整體顧客終身價值，本研究排除了懲罰分數，運用收益比公式($\text{Fitness}(Y)/\text{Cost}$)來折算，以1單位的成本可以轉換多少收益，以有效評估方法有效性。結果顯示，當二進制差分進化模型的收益比從0.99增加到1.26，意味著同樣的1單位獲客成本相比人工規劃方式增加了0.27單位收益。上述結果表明，所建立的模型可以為企業在通路規劃求解過程做出較佳的策略，協助管理者進行較佳化決策。

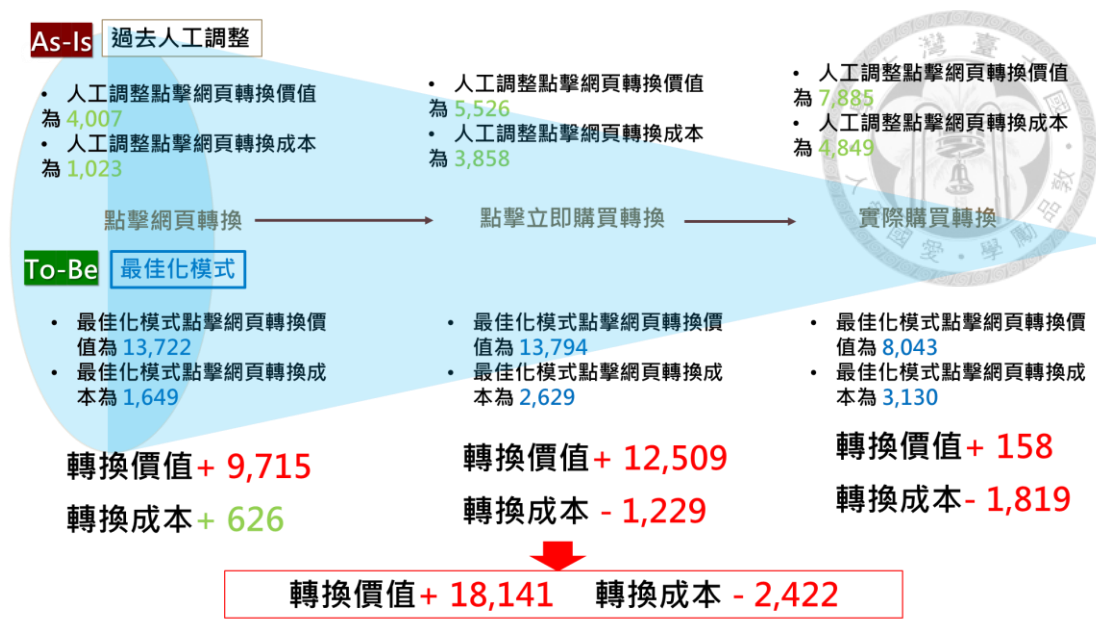


圖24 方案前後效益比較
(本研究整理)

第六節 通路資源配置法則

本研究評估通路轉換目標價值及多通路顧客終身價值最佳化之過程，為在預算與資源有限的情況下，有組織地規劃行銷通路以實現未來的目標轉換；我們嘗試瞭解目標受眾的特徵以及行銷通路和顧客集群之間的關係，試圖瞭解預測模型對客群營運與通路接觸之目標轉換運算時，以及最佳化多通路顧客終身價值進行分派時，預測模型與最佳化模型之規則為何，進而協助管理者制定最佳化管理準則。

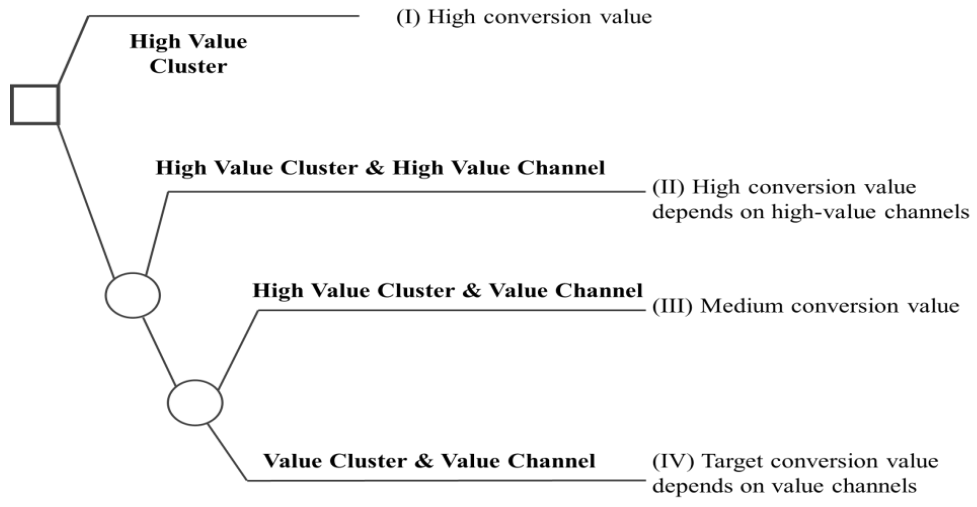


圖25 通路資源配置之管理準則
(本研究整理)

本研究探討以產品經理角度進行目標顧客集群與行銷通路之操作，是採用考量到不同購買階段的顧客轉換目標達成狀況之最佳化模型結果，進行邏輯梳理，根據圖25決策樹狀圖的四種情況，分別進行說明與策略應對，整理如下：

第一種情況是，對於產品經理的直接目標，是能夠帶來較高的購買轉換，以樹狀圖頂部顯示，當本研究的高貢獻集群如小資族群、VIP顧客群、主力顧客群，配對到高購買轉換的行銷通路時，如透過直接流量或自有媒體到達頁面，用戶多是在購買階段直接通過導流進站進行購買轉換。則產品經理應持續強化該些高價值轉換管道，確保這些管道的高效運行，以數據分析進一步提升顧客體驗，平衡資源配置，並注意避免過度依賴該行銷通路，以防止在此接觸點出現顧客疲勞或競價市場的激烈競爭。

第二種情況是，當發現高貢獻集群未使用高購買轉換通路時，表示顧客可能處於考慮階段或瀏覽階段。產品經理應調整曝光和誘導策略，利用關鍵字廣告、外部廣告和企業首頁等方式，吸引這些高價值用戶進行更多目標轉換行為，如點擊集購購買按鈕或瀏覽其他網站分頁。並持續增強行銷通路文案內容與服務體驗。而該行銷通路可能為與顧客互動之新興管道，在競價市場中的目標轉換成本，可能還處在較低的價格，是潛在關鍵資源。

第三種情況是，當目標用戶不屬於高貢獻群集時，產品經理將考慮是否值得繼續在顧客群身上投入高價值轉換管道的資源，評估是否有提升該行銷通路轉換率的空間，並考慮將這些用戶進一步細分，如將其分群出潛在顧客群、瞌睡顧客群、靜止戶顧客群、流失戶顧客群等，探索各集群的潛在價值及其關鍵購買特徵，並進行針對性行銷策略，為近年產業精準行銷模式欲有效經營的對象。

第四種情況是，當決策者開發的行銷通路對目標顧客集群為較低的購買目標轉換價值時，且此行銷通路亦不是目標市場顧客集群的主要接觸點，產品經理將根據本研究分析模式進行分析，根據用戶反饋和數據分析，重新調整目標客戶群集和轉換管道，不斷調整溝通內容和服務體驗設計。如以上分析結果探討，若企

業目標包括長期會員管理，應考慮通過曝光/誘導之行銷管道，將這些用戶轉化為點擊購買按鈕或任意按鈕的用戶，增加網站流量和潛在轉換機會。

總之，資源配置規則主要為，第一階段配置先進行高價值轉換優先策略，短期經營以經常接觸高價值群集並使用高價值轉換管道，獲得直接效益；長期經營則避免過度集中資源於特定群集和管道，以防止其他潛在高價值群體的流失；第二階段配置再進行會員經營管理策略，不僅促進購買，還採取會員策略，增加網站流量和用戶互動。利用曝光/誘導管道，將「非購買」用戶轉換為點擊購買按鈕或任意按鈕的用戶，長期提升會員管理效益和降低通路成本。總之，企業應根據具體目標和用戶行為特徵，靈活調整資源配置策略，平衡短期收益和長期發展。

第五章 研究二：最佳化產品規格推薦求解

第一節 研究案例說明

為了驗證本研究所提出最佳化產品規格推薦模型的可行性，本研究以國內一間製造公司之研發部門的產品研發工作流程與真實數據作為研究案例，依據該部門產品研發運作架構與流程，建立本研究量化分析模式之訓練模型數據及最佳化模型之相關參數。該公司近年進北美電子商務市場進行銷售，並打算建立產品數據研發管理機制，希望有效追蹤北美消費市場需求與新產品開發規格。經與部門管理者深入訪談，管理者提出三個主要的顧客分析需求，第一為，將北美電子商務需求依據產品類彙整，根據不同消費需求建立不同產品功能的對應；第二為，根據消費需求、產品功能建議產品研發規格，並進行系統化推薦模式；第三為，希望能夠能持續最佳化新產品開發，並建立數據驅動商業模式以強化海外產品創新及運營；近年顧客直對製造端（Customer to- Manufactory，簡稱為C2M）模式在全球引發廣大關注與資源投注，以數據分析技術輔助消費需求探索、產品研發，此分析模式，加速研發流程、降低成本，透過即時的數據管理整合研發、生產、

行銷部門，將「數據與決策」結合，帶動產業轉型，擺脫臺灣以往代工生產(Original Equipment Manufacturer，簡稱為OEM)思維。本研究根據C2M商業模式加以改良，運用在案例二之製造公司，試圖建立以消費市場數據推動新產品研發之營運模式，進而協助國內研發業者掌握數據應用精準研發最新趨勢，加速新產品研發速度，如圖26消費市場數據推動新產品研發之營運模式。

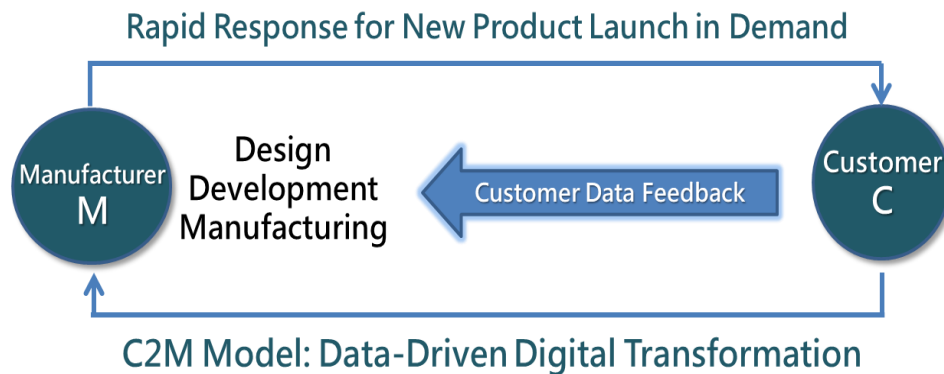
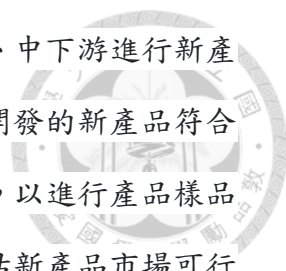


圖26 消費市場數據推動新產品研發之營運模式
(本研究整理)

以下詳述部門作業痛點與本研究解決方案

本研究首先深入分析該公司研發部門系統流程需求，在目標市場調查階段，公司部門產品經理較常採用方式是，按照國外市場調研機構調查報告了解目標市場消費趨勢，再據此推算目標市場銷量，根據既有生產線進行新產品樣本設計。然而，該方式無法確定目標市場真實消費偏好，也無法定位新產品開發類別，僅是將既有產品稍作改良，便直接推往海外目標市場，時常導致新產品不受當地市場青睞，未能有效定位海外市場。而本研究根據目標市場產品類進行顧客需求分析建模，透過主題模型分析產品評論資訊並產生顧客需求特徵與顧客偏好之產品功能，該模式除了能夠較為精準定位顧客需求與產品開發功能之外，還為其產生更多的設計特徵與開發優先順序，協助產品經理了解目標市場產品需求，幫助其快速產出新產品概念與其開發計畫。本模式並藉由系統串接為該產品類制定消費數據追蹤機制，使產品經理能即時了解顧客需求，取代較昂貴的市調報告、冗長的焦點小組會議。



其次，在研發階段，公司研發部門通常舉辦研討會與同行、中下游進行新產品設計之研討，並試圖從不同經銷商取得市場資訊，以確保所開發的新產品符合終端市場的消費需求，接著再根據回饋資訊組合不同產品規格，以進行產品樣品之開發。然而儘管已舉辦與參與數十個研討會，仍無法有效評估新產品市場可行性，也無法從經銷商市場資訊推薦最適生產規格，更無法進行開發新產品模組。本研究整合消費市場之顧客需求、產品功能資料，以及結合開發部門提供之產品規格資料，建立產品規格預測模式，分析在所有顧客需求下的產品功能與產品規格之不同組合，哪些規則能產生較高的顧客滿意度，再根據這些評分結果根據產品效用及研發限制下，對所有組合進行最佳化之產品規格推薦，相較過往參展、次級資料蒐集方式，本研究提出模式可以協助研發部門，快速評估市場需求並更精準地推薦合適的研發規格。最後，以系統設計角度，研發部門希望據以上新流程建立新數據營運模式。因此本研究根據文獻品質機能展開架構，根據上述的顧客消費需求分析、需求與功能規格轉換分析，以及最佳化產品規格推薦，以品質機能展開架構執行，並整合至企業產品服務系統(Product Service System, 簡稱為PSS)，進而發展市場數據推動新產品研發之營運模式，以此協助管理者有效達到更有效的新產品研發。

本研究收集分析模式之顧客評論資料與相關參數資料，本研究先與亞馬遜第三方服務廠商對接設定產品類評論追蹤，再啟用數據匯送服務來定期取得產品類銷售資料、產品類評論資料、產品類評分等資訊。資料擷取時間為2021年1月到2022年8月的數據記錄，經本研究整理共為在23個產品規格類別中，76個產品項目的3,492,632條產品評論觀測記錄。根據文獻的產品關鍵特徵，彙整為七種行銷通路；每個產品都有單獨ASIN，屬於亞馬遜標準識別碼。解釋變數為，包括尺寸、重量、特性、USB端口、功率輸出、輸出功率、快速充電技術、認證、廣告、電纜、充電速度、兼容設備、連接、設計、耐久性與品質、快速充電技術、GaN、輸出功率、價格、安全與保護、USB端口與保修等變數。預測變數為顧客評分。

(1)產品類別部分資料示意表：

表23 產品類別部分資料示意表


| ASIN | 產品類別 | 評論數 | 產品售價 |
|------------|------------------------------|--------|--------|
| B09MV3M4GL | Cell phones and accessories | 11,899 | 51.62 |
| B07PZSXL9J | Cell phone wall chargers | 8017 | 39.99 |
| B01IUTIUEA | Cell phone wall chargers | 5660 | 39.99 |
| B00P933OJC | Cell phone wall chargers | 3765 | 30.99 |
| B07D64QLQ1 | Laptop chargers and adapters | 3754 | 25.99 |
| B097PTBB5V | Laptop chargers and adapters | 3744 | 29.99 |
| B07ZCGYP27 | Cell phone wall chargers | 2928 | 54.99 |
| B08KTG9L3H | Chargers and adapters | 2444 | 49.99 |
| B07VSMK849 | Cell phone wall chargers | 2150 | 24.53 |
| B07DFGXLY4 | Cell phone wall chargers | 2120 | 119.99 |
| B08YJLMQGD | Cell phone wall chargers | 2047 | 49.99 |

(2)產品評論部分資料示意表：

表24 產品評論部分資料示意表

| ASIN | 產品類別 | 產品評論 | 標題 | 評分 |
|------------|---|---|--------------------------|----|
| B07D64QLQ1 | USB-C Power adapter /charger Above 60 W | Now that most brands are switching to USB-C (apple included), it's really ridiculous that brands still charge absurd amounts of money for their own-brand charger. This will charge any 65 w device regardless of brand for a fraction of the price. Beautifully made; I plan to buy more. | Don't buy anything else | 5 |
| B07D64QLQ1 | USB-C Power adapter /charger Above 60 W | It works with the dell xps13. What I like is the compact nature of it—the small form factor is great for travel. Excellent. However, for travel and a future where you'll be in coffee shops doing work, a longer cord is needed. It looks to be about a three-foot cord which barely stretches from a floor outlet to your device. Wish it came with a 6- or 10-foot cord. | Good charger, short cord | 4 |
| B07D64QLQ1 | USB-C Power adapter/ charger Above 60 W | Works great. I bought it as a spare charger. for my thinkpad, but it also charges my HP and several other USB-C devices. | Works great | 5 |

第二節 最佳化產品規格分析模式之主題分析



本研究使用進行主題分析，將類似顧客需求及產品功能與規格偏好的評論分為同一主題，並定義出不同顧客需求對應的產品功能、產品規格之關係（例如：該主題內顧客偏好哪些產品需求或產品功能）。一般而言，主題數量的選擇主要分為評論數據的規模與複雜度、模型解釋性、任務目的三者，而本研究之主題模型設定是採用專業知識與文獻研究結果方式，透過綜合部門產品經理討論、文獻產品特徵變數結果，以決定選擇五個主題數，其他參數如N-gram設定為雙詞，以相鄰的兩個詞彙作為一個單位，N-gram字典大小則設定20000，可避免字典過大、運算資源不足等問題。

表25 主題模型參數

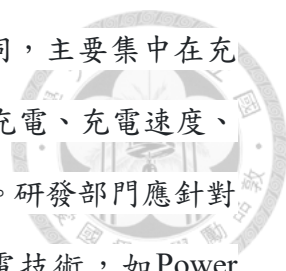
| 主題模型參數名稱 | 參數設定值 |
|------------------------|-------|
| LDA numbers | 5 |
| N-gram | 2 |
| N-gram dictionary size | 20000 |

本研究將詳細分析結果，依顧客評論萃取各主題顧客討論內容，分別找出顧客需求與產品功能相關關鍵詞，並進行產品開發策略建議，茲整理如下：

一、第一個主題的顧客需求與產品偏好

本研究將第一個主題定義為「品牌意識」，這些詞彙主要集中在不同品牌名稱上，應為顧客關注的品牌，主要為電子配件品牌偏好、知名電子品牌、科技配件品牌、電子產品品牌選擇等，如SAMSUNG 三星、Apple蘋果、Anker安克、ZMI紫米等品牌，大部分為充電器、電池或其他電子配件，因此可根據文獻將其取名為品牌意識。產品經理可據此瞭解市場趨勢，研究Anker、Samsung、Apple等品牌的產品特點和市場定位，以了解自家產品在市場上競爭的優勢及不足。需求對應的開發功能部分，則以尺寸較為顯著，產品經理可借鑒品牌如Nekteck、Spigen等在產品便攜性及設計美學規劃上創新，設計更輕便、更符合現代美學的充電器。

二、第二個主題的顧客需求與產品偏好



本研究定義第二個主題為「充電效率」，根據所提及關鍵詞，主要集中在充電效率與速度相關的關鍵詞上，如充電性能、快速充電、高效充電、充電速度、充電功率等，顯示顧客對充電器性能與充電時間的偏好與需求。研發部門應針對快充技術制定支援計畫，使新產品支持市場上主流快速充電技術，如Power Delivery (PD)、Quick Charge (QC)，滿足顧客對快速充電的需求，顯著縮短充電時間。根據需求與開發功能分析結果，GaN技術較為顯著；研發部門可以採用GaN技術提供更高的功率輸出，並配合引入智慧充電管理技術，根據設備需求調整電流和電壓，確保充電器能提供高功率輸出，適應多種設備需求，提升顧客體驗。

三、第三個主題的顧客需求與產品偏好

本研究定義第三主題為「購買價格」，該主題關鍵詞主要集中在價格、購買意向、性價比相關的關鍵詞，包括：價格與性價比、產品定價、經濟實惠等，其顧客偏好為較符合預算、負擔得起的產品。研發部門應進行高性價比的產品設計，專注於核心功能品質，並簡化不必要之功能；行銷端則在宣傳中比較同類競品突顯價格優勢，讓顧客感覺購買產品符合性價比。

四、第四個主題的顧客需求與產品偏好

本研究將第四主題定義為「認證與技術規格」，其關鍵詞彙主要集中在產品認證及技術規格上，如認證與合規、技術標準與認證、安全與技術認證、PD 3.0、PDO、TUV等認證，顧客需求主要為充電器能通過多種安全認證（如UL、FCC、CE、RoHS等），不同市場的規定與標準（如PSE、TUV、ETL等），以及最新技術支持（如USB PD 3.0、PPS等）。根據需求與開發功能分析結果，GaN技術、尺寸與USB埠較為顯著；GaN技術可以提高充電器的效率和性能，同時減少充電器的體積，但同時也需要確保產品的安全性能。尺寸和USB埠的設計也需要考慮產品的安全性和功能性，以確保產品能夠符合顧客的期望，並滿足相關的國際認證要求。因此，研發部門在開發新產品時應該密切關注這些因素，確保產品在安全性和技術水平方面能夠滿足顧客的期望。

五、第五個主題的顧客需求與產品偏好

本研究將第五主題定義為「品質與耐用度」，根據關鍵詞內容，該些詞彙主要集中在產品品質及耐用度相關，例如停止工作、過電流保護、強大的噪音抗干擾等產品品質與耐用性、可靠性與穩定性相關詞彙，因此顧客產品需求為，高品質與耐用性、穩定與一致性能、安全性與保護功能，根據需求與開發功能分析結果，GaN技術與USB埠較為顯著；因此，GaN技術和USB埠的選擇與產品的安全性和可靠性密切相關，對於確保產品的品質和安全性至關重要。因此研發部門在設計階段必須確定產品的品質標準所使用的材料和元件，這包括選擇適合的GaN技術和USB埠，以確保產品能夠經受長期使用而不易損壞。

表26 主題分析結果

| 主題1 品牌意識 | 主題2 充電效率 | 主題3 購買價格 | 主題4 認證與技術規格 | 主題5 品質與耐用度 |
|-------------|---------------------|-----------------------|-------------------|------------------------|
| Anker | Charged fast | Cheap | TUV certification | Break your phone |
| Samsung | Charges fast | Expensive | IEC 62368-1 | Robust noise immunity |
| Nekteck | Charging efficiency | Pricy | USB-IF | Overcurrent protection |
| Apple | Charging speed | Affordable | UL certification | Died |
| Spigen | Charging time | Cost-effective | UE | Quit working |
| Innergie | Consistent power | Reasonable | FCC | Spotty |
| Syncwire | Efficiently | Costly | SGS NA listed | Stop charging |
| Nekmit | Enough power | Inexpensive | DOE Level VI | Stopped working |
| ZMI | Fast | Awesome price | CE | Well built |
| TECKNET | Fast charge | Cheaper | ETL | Temperature |
| Baseus | Have a fast charge | Reasonably priced | RoHS | Worked flawlessly |
| UGREEN | High-speed charging | Great value for money | PSE Certificate | Pitched sound |
| Hyphen-X | Lose power | Great price | PD 3.0 | Sketchy |
| AOHI | Max output | Good price | PDO | Terrific |
| Ixcv | Powerful | Pricy | PPS | Charge intermittently |

表27 主題特徵矩陣

| 顧客需求 \ 產品功能 | GaN | 功率 | 兼容設備 | 尺寸 | USB埠 | 重量 |
|-------------|-------|-------|-------|-------|-------|-------|
| 主題1 品牌意識 | 0.63% | 0.15% | 0.12% | 1.41% | 0.55% | 0.52% |
| 主題2 充電效率 | 1.03% | 0.01% | 0.02% | 0.02% | 0.69% | 0.65% |
| 主題3 購買價格 | 0% | 0% | 0% | 0.01% | 0.01% | 0% |
| 主題4 認證與技術規格 | 1.11% | 0.11% | 0.11% | 0.86% | 0.75% | 0.06% |
| 主題5 品質與耐用度 | 1.14% | 0.03% | 0.03% | 0.25% | 0.59% | 0.06% |

第三節 最佳化產品規格分析模式之機器學習分析

(1)預測模型參數設定：本研究根據較佳範圍組合彙整超參數最佳候選值結果：

表28 模型參數最佳候選值結果

| 模型名稱 | 參數名稱 | 參數值 |
|----------|---|-----------------------------|
| CNN | Padding | {same, 2} |
| | Pool size | |
| LSTM | Activation | {relu,0.3,20,100,0.001,100} |
| | Dropout rate | |
| | Timesteps | |
| | Hidden nodes | |
| | Learning rate | |
| | Number of iteration | |
| XGBoost | Maximum number of leaves per tree | {20,10,0.1,100} |
| | leaves per tree | |
| | Minimum number of samples per leaf node | |
| | Learning rate | |
| 隨機森林 | Total number of trees constructed | {8,32,1} |
| | Number of decision tree | |
| | Number of decision tree | |
| | Maximum depth of tree | |
| | Minimum number of sample per leaf node | |
| LightGBM | Maximum number of leaf tree | {20,10,0.2,100} |
| | Maximum number of sample leaf node | |
| | Learning rate | |
| | Total number of trees constructed | |

Note: *資料筆數為 3,492,632

(2)預測模型準確度與穩健度檢定：

在預測模型的準確度檢定方面，四個模型（LSTM、CNN、CNN-LSTM、LDA-LightGBM）的 MAE、RMSE、RSE、RAE 與決定係數值皆非常接近，顯示預測表現較為相近。其中，LDA-LightGBM 稍高於其他三個模型。從運算時間方面來看，LDA-LightGBM 的訓練時間最短（403 秒）。在預測模式的穩健度檢定方面，無論訓練資料百分比為 70%、80% 或 90%，各模型對不同主題的預測結果都非常相似，顯示分析模式已呈現相對穩定之狀態，增加訓練資料百分比及調整主題數等參數之增加應不影響預測性能。綜合準確度與訓練時間實測結果，LDA-LightGBM 建模為效率相對較高之選擇，尤其在執行大型數據集時效率差異會較為明顯。因此，本研究採用 LDA-LightGBM 模式進行預測。

表29 預測模式模型檢定

| 模型名稱 | MAE | RMSE | RSE | RAE | Coefficient of Determination | Time* |
|--------------|------|------|------|------|------------------------------|-------|
| LSTM | 1.10 | 1.35 | 1.00 | 0.98 | 1.03% | 5765 |
| CNN | 1.10 | 1.34 | 0.99 | 0.98 | 1.25% | 1240 |
| CNN-LSTM | 1.09 | 1.34 | 0.99 | 0.98 | 2.34% | 3482 |
| LDA-LightGBM | 1.08 | 1.33 | 0.98 | 0.98 | 3.15% | 403 |

Note: *time to train the model (in second)

表30 預測模式穩健度檢定 (RMSE)

| 訓練資料百分比% | 模型名稱 | 主題 1 | 主題 2 | 主題 3 | 主題 4 | 主題 5 |
|----------|----------|------|------|------|---------|--------|
| | | 品牌意識 | 充電效率 | 購買價格 | 認證與技術規格 | 品質與耐用度 |
| 70 | LSTM | 1.36 | 1.35 | 1.35 | 1.35 | 1.35 |
| | CNN | 1.34 | 1.34 | 1.34 | 1.34 | 1.34 |
| | CNN-LSTM | 1.34 | 1.34 | 1.34 | 1.34 | 1.34 |

| | | | | | | |
|----|------------------|------|------|------|------|------|
| | LDA- LightGBM | 1.34 | 1.33 | 1.33 | 1.33 | 1.33 |
| 80 | LSTM | 1.36 | 1.35 | 1.35 | 1.35 | 1.35 |
| | CNN | 1.35 | 1.34 | 1.34 | 1.34 | 1.34 |
| | CNN-LSTM | 1.35 | 1.34 | 1.34 | 1.34 | 1.34 |
| | LDA- LightGBM | 1.34 | 1.33 | 1.33 | 1.34 | 1.33 |
| 90 | LSTM | 1.36 | 1.35 | 1.35 | 1.35 | 1.35 |
| | CNN | 1.35 | 1.34 | 1.34 | 1.34 | 1.34 |
| | CNN-LSTM | 1.35 | 1.34 | 1.34 | 1.34 | 1.34 |
| | LDA- LightGBM | 1.34 | 1.33 | 1.33 | 1.34 | 1.33 |

(3)顧客需求及產品功能重要性排序：

表31 顧客需求與產品功能排序

| 排名 | 顧客需求 |
|----|--------------|
| 1 | 主題 3 購買價格 |
| 2 | 主題 2 充電效率 |
| 3 | 主題 4 認證與技術規格 |
| 4 | 主題 5 品質與耐用度 |
| 5 | 主題 1 品牌意識 |

| 排名 | 產品功能 |
|----|-------|
| 1 | 功率 |
| 2 | 尺寸 |
| 3 | USB 埠 |
| 4 | 重量 |
| 5 | 兼容設備 |
| 6 | GaN |

本研究運用機器學習模型進行 Permutation Feature Importance 分析，通過標準化數據評估顧客需求與產品功能之重要性。根據表 31 的排序結果，我們清楚地了解到顧客對產品的關注點以及他們對產品功能的期望。顧客需求方面，購買價格、充電效率、認證與技術規格、品質與耐用度以及品牌意識是排名前五的關注重點。在產品功能方面，功率、尺寸和 USB 埠是北美電子商務平台顧客尤其關注的特點，這些屬性應該是研發部門重點考慮的開發功能。而重量、兼容設備和 GaN 的重要性顯示北美顧客對充電器的便利性和通用性功能的重視程度。整體而言，若新產品缺乏以上特點，將無法滿足北美消費者的需求，也將缺乏市場競爭力。該分析提供了有價值的顧客洞察，可以指導產品研發部門在開發新產品時應該考慮因素，掌握生產這些產品所該具備的關鍵規格及其未來要發展方向。

第四節 最佳化產品規格分析模式之最佳化模式計算

(1)最佳化模型參數設定：本研究欲解決核心問題是在分析符合顧客產品需求之產品規格，並進行最佳化推薦。本研究為研發部門建構最佳化產品規格分析量化分析模式，推薦他們產品規格制定新產品開發計劃，藉由分析所得之顧客規格評分資料、顧客需求與產品特徵資料及產品功能與規格對應資料，進行產品價值(或產品效用)最佳化求解，表32為本研究最佳化模型參數設定區間：

表32 最佳化模型參數設定區間

| 參數符號 | 數值區間 | 中文涵義 |
|----------|---|------------------------|
| i | $i=1$ (第一個顧客需求), 2 (第二個顧客需求)⋯ 5 (第5個顧客需求) | 顧客需求，取五個關鍵顧客需求 |
| j | $j =1$ (產品規格1), 2 (產品規格2)⋯ 252 (產品規格252) | 產品規格，共252個規格 |
| k | $k =1$ (產品功能1), 2 (產品功能2)⋯ 6 (產品功能6) | 產品功能，取六個關鍵產品功能 |
| C_{ij} | 數值數據，為主題特徵矩陣 | 顧客需求 i 與產品規格 j 配適值 |
| R_{ij} | 數值數據，為產品需求對應產品規格之評分 | 顧客需求 i 與產品規格 j 配分值 |

| | | |
|---|-----------------------------|--|
| P_{kj} | 數值數據，為產品功能與產品規格的對應值 | 用於對應功能與規格，功能 k 具有規格 j |
| X_{ij} | 1 or 0 | 顧客需求 i 匹配產品規格 j 為1，否則為0，為決策變數與二元數據 |
| $\begin{aligned} & \text{Max Product utility} \\ & = \sum_i \sum_j C_{ij} X_{ij} \\ & + \sum_i \sum_j R_{ij} X_{ij} \\ & - 10^5 \left(\sum_i P_{kj} - 1 \right)^2 \end{aligned}$ | 最大化產品效用價值，並確保每個產品功能對應一個產品規格 | $C_{ij} X_{ij}$ ：所有顧客需求與產品規格特徵值參數資料 $R_{ij} X_{ij}$ ：有顧客需求與產品規格評分參數資料 P_{kj} ：所有產品功能與產品規格的對應資料 |

(2) 最佳化推薦產品規格及產品效用值

表33 最佳化推薦產品規格及產品效用值

| 產品功能 | 推薦產品規格 | 產品效用 |
|------|---------------------------|------|
| GaN | GaN I | 133 |
| | GaN II | 66 |
| | GaN III | 25 |
| 功率 | A1 Max 20W | 485 |
| | A2 Max 20W | 485 |
| | A3 Max 20W | 485 |
| | C3 Max 18W | 284 |
| | A2 Max 12W | 283 |
| 兼容設備 | PD3.0 | 257 |
| | QC4.0 | 111 |
| | PowerIQ 3.0 | 120 |
| | PPS | 178 |
| | SCP | 69 |
| 尺寸 | 4.19 x 3.37 x 1.34 inches | 886 |
| | 3.5 x 4.5 x 1.3 inches | 501 |
| | 3.54 x 3.41 x 0.79 inches | 488 |
| | 2.09 x 1.6 x 1.17 inches | 370 |
| | 2.56 x 2.56 x 1.3 inches | 304 |
| | 2.95 x 1.42 x 1.26 inches | 264 |
| | 1C | 203 |

| | | |
|-------|-------------|-----|
| USB 埠 | 1C1A | 57 |
| | 2C | 135 |
| | 2C1A | 250 |
| | 3C1A | 289 |
| | 1C3A | 488 |
| | 2C2A | 264 |
| | 4C | 25 |
| 重量 | 2.99 ounces | 164 |
| | 4.6 ounces | 154 |
| | 13.4 ounces | 153 |
| | 2.88 ounces | 148 |
| | 2.1 ounces | 148 |

第五節 最佳化產品規格分析模式之推薦系統

以研究案例二公司為例，製造商在開發新產品時，通常難以在第一時間取得第一手消費者回饋，必須依賴過去經驗對顧客消費需求進行人工判讀，推估既有市場顧客可能喜歡之產品特性，以不斷試錯的方式進行新產品開發，距離所謂精準研發尚有改善的空間。本研究在案例公司研發流程中，整合機器學習模型與品質功能展開分析架構，透過將顧客需求轉化為具體的產品功能與產品規格，藉以推薦研發人員最適研發規格，加速研究公司產品研發速度，包括縮短市場調查、概念提案、產品樣品設計、生產模組規劃之作業時間，並設計符合顧客消費需求之新產品，確保研究公司推出的新產品能提升顧客滿意度，將消費資訊快速回饋至研發流程中，簡化行銷人員和研發人員跨部門溝通流程。

以下為本研究分析模組介紹與系統整合步驟說明：

步驟一：顧客消費需求分析模組，將主題分析模型整合進品質機能展開架構中之顧客需求部分，將產生之主題構面做為顧客需求輸入品質機能展開架構顧客需求列表。

步驟二：需求重要性排序模組：在市場顧客需求調查過程中，根據Permutation

Feature Importance分析結果進行顧客需求重要性排序，藉此將顧客的需求排序，列出相對權重分數。

步驟三：產品技術規格評估模組，主題分析模型生成基於個別顧客需求的“顧客需求-產品功能”特徵矩陣。將顧客需求分析結果整合進產品開發過程之中將顧客需求分析產生的主題分析之特徵矩陣，並透過設定截取值、擷取顧客需求與產品功能配適度較高數值，將顧客聲音及產品設計要求聯繫起來，取得解決顧客需求之產品功能特徵，並作後續產品規格推薦分析之重要參考數值。

| Weight Chart | Customer Importance | Product Attribute | GaN | Wattage | Compatible devices | Size | USB Ports | Weight |
|--------------|---------------------|------------------------|--------|------------|--------------------|---------------------------|-----------|-------------|
| | | Customer needs | | | | | | |
| | 1 | Price | | | | | | |
| | 2 | Charging speed | | | | | | ● |
| | 3 | Certification | | | | | ● | |
| | 4 | Quality & Durability | ● | | | | | |
| | 5 | Brand | | ● | ● | ● | | |
| | | Product specifications | GaN I | AI Max 20W | PD3.0 | 4.19 x 3.37 x 1.34 inches | 1C3A | 2.99 ounces |
| | | Product rating | 4.66 | 4.53 | 4.76 | 4.68 | 4.49 | 3.01 |
| | | Product sales | 21,897 | 272,643 | 33,817 | 871,010 | 478,879 | 137,889 |
| | | Product utility | 2,413 | | | | | |

圖27 AI-QFD架構

(本研究整理)

步驟四：產品規格關聯分析模組，透過機器學習分析建立現有的產品規格與產品需求之關聯性，做為工程技術取捨考量，並分析較高評分之產品規格組合，使本

研究能夠更加瞭解產品需求、產品規格與顧客滿意度之間的關係。

步驟五：推薦最適化規格模組：計算每個產品規格之加權分數，並根據顧客需求配適及所屬工程技術/產品功能進行最佳化規格推薦，據此排出研發採用規格的優先順序，愈高分表示愈能影響終端市場顧客評價。經過專案團隊討論後，再設定出各工程技術應該達成的規格目標，做為產品設計和生產的參考。

步驟六：A-IQFD架構：最後運用品質機能展開架構整合上述分析模組，該模式結合人工智慧方法輔助品質機能展開(AI-assisted Quality function Deployment, 簡稱AI-QFD)架構整合推薦符合顧客效用的產品設計規格。每個階段的輸入主要與顧客需求相關、輸出則與產品設計規格相關，在本階段中，本研究將分析結果與所提供之模式，藉由QFD架構將其整合至企業的研發管理系統或行銷管理系統。透過上述分析模型，本研究將制定模型及各項產品需求項與規格項，整合至產品研發系統，串接產品資料庫即時分析，再以QFD視覺化呈現，該架構可作為顧客需求驅動的產品服務系統(Product Service System, 簡稱PSS)。如此一來，製造業在設計新產品或市場調查將有實質性幫助。也可以提升管理系統的使用者體驗，幫助業者快速上手。

第六節 產品研發2X2矩陣

過去製造市場的消費數據都在經銷商與通路手上，對於消費者喜好變動和區域偏好缺乏掌握，產品經理無法有效推展新產品開發計畫，產品研發則持續倚靠自身經驗不斷試錯以找出較佳樣品，以致後續推出的產品不符合目標市場需求。

本研究透過分析消費市場顧客數據精準研發新產品，嘗試瞭解終端市場的顧客需求以及產品需求和產品功能之間的關係，並據此些資訊進行最佳化研發產品規格推薦，以及進行推薦時，預測模型與最佳化模型之輸出結果，如何轉換為行動方案，協助決策者在開發新市場時，有可依循的準則進行新品研發。

首先以主流市場規格與產品規格需求度之實際配適程度，結合 Clayton Christensen 之創新理論，將最佳化模型輸出結果進行邏輯梳理，概分為四種情況，



表 33 為 2X2 產品研發矩陣：

表33 2X2 產品研發矩陣

| 產品規格需求度 / 主流市場規格 | 該規格為目標市場的主流標準規格 | 該規格非目標市場的主流標準規格 |
|------------------|--|---|
| 該產品規格符合目標市場顧客需求 | 應採用採用漸進式創新，繼續改善既有產品的性能，驅使產品逐步往高階市場發展，注意必須過度依賴該延續性技術，以防止市場競爭更加激烈，提早進入出現紅海市場 | 有機會產生破壞式創新，目前這些規格還未在主流市場熱門，卻符合主流市場的顧客需要，研發部門應基於此些規格快速推出新產品，以發掘潛在藍海市場。 |
| 該產品規格不符合目標市場顧客需求 | 該技術規格可能進入現有產品生命週期第一曲線之衰退期，研發部門應盡快對該技術規格進行市場評估，評估其是否值得進行研發投資，並重新擬定新產品開發策略，開啟第二曲線創新。 | 該技術可能已無市場需求，逐漸被新技術取代，研發部門應持續追蹤買家與賣家的反饋意見，並適時地減少投入逐漸轉向其他新興市場，規劃新產品線。 |

以下將分別根據四種情況進行說明與產品開發策略，茲整理如下：

第一種情況是，當模型模擬得出，該產品規格符合目標市場顧客需求時，且該規格同時為目標市場的主流標準規格，則研發部門應採用漸進式創新，繼續改善既有產品的性能，驅使產品逐步往高階市場發展，注意必須過度依賴該延續性

技術，以防止市場競爭更加激烈，提早進入出現紅海市場。

第二種情況是，當模型模擬得出，該產品規格符合目標市場顧客需求時，但此規格不是目標市場的主要標準規格，則有機會產生破壞式創新，目前這些規格還未在主流市場熱門，卻符合主流市場的顧客需要，研發部門應基於此些規格快速推出新產品，以發掘新藍海市場。

第三種情況是，當模型模擬得出，該產品規格不符合目標市場顧客需求時，但此規格仍為目標市場的主流標準規格，表示消費者偏好轉變，該技術規格可能進入現有產品生命週期第一曲線之衰退期，研發部門應盡快對該技術規格進行市場評估，評估其是否值得進行研發投資，並重新擬定新產品開發策略，開啟第二曲線創新。

第四種情況是，當模型模擬得出，該產品規格不符合目標市場顧客需求時，並且此規格不是目標市場的主流標準規格，表示該技術可能已無市場需求，逐漸被新技術取代，研發部門應持續追蹤買家與賣家的反饋意見，並適時地減少投入逐漸轉向其他新興市場，規劃新產品線。

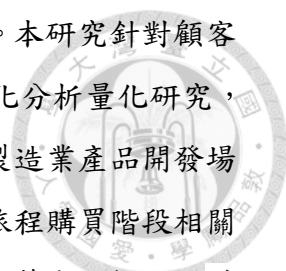
第六章 研究結論與建議

第一節 研究結論與貢獻



考慮到數位競爭的激烈程度以及先前文獻中的理論缺口，本研究專注於三階段購買流程的差異，並提出一個整合購買三階段分析流程及其最佳化分析模型。基於該分析模型，本研究透過先進的機器學習技術與方法論建構一個系統分析框架，進一步分析以實地應用臺灣產業數位行銷及產品開發場景，以兩個概念驗證（Proof of Concept）研究案例進行理論之實證研究。先探討續顧客旅程購買三階段分析方法論以及最佳化量化分析模式文獻，歸納出三階段分析模式；再整合各種先進機器學習預測技術、最佳化方法及啟發式演算運算架構，建置跨行業標準化系統分析，使電子商務行業能以現有的工作流程為基礎，自動化半結構化及非結構資料轉換、並將資料進行不同維度轉換應用，如產生顧客分群、生成顧客需求構面等，再根據顧客-通路-產品三角關鍵特徵進行購買前、購買時、購買後整合分析與預測，產生完整參數資訊以求解最佳化顧客價值或產品效用，在不同資料限制下找出最佳的資源配置或產品開發方式。演算架構也將自適化更改預測模式，重新構建訓練模型及校正更新，根據模型性能自動採行當前最適用的模型演算法與最佳化架構。

為了精準估計顧客在所有通路序列下對不同產品屬性之購買轉換價值，並有效執行演算法運算，產生具準確性及穩健性的預測結果，本研究先對非結構化資料及半結構化資料進行維度轉換處理，再混合先進梯度提升技術及二進制差分進化技術順利執行大規模求解，並確認該分析模式在執行分類與迴歸預測問題與最佳化問題求解時，分析模式較文獻基準模式準確與穩健。在數位行銷專案實地執行中，啟發式演算架構跳脫全域最佳解的特性，尋求一區域可行解，即時提供決策者通路規劃之可行策略。也確認，相較整數規劃法在求解小型規劃問題時會有執行時間過長之情況，啟發式演算架構較能順利運作，分析模型參數設定和流程設定更為簡易，利於企業決策支援模式之建置。



而本研究 and 過往顧客購買分析研究相比，有以下幾項貢獻。本研究針對顧客旅程購買階段管理、顧客-通路-產品三角關鍵特徵探討、最佳化分析量化研究，以臺灣企業真實工作場景和數據，分別針對金融業數位行銷與製造業產品開發場景進行系統性分析框架的實證研究；透過應用過往文獻中顧客旅程購買階段相關理論觀點，以兩個研究案例實證所提出之購買三階段分析架構。藉由所提供之購買三階段分析架構，以及整合非結構化資料維轉轉換、先進機器學習預測系統與最佳化分析等量化模式，解決金控公司數位部門常見數位行銷工作問題（目標顧客經營、行銷通路規劃、通路資源配置管理準則），及製造公司產品研發部門常見的產品設計問題（目標市場調查、開發產品規格、產品研發管理準則）。對企業在系統化評估各顧客/通路/產品價值，及最佳化顧客購買流程皆有實質性的幫助。為管理科學方法在行銷與研發研究領域之實務運用提供參考，該數據分析模型適用於產業中企業對消費者（Business to Consumer，簡稱為 B2C）、直接對消費者（Direct to Consumer，簡稱為 D2C）與消費者對製造商（Consumer to Manufacturer，簡稱為 C2M）商業模式的電子商務公司。

第二節 管理意涵

本研究主要有兩項理論意涵。首先，本研究從顧客旅程管理和「顧客-通路-產品」的學理，推導出電子商務部門應發展出「顧客旅程購買週期三階段」和「顧客-通路-產品三角關係」這兩項能力來為顧客價值估計模型創造價值，並對提出的整合機器學習與最佳化技術之分析框架進行實證研究。這些成果不僅推進了顧客價值估計、顧客關係管理、顧客旅程購買週期等研究的理論發展，也可作為企業進行顧客價值評估和多通路顧客價值最佳化的參考依據。其次，本研究證實由機器學習預測技術和最佳化分析技術整合可以有效地提昇企業的動態數據分析能力及最佳化企業資源配置之效益，顧客洞察分析系統的分析框架為企業系統提供了數值數據、非結構化分析和自動化分析能力。這項研究發現不僅可作為企業構建和發展電子商務顧客數據分析方案建置的參考模式，也透過最佳化通路資源配置法則與產品研發矩陣在營運管理情境下，為管理者在營運管理問題（如顧客價值預測、會員經營管理、行銷通路自動配置、通路資源管理準則）及產品

研發問題（如顧客需求分析、產品功能模組設計、新產品規格推薦、產品研發管理準則）上提供了實務應用參考，對企業在系統化管理顧客購買週期、最佳化顧客旅程管理及產品創新與敏捷開發方面皆有實質性的幫助。

在實務意涵方面，根據最佳化模型輸出結果進行商業邏輯梳理，整理出數位行銷與產品開發管理法則，分別為通路資源配置之管理準則與產品研發矩陣，透過呈現顧客與通路、市場與產品之間的情況與其較佳應對策略，部門決策者可據此理解本研究分析模式所預測產生之最佳規則，使有價值的資訊成為可執行的方案，並同時促進組織標準化智慧決策程序推進。

以下三點建議，供企業在導入顧客洞察分析系統時參考。

（一）多通路整合與動態分析的應用

行銷科技（Martech）這類新型業務模式，往往需要較多新知識和經驗的累積，並且公司常需耗費大量的時間與人力運營。正如研究所示，若企業缺乏優良的顧客洞察分析技術，在行銷管理、顧客經營、行銷通路開發與資源規劃上可能會面臨更多問題。本研究驗證了整合不同通路的顧客數據進行顧客終身價值分析，實現顧客購買旅程的全方位動態分析。這不僅能強化各種類型線上通路的顧客互動和點擊行為數據，還能降低企業的整體轉換成本。管理者可以更深入地了解顧客群體、購買行為、通路接觸點對電子商務轉換的影響，進而制定更精準的行銷策略，達到數據驅動精準行銷之目的，也可以讓企業內專責團隊與代理商有較佳的合作模式。

（二）數據驅動的產品服務系統

根據實地走訪臺灣製造業公司，發現公司研發痛點往往在於市場調研不準確、不清楚顧客產品需求，導致設計出的研發功能或規格不符合消費市場需求。儘管這些公司擁有熟悉通路資訊的工程師，或具備創新研發構想的工程師，但仍缺乏完整的消費資訊進行評估，並且缺少分析這些數據的技術與人才，難以廣泛應用數據驅動技術。再者，產業受到 Covid-19 疫情的衝擊，更加速了製造業服務化與

數位轉型步伐，數據導向的業務活動將越來越重要。為了使企業能夠更快地採用新的資訊技術，本研究通過引入先進的數據分析方法和品質機能展開（QFD）架構，使企業能夠自動產生顧客需求和產品功能的重要性排序，並根據這些資訊進行產品功能對應和最佳化產品規格推薦。這幫助研發部門能夠即時識別關鍵研發規格，快速展開新產品開發規劃，支持顧客驅動製造（C2M）的商業模式，提高市場響應速度和產品創新能力，並在變動快速、不確定性高的商業環境中獲得持續性的競爭優勢。

（三）整合機器學習與啟發式最佳化技術的實地應用

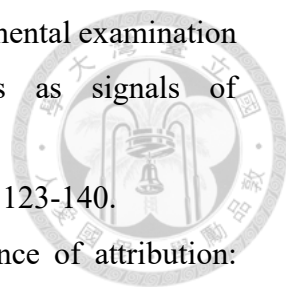
在真實業務環境中，構建以數據化、自動化與智慧化為核心的新系統，將有助於將營運數據自動化分析並轉換為實際工作決策，促進運營人員工作效率。本研究將機器學習與啟發式最佳化技術結合，形成企業決策支援系統的核心引擎。藉由本研究兩個研究案例的概念性驗證，企業在導入顧客洞察分析系統，其導入可以加強動態數據分析和資源分配，支援數值數據和非結構化數據的處理，不僅提升了工作決策預測準確性，還能提供自動化的數據分析和決策支援，管理法則之建構還強化了人工智慧技術的可解釋性，增加員工對新科技的信任度。數據技術應用能持續積累決策與反饋資訊，逐漸發展成為企業的核心資源，形成長遠的企業能耐。

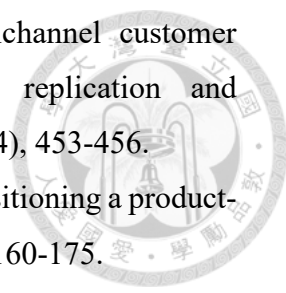
第三節 研究限制與未來方向

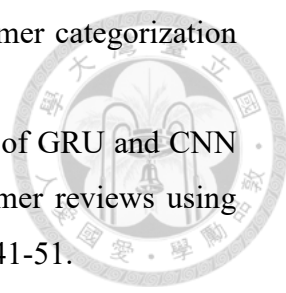
在研究限制方面，因電子商務資料疊代較快，顧客常有非結構化資料、時間序列、資料分布、資料稀疏性等問題，本研究探討諸多方法文獻克服以上問題，如提出資料前處理機制、整合多源資料、導入先進技術處理序列性資料與產生推薦參數、整體式學習方式平衡資料與增添隨機性等，解決因資料結構、時間序列、資料分布等問題。而在最後預測產品規格，決策建議，技術演進和市場演進，受限於當下的技術層次，未來仍需持續研究分析模式自我學習機制，包括模型自適化學習和參數回饋機制，進一步建構更完備分析模式，使實務上系統自動化執行更臻完善。


參考文獻

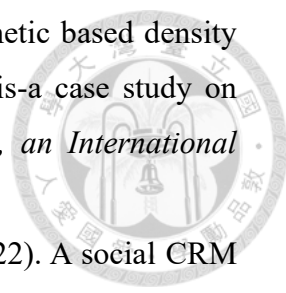
1. Abbasimehr, H., and Shabani, M. (2021). A new methodology for customer behavior analysis using time series clustering: A case study on a bank's customers. *Kybernetes*, 50(2), 221-242.
2. AboElHamd, E., Shamma, H. M., and Saleh, M. (2020). Dynamic programming models for maximizing customer lifetime value: An overview. In *Intelligent Systems and Applications: Proceedings of the 2019 Intelligent Systems Conference (IntelliSys) Volume 1* (pp. 419-445). Springer International Publishing.
3. Akaka, M. A., and Vargo, S. L. (2014). Technology as an operant resource in service (eco) systems. *Information Systems and e-business Management*, 12, 367-384.
4. Anderl, E., Becker, I., Von Wangenheim, F., and Schumann, J. H. (2016). Mapping the customer journey: Lessons learned from graph-based online attribution modeling. *International Journal of Research in Marketing*, 33(3), 457-474.
5. Anderl, E., Schumann, J. H., and Kunz, W. (2016). Helping firms reduce complexity in multichannel online data: A new taxonomy-based approach for customer journeys. *Journal of Retailing*, 92(2), 185-203.
6. Arthur, D. Y., Harris, E., and Annan, J. (2012). Principal Component Analysis of Customer Churns in Ghanaian Telecommunication Industry. *American International Journal of Contemporary Research*, 2(12).
7. Barwitz, N., and Maas, P. (2018). Understanding the omnichannel customer journey: determinants of interaction choice. *Journal of interactive marketing*, 43(1), 116-133.
8. Bauer, J., and Jannach, D. (2021). Improved customer lifetime value prediction with sequence-to-sequence learning and feature-based models. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 15(5), 1-37.
9. Berendes, C. I., Bartelheimer, C., Betzing, J. H., and Beverungen, D. (2018). Data-driven customer journey mapping in local high streets: A domain-specific modeling language.
10. Birant, D. (2011). Data mining using RFM analysis. In *Knowledge-oriented applications in data mining*. IntechOpen.

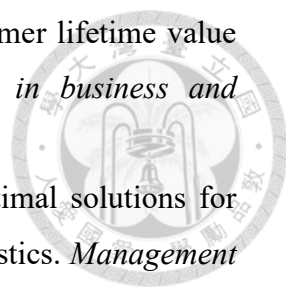
- 
11. Boulding, W., and Kirmani, A. (1993). A consumer-side experimental examination of signaling theory: do consumers perceive warranties as signals of quality?. *Journal of consumer research*, 20(1), 111-123.
 12. Breiman, L. (1996). Bagging predictors. *Machine learning*, 24, 123-140.
 13. Bui, M. T., Jeng, D. J. F., and Lin, C. (2015). The importance of attribution: connecting online travel communities with online travel agents. *Cornell Hospitality Quarterly*, 56(3), 285-297.
 14. Cha, J. E., Kim, S., and Lee, Y. (2009). Application of multidimensional scaling for marketing-mix modification: A case study on mobile phone category. *Expert Systems with Applications*, 36(3), 4884-4890.
 15. Chang, H. H., Jeng, D. J. F., and Hamid, M. R. A. (2013). Conceptualising consumers' word-of-mouth behaviour intention: evidence from a university education services in Malaysia. *Service Business*, 7, 17-35.
 16. Chen, L., and Homem-de-Mello, T. (2010). Re-solving stochastic programming models for airline revenue management. *Annals of Operations Research*, 177(1), 91-114.
 17. Chen, P. P., Guitart, A., del Río, A. F., and Perriñez, A. (2018, December). Customer lifetime value in video games using deep learning and parametric models. In *2018 IEEE international conference on big data (big data)* (pp. 2134-2140). IEEE.
 18. Colicev, A., Kumar, A., and O'Connor, P. (2019). Modeling the relationship between firm and user generated content and the stages of the marketing funnel. *International Journal of Research in Marketing*, 36(1), 100-116.
 19. Covington, P., Adams, J., and Sargin, E. (2016, September). Deep neural networks for youtube recommendations. In *Proceedings of the 10th ACM conference on recommender systems* (pp. 191-198).
 20. Crosier, A., and Handford, A. (2012). Customer journey mapping as an advocacy tool for disabled people: A case study. *Social Marketing Quarterly*, 18(1), 67-76.
 21. De Haan, E., Wiesel, T., and Pauwels, K. (2016). The effectiveness of different forms of online advertising for purchase conversion in a multiple-channel attribution framework. *International journal of research in marketing*, 33(3), 491-507.

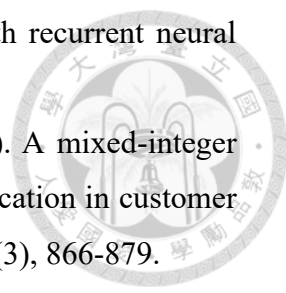
- 
22. De Keyser, A., Schepers, J., and Konuş, U. (2015). Multichannel customer segmentation: Does the after-sales channel matter? A replication and extension. *International Journal of Research in Marketing*, 32(4), 453-456.
23. Dobson, G., and Kalish, S. (1993). Heuristics for pricing and positioning a product-line using conjoint and cost data. *Management Science*, 39(2), 160-175.
24. Dodds, W. B., Monroe, K. B., and Grewal, D. (1991). Effects of price, brand, and store information on buyers' product evaluations. *Journal of marketing research*, 28(3), 307-319.
25. Dorigo, M., Maniezzo, V., & Colomi, A. (1996). Ant system: optimization by a colony of cooperating agents. *IEEE transactions on systems, man, and cybernetics, part b (cybernetics)*, 26(1), 29-41.
26. Edelman, D. C., and Singer, M. (2015). Competing on customer journeys. *Harvard business review*, 93(11), 88-100.
27. Edelman, D. C., and Singer, M. (2015). Competing on customer journeys. *Harvard business review*, 93(11), 88-100.
28. Edvardsson, B., Gustafsson, A., and Roos, I. (2005). Service portraits in service research: a critical review. *International journal of service industry management*, 16(1), 107-121.
29. Ellamil, M., Fox, K. C., Dixon, M. L., Pritchard, S., Todd, R. M., Thompson, E., and Christoff, K. (2016). Dynamics of neural recruitment surrounding the spontaneous arising of thoughts in experienced mindfulness practitioners. *Neuroimage*, 136, 186-196.
30. Fader, P. S., Hardie, B. G., and Lee, K. L. (2005). RFM and CLV: Using iso-value curves for customer base analysis. *Journal of marketing research*, 42(4), 415-430.
31. Følstad, A., and Kvale, K. (2018). Customer journeys: a systematic literature review. *Journal of service theory and practice*, 28(2), 196-227.
32. Foster, M., Whittle, S., Smith, S., and Hyde, P. (1991). Improving the service quality chain. *Managing Service Quality: An International Journal*, 1(1), 41-46.
33. Goldberg, D. E. (1989). Genetic Algorithms in Search, Optimization and Machine Learning. *Addison-Wesley google schola*, 2, 17-26.
34. Grewal, D., and Roggeveen, A. L. (2020). Understanding retail experiences and customer journey management. *Journal of Retailing*, 96(1), 3-8.

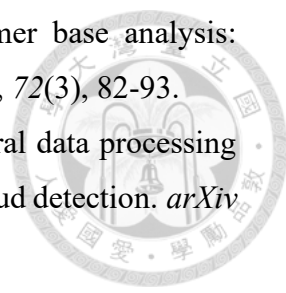
- 
35. Gutman, J. (1982). A means-end chain model based on consumer categorization processes. *Journal of marketing*, 46(2), 60-72.
36. Habbat, N., Anoun, H., and Hassouni, L. (2022). Combination of GRU and CNN deep learning models for sentiment analysis on French customer reviews using XLNet model. *IEEE Engineering Management Review*, 51(1), 41-51.
37. Han, S. C., Lim, T., Long, S., Burgstaller, B., and Poon, J. (2021, October). Glocalk: Global and local kernels for recommender systems. In *Proceedings of the 30th ACM International Conference on Information and Knowledge Management* (pp. 3063-3067).
38. He, B., Shi, Y., Wan, Q., and Zhao, X. (2014). Prediction of customer attrition of commercial banks based on SVM model. *Procedia computer science*, 31, 423-430.
39. Heuchert, M. (2019, July). Conceptual modeling meets customer journey mapping: Structuring a tool for service innovation. In *2019 IEEE 21st Conference on Business Informatics (CBI)* (Vol. 1, pp. 531-540). IEEE.
40. Hochreiter, S., and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
41. Huang, C. Y., Shen, Y. C., Chiang, I. P., and Lin, C. S. (2007). Characterizing Web users' online information behavior. *Journal of the American society for information science and technology*, 58(13), 1988-1997.
42. Hübner, A., Hense, J., and Dethlefs, C. (2022). The revival of retail stores via omnichannel operations: A literature review and research framework. *European Journal of Operational Research*, 302(3), 799-818.
43. Jain, P. K., Saravanan, V., and Pamula, R. (2021). A hybrid CNN-LSTM: A deep learning approach for consumer sentiment analysis using qualitative user-generated contents. *Transactions on Asian and Low-Resource Language Information Processing*, 20(5), 1-15.
44. Jaiswal, E. S. (2012). A case study on quality function deployment (QFD). *IOSR Journal of Mechanical and Civil Engineering*, 3(6), 27-35.
45. Jasin, S., and Kumar, S. (2012). A re-solving heuristic with bounded revenue loss for network revenue management with customer choice. *Mathematics of Operations Research*, 37(2), 313-345.

- 
46. Jayachandran, S., Sharma, S., Kaufman, P., and Raman, P. (2005). The role of relational information processes and technology use in customer relationship management. *Journal of marketing*, 69(4), 177-192.
47. Jiang, Y., Liu, Y., Shang, J., Yildirim, P., and Zhang, Q. (2018). Optimizing online recurring promotions for dual-channel retailers: Segmented markets with multiple objectives. *European Journal of Operational Research*, 267(2), 612-627.
48. Jiao, J., Zhang, Y., and Wang, Y. (2007). A generic genetic algorithm for product family design. *Journal of Intelligent Manufacturing*, 18, 233-247.
49. Jimenez, D. Z., Lim, V., Cheok, L., and Ng, H. (2018). Unlocking the economic impact of digital transformation in Asia Pacific. *IDC White Paper*.
50. Kao, L. J., Chiu, C. C., Wang, H. J., and Ko, C. Y. (2021). Prediction of remaining time on site for e-commerce users: A SOM and long short-term memory study. *Journal of Forecasting*, 40(7), 1274-1290.
51. Karmarkar, N. (1984, December). A new polynomial-time algorithm for linear programming. In *Proceedings of the sixteenth annual ACM symposium on Theory of computing* (pp. 302-311).
52. Katz, M. L., and Shapiro, C. (1986). Product compatibility choice in a market with technological progress. *Oxford Economic Papers*, 38, 146-165.
53. Keller, K. L., and Kotler, P. (2015). Holistic marketing: a broad, integrated perspective to marketing management. In *Does marketing need reform?: Fresh perspectives on the future* (pp. 308-313). Routledge.
54. Kirkpatrick, S., Gelatt Jr, C. D., & Vecchi, M. P. (1983). Optimization by simulated annealing. *science*, 220(4598), 671-680.
55. Ko, Y. H., Hsu, P. Y., Cheng, M. S., Jheng, Y. R., and Luo, Z. C. (2019). Customer retention prediction with CNN. In *Data Mining and Big Data: 4th International Conference, DMBD 2019, Chiang Mai, Thailand, July 26–30, 2019, Proceedings 4* (pp. 104-113). Springer Singapore.
56. Koch, C., Lindenbeck, B., and Olbrich, R. (2023). Dynamic customer journey analysis and its advertising impact. *Journal of Strategic Marketing*, 1-20.
57. Kohli, R., and Krishnamurti, R. (1987). A heuristic approach to product design. *Management Science*, 1523-1533.
58. Kuo, R. J., and Cheng, H. R. (2022). A content-based recommender system with consideration of repeat purchase behavior. *Applied Soft Computing*, 127, 109361.

- 
59. Kuo, R. J., Alfareza, M. N., and Nguyen, T. P. Q. (2023). Genetic based density peak possibilistic fuzzy c-means algorithms to cluster analysis-a case study on customer segmentation. *Engineering Science and Technology, an International Journal*, 47, 101525.
60. Lamrhari, S., El Ghazi, H., Oubrich, M., and El Faker, A. (2022). A social CRM analytic framework for improving customer retention, acquisition, and conversion. *Technological Forecasting and Social Change*, 174, 121275.
61. Larson, J. S., Bradlow, E. T., and Fader, P. S. (2005). An exploratory look at supermarket shopping paths. *International Journal of research in Marketing*, 22(4), 395-414.
62. Lee, W. J., and Kim, D. (1993). Optimal and heuristic decision strategies for integrated production and marketing planning. *Decision Sciences*, 24(6), 1203-1214.
63. Lemon, K. N., and Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of marketing*, 80(6), 69-96.
64. Liu, Y., Soroka, A., Han, L., Jian, J., and Tang, M. (2020). Cloud-based big data analytics for customer insight-driven design innovation in SMEs. *International Journal of Information Management*, 51, 102034.
65. Liu, Y., Soroka, A., Han, L., Jian, J., and Tang, M. (2020). Cloud-based big data analytics for customer insight-driven design innovation in SMEs. *International Journal of Information Management*, 51, 102034.
66. Machchhar, R. J., Toller, C. N. K., Bertoni, A., and Bertoni, M. (2022). Data-driven value creation in Smart Product-Service System design: State-of-the-art and research directions. *Computers in Industry*, 137, 103606.
67. Mak, H. Y., and Max Shen, Z. J. (2021). When triple-A supply chains meet digitalization: The case of JD. com's C2M model. *Production and Operations Management*, 30(3), 656-665.
68. Marmol, M., Goyal, A., Copado-Mendez, P. J., Panadero, J., and Juan, A. A. (2021). Maximizing customers' lifetime value using limited marketing resources. *Marketing Intelligence and Planning*, 39(8), 1058-1072.
69. Mithas, S., Krishnan, M. S., and Fornell, C. (2005). Why do customer relationship management applications affect customer satisfaction?. *Journal of marketing*, 69(4), 201-209.

- 
70. Mzoughia, M. B., and Limam, M. (2015). An improved customer lifetime value model based on Markov chain. *Applied stochastic models in business and industry*, 31(4), 528-535.
71. Nair, S. K., Thakur, L. S., and Wen, K. W. (1995). Near optimal solutions for product line design and selection: Beam search heuristics. *Management Science*, 41(5), 767-785.
72. Neslin, S. A. (2022). The omnichannel continuum: Integrating online and offline channels along the customer journey. *Journal of retailing*, 98(1), 111-132.
73. Niu, Z., Zhong, G., and Yu, H. (2021). A review on the attention mechanism of deep learning. *Neurocomputing*, 452, 48-62.
74. Oh, D., Yoo, M. M., and Lee, Y. (2019). A holistic view of the service experience at coffee franchises: A cross-cultural study. *International Journal of Hospitality Management*, 82, 68-81.
75. Papadimitriou, C. H. (1981). On the complexity of integer programming. *Journal of the ACM (JACM)*, 28(4), 765-768.
76. Peter, A. J., and Viraraghavan, T. (2005). Thallium: a review of public health and environmental concerns. *Environment international*, 31(4), 493-501.
77. Peterson, R. A., and Merino, M. C. (2003). Consumer information search behavior and the Internet. *Psychology and Marketing*, 20(2), 99-121.
78. Pöppel, J., Finsterwalder, J., and Laycock, R. A. (2018). Developing a film-based service experience blueprinting technique. *Journal of Business Research*, 85, 459-466.
79. Purohit, D., and Srivastava, J. (2001). Effect of manufacturer reputation, retailer reputation, and product warranty on consumer judgments of product quality: A cue diagnosticity framework. *Journal of consumer psychology*, 10(3), 123-134.
80. Rao, A. R., and Monroe, K. B. (1988). The moderating effect of prior knowledge on cue utilization in product evaluations. *Journal of consumer research*, 15(2), 253-264.
81. Reinartz, W., Krafft, M., and Hoyer, W. D. (2004). The customer relationship management process: Its measurement and impact on performance. *Journal of marketing research*, 41(3), 293-305.
82. Richardson, P. S., Dick, A. S., and Jain, A. K. (1994). Extrinsic and intrinsic cue effects on perceptions of store brand quality. *Journal of marketing*, 58(4), 28-36.

- 
83. Robin, D., and Hugues, B. (2016). Collaborative filtering with recurrent neural networks. *Computer Science*, 1-8.
84. Sağlam, B., Salman, F. S., Sayın, S., and Türkay, M. (2006). A mixed-integer programming approach to the clustering problem with an application in customer segmentation. *European Journal of Operational Research*, 173(3), 866-879.
85. Suguna, R., Devi, M. S., and Mathew, R. M. (2019). Customer segment prognostic system by machine learning using principal component and linear discriminant analysis. *International Journal of Recent Technology and Engineering*, 8(2), 6198-6203.
86. Sun, C., Adamopoulos, P., Ghose, A., and Luo, X. (2022). Predicting stages in omnichannel path to purchase: A deep learning model. *Information Systems Research*, 33(2), 429-445.
87. Tabianan, K., Velu, S., and Ravi, V. (2022). K-means clustering approach for intelligent customer segmentation using customer purchase behavior data. *Sustainability*, 14(12), 7243.
88. Tarnowska, K. A., and Ras, Z. (2021). NLP-based customer loyalty improvement recommender system (CLIRS2). *Big Data and Cognitive Computing*, 5(1), 4.
89. Valentini, S., Montaguti, E., and Neslin, S. A. (2011). Decision process evolution in customer channel choice. *Journal of Marketing*, 75(6), 72-86.
90. Wang, C. H., and Chen, J. N. (2012). Using quality function deployment for collaborative product design and optimal selection of module mix. *Computers and Industrial Engineering*, 63(4), 1030-1037.
91. Wang, C. H., and Chin, H. T. (2017). Integrating affective features with engineering features to seek the optimal product varieties with respect to the niche segments. *Advanced Engineering Informatics*, 33, 350-359.
92. Wang, Y. H., Lee, C. H., and Trappey, A. J. (2017). Service design blueprint approach incorporating TRIZ and service QFD for a meal ordering system: A case study. *Computers and Industrial Engineering*, 107, 388-400.
93. Wigand, R. T. (1997). Electronic commerce: Definition, theory, and context. *The information society*, 13(1), 1-16.
94. Wijaya, I. W. R. (2022). Development of conceptual model to increase customer interest using recommendation system in e-commerce. *Procedia Computer Science*, 197, 727-733.

- 
95. Wübben, M., and Wangenheim, F. V. (2008). Instant customer base analysis: Managerial heuristics often “get it right”. *Journal of Marketing*, 72(3), 82-93.
96. Zhang, R., Zheng, F., and Min, W. (2018). Sequential behavioral data processing using deep learning and the Markov transition field in online fraud detection. *arXiv preprint arXiv:1808.05329*.
97. Zhang, Y., and Gelb, B. D. (1996). Matching advertising appeals to culture: The influence of products' use conditions. *Journal of advertising*, 25(3), 29-46.
98. Zhang, Y., Dai, H., Xu, C., Feng, J., Wang, T., Bian, J., ... and Liu, T. Y. (2014, June). Sequential click prediction for sponsored search with recurrent neural networks. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 28, No. 1).

附錄

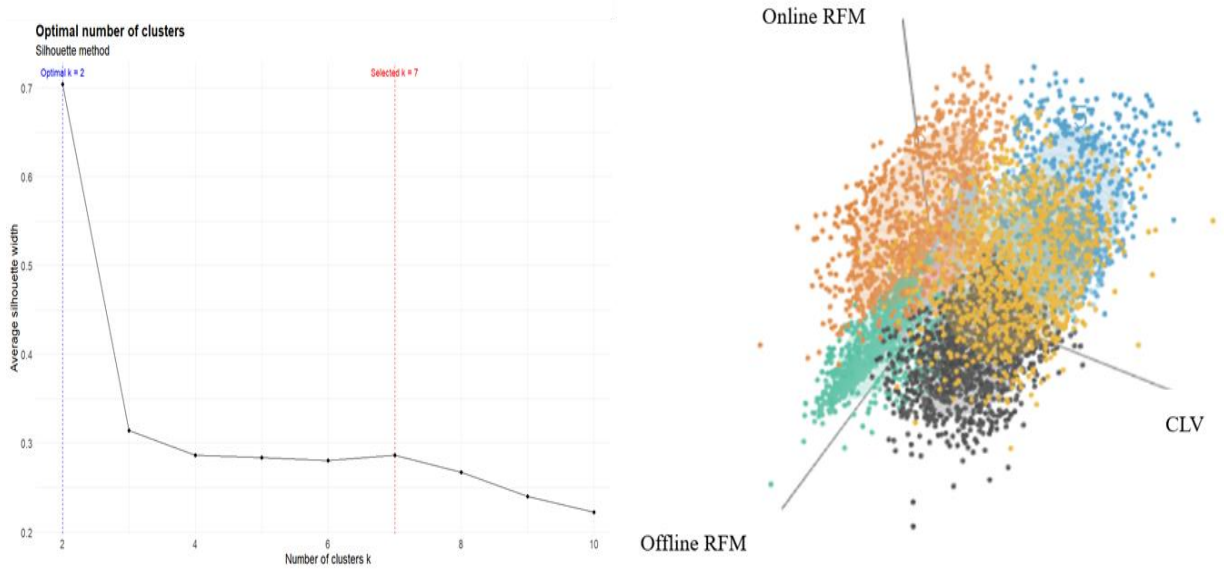


圖26 最佳集群數與視覺化圖
(本研究整理)




圖27 最佳主題數圖
(本研究整理)