

# 結合長短期記憶和大型語言模型之混合型銷售預測模式

\*吳昭儀<sup>1</sup>、楊曉姍<sup>1</sup>、王靜怡<sup>2</sup>

<sup>1</sup>南臺科技大學資訊管理系、<sup>2</sup>南臺科技大學財務金融系

\*jywu@stust.edu.tw

## 摘要

個案公司主要供應國際汽車大廠的各式扣件，目前都是接到訂單後以經驗法則安排後續作業，但面臨原物料採購前置時間長且需求變動大的情況下，常出現待料停機和延遲交貨的問題。對此，本研究提出一結合量化與質性分析的混合式銷售預測模式，協助管理者提前掌握銷售變動，制定更韌性的原物料庫存計畫。量化預測方面使用 ERP 歷史訂單，以 ARIMA 驗證時間序列特性，再訓練建構長短期記憶模型（LSTM）提供銷售預測值，結果顯示排除疫情期間資料的判定係數（ $R^2$ ）達到 0.851。質性分析方面則是收集 775 篇汽車市場景氣報導，微調 BERT 語言模型使其能辨識文章的景氣分類，預測時將當月多篇景氣文章的分類彙整呈現，提供管理者綜合判斷後，適度調整銷售預測值，藉以彌補僅靠時間序列變動軌跡預測時未反應外部變化的風險。本研究混合型方法能更全面地考慮經營環境因素，可有疾改善銷售預測準確性，提昇企業滿足訂單需求的能力。

**關鍵詞：**銷售預測、時間序列、大型語言模型微調、長短期記憶模型

## A Hybrid Model for Sales Forecasting Based on LSTM and LLM Approaches

\*Chao-Yi Wu<sup>1</sup>, Hsiao Shan Yang<sup>1</sup>, Ching-Yi Wang<sup>2</sup>

<sup>1</sup>Department of Information Management, Southern Taiwan University of Technology

<sup>2</sup>Department of Finance, Southern Taiwan University of Technology

### Abstract

The case company primarily supplies various fasteners to international automotive manufacturers. The company currently relies on experience-based rules to schedule subsequent operations after receiving orders. However, given the long lead times for raw material procurement and high demand variability, the company frequently experiences machine downtime caused by material shortages and delayed deliveries. To address this issue, this study proposes a hybrid sales forecasting model that integrates quantitative and qualitative analyses. For the quantitative analysis, historical order data from the ERP system is used. The ARIMA model is employed to verify the time series characteristics, followed by the training and construction of a LSTM model to generate sales forecasts. Results indicate that the  $R^2$  reaches 0.837 after excluding data from the pandemic period. For the qualitative analysis, 775 automotive market reports were collected, and the BERT language model was fine-tuned to identify the sentiment classification of the articles. During forecasting, the classifications of multiple market articles in the target month are aggregated and presented to managers, helping them to make comprehensive judgments and adjust the sales forecasts accordingly. This approach mitigates the risk of failing to reflect external changes when solely relying on time series trends for forecasting. The hybrid approach of this study offers a more comprehensive consideration of external environment factors, significantly improves sales forecast accuracy, and enhances the company's ability to meet customer order demands.

**Keywords:** Sales forecast, Time series, Finetuning large language model, Long short-term memory model

Received: Dec. 6, 2024; first revised: Feb. 10, 2025; second revised: Mar. 19, 2025; accepted: Apr. 2025.

Corresponding author: C.-Y., Wu, Department of Information Management, Southern Taiwan University of Science and Technology, Tainan 710301, Taiwan.

## 壹、緒論

台灣的扣件產業以其高品質產品和嚴格國際標準而聞名，在全球市場上具有舉足輕重的地位，有"螺絲王國"稱號，2023 全年出口達新台幣 1481.5 億元 [1–2]。本研究個案公司致力生產研發高階車用扣件，主要客戶為知名汽車品牌車廠，佔整體營業額九成以上，少量供應車用售後市場零組件製造商。隨著打入國際車廠供應鏈與公司規模日漸擴大後，目前遭遇以下挑戰：首先，接單狀況為大數量訂單，再依指定交期於半年或一年內分批交貨，每月銷售量容易出現較大波動，生產計劃和庫存管理的不穩定性高，使得管理工作更加複雜。其次，生產所需的沖棒、盤元、牙攻等料件因供應鏈特性，採購前置時間可能長達 4 至 5 個月，尤其是新冠疫情後許多供應商交期拉更長，導致個案公司備料時需要更提前或準備更高的安全庫存量。

個案公司目前作法是接到訂單後，依據經驗法則安排原物料採購及庫存水準，但因採購前置時間長，以致時常發生備料不足、採購來不及的情況，迫使機器停工待料，耽誤後續準時交貨達成度。尤其供應商在疫情發生後拉長交貨時間，導致情況更加惡化。如果可以有效預估近期的可能銷售量，將可不必等接到訂單再進行後續處理，而是在訂單發生前，提早一或兩個月準備原物料，就能有效協助改善上述問題。

本研究提出一結合量化預測與質性景氣報導分析的混合型銷售預測模式，協助管理者掌握近期需求量變化，據以建立更穩健的生產計劃和庫存管理。量化預測方面，將使用 ERP 系統的訂單資料建置長短期記憶模型（LSTM）銷售預測模型，提供時間序列基礎的銷售預測值。

但是依賴時間序列變動軌跡進行的預測，並未將當下外在環境的變化因子納入考量並及時反應，而且企業經營所面對的外部環境相當複雜，也很難找到僅以數個因子就能完整表達的模式。因此由具專業知識與多年經驗的機構所提出的未來市場景氣分析文章，則提供了一個可靠的銷售預測參考。藉由收集大量汽車市場景氣文章，微調訓練大型語言模型，使其能自動辨識單一文章的景氣看法，並將多篇報導彙整呈現後，便可以提供市場景氣的質性專家預測參考。

進行預測時，分別進行兩種模型的預測與分析後，管理者便可以在量化銷售預測量的基礎上，依質性的景氣文章彙整進行綜合判斷，適度增減調整銷售預測。如此可以提供更全面向資訊以協助管理者更有效地應對訂單處理時生產計劃複雜與原物料長前置時間的挑戰。

## 貳、文獻探討

### 一、銷售預測

根據過去的銷售資料或相關變數，利用資料分析和統計方法預測未來銷售趨勢和需求量的過程是銷售預測的核心。隨者科技進步、資料量快速增加以及企業需求的不斷變化，銷售預測方法不斷地演進，以下分別探討廣泛使用的統計與機器學習兩類型方法。

#### （一）統計類型方法

統計方法在銷售預測中扮演著關鍵角色，透過分析歷史資料、識別趨勢和模式預測未來。時間序列分析是其中一項主要方法，依時間順序排列並以固定間隔彙集資料，例如每日、每月或每年，通過觀察和建模隨時間變化的態勢來預測未來的走向。主要的時間序列方法包含指數平滑（Exponential Smoothing, ES）、移動平均（Moving Average, MA）與差分整合移動平均自我迴歸模型（Auto Regressive Integrated Moving Average, ARIMA）。

ES 將歷史資料以指數遞減的方式給予權重，近期資料具有較高權重，而較舊資料權重較低，用於捕

捉趨勢和短期變化非常有效 [3]。MA 通過計算一定時間內的資料平均值，並將其應用於連續的時間點，有助於減少噪音和隨機波動的影響，以便更好地觀察趨勢和模式 [4]。Swari et al. [5]開發基於 MA 的系統，幫助企業更好地理解和預測醫療設備銷售趨勢，結果顯示該系統能夠有效地分析銷售資料並提供實時洞察。

ARIMA 則是目前廣泛應用於時間序列預測的統計方法，一般記法為  $ARIMA(p, d, q)$ ，其中  $p, d, q$  分別代表自迴歸 (AR)、差分 (I)、移動平均 (MA)。自迴歸是指模型中與自身的延遲值相關的部分，表示當前觀測值與過去觀測值之間的關係；差分用於將非平穩的時間序列資料轉換為平穩的時間序列資料，可以消除趨勢和季節性等影響因素，使得資料更加穩定；移動平均則是用以表示當前觀測值與過去觀測誤差的關係 [6]。ARIMA 模型對於季節性或是短期的趨勢預測具有很強的效率與精準度，相關文獻如 Fan [7]研究顯示 ARIMA 模型在預測貨幣基金的未來趨勢方面具有較高的精度和可靠性；Kobiela et al. [8] 比較 ARIMA 和深度學習 LSTM 兩種模型預測 NASDAQ 選定公司的日均或月均價格，發現僅使用歷史價格值一個特徵預測時，ARIMA 模型優於 LSTM 模型。

## (二) 深度學習類型方法

深度學習是機器學習的分支，模擬人類大腦的神經網路結構，能夠自主學習並進行深層次的資料分析和預測，更好地理解解析大量且複雜的資料，處理非線性問題時具有多樣性。循環神經網路 (Recurrent Neural Networks, RNN) 與長短期記憶網路 (Long Short-Term Memory, LSTM) 是應用於時間序列預測問題的主要模型。

RNN 具記憶能力，能夠捕捉資料的時間依賴性和序列特徵，可以應用於捕捉短期時間序列資料的趨勢和季節性變化。Lin et al. [9]探討台灣高速公路服務站營運的銷售預測，RNN 對假期的預測表現更出色。Ullah and Qasim [10]使用 RNN 預測 Google 公司股票價格，以 2012 至 2016 年期間資料建立模式預測 2017 年前二個月股價，準確率達到 87.32%。但 RNN 在長序列資料上訓練時，由於梯度在反向傳播過程中的連續相乘，容易發生梯度消失或爆炸問題，難以捕捉長距離依賴關係 [11]。

LSTM 可視為 RNN 的一種變體，透過三個控制閘：遺忘閘 (forget gate)、輸入閘 (input gate) 和輸出閘 (output gate)，根據過去的資訊決定何時遺忘、更新或輸出記憶，改善處理長期時間序列資料的問題。另外引入細胞狀態 (cell state) 貫穿整個 LSTM 網路，作為傳遞資訊的機制，能有效地記憶和傳遞長期依賴關係，此結構設計已被證實在處理長序列時能夠更好地捕捉和利用重要特徵，從而提高模型的預測能力 [12]。應用於預測問題方面的文獻包括：Xie et al. [13]結合 LSTM 與 LightGBM (梯度提升樹) 預測 Walmart 銷售量，RMSSE 達到 0.821，優於線性迴歸與支援向量機等傳統方法。Palkar et al. [14]使用 LSTM 進行酒類消費需求預測，不論是單項商品或是總銷售量的模式  $R^2$  值均超過 0.9，也優於迴歸與支援向量機。Moghar and Hamiche [15]研究探討 LSTM 對股價預測的可行性，使用 Google 與 NKE 兩檔股票 2004~2019 年的開盤價進行驗證，結果證實模型可以追蹤開盤價的變動趨勢。

## 二、大型語言模型微調

自然語言處理 (Natural Language Processing, NLP) 是人工智慧和語言學的交叉領域，聚焦於使電腦能夠理解人類的語言，並分析訊息中的意圖或情緒。但從零開始建置語言模型，對軟硬體設備要求很高、建置時間成本龐大、需要大量的資料支援，對於一般使用者或企業而言難度很高。因此，常用的方法之一是以大型公司或研究機構所推出的大型語言模型 (預訓練模型) 為基礎，再以收集的特定領域資料進行微調訓練 (Fine-tuning) 使其具備解決該領域問題的能力，此作法具備上下文理解、遷移學習、效果提升等多方面優勢 [16]。

常見的主要大型語言模型中，Google BERT 是開源授權且模型大小適中，雖然推出時間早，但在 Google 搜尋伺服器龐大資料支援下，仍是廣泛使用的預訓練模型之一 [17]。考量個案公司的使用成本 (開源性) 與硬體設備 (模型大小) 下，本研究選擇採用 BERT 模型。

## 參、結合量化預測與質性市場文章之混合式銷售預測模式

本研究針對個案公司面臨的挑戰提出一混合式的銷售預測模式，提供可靠預測值協助管理人員提早進行生產規劃與備料採購作業，不必等接到訂單後才開始，減少因庫存不足而停工所衍生的相關問題。

### 一、混合式銷售預測模式架構

混合式銷售預測模式的建構與應用流程如圖1，包括公司歷年訂單趨勢的量化銷售預測與汽車產業景氣文章的質性分析兩部份。個案公司的銷售特色是單一訂單的數量多、於半年至一年間分批生產與出貨，並非每天都有訂單，因此為配合訂單後續的備料與生產管理，選擇以月為預測時間單位。

#### （一）左半部分的量化銷售預測：

蒐集個案公司 ERP 系統的歷年銷售訂單，進行資料清洗與月份彙總等前處理後，先以 ARIMA 確認資料集是否符合時間序列特性，再開始 LSTM 模型訓練，經嘗試不同架構與參數找出符合實務應用標準的量化銷售預測模式。

#### （二）右半部分的質性市場文章分類與彙整分析：

個案公司產品主要銷售至國內外汽車廠，其銷售量高低取決於汽車市場景氣。汽車市場景氣趨勢的報導文章可視為專家經驗與知識的綜合見解，相較於量化預測模型只考慮上下變動型態，可以提供另外的銷售變動可能性參考。先收集網路上關於汽車市場景氣報導，再人工設定景氣分類標籤，包括確定上升、可能上升、持平、可能下降、確定下降等五個級別。接著進行 BERT 模型的微調訓練，藉由不同訓練參數的嘗試，使其可以辨識單一文章的景氣分類。當預測月份別銷售量時，一個月可能會有許多篇市場報導，在識別單一文章的分類後，必須彙整提供統合的參考資訊。

#### （三）綜合評估分析與預測調整：

將指定預測期數輸入 LSTM 銷售預測模型取得量化銷售預測值，並收集當月文章以市場文章景氣分類模型進行單篇分類並彙整。管理者進行綜合評估，依景氣文章彙整資訊調整銷售預測值。

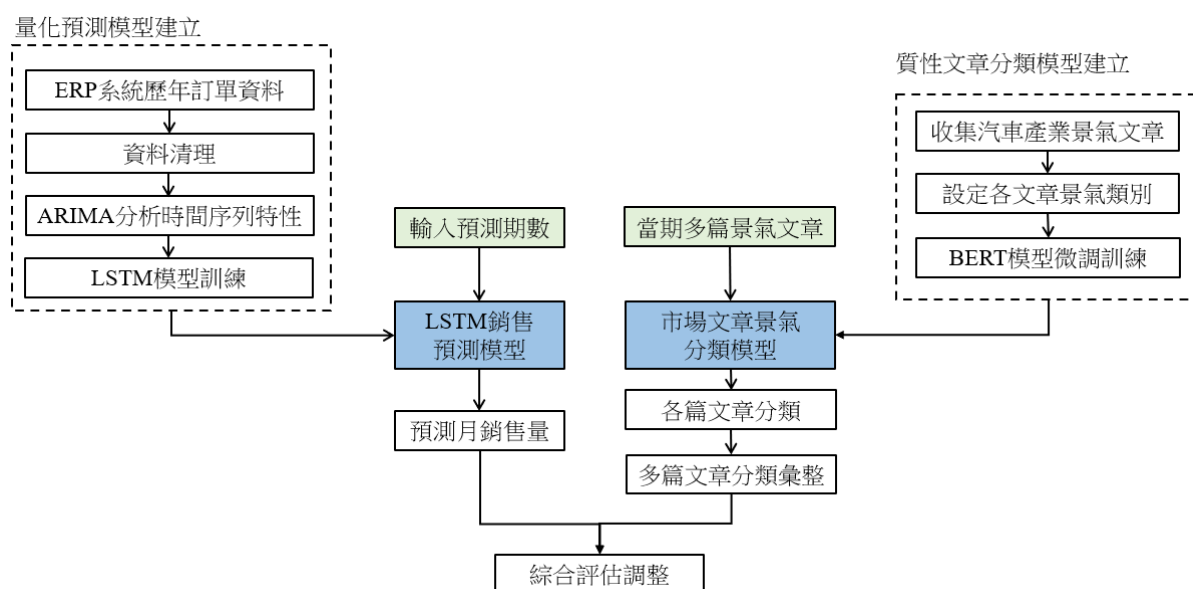


圖1 混合式銷售預測方法架構

## 二、資料蒐集與前處理

研究蒐集量化銷售訂單與質性汽車市場銷售預測報導兩類資料以進行後續模型建置，分別說明如下。

### （一）量化銷售訂單資料

個案公司自 2010 年導入 ERP 系統，此次研究匯出 2010 年 6 月至 2023 年 3 月訂單資料，共計 25,231 筆，經檢查錯誤、缺失、非主要商品等清理工作後，剩餘共 21,699 筆。因以月為預測時間單位，將訂單資料以月份別進行加總後的總筆數為 154 筆。

### （二）質性汽車市場銷售景氣報導

使用 Google 新聞區，以「Car sales forecast」、「Automotive industry outlook」、「Future automotive industry prospects」、「汽車未來銷售預測」、「汽車產業銷售預測」等關鍵字搜尋不同時期產業未來景氣或趨勢相關新聞與報導，篩選後共計 775 篇。每篇報導先經由個案公司高階主管與作者分別逐篇閱讀後，依文章內容採專家判斷法設定景氣類別標籤為確定上升、可能上升、持平、可能下降或確定下降。兩人判定不同部份，再共同討論決定其景氣類別。

## 三、量化的銷售預測模型建構

量化模型建構過程是先以 ARIMA 模型分析資料集的時間序列特性，接著使用 LSTM 建構預測模型並評估模型結果。

### （一）ARIMA 模型分析資料集特性

透過 ARIMA 模型觀察月訂單量的標準化殘差時間序列圖、殘差直方圖及估計密度圖、殘差常態 Q-Q 圖以及殘差自相關圖圖形分佈，評估資料是否符合時間序列的適配、殘差獨立分佈和常態分配假設，確保後續所建置的模型具有穩定和可預測的性能。

### （二）量化 LSTM 銷售預測模型建構

文獻中建立 LSTM 模型時普遍會採用較多層數的複雜結構，目的是希望能在大量資料中找出豐富特徵與降低長時間依賴性的問題。本研究使用的是月份訂單銷售量，資料集共計 154 筆，在嘗試不同建置層級架構過程中發現，因資料筆數不多，過深或是多層複雜的模型結構都會發生過度擬合與難以收斂的問題，預測效果不佳。因此選擇如圖 2 的三層式架構：輸入層、中間層（LSTM 層）、輸出層（全連接層）。LSTM 層中，設置 50 個隱藏單元，並使用 ReLU 作為啟動函數，以增強模型的非線性建模能力，輸入序列的形狀設置為一個時間步長和一個特徵數。全連接層中，僅包含一個神經元，用於輸出單一數值的預測結果。模型的編譯中，選擇 Adam 作為優化器，並將損失函數設置為均方差。模型訓練過程使用早停法，通過監控訓練過程，及時停止訓練，提高模型的泛化能力，確保模型能夠快速收斂並避免過度擬合。




圖 2 LSTM 模型建構層次架構

資料集依 90%、10% 的比例分割為訓練集和測試集，並且為了提高模型的穩定性，資料先進行標準化處理為  $[-1, 1]$  區間。模型的預測結果，則以下列方式評估預測模式適用度：決定係數 ( $R^2$ )、平均絕對百分比誤差 (MAPE)、均方根誤差 (RMSE)、平均絕對誤差 (MAE)，並繪製實際值與模型預測值的比對圖，觀察上下波動轉折的一致性與差異程度。

#### 四、質性市場文章分類模式微調與多篇文章彙整

本研究使用 BERT 語言模型進行微調訓練，以具備汽車市場景氣文章的分類任務。微調方式是將蒐集到的文章集先由作者閱讀內容後進行景氣類別標記，再將已標記文章對 BERT 模型進行訓練。訓練模型建構過程使用 PyTorch 相關套件，嘗試使用不同的訓練週期參數找到最佳辨識能力模型。

以 BERT 微調模型進行文章分類判別時，一般是以最大機率所在類別做為此篇的落點，例如一篇文章的模型判別結果中，各景氣類別（確定上升，可能上升，持平，可能下降，確定下降）隸屬機率值為（0.4787, 0.5157, 0.0041, 0.0005, 0.0009）時，該篇文章會歸類為「可能上升」。然而，當有兩個以上的類別判定機率值相近時，只採用最大值作為落點類別會喪失許多資訊。因此採用以下兩種方法彙整當月多篇景氣文章資訊：

##### （一）方法 1

1. 設定五個類別代表數值：（確定上升，可能上升，持平，可能下降，確定下降）分別為（1, 2, 3, 4, 5）。
2. 計算各篇文章的機率加權平均值，以上述範例而言，  

$$0.4787 \times 1 + 0.5157 \times 2 + 0.0041 \times 3 + 0.0005 \times 4 + 0.0009 \times 5 = 1.5289$$
3. 加總同一月份內文章的機率加權平均值，並除以該月份的文章總數，得到該月份的平均落點值。
4. 透過檢視每篇文章在五個標籤中的分佈情況，可以有效地將各落點都納入考量並分析文章在不同時間段內的標籤分佈變化，從而更全面地涵蓋文章分類的細節資訊。

##### （二）方法 2

除了上述單一平均落點值特徵外，一篇文章內容對於未來景氣狀況的評估可能涵蓋不僅一個月，而是一季甚至更長，但在大多數文章中並未說明預測期間，因此藉由將最近三個月（一季）文章類別的分佈情況以圖形彙總呈現，提供更完整的市場趨勢。以 2022 年 11 月預測為例，統整最近一季文章落點如圖 3，顏色標示採用與景氣對策燈號相同表示方式，紅色代表上升，藍色為下降。從圖中可以觀察到（1）8, 9 月均為黃、藍區塊，顯示對景氣看法保守偏弱；（2）進入 10 月出現景氣上升（紅色）訊號，到 11 月時均為紅色區塊，顯示景氣趨勢的看法已呈現反轉為樂觀。




圖 3 2022 年 11 月銷售預測近一季市場景氣文章綜合趨勢圖

#### 五、混合型銷售預測模型應用步驟

結合以上方法，本研究提出之扣件產業公司混合型銷售預測模型實際應用時的步驟如下：

- （一）以 LSTM 量化模式預測下期的銷售預測值，並將該預測值與當期實際銷售量相比得到升降率。
- （二）收集當期市場景氣相關文章，以 BERT 微調模型辨識各文章的分類後，依上一節方法計算加權平均落點與繪製近期市場綜合趨勢圖。
- （三）綜合評判量化預測值與市場景氣報告，依預測值升降率與質性多篇文章預測分類的落點幅度兩邊進行對比，判斷是否需要對預測值進行調整。

## 肆、混合型銷售預測模型建置與討論

本研究使用的硬體配置包括 Intel Core i7-12700H、16GB 記憶體與 NVIDIA GeForce RTX 3070 Ti 8GB，軟體方面使用 Python 3.9、模型建置與訓練的 PyTorch、Keras、sklearn.metrics 等進行模型建置與評估。

### 一、ARIMA 分析資料集時間序列特性

先以 ARIMA 判斷資料集是否符合時間序列的特性，確認符合後再進行 LSTM 銷售預測模型訓練。ARIMA 模型殘差診斷圖繪製如圖 4，分析說明如下：

- (一) 時間序列圖：沒有明顯時間波動趨勢，表明具足夠擬合性。
- (二) 直方圖及估計密度圖：曲線顯示殘差大致符合常態分佈。
- (三) Q-Q 圖：大部分殘差點沿著對角線分佈，少數在極端值處有一定的偏離，但整體符合常態分佈。
- (四) 自相關圖：絕大部分的自相關係數在置信區間內，表明殘差之間沒有顯著的自相關性。

由上述分析可以確認個案公司訂單資料集符合 ARIMA 適配性。

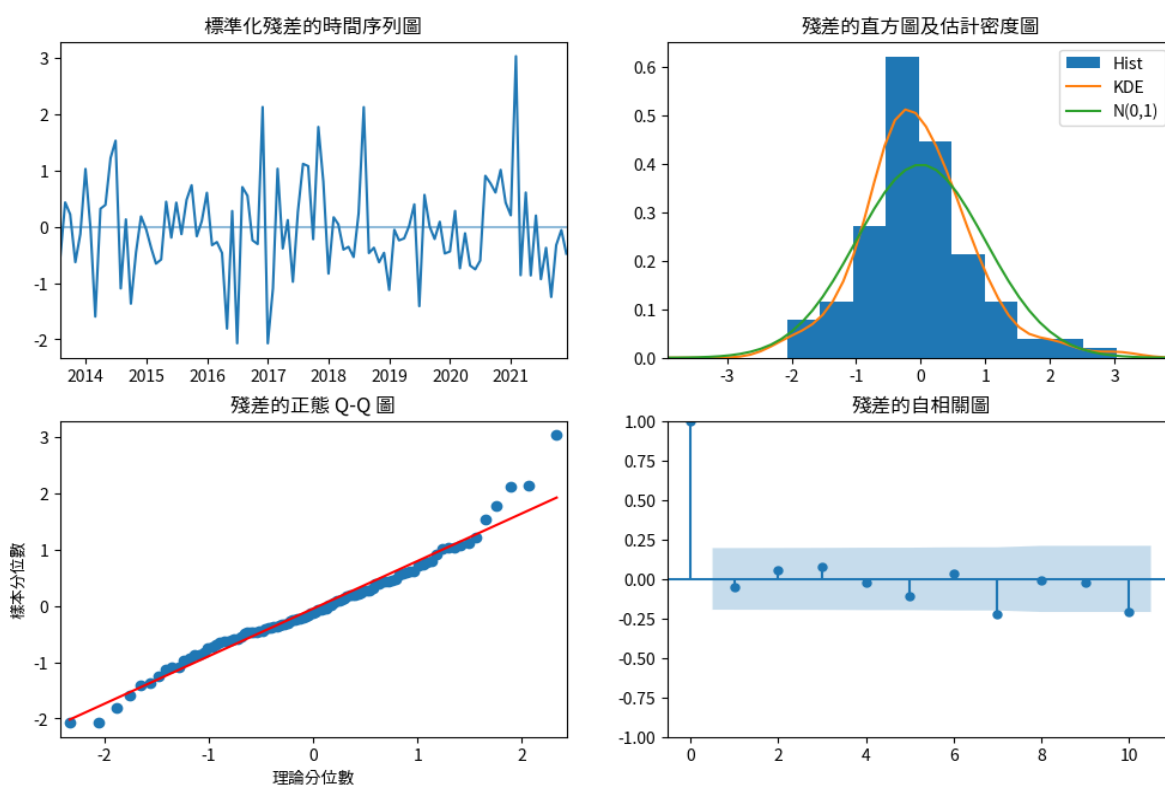


圖 4 ARIMA 模型殘差診斷

接著採用 AUTO ARIMA 方法得到參數  $(p, d, q) = (0, 1, 1)$  為最佳模型，其時間序列的趨勢、季節性和殘差分析如圖 5。分析圖中的時間序列特性：(1) 訂單數量在 2010 年至 2022 年間有明顯的波動，其中一些時期有顯著的高峰和低谷；(2) 趨勢圖資料的長期變化趨勢，整體而言有上下波動的景氣循環，周期長度約在 3~4 年之間；(3) 季節性圖顯示出明顯的季節性特徵，每年都有固定的波峰和波谷，呈現出約一年的週期性波動模式；(4) 殘差的波動則是沒有明顯的結構或模式。由以上分析表明趨勢和季節性分解具充分捕捉資料主要變化特徵的可能性。






圖5 時間序列趨勢、季節性和殘差分析

## 二、 量化 LSTM 銷售預測模型建置與分析

繪製所有月份銷售量的時間序列如圖 6，可以觀察到 2020 年附近出現驟降驟升的不規則情形，探究原因是因為 COVID-19 疫情影響，使得外銷訂單大量減少。因此為了觀察此期間對預測模式建構的影響，將使用兩組資料：第一組是完整年度資料，共 154 筆；第二組是扣除新冠肺炎疫情最嚴重的 2020 年 2 月至 2021 年 6 月資料，共 137 筆。再依 9 比 1 比例分割為訓練集、測試集，作為模型訓練與測試使用，完整全年度資料集將區分為訓練 138 筆、測試 16 筆，扣除疫情期間資料集則是訓練 123 筆、測試 14 筆




圖 6 個案公司 ERP 系統中歷年月銷售量時間序列分布

### (一) 完整年度資料集使用不同訓練週期實驗結果

依建構的三層式 LSTM 模型（隱藏單元數為 7）分別進行 50、100、150、200、250、300 等不同週期數訓練，訓練過程中損失均呈現出快速下降並趨於穩定收斂在 0.05 左右，均能成功擬合訓練資料。接著使用測試資料集驗證各訓練後模型的預測能力，如表 1 結果所示，當訓練週期數增加，RMSE



和 MAE 數值隨著訓練週期數增加而下降，在訓練週期數為 200 次時，兩者均達到最低值，分別為 7260.52 和 6738.39。 $R^2$ 也隨著訓練週期數的增加而逐漸提升，訓練週期 200 時達到最高的 0.168。但增加至 250 次時， $R^2$ 降低為 0.077，300 次時甚至降至 0.037，模型解釋能力反能降低，出現過度訓練擬合現象。整體而言，完整年度資料集訓練模式最高  $R^2$ 值為 0.168，解釋能力仍偏低。

表 1 完整年度資料 LSTM 不同訓練週期結果

訓練週期數 (Epoch)	50	100	150	200	250	300
均方根誤差 (RMSE)	8088.83	8020.63	7945.70	7260.52	7650.08	7812.96
平均絕對誤差 (MAE)	7474.18	7394.30	7246.05	6738.39	7084.99	7222.44
平均絕對百分比誤差 (MAPE)	27.57%	27.32%	26.95%	24.79%	26.10%	26.64%
決定係數 ( $R^2$ )	-0.09	-0.014	0.004	0.168	0.077	0.037

## (二) 扣除疫情期間資料集使用不同訓練週期實驗結果

接著使用扣除疫情期間資料集進行 50、100、150、200、250、300 等不同訓練週期，隱藏單元數同樣為 7，訓練過程中損失也均顯示出快速下降並趨於穩定收斂，而且收斂值明顯低於全年度資料集，最低達 0.04 左右，訓練資料擬合度顯著更佳。再以測試資料集驗證各週期訓練後模型的預測能力，結果如表 2，訓練週期增加至 150 次時得到最佳的預測結果，MAPE 降至 9.89%， $R^2$ 值提高到 0.851，模式解釋能力達到實務應用可行性。但再加訓練次數時的誤差反而逐漸增加，出現過度擬合現象。

表 2 扣除疫情期間資料 LSTM 不同訓練週期結果

訓練週期數 (Epoch)	50	100	150	200	250	300
均方根誤差 (RMSE)	3888.99	3933.87	3073.58	3342.47	3954.88	3814.06
平均絕對誤差 (MAE)	3634.39	3634.76	2828.23	3101.01	3742.69	3611.35
平均絕對百分比誤差 (MAPE)	12.83%	12.77%	9.89%	11.02%	13.40%	12.88%
決定係數 ( $R^2$ )	0.761	0.756	0.851	0.823	0.753	0.770

此外，LSTM 模型建立的隱藏單元數會大幅影響訓練參數量，過多的訓練參數容易造成過度擬合現象。為了解其影響，分別以 50、25、10、7、4 等隱藏單元數各進行 10 次訓練，擷取測試結果最佳的 3 次彙整如表 3。

表 3 扣除疫情期間資料 LSTM 不同隱藏單元數結果 (訓練週期數=150)

隱藏單元數	訓練參數量	$R^2$	MAPE	RMSE	MAE
50	10,451	0.624	15.66%	4883.51	4518.57
		0.623	15.08%	4891.99	4345.01
		0.753	10.96%	3960.85	3265.87
25	2,726	0.615	15.96%	4938.99	4562.93
		0.810	10.07%	3475.62	2948.71
		0.433	19.97%	5996.90	5603.53
10	491	0.820	11.07%	3375.65	3122.52
		0.688	14.85%	4446.91	4229.65
		0.726	13.91%	4172.78	3961.82
7	260	0.824	10.99%	3346.13	3082.77
		0.843	10.14%	3151.37	2861.40
		0.851	9.89%	3073.58	2828.24
4	101	0.819	11.17%	3392.76	3135.03
		0.715	14.19%	4255.77	4032.15
		0.779	12.36%	3747.17	3475.32

從表 3 中的數據可以看出，隱藏單元數=7 時的預測結果最佳，隨著單元數漸增， $R^2$  變小且預測誤差逐漸增加；降為 4 的模型預測結果也不如 7 時。

### (三) LSTM 模型以最佳訓練週期的預測結果圖形分析

分別使用完整年度資料、扣除疫情期間兩組資料集進行 LSTM 模型訓練後，選擇學習預測效果最佳的模型進行預測，繪製測試資料集的預測銷售量與實際銷售量比對圖，如圖 7(a)與圖 7(b)。圖中藍色線代表實際銷售量，橘色線則代表模型預測值。比較結果說明如下：


1. 模型的趨勢捕捉能力佳，圖 7(a)、7(b)中兩個模型都能很好地捕捉到銷售量的趨勢變化轉折點，顯示模型在時間序列預測方面能夠根據歷史資料學習到訂單銷售量的波動特性。
2. 疫情期間的資料有較強的異常性和波動性，圖 7(a)中兩條線間的差距顯著大於圖 7(b)，顯示疫情期間資料嚴重干擾模型的訓練學習效果。
3. 扣除疫情期間資料集的預測誤差顯著低於完整年度資料集，擬合效果更好，預測性能更優越。
4. 扣除疫情期間資料集進行模型訓練的結果更為準確，預測模式  $R^2$  達 0.851，達到實務可行的標準。

### (四) 與 ARIMA、XGBoost 模型預測結果分析比較

#### 1. 與 ARIMA 模型預測結果分析比較：

使用驗證資料集時間序列特性時 AUTO ARIMA 得到的最佳模型參數  $(p, d, q) = (0, 1, 1)$ ，對兩組資料集進行預測，繪製測試資料集的預測銷售量與實際銷售量比對如圖 8(a)與圖 8(b)。圖 8(a)的完整年份預測值高低點位置與實際訂單銷售差異很大，幾乎都不在相同時間點；圖 8(b)扣除疫情期間的預測波動轉折則接近實際值很多，但出現多處預測落後（x 軸 8、10）與方向相反（x 軸 12）的情況，相較於 LSTM 的圖 7(a)與圖 7(b)明顯誤差大上許多。


數值評估指標方面，扣除疫情期間的預測誤差 RMSE、MAE 分別為 7155.95、5832.69，相比於 LSTM 的 3080.08、2823.39 均顯著偏高。 $R^2$  方面僅達 0.204，模型解釋力偏低，不如 LSTM 的 0.851。



(a)完整年度測試集實際與預測值比對

(b)扣除疫情期間測試集實際與預測值比對

圖 7 LSTM 模型的趨勢捕捉能力



(a)ARIMA 完整年度實際與預測值比對

(b) ARIMA 扣除疫情期間實際與預測值比對

圖 8 ARIMA 模型的趨勢捕捉能力

## 2. XGBoost 模型預測結果分析比較：

XGBoost 是基於梯度提升框架的強大機器學習演算法，在各項競賽中表現出色，廣泛應用於商業場景，本節中討論使用於扣除疫情期間資料集的實驗結果。參數調整過程節錄如表 4，說明如下：

階段1: 首先使用以貝葉斯優化技術、適合大範圍參數調整的 Optuna 方法，得到建議最佳模型參數並以測試集資料驗證，結果中  $R^2$  僅為 0.623、MAPE 為 15.14%，效果不佳。

階段2: 增加  $n\_estimators$  不同參數值，表 4 列 3~5 資料顯示 200 時預測效果最佳， $R^2$  提升至 0.707、MAPE 為 12.29%。

階段3:  $min\_child\_weight$  參數調整為 25 時（表 4 列 6）， $R^2$  提升至 0.847、MAPE 為 8.72%。但再增減為 30 與 22 時，預測準確性均降低，選擇 25 為最佳參數值。

階段4: 首先嘗試不同  $max\_depth$  值，並不會影響模型驗證結果。接著增減  $subsample$  參數值為 0.8、0.6，如表 4 列 9~10 所示，預測準確性均降低，選擇 0.6883 為  $subsample$  最佳參數值。

階段5: 嘗試不同  $colsample\_bytree$  值，並不會影響模型驗證結果。接著增減  $learning\_rate$  參數值為 0.05、0.02，如表 4 列 11~12 所示，預測準確性均降低，選擇 0.0104 為最佳參數值。

階段6: 使用  $gamma$  不同參數值，由表 4 列 13~14 資料可以看出預測準確性均不如 0.1 時。

經由以上各階段嘗試得到的最佳模型為表 4 第 6 列， $R^2$  達到 0.847，略低於 LSTM 的 0.851，預測誤差 RMSE、MAE 分別為 3118.94、2968.444，也比 LSTM 的 3080.08、2823.39 稍近，LSTM 模型仍具有比較準確預測效果。

表 4 扣除疫情期間測試集資料 XGBoost 不同參數驗證結果

階段	$n\_estimators$	$min\_child\_weight$	$max\_depth$	$subsample$	$colsample\_bytree$	$learning\_rate$	$gamma$	$R^2$	MAPE	RMSE	MAE
1	100	20	10	0.6883	0.6003	0.0104	0.1	0.623	15.14%	4888.15	4499.57
	200							0.707	12.29%	4314.73	3798.62
2	300	20	10	0.6883	0.6003	0.0104	0.1	0.695	12.56%	4400.13	3845.53
	250							0.695	12.55%	4398.96	3861.22
3	200	25	10	0.6883	0.6003	0.0104	0.1	0.847	8.72%	3118.94	2968.44
		30						0.796	10.03%	3600.81	3083.09
		22						0.794	10.24%	3619.08	3171.17
4	200	25	不影響	0.8	0.6003	0.0104	0.1	0.656	12.91%	4669.09	3986.97
				0.6				0.826	9.15%	3320.66	2998.17
5	200	25	10	0.6883	不影響	0.02	0.1	0.843	9.25%	3158.50	2991.67
						0.05		0.827	10.09%	3314.28	3058.03
6	200	25	10	0.6883	0.6003	0.0104	0.15	0.842	9.04%	3168.94	2974.92
							0.05	0.840	8.92%	3183.90	2972.34

## 三、質性市場文章分類模式微調訓練

在 BERT 模型微調過程中，775 篇文章分割為訓練集 750 篇與測試集 25 篇。模型先進行 30 次訓練週期，但在第 15 次迭代後，損失值的下降趨勢變得不明顯，甚至出現波動且無法降低至穩定收斂。因此採用梯次訓練（Staged training）策略，通過分階段調整學習速率和訓練參數，以提升模型的收斂速度和精度。先以 30 次訓練週期的模型作為原始模型，逐梯增加 5 次訓練週期方式，進行三個梯次的訓練，即以原始模型為基礎，梯次 A 增加 5 次、梯次 B 增加 10 次、梯次 C 增加 15 次，各梯次的訓練過程遺失值如圖 9，可以明顯看出梯次 C 時的遺失值可達到穩定收斂且趨近 0。

再分別以 25 篇測試集文章對各梯次模型進行分類判定，結果彙整如表 5。可以看出隨著訓練週期數增加，模型的準確性顯著提高，梯次 C 可達到 100% 準確率。因此，採用梯次 C 模型作為市場景氣文章分類使用。

表 5 不同梯次訓練模型下測試集分類結果正確率比較

組別	原始	梯次 A	梯次 B	梯次 C
訓練週期數	30 次	(30+5)次	(30+10)次	(30+15)次
正確數	22	24	24	25
錯誤數	3	1	1	0
正確率	88.0%	96.0%	96.0%	100.0%

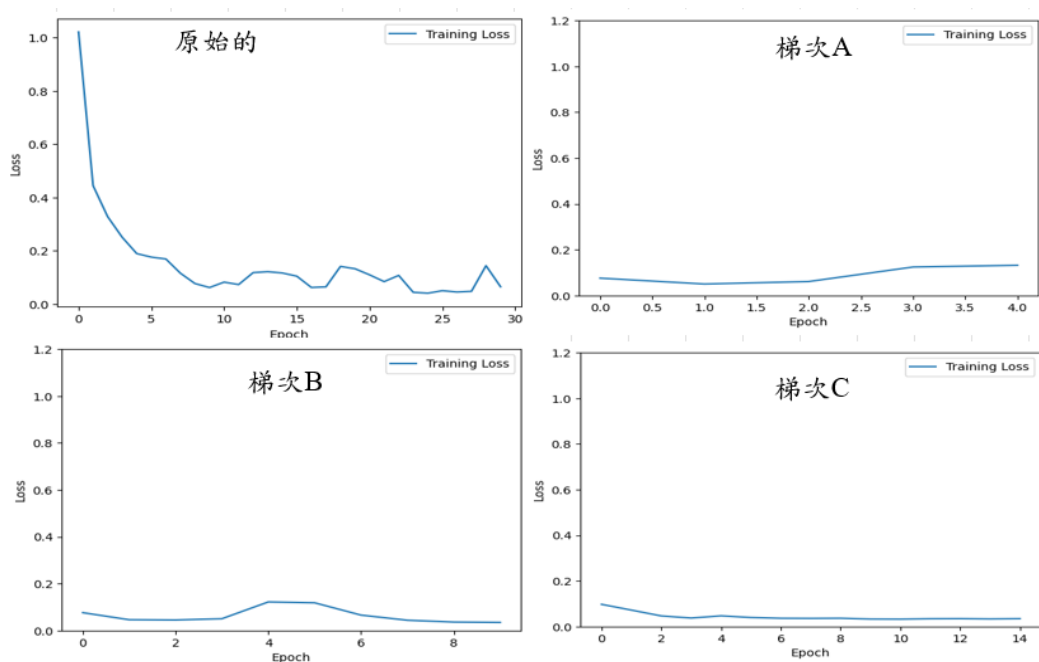


圖 9 各梯次訓練過程收斂情形

#### 四、質性市場多篇文章分類結果彙整

當預測某一月份銷售量時，會有多篇未來市場景氣趨勢的文章，每篇文章有各自的分類結果，需要彙整提供綜合資訊。本研究提出兩種方法進行多篇文章的彙整：

##### (一) 方法一

以 2023 年 2 月份為例，收集到四篇文章，每篇文章經市場文章景氣分類模型判定其各類別機率值與分類結果，彙整如表 6。計算各文章的機率加權平均值，如表 4 最後一欄。再加總四篇文章的機率加權平均值，除以該月份的文章總數，得到該月份的平均落點值： $(1.0450 + 1.0518 + 2.0022 + 1.0128) / 4 = 1.2779$ ，作為 2023 年 2 月份的落點參考。對決策者而言，可解讀為市場對下月景氣的綜合看法幾乎是確定上升。

表 6 月蒐集文章類別落點機率值範例 - 以 2023 年 2 月為例

文章日期	模型類別機率值					分類	加權平均
	確定上升(1)	可能上升(2)	持平(3)	可能下降(4)	確定下降(5)		
2023/2/5	0.9626	0.0314	0.0049	0.0004	0.0006	1	1.0450
2023/2/11	0.9490	0.0507	0.0001	0.0001	0.0001	1	1.0518
2023/2/15	0.0002	0.9984	0.0003	0.0010	0.0001	2	2.0022
2023/2/27	0.9879	0.0118	0.0002	0.0001	0.0001	1	1.0128

## (二) 方法二

加權平均提供具參考性的單一數值特徵，但無法表達文章間看法分歧的狀況，因此計算近期一季內各月份各類別的文章數量，再繪製近期市場綜合趨勢圖，協助決策者不僅可以看到月份內不同報導的分布，還可以觀察趨勢變化。以 2023 年 2 月為例，統計如圖 10，該月文章有 3 篇文章為確定上升趨勢，1 篇可能上升，而沒有持平、可能下降或確定下降的看法。再觀察往前一季的文章分布狀況，多數認為汽車產業會由景氣熱絡下降些至 2023 年初後才再次回升。




圖 10 2023 年 2 月近一季市場景氣文章綜合趨勢圖

## 伍、混合型銷售預測模式應用與分析

本章將探討混合型銷售預測情境分析，以及歷年資料的驗證分析。

### 一、混合型單月銷售預測應用與情境分析

本研究提出之混合型銷售預測模型在分別 (1) 以 LSTM 量化模式預測銷售量，並計算與前期實際銷售量相比的升降率；(2) 收集當期市場景氣文章，以 BERT 微調模型辨識各文章的分類、計算加權平均落點與繪製近期市場綜合趨勢圖後；(3) 決策者以量化預測銷售量為主要依據，再參考質性文章資訊進行適度調整。

然而量化預測模型雖已具備良好的解釋能力 ( $R^2=0.850$ )，圖 6(b) 也顯示能相當準確地掌握變動轉折，但仍有兩點不足：(1) 量化預測值與實際銷售量間仍存在或大或小的誤差；(2) 無法即時反應外部環境突發事件的影響。因此可以透過比較「量化預測值相比前期銷售量的增減幅度」與「質性文章景氣落點值」的變動方向，作為是否調整量化預測值的判斷標準。當變動方向一致時，若增減幅度高、景氣上升確定性高，便可更有信心採用量化預測值或再適度增加；但若增減幅度高、景氣上升確定性偏低，則可以維持或考慮調低增減幅度。反之增減幅度低時也是相同判斷方式。當變動方向不一致時，則有相當機率代表發生外部事件（例如疫情），此時應再檢視外部環境，謹慎考慮調整增減幅度。以下列舉四種不同情境說明：

#### (一) 量化預測「上升」，質性文章景氣「上升」

1. 量化預測：以 2023 年的 2 月為例，LSTM 銷售預測值為 34918.270，前一期實際銷售量為 23037.470，兩者間的變化百分比為上升 51.6%。
2. 質性文章彙整：質性分析顯示，景氣加權平均落點值為 1.25，代表蒐集的文章高度偏向「確定上升」。繪製近期市場綜合趨勢圖如圖 10。
3. 綜合評判：量化預測值相較前期增加 51.6%，蒐集文章的分類落點值為 1.25，兩者方向一致，建議採用銷售預測。但是近期市場綜合趨勢圖介於可能上升轉向確定上升，代表景氣上升仍有疑慮，決策者

可考慮微量下修量化預測值增加率。

## (二) 量化預測「上升」，質性文章景氣「下降」

1. 量化預測：以 2022 年的 3 月為例，LSTM 銷售預測為 44207.240，前一期實際銷售量為 25,851.190，兩者間的變化百分比為上升 70.9%。
2. 質性文章彙整：質性分析顯示，景氣加權平均落點值為 4，代表蒐集的文章高度偏向的「可能下降」，繪製近期市場綜合趨勢圖如圖 11。
3. 綜合評判：量化預測值相較前期增加 70.9%，蒐集文章的分類落點值為 4.24，兩者對下期銷售可能方向成相反看法，代表可能有潛在事件會發生，決策者應謹慎檢視外部環境後決定是否修正量化預測。




圖 11 2022 年 3 月近一季市場景氣文章綜合趨勢圖

## (三) 量化預測「下降」，質性文章趨勢「上升」

1. 量化預測：以 2022 年的 12 月為例，LSTM 銷售預測為 23037.470，前一期實際銷售量為 34974.070，兩者間的變化百分比為下降 34.1%。
2. 質性文章彙整：質性分析顯示，景氣加權平均落點值為 1.5，代表蒐集的文章介於「確定上升」、「可能上升」中間，繪製近期市場綜合趨勢圖如圖 12。
3. 綜合評判：量化預測值相較前期下降 34.1%，蒐集文章的分類落點值為 1.5，兩者對下期銷售可能方向成相反看法。這意謂銷售趨勢雖然是下降，但外部市場可能已呈現反轉利多氛圍，決策者可以再進一步了解市場狀況，決定是否修正量化預測。




圖 12 2022 年 12 月近一季市場景氣文章綜合趨勢圖

## (四) 量化預測「下降」，質性文章趨勢「下降」

1. 量化預測：以 2022 年的 4 月為例，LSTM 銷售預測為 29,434.820，前一期實際銷售量為 50,315.960，



兩者間的變化百分比為下降 41.5%。

2. 質性文章彙整：質性分析顯示，景氣加權平均落點值為 5，代表蒐集的文章高度偏向的「確定下降」。
- 繪製近期市場綜合趨勢圖如圖 13。
3. 綜合評判：量化預測值相較前期下降 41.5 %，蒐集文章的分類落點值為 5，兩者對下期的銷售均持下降看法，所以決策者可以接受量化預測值或是視情況微調下降率。

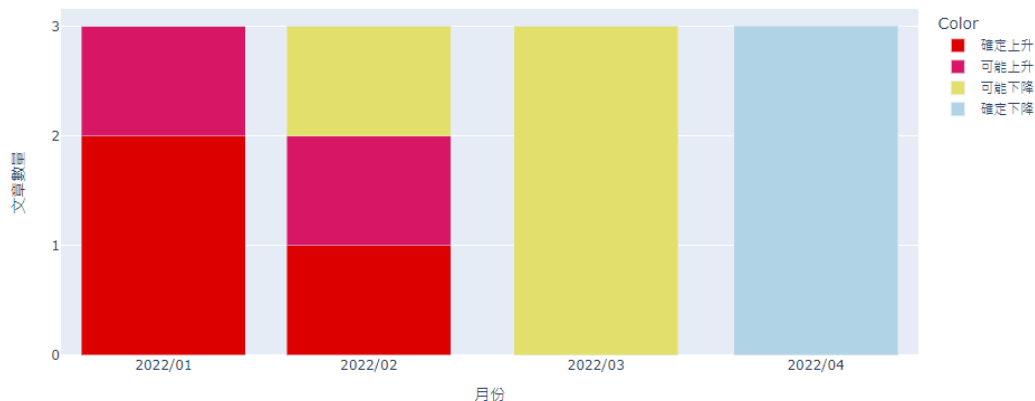


圖 13 2022 年 4 月近一季市場景氣文章綜合趨勢圖

## 二、歷年資料回顧分析

進一步使用 2022 年 1 月到 2023 年 1 月測試資料集回顧模式的應用狀況，將各月份的實際銷售量、LSTM 預測銷售量與文章景氣落點彙合併繪製如圖 14(a)(b)(c)。綜合比較如下：

- (一) 從圖 14(a)的實際與銷售量折線圖可以看出，兩者之間雖然存在一些差異，但主要趨勢和起伏轉折點均保持高度一致性，預測模型能夠有效地跟隨實際銷售資料的走勢。
- (二) 圖 14(a)的量化預測與圖 14(b)(c)的質性景氣文章落點值方面，可以區分以下四個時期進行分析：
  1. 2022 年 2 月之前，從新冠疫情衝擊開始逐漸復甦：此時期的圖 14(b)平值落點值趨勢上揚、圖 14(c)紅色區塊佔比高，反應出市場的樂觀看法，符合圖 14(a)中 2022/2 微降後大幅增加的樣態。
  2. 2022 年 3 月至 2022 年 5 月，俄羅斯突襲烏克蘭爆發戰爭，全球景氣受到衝擊下降：此時期的圖 14(b)平值落點值降至 4~5 間、圖 14(c)全為藍色區塊，呈現全面悲觀，符合圖 14(a)2022/3~2022/5 間的需求急速下降。
  3. 2022 年 6 月至 2022 年 9 月，俄烏戰爭形成僵持：戰爭影響降低，開始有景氣翻轉看法，整體傾向景氣持平，此時期的圖 14(b)平值落點值在 3 上下、圖 14(c)以黃、淺藍色區塊為主，與圖 14(a)同時期需求平緩狀況相符。
  4. 2022 年 10 月之後，俄烏戰爭限縮為局部衝突後回復期：此時期的圖 14(b)平值落點值從 3.5 開始下降（景氣偏上升）、圖 14(c)轉為紅色區塊為主。檢視圖 14(a)，2022/10 後出現兩期需求下降再開始增加，整體趨勢也是上昇態勢，大致相符。但景氣文章的反轉時間比較早，可能是文章中對景氣的預估涵蓋較長期間，不只單一月份，包括對從衰退中回復的期待會提早出現等情形，未來研究將加入文章景氣預測期間變數進一步探討分析。對於個案公司營運作業安排而言，2023 年 1,2 月銷售即快速上升，整體對庫存水準管理影響不大。
- (三) 圖 14(c)的全部文章落點分佈相較於圖 14(b)的單一落點值可以呈現更全面的趨勢變化，包括 2021 年底的新冠疫情影响慢慢復甦、晶片荒、2022 年 3 月後俄烏戰爭影響。有些期間的報導看法一致，但也有許多時候專家們的見解並不相同，透過文章落點分佈能更完整看出市場前景趨勢變化的不同判斷。






圖 14(a) LSTM 月銷售量實際值與預測值



圖 14(b) 每月景氣文章彙總加權平均落點




圖 14(c) 每月景氣文章落點數量分佈

## 陸、結論

個案是一家汽車扣件生產公司，目前採接到訂單後開始安排生產與備料，但因原物料交期長且僅以經驗法則決定物料採購與庫存水準，導致存貨準備不足而停機的狀況持續發生。本研究提出一結合量化預測與質性景氣報導分析的混合型銷售預測模式，協助管理者有效掌握近期需求量變化，據以提早安排，建立更穩健的生產計劃和庫存管理。

量化預測方面，將 ERP 系統約 13 年的訂單資料經清理並彙整為月銷售量後，先以 ARIMA 方法驗證資料集符合時間序列特性，再進行 LSTM 銷售預測模型的訓練與測試。經由嘗試不同模式參數與資料集的分析結果發現：1. 疫情期間確實造成公司銷售狀況偏離原來市場需求，扣除後的模式預測結果明顯能有效掌握變化趨勢；2. 使用扣除疫情期間資料集得到的最佳 LSTM 預測模式，其  $R^2$  達 0.850，達到實務可

行的標準。

量化銷售預測雖然有相當準確性，但無法及時反應外在環境的變化，因此使用 775 篇汽車市場景氣文章對 BERT 模型進行微調訓練，測試結果達到可正確分類單篇文章的景氣看法所屬類別，並將一個月內的多篇報導以加權平均落值與近期文章分佈圖兩種方法進行彙整呈現，藉由未來市場景氣分析文章的專家意見輔助，可以提供更全面的銷售量變動參考。

綜上所述，本研究結合量化和質性方法提出的混合型預測模型具備以下特性：

#### （一）達到可行標準的量化預測：

在沒有外部大型事件發生下，建置的 LSTM 模型經歷史資料驗證可準確掌握變化轉折，模型配適度超過 0.8，MAPE 低於 10%，可以提供具參考價值的訂單預測量。

#### （二）外部環境風險警示：

汽車市場報導文章是產業專家的經驗與知識綜合見解，藉由微調大型語言模型使其能對文章分類其景氣意見，並彙整呈現趨勢變動資訊，可以提供外部變化的風險警示，彌補量化預測的不足。

未來研究方面，一般產業報導內容並沒有一定格式，有些明確指出上升或下降百分比，但也可能僅是隱喻說明，本研究中採用專家法對每篇質化景氣文章進行評斷，設定五等級的景氣類別標籤後對 BERT 預訓練模型進行微調訓練。未來若能設定完整評判尺規，更嚴謹分類報導文章，將可以進一步提昇質性景氣判定研究方法的論證以及應用至其他公司或領域的泛用性。

## 參考文獻

- [1] 紀翔瀛 (2023 年 02 月 17 日)。2022 年第四季及全年我國扣件產業回顧與展望。ITIS 智網。  
[https://www.itis.org.tw/NetReport/NetReport\\_Detail.aspx?rpno=356815962&type=netreport](https://www.itis.org.tw/NetReport/NetReport_Detail.aspx?rpno=356815962&type=netreport)。
- [2] 遠見雜誌 (2021)。小螺絲螞蟻雄兵衝上全球第三大。遠見雜誌出版。  
<https://event.gvm.com.tw/anniversary/35/feature/hardware.html>。
- [3] Panggabean, S., Sihombing, P.R., Dewi, K.H.S., Pramarta, I.N.B., Junaidy, J., & Syaharuddin, S. (2021). Simulasi Exponential Moving Average dan Single Exponential Smoothing: Sebuah Perbandingan Akurasi Metode Peramalan. *Jurnal Pemikiran dan Penelitian Pendidikan Matematika (JP3M)*, 4(1), 1–10.
- [4] Hansun, S. (2013). A new approach of moving average method in time series analysis. *2013 Conference on New Media Studies (CoNMedia)* (pp.1–4). Tangerang, Indonesia.
- [5] Swari, M., Qusyairi, M., Mandyartha, E., & Wahanani, H. (2021). Business intelligence system using simple moving average method (Case study: Sales medical equipment at PT. Semangat Sejahtera Bersama). *J. Phys. Conf. Ser.*, 1899(1), 012121. IOP Publishing.
- [6] Shumway, R.H., & Stoffer, D.S. (2017). *ARIMA models*. Time series analysis and its applications: with R examples, 75–163.
- [7] Fan, W. (2022). Prediction of monetary fund based on ARIMA model. *Procedia Comput. Sci.*, 208, 277–285.
- [8] Kobiela, D., Krefta, D., Król, W., & Weichbroth, P. (2022). ARIMA vs LSTM on NASDAQ stock exchange data. *Procedia Comput. Sci.*, 207, 3836–3845.

- [9] Lin, Y.F., Cheng, C.S., & Chen, Y.C. (2021). Sales forecasting using ANNs or RNNs-A case study of freeway service station in Taiwan. In *2021 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)* (pp.1–2). Penghu, Taiwan.
- [10] Ullah, K., & Qasim, M. (2020). Google stock prices prediction using deep learning. *2020 IEEE 10th International Conference on System Engineering and Technology (ICSET)* (pp.108–113). Shah Alam, Malaysia. <https://doi.org/10.1109/ICSET51301.2020.9265146>
- [11] Fang, W., Chen, Y., & Xue, Q. (2021). Survey on research of RNN-based spatio-temporal sequence prediction algorithms. *J. Big Data*, 3(3), 97–110.
- [12] DiPietro, R., & Hager, G.D. (2020). *Deep learning: RNNs and LSTM*. In *Handbook of medical image computing and computer assisted intervention*. Elsevier.
- [13] Xie, H.H., Li, C., Ding, N., & Gong, C. (2021). Walmart sale forecasting model based on LSTM and LightGBM. *2021 2<sup>nd</sup> International Conference on Education, Knowledge and Information Management (ICEKIM)* (pp.366–369). Xiamen, China. <https://doi.org/10.1109/ICEKIM52309.2021.00087>
- [14] Palkar, A., Deshpande, M., Kalekar, S., & Jaswal, S. (2020). Demand forecasting in retail industry for liquor consumption using LSTM. *2020 International Conference on Electronics and Sustainable Communication Systems (ICESC)* (pp.521–525). Coimbatore, India. <https://doi.org/10.1109/ICESC48915.2020.9155712>
- [15] Moghar, A., & Hamiche, M. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Comput. Sci.*, 170, 1168–1173.
- [16] Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). *Roberta: A robustly optimized bert pretraining approach*. *arXiv preprint arXiv:1907.11692*.
- [17] GeeksforGeeks. (2024, April 30). Top 20 LLM (Large Language Model) Models. GeeksforGeeks.