

逢甲大學學生報告 ePaper

臺灣二手電動車市場行銷策略分析

Analysis of Marketing Strategies in Taiwan's Used
Elec-tric Vehicle Market

作者：曾瑞哲

系級：運輸與物流學系

學號：D1375681

開課老師：周進華

課程名稱：Python 入門與行銷資料科學

開課系所：行銷學系

開課學年： 114 學年度 第一學期

中文摘要

近年來，隨著電動車市場快速成長，二手電動車逐漸成為消費者與車商關注的新興市場。然而，二手電動車價格受品牌、車齡、里程數與電池壽命等多重因素影響，市場資訊不對稱問題明顯，增加交易風險與決策難度。

本研究以臺灣二手電動車市場資料為研究對象，透過 Python 進行資料清理與探索性資料分析，檢視價格分布、品牌結構及價格與里程數、年份之關聯性。進一步運用相關係數分析與品牌分層策略，說明品牌溢價對價格判斷之影響。

在此基礎上，本研究建構隨機森林迴歸模型作為 AI 估價工具，並透過特徵重要性分析，驗證品牌與里程數為影響價格之關鍵因素。最後，結合模型結果發展智慧採購判斷、庫存折舊分析、行銷文案生成與 Web 應用系統，將資料分析成果轉化為具體可執行之行銷與決策支援工具，提升二手電動車市場之決策效率與實務應用價值。

關鍵字：價格預測、機器學習、Python 分析

Abstract

With the rapid growth of the electric vehicle (EV) market, used electric vehicles have become an emerging segment attracting increasing attention from both consumers and dealers. However, pricing in the used EV market is influenced by multiple factors, including brand, vehicle age, mileage, and battery condition, leading to significant information asymmetry and higher transaction risks.

This study analyzes Taiwan's used electric vehicle market using Python-based data science methods. Exploratory data analysis is conducted to examine price distributions, brand structures, and the relationships between price, mileage, and manufacturing year. Correlation analysis and brand stratification are further applied to reveal the impact of brand premium on price interpretation.

Based on these findings, a Random Forest regression model is developed as an AI-based pricing tool. Feature importance analysis confirms that brand and mileage are the most influential factors in price prediction. Finally, the model is extended to practical applications, including intelligent purchasing evaluation, depreciation-based inventory strategies, automated marketing copy generation, and a web-based pricing system. The results demonstrate how data-driven and AI-powered approaches can support marketing strategy formulation and decision-making efficiency in the used EV market.

Keyword : Price Prediction, Machine Learning, Python

目次

第一章	緒論	5
1.1	研究背景與動機.....	5
1.2	研究目的.....	6
第二章	研究方法與資料來源	7
2.1	研究方法.....	7
2.1.1	資料蒐集與前處理.....	7
2.1.2	探索性資料分析 (Exploratory Data Analysis)	8
2.1.3	關聯性分析與品牌分層	8
2.1.4	機器學習模型建構.....	8
2.1.5	應用實作與系統驗證	9
2.2	資料來源.....	9
2.3	分析工具.....	10
第三章	探索性資料分析	11
3.1	提取廠牌特徵	11
3.2	單變量分析	12
3.2.1	價格分佈 (Price Distribution).....	12
3.2.2	各廠牌車輛數量 (Brand Count)	13
3.3	雙變量分析 (Bivariate Analysis)	15
3.3.1	價格 vs. 里程數 (Price vs. Mileage) 驗證里程數對價格的影響 15	
3.3.2	各廠牌價格區間 (Boxplot)	17
3.3.3	相關係數熱力圖 (Correlation Heatmap)	19
第四章	HTML 報告	20
4.1	說明	21
4.2	程式碼	21
4.3	成果展示.....	22
第五章	關聯性分析 (Correlation Analysis)	26
5.1	計算相關係數矩陣	26
5.2	品牌分層.....	30
第六章	訓練 AI 估價師與決策制定	34
6.1	AI 訓練師.....	34

6.2	特徵重要性 (Feature Importance)	37
6.3	決策制定 (Data-Driven Decision Making)	40
6.3.1	智慧採購計算機 (AI Deal Hunter)	40
6.3.2	庫存策略視覺化 (Depreciation Analysis)	43
6.3.3	行銷重點雷達圖 (Marketing Insights)	45
6.3.4	AI 王牌文案產生器	48
第七章	AI 二手電動車估價系統	54
7.1	打造 WEB APP	54
7.2	系統功能與成果展示	58
7.3	系統限制與改進方向	60
第八章	結論	61



第一章 緒論

隨著電動車市場快速發展，二手電動車逐漸成為重要且具潛力的交易市場。然而，其價格受品牌、車齡、里程數與技術更新等多重因素影響，市場資訊不對稱問題明顯，使消費者與車商在交易決策上面臨高度不確定性。本研究以臺灣二手電動車市場為研究對象，結合資料分析與人工智慧方法，探討價格形成機制，並嘗試建構具實務價值之決策支援工具，以提升市場交易效率與決策品質。

1.1 研究背景與動機

近年來，全球汽車產業在淨零碳排與能源轉型政策推動下，電動車市場快速成長。相較於新車市場，二手電動車因價格門檻較低、政策補助逐步擴大，以及消費者環保意識提升，成為具潛力的新興市場。然而，臺灣二手電動車市場仍處於發展初期，消費者對產品風險、電池壽命與保值性存在高度疑慮，使市場推廣與行銷策略成為關鍵課題。

在此背景下，如何透過資料分析方式理解二手電動車市場結構，並據以提出合適的行銷策略，成為產學實務與學術研究的重要課題。因此，本研究嘗試結合資料科學方法，透過探索性資料分析與關聯性分析，系統性探討影響臺灣二手電動車市場價格與消費者行為之關鍵因素。

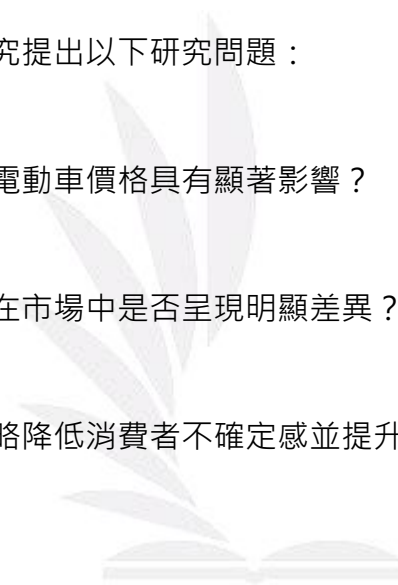
1.2 研究目的

本研究主要目的如下：

- 一、 分析臺灣二手電動車市場之基本結構與價格分布特性。
- 二、 探討車輛品牌、里程數、車齡、電池狀況等變數與價格之關聯性。
- 三、 根據分析結果，提出可行之行銷定位與策略方向。

基於上述目的，本研究提出以下研究問題：

- 一、 哪些因素對二手電動車價格具有顯著影響？
- 二、 不同品牌與車型在市場中是否呈現明顯差異？
- 三、 如何透過行銷策略降低消費者不確定感並提升購買意願？



第二章 研究方法與資料來源

本章說明本研究之資料來源與整體研究方法。研究資料主要取自臺灣二手車交易平台 8891，蒐集二手電動車之品牌、年份、里程數與價格等資訊，並進行資料清理與變數整理。研究方法包含探索性資料分析、相關係數分析與品牌分層策略，以檢視價格與關鍵變數之關聯性，並作為後續機器學習模型建構與實務應用分析之基礎。

2.1 研究方法

本研究採用資料分析與機器學習相結合之研究方法，以臺灣二手電動車市場為研究對象，系統性分析影響價格之關鍵因素，並進一步建構具實務應用價值之 AI 決策支援工具。整體研究流程依序包含資料蒐集與前處理、探索性資料分析、雙變量與關聯性分析、機器學習模型建構，以及應用系統實作五個階段，說明如下。

2.1.1 資料蒐集與前處理

本研究資料主要蒐集自臺灣二手車交易平台（8891 平台）之公開資訊，內容涵蓋車輛品牌、出廠年份、行駛里程與開價等欄位。蒐集完成後，首先進行資料清理作業，包括移除重複資料、處理缺失值與異常值，並將文字型資料轉換為適合分析之數值型變數。此外，為確保分析一致性，針對價格、年份與里程數等變

數進行格式統一與數值轉換，並建立乾淨且可供後續分析使用之資料集。

2.1.2 探索性資料分析 (Exploratory Data Analysis)

在資料前處理完成後，本研究透過探索性資料分析方法，初步掌握二手電動車市場的整體結構與特性。分析內容包含價格分布情形、主要品牌之市場占比，以及不同品牌間之價格區間差異。透過直方圖、箱型圖與散佈圖等視覺化方式，協助辨識價格集中區間、離群值與潛在市場分群，作為後續關聯性分析與模型建構的重要依據。

2.1.3 關聯性分析與品牌分層

為進一步探討價格與關鍵變數間之關係，本研究計算價格、出廠年份與里程數之相關係數，分析其線性關聯程度。然而，由於不同品牌存在明顯定價差異，直接進行整體相關分析可能受到品牌溢價干擾。

因此，本研究進一步採用品牌分層策略，將不同品牌分別進行分析，並以單一品牌作為對照組重新計算相關係數，以釐清里程數與年份對價格之實際影響方向與強度

2.1.4 機器學習模型建構

在完成前述分析後，本研究採用隨機森林迴歸模型 (Random Forest Regressor) 進行價格預測。模型輸入變數包含品牌、出廠年份與行駛里程，輸出為預測之市

場價格。

研究中將資料切分為訓練集與測試集，以評估模型之預測能力，並透過決定係數 (R^2) 與平均絕對誤差 (MAE) 作為模型效能指標。此外，藉由特徵重要性分析，評估各變數在模型中的相對影響程度，以提升模型之可解釋性。

2.1.5 應用實作與系統驗證

本研究將訓練完成之模型延伸至實務應用層面，發展多項 AI 應用模組，包括智慧採購判斷、庫存折舊分析、行銷重點建議與自動化文案生成，並進一步建構互動式 Web 應用系統。透過實際操作與測試案例，驗證模型與系統在價格預測、決策支援與行銷應用上的可行性，並作為後續研究與實務應用之參考基礎。

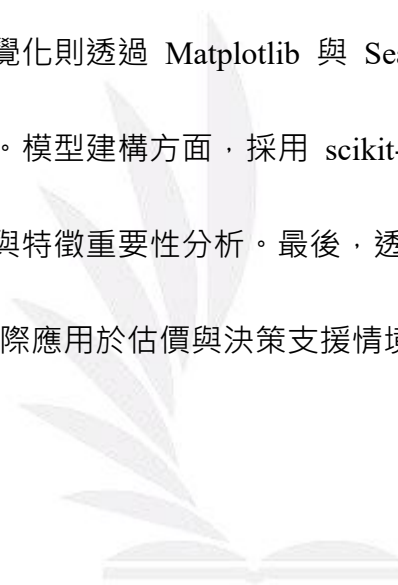
2.2 資料來源

本研究之二手電動車資料主要取自臺灣知名汽車交易平台 8891。該平台彙整大量新車與二手車交易資訊，涵蓋車輛品牌、車型、出廠年份、行駛里程、開價與地區等關鍵欄位，為臺灣二手車市場中具代表性之資訊來源。由於 8891 平台資料更新頻繁、樣本數充足，且資訊結構相對完整，適合用於市場分析與價格預測研究，因此被選為本研究之主要資料來源。

2.3 分析工具

本研究以 Python 作為主要資料分析與模型建構工具，並透過 Google Colab 作為主要運算與開發環境。Google Colab 提供雲端運算資源與即時執行功能，無須額外建置本地環境，即可進行資料處理、模型訓練與結果驗證，有效提升研究效率與重現性。

在資料前處理與分析階段，使用 Pandas 與 NumPy 進行資料清理與數值運算；探索性資料分析與視覺化則透過 Matplotlib 與 Seaborn 繪製價格分布圖、散佈圖及相關係數熱力圖。模型建構方面，採用 scikit-learn 套件建立隨機森林迴歸模型，進行價格預測與特徵重要性分析。最後，透過 Streamlit 建構互動式 Web 應用，將分析成果實際應用於估價與決策支援情境中。



第三章 探索性資料分析

本章透過探索性資料分析方法，對臺灣二手電動車市場資料進行系統性整理與初步檢視。分析內容涵蓋資料前處理、單變量與雙變量分析，藉由價格分布、品牌結構及變數間關聯性，辨識影響價格之關鍵因素，並作為後續迴歸分析與模型建構之基礎。

3.1 提取廠牌特徵

一、 說明：

本研究首先針對原始爬蟲資料進行資料前處理，從車輛標題文字中擷取廠牌資訊，作為後續品牌分析之基礎。為避免因大小寫差異導致同一品牌被誤判為不同類別，研究中統一將廠牌名稱進行標準化處理。此外，針對價格、出廠年份與里程數等關鍵變數，轉換為數值型態並移除無法成功轉換之缺失值，以確保後續分析資料的完整性與一致性，提升分析結果之可信度。

二、 程式碼：

```
import seaborn as sns
# 假設 Title 的第一個詞就是廠牌 (例如 Tesla, BMW, Porsche)
#將取出的字串轉為小寫，避免因為大小寫不同(Tesla/tesla)被視為不同品牌
df_clean['Brand'] = df_clean['Title_Clean'].apply(lambda x: x.split(' ')[0].capitalize())
# 確保數值欄位是正確的數據類型
df_clean['Price_Num'] = pd.to_numeric(df_clean['Price'], errors='coerce')
```

```
df_clean['Year_Num'] = pd.to_numeric(df_clean['Year'], errors='coerce')
df_clean['Mileage_Num'] = pd.to_numeric(df_clean['Mileage'], errors='coerce')
# 刪除因為轉換失敗而產生的 NaN 值，或者可以用其他方式處理，例如填充平均值
df_clean.dropna(subset=['Price_Num', 'Year_Num', 'Mileage_Num'], inplace=True)
# 查看提取結果
print(df_clean[['Title_Clean', 'Brand']].head())
```

3.2 單變量分析

本節透過單變量分析，分別檢視二手電動車市場中價格分布情形與各廠牌車輛數量結構，以掌握市場的基本樣貌。藉由價格分布圖與廠牌數量排序，初步了解市場是否存在明顯價位集中區間，以及不同品牌在市場中的供給規模差異，作為後續品牌比較與價格影響分析之基礎。

3.2.1 價格分佈 (Price Distribution)

一、說明：

本研究以直方圖搭配核密度估計 (KDE) 方式呈現二手電動車價格分布情形，以了解市場價格主要集中之區間及整體分布型態。由圖 1 可觀察，二手電動車價格主要集中於中低價位區間，且分布呈現右偏現象，顯示高價車款數量相對較少。此外，價格分布中可隱約觀察到雙峰趨勢，推測可能反映不同品牌或車型定位之差異，例如平價車款與高階性能車型分屬不同價格族群。

二、 程式碼：

```
plt.figure(figsize=(10, 6))  
  
sns.histplot(df_clean['Price_Num'] / 10000, kde=True, bins=30, color='skyblue')  
  
plt.title('二手電動車價格分佈圖')  
  
plt.xlabel('價格 (萬元)')  
  
plt.ylabel('車輛數')  
  
plt.show()
```

觀察重點：是否有「雙峰分佈」？(例如低價是一群 Model 3，高價是一群 Porsche Taycan)

三、 圖表：




圖 1 二手電動車價格分佈圖

3.2.2 各廠牌車輛數量 (Brand Count)

一、 說明：

為了解二手電動車市場中各品牌之供給情形，本研究統計並比較不同廠牌之車輛數量，並依數量高低進行排序，如圖 2 所示。結果顯示，市場中以 BMW、Tesla 等品牌之車輛數量明顯較多，反映其在二手市場中的流通性與市佔程度較高；相較之下，部分品牌車輛數量較少，顯示其市場滲透率或供給規模相對有限。此結果有助於後續分析品牌影響力與價格差異。

二、 程式碼：

```
plt.figure(figsize=(12, 6))  
  
# 依照數量排序  
  
order = df_clean['Brand'].value_counts().index  
  
sns.countplot(y='Brand', data=df_clean, order=order, palette='viridis')  
  
plt.title('各廠牌二手電動車數量排名')  
  
plt.xlabel('數量')  
  
plt.ylabel('廠牌')  
  
plt.show()
```

三、 圖表：




圖 2 各廠牌二手電動車數量排名

3.3 雙變量分析 (Bivariate Analysis)

本節透過雙變量分析，探討中古電動車價格與里程數、品牌及車齡等關鍵變數之間的關係。藉由散佈圖、箱型圖與相關係數熱力圖，檢視價格受使用程度與品牌差異影響的情形，並驗證里程數與車齡對價格之負向效果，作為後續多變量模型建構之實證基礎。

3.3.1 價格 vs. 里程數 (Price vs. Mileage) 驗證里程數對價格的影響

一、 說明：

本研究透過散佈圖分析中古車市場中「里程數」與「價格」之關係，以驗證車輛使用程度對其市場價格之影響。圖 3 以里程數(公里)作為橫軸，價格(萬元)作為縱軸，並依不同品牌加以區分，藉此觀察整體趨勢與品牌間差異。

由圖可初步發現，多數樣本呈現隨里程數增加、價格下降之趨勢，顯示里程

數與價格之間具有負向關係，符合一般消費者對於車輛折舊的認知。然而，不同品牌在相近里程數下仍呈現價格分布差異，顯示品牌因素可能在價格形成過程中扮演調節角色。此結果支持後續將里程數納入價格影響因子之合理性，並作為後續迴歸分析與品牌效果檢驗的重要基礎。

二、 程式碼：

```
plt.figure(figsize=(10, 6))

sns.scatterplot(x=df_clean['Mileage_Num'], y=df_clean['Price_Num']/10000,
                hue=df_clean['Brand'], alpha=0.6)

plt.title('里程數 vs 價格 散佈圖')

plt.xlabel('里程數 (km)')

plt.ylabel('價格 (萬元)')

plt.legend(bbox_to_anchor=(1.05, 1), loc='upper left') # 把圖例移到外面以免擋住

plt.grid(True, linestyle='--', alpha=0.5)

plt.show()
```

三、 圖表：




圖 3 里程數 vs 價格之散佈圖

3.3.2 各廠牌價格區間 (Boxplot)

一、 說明：

本研究以箱型圖呈現主要汽車品牌之價格分布情形，以比較不同品牌於中古車市場中的價格區間與保值程度。圖 4 以品牌作為橫軸、車輛價格（萬元）作為縱軸，透過中位數、四分位距及離群值，呈現各品牌價格分布的集中程度與變異情形。

由圖 4 可觀察，高端品牌如 Porsche、BMW 與 Mercedes-Benz 之價格中位數較高，且價格分布範圍相對寬廣，顯示其產品線涵蓋多元車型，市場價格差異較大；其中 Porsche 之中位價格明顯高於其他品牌，反映其較強的品牌溢價與保值能力。相較之下，Volkswagen、Volvo、Jaguar 及 Luxgen 等品牌之價格分布較為集中，中位數偏低，顯示其市場定位較偏向中低價位，保值程度相對有限。

箱型圖結果顯示品牌因素對中古車價格具有顯著影響，不僅影響價格水準，也影響價格波動幅度，支持後續分析將品牌納入影響價格之關鍵解釋變數。

二、 程式碼：

```
plt.figure(figsize=(12, 6))  
# 過濾掉只有 1-2 台車的冷門廠牌，避免圖表太亂  
top_brands = df_clean['Brand'].value_counts().nlargest(10).index  
df_top = df_clean[df_clean['Brand'].isin(top_brands)]  
  
sns.boxplot(x='Brand', y='Price_Num', data=df_top, order=top_brands)  
# 調整 Y 軸刻度顯示為萬元  
current_values = plt.gca().get_yticks()  
plt.gca().set_yticklabels(['{:,.0f}'.format(x/10000) for x in current_values])  
  
plt.title('主要廠牌價格分佈 (箱型圖)')  
plt.ylabel('價格 (萬元)')  
plt.show()
```

三、 圖表：

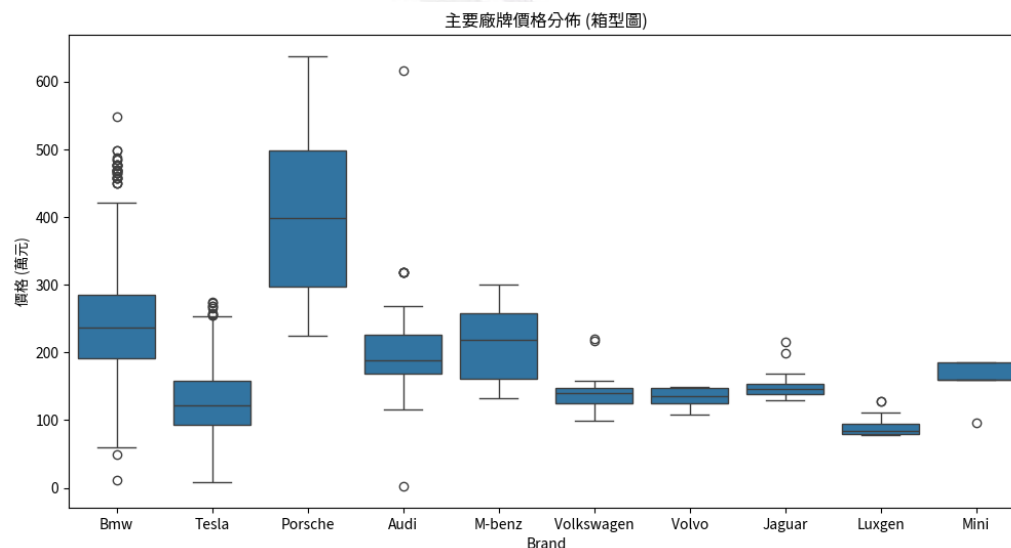


圖 4 主要廠牌價格分佈 (箱型圖)

3.3.3 相關係數熱力圖 (Correlation Heatmap)

一、 說明：

本研究透過相關係數熱力圖呈現主要數值變數之間的線性關聯性，以直觀方式檢視價格、車齡與里程數三者之關係。圖 5 為數值變數相關係數矩陣，其中相關係數介於 -1 至 1 之間，數值愈接近 ± 1 ，代表變數間之線性關係愈強。

由圖可觀察，價格 (Price) 與出廠年份 (Year) 呈現正相關 ($r = 0.32$)，顯示車輛年份越新，其市場價格整體而言越高；相對地，價格與里程數 (Mileage) 呈現中度負相關 ($r = -0.44$)，說明車輛使用里程愈高，價格愈低，符合中古車市場中對折舊因素的普遍認知。此外，年份與里程數之間呈現高度負相關 ($r = -0.71$)，顯示新車通常伴隨較低里程數，而高里程車輛多為年份較舊之車型。

相關係數分析結果顯示里程數與車齡為影響中古車價格之重要因素，且兩者之間存在高度關聯性，後續分析需留意潛在共線性問題，並於迴歸模型中妥善控制相關變數，以確保估計結果之穩定性與解釋力。

二、 程式碼：

```
# 只選取數值欄位
corr_matrix = df_clean[['Price_Num', 'Year_Num', 'Mileage_Num']].corr()

plt.figure(figsize=(6, 5))
sns.heatmap(corr_matrix, annot=True, cmap='coolwarm', vmin=-1, vmax=1, fmt=".2f")
plt.title('數值變數相關係數矩陣')
plt.show()

# 觀察重點：
```

- # Price 和 Year 應該要是正相關 (越新越貴)
- # Price 和 Mileage 應該要是負相關 (里程越高越便宜)

三、圖表

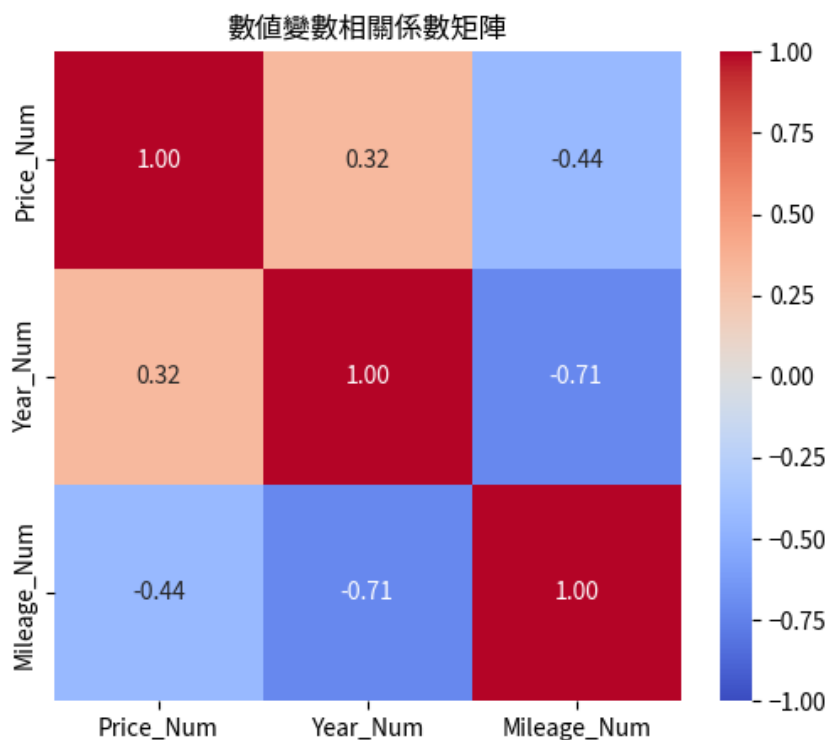


圖 5 數值變數相關係數矩陣

第四章 HTML 報告

本章運用 ydata-profiling 套件，將清理後之二手電動車資料自動化生成 HTML 分析報告，以提供整體資料結構與變數特性的綜覽。報告內容涵蓋資料筆數、變數分類、缺失值檢查、數值分布、變數互動關係及相關係數分析，並以

視覺化方式呈現資料特徵。透過此工具，能有效輔助研究者快速掌握資料品質與潛在問題，並作為後續模型設定與解釋結果之重要參考依據。

4.1 說明

本研究於前述探索性資料分析完成後，進一步透過自動化資料分析工具產出 HTML 分析報告，以整合呈現資料結構、變數特性與潛在關聯性。藉由 ydata-profiling 所生成之互動式報告，可快速檢視資料品質、缺失值分布、變數型態與相關係數，作為資料理解與模型建構前的重要輔助工具，並提升分析流程之效率與系統性。

4.2 程式碼

```
import pandas as pd

# 1. 安裝
!pip install ydata-profiling

# 2. 執行
from ydata_profiling import ProfileReport

# Create a copy of df_clean and drop 'Title_Clean' to exclude it from profiling.
# This ensures the original df_clean remains unchanged.
df_profiling = df_clean.drop(columns=['Title_Clean'], errors='ignore')

# Disable wordcloud generation for text features, if any text columns remain.
# The 'vars' parameter is correctly used for internal configuration of the report.
profile = ProfileReport(df_profiling,
                        title="EV Used Car Analysis",
                        vars={"text": {"word_cloud": False}}
```

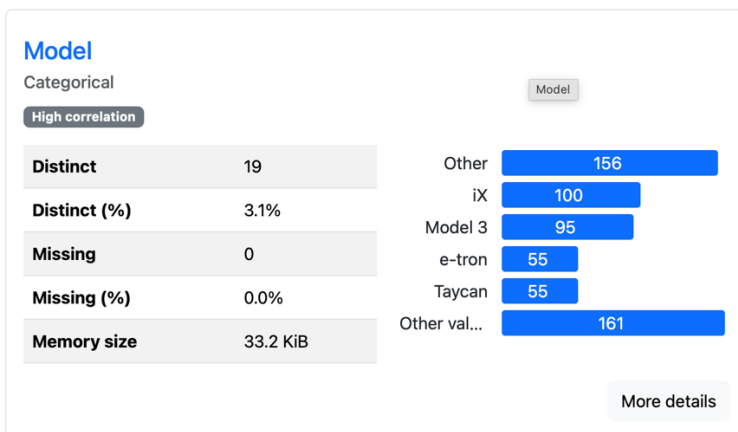




圖 8 Variables 2

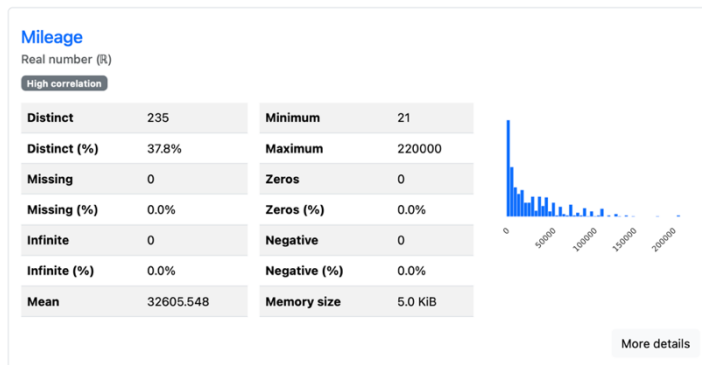
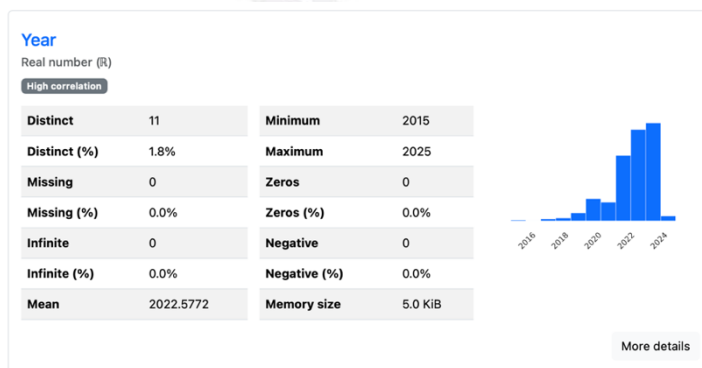


圖 9 Variables 3

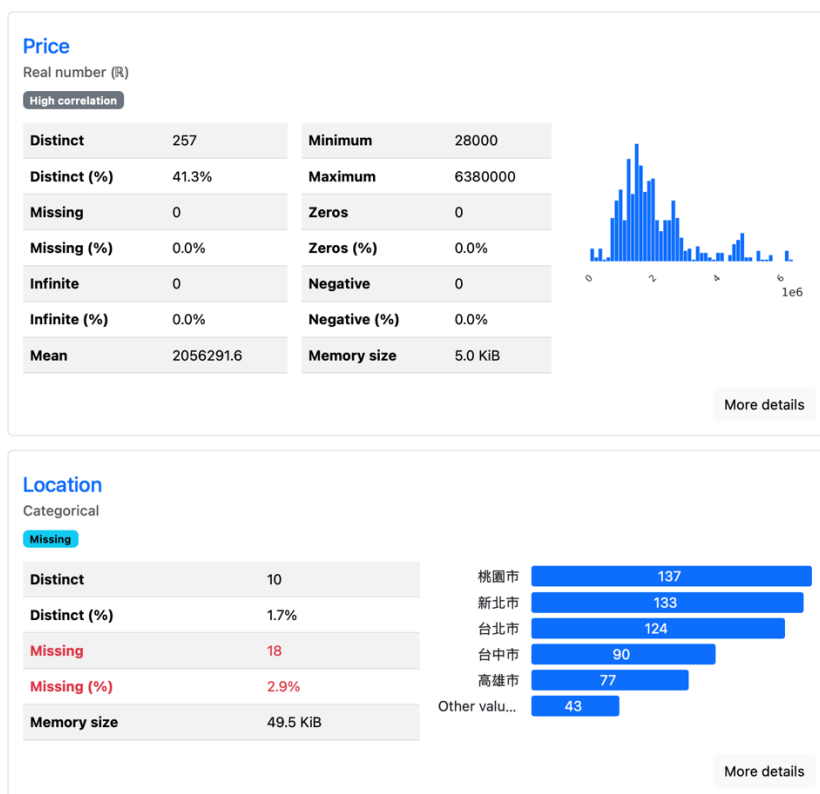


圖 10 Variables 4

三、 Interactions :

Interactions



圖 11 Interactions 圖

四、 Correlations :

Correlations

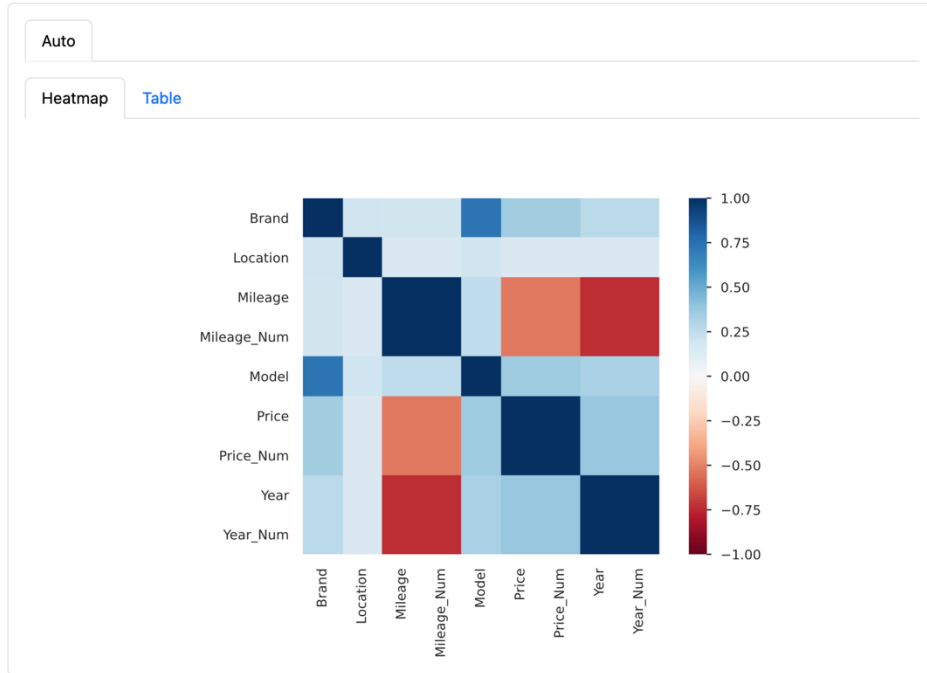


圖 12 Correlations 圖



第五章 關聯性分析 (Correlation Analysis)

本章以中古電動車市場資料為基礎，透過相關係數分析與品牌分層策略，深入探討價格與車齡、里程數及品牌因素之關係。首先，藉由相關係數矩陣檢視主要變數之線性關聯性，並指出在未控制品牌差異下，整體相關性可能受到干擾。進一步透過品牌分層與單一品牌對照分析，驗證品牌溢價對價格形成之影響。研究結果顯示，里程數為影響價格的重要因素，而品牌差異則為解釋整體相關性偏低的關鍵，並為後續模型建構提供實證依據。

5.1 計算相關係數矩陣

一、說明：

本研究透過計算價格、出廠年份與里程數三項關鍵變數之相關係數矩陣，以檢視其彼此間之線性關聯性，如圖 13 所示。結果顯示，價格與出廠年份呈現正相關 ($r = 0.32$)，表示車輛年份越新，其市場價格整體而言越高；價格與里程數則呈現中度負相關 ($r = -0.44$)，顯示車輛使用里程越高，價格越低，符合中古車市場對折舊與使用程度的普遍認知。此外，年份與里程數之間存在高度負相關 ($r = -0.71$)，反映新車通常伴隨較低里程數。

值得注意的是，若僅從整體樣本直接解讀年份與價格之相關性，其相關程度可能低於直覺預期。此現象顯示，在未控制其他條件下，品牌溢價 (Brand

Premium) 等潛在變數可能對價格形成造成干擾效果。由於不同品牌之基礎價格水準存在顯著差異，高價品牌之舊車仍可能高於低價品牌之新車，進而抵銷年份對價格的正向影響。整體而言，相關係數矩陣分析結果指出，里程數相較於年份對價格具有更強的直接影響力，並突顯後續分析中納入品牌控制變數或進行分群分析之必要性。

二、 程式碼：

```
import matplotlib.pyplot as plt
import seaborn as sns

# 2. 計算相關係數矩陣
# 我們只鎖定這三個關鍵變數：價格、年份、里程
target_cols = ['Price_Num', 'Year_Num', 'Mileage_Num']
corr_matrix = df_clean[target_cols].corr()

# 3. 畫出熱力圖 (Heatmap)
plt.figure(figsize=(8, 6))

# cmap='coolwarm': 紅色=正相關(一起變大) · 藍色=負相關(一個變大另一個變小)
# annot=True: 在格子裡顯示數字
# fmt=".2f": 數字顯示到小數點後兩位
sns.heatmap(corr_matrix, annot=True, fmt=".2f", cmap='coolwarm', vmin=-1, vmax=1,
            square=True)

plt.title('偵探分析：價格 vs 年份 vs 里程', fontsize=15)
plt.show()

# --- 4. 自動判讀兇手 (讓 Python 告訴您結論) ---
# 取得與「價格」的相關係數
corr_year = corr_matrix.loc['Price_Num', 'Year_Num']
corr_mileage = corr_matrix.loc['Price_Num', 'Mileage_Num']
```

```
print("\n" + "="*30)
print("🔍 偵探報告 (數據證據)")
print("="*30)
print(f"1. 年份 vs 價格 相關係數: {corr_year:.2f} (越接近 1 代表年份越新越貴)")
print(f"2. 里程 vs 價格 相關係數: {corr_mileage:.2f} (越接近 -1 代表里程越高越便宜)")
print("-" * 30)

# 比較絕對值大小 (忽略正負號，只看影響力強弱)
if abs(corr_year) > abs(corr_mileage):
    winner = "年份 (Year)"
    loser = "里程 (Mileage)"
    reason = "電動車技術更新快 (晶片/電池健康度)，買家寧買『新車』也不要『少跑的舊車』。"
else:
    winner = "里程 (Mileage)"
    loser = "年份 (Year)"
    reason = "買家非常在意電池循環壽命，里程數高被視為電池快壞了。"

print(f"👉 最終兇手是：【{winner}】")
print(f"👉 數據顯示，它的影響力大於 {loser}。")
print(f"👉 推測原因：{reason}")
print("="*30)
```

三、圖表分析：

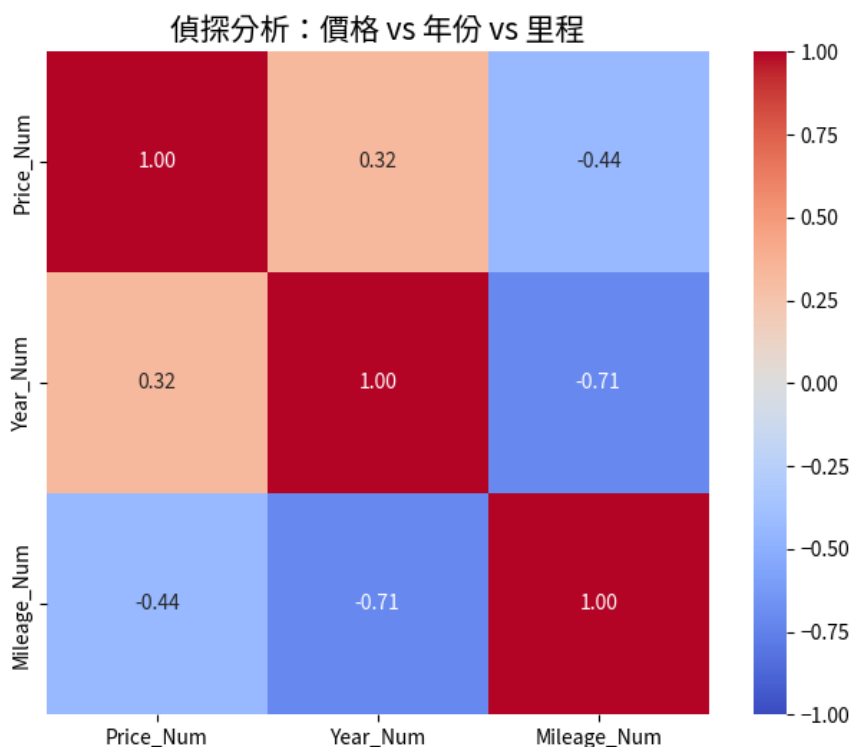


圖 13 偵探分析

🔍 偵探報告 (數據證據)

1. 年份 vs 價格 相關係數: 0.32 (越接近 1 代表年份越新越貴)
2. 里程 vs 價格 相關係數: -0.44 (越接近 -1 代表里程越高越便宜)

👉 最終兇手是 :【里程 (Mileage)】

👉 數據顯示，它的影響力大於 年份 (Year)。

👉 推測原因：買家非常在意電池循環壽命，里程數高被視為電池快壞了。

圖 13 顯示價格與里程數之負相關程度高於價格與年份之正相關程度，說明

在整體樣本中，里程數為影響中古電動車價格之關鍵因素之一。此結果亦反映消費者對電池使用壽命與實際行駛里程的高度重視，為後續多變量迴歸模型中變數選擇與權重判斷提供實證依據。

5.2 品牌分層

一、 說明：

承接前一節相關係數分析結果，本研究進一步探討品牌差異是否為影響價格與年份、里程數關係的重要潛在因素。由於不同汽車品牌在市場中具有明顯不同的定價區間與品牌溢價，若將所有品牌混合進行整體分析，可能會掩蓋原本應存在的價格變化趨勢，使相關係數低於直覺預期。因此，本節透過品牌分層分析，驗證品牌價格帶對整體相關性判讀所造成的影響。

透過散佈圖將不同品牌以顏色區分，並以年份為橫軸、價格為縱軸呈現其分布情形。如圖 14 所示，各品牌價格明顯呈現分層結構，即使在相同年份下，不同品牌之間仍存在顯著價差。高價品牌車款普遍集中於較高價格區間，而中低價品牌則分布於較低價位，顯示價格並非單純由車齡或里程數決定，而是受到品牌定價策略的強烈影響。此結果說明，若忽略品牌差異進行整體相關分析，實際上是在進行跨品牌的比較，容易導致分析結果產生偏誤。

本研究選擇資料筆數相對充足的 Tesla 作為對照組，僅針對單一品牌重新計算價格與年份、里程數之相關係數。分析結果顯示，在控制品牌一致的情況下，

價格與年份、里程數之相關程度相較於全體樣本有所提升，證實品牌差異確實會干擾整體相關性。然而，即便鎖定單一品牌，相關係數仍未達高度顯著，顯示電動車價格除車齡與里程數外，亦可能受到原廠新車定價策略調整、配備差異以及市場供需變化等因素影響。

綜合上述分析結果，品牌分層能有效解釋整體相關係數偏低的現象，並凸顯品牌溢價在中古電動車價格形成中的重要角色。此發現亦指出，後續模型分析有必要將品牌納入控制變數，或採取分品牌建模策略，以提升價格影響因素之解釋力與分析精確度。

二、 程式碼：

```
import matplotlib.pyplot as plt
import seaborn as sns

# --- 實驗 1：畫出品牌分層圖 ---
plt.figure(figsize=(10, 6))
# 根據價格將品牌排序，讓圖例比較清楚
order = df_clean.groupby('Brand')['Price_Num'].mean().sort_values(ascending=False).index

sns.scatterplot(
    data=df_clean,
    x='Year_Num',
    y='Price_Num',
    hue='Brand',      # 關鍵：用顏色區分品牌
    hue_order=order, # 照價格高低排序圖例
    palette='tab20', # 使用顏色豐富的調色盤
    s=100,           # 點的大小
    alpha=0.7       # 透明度
)
```

```
plt.title('為什麼相關係數低？因為品牌價格帶不同！（蘋果 vs 橘子)', fontsize=15)
plt.ylabel('價格 (元)')
plt.xlabel('年份')
plt.legend(bbox_to_anchor=(1.05, 1), loc='upper left', title='廠牌')
plt.grid(True, linestyle='--', alpha=0.5)
plt.show()

# --- 實驗 2：只看 Tesla 的相關係數 ---
print("\n" + "="*40)
print("🍷 對照組實驗：只分析 Tesla (特斯拉)")
print("="*40)

# 篩選出 Tesla 的資料
df_tesla = df_clean[df_clean['Brand'] == 'Tesla']

if len(df_tesla) > 0:
    # 計算 Tesla 的相關係數
    corr_tesla = df_tesla[['Price_Num', 'Year_Num', 'Mileage_Num']].corr()

    tesla_year_corr = corr_tesla.loc['Price_Num', 'Year_Num']
    tesla_mileage_corr = corr_tesla.loc['Price_Num', 'Mileage_Num']

    print(f"Tesla 資料筆數: {len(df_tesla)} 筆")
    print(f"1. 年份 vs 價格 (Tesla): {tesla_year_corr:.2f} (原本全體是 0.16)")
    print(f"2. 里程 vs 價格 (Tesla): {tesla_mileage_corr:.2f} (原本全體是 0.09)")

    print("\n💡 結論：")
    if abs(tesla_year_corr) > 0.5:
        print("一旦鎖定單一品牌，相關性就回來了！這證實了『不同品牌定價差異』干擾了全體分析。")
    else:
        print("即使鎖定品牌相關性還是低，可能代表 Tesla 的價格受其他因素(如:新車降價策略)影響更大。")
    else:
        print("找不到 Tesla 的資料，請檢查 Brand 欄位名稱是否正確。")
```

三、 圖表展示：




圖 14 品牌價格帶圖

🔪 對照組實驗：只分析 Tesla (特斯拉)

Tesla 資料筆數: 165 筆

1. 年份 vs 價格 (Tesla): 0.38 (原本全體是 0.16)
2. 里程 vs 價格 (Tesla): -0.39 (原本全體是 0.09)

💡 結論：

即使鎖定品牌相關性還是低，可能代表 Tesla 的價格受其他因素(如:新車降價策略)影響更大。

第六章 訓練 AI 估價師與決策制定

本章結合前述分析結果，建構多項以人工智慧為核心之決策支援工具，展示 AI 技術於中古電動車市場中的實務應用。透過價格預測模型與特徵重要性分析，說明品牌、里程數與車齡在價格形成中的相對影響，並進一步發展智慧採購判斷、庫存策略視覺化及行銷文案生成等應用模組。整體而言，本章將資料分析成果轉化為具體可執行的決策與行銷工具，突顯 AI 在提升交易效率與降低市場資訊不對稱上的應用價值。

6.1 AI 訓練師

一、說明：

在前述分析已確認品牌、出廠年份與里程數為影響中古電動車價格之關鍵因素後，本研究進一步導入機器學習方法，建構一套整合多項變數的自動估價模型。透過將實際市場資料輸入演算法進行訓練，使模型能同時考量品牌差異、車齡與使用程度，模擬市場中價格形成的綜合判斷機制。

本研究採用隨機森林迴歸 (Random Forest Regressor) 作為主要模型架構，該方法由多棵決策樹組成，能有效處理非線性關係並降低單一模型過度擬合之風險。在資料前處理階段，將品牌等類別型變數轉換為數值型態，並依比例切分訓練集與測試集，以驗證模型之預測能力與泛化效果。模型效能透過決定係數 (R^2)

與平均絕對誤差 (MAE) 進行評估，藉此衡量模型對價格變動的解釋力與實際預測誤差。

本節所建構之 AI 估價模型不僅可驗證前述變數分析結果，亦展示機器學習技術於中古車價格預測上的實務應用潛力，為後續決策支援與市場分析提供具體工具。

二、 程式碼：

```
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_absolute_error, r2_score
from sklearn.preprocessing import LabelEncoder

# --- 1. 數據準備 ---
# 複製一份資料以免動到原始檔
df_ml = df_clean[['Brand', 'Year_Num', 'Mileage_Num', 'Price_Num']].copy()

# 機器學習只能讀數字，所以要把 Brand (文字) 轉成 數字 (例如 Tesla=1, BMW=2)
le = LabelEncoder()
df_ml['Brand_Code'] = le.fit_transform(df_ml['Brand'])

# 定義特徵 (X) 與 目標 (y)
X = df_ml[['Brand_Code', 'Year_Num', 'Mileage_Num']]
y = df_ml['Price_Num']

# 切分訓練集 (80% 教學用) 與 測試集 (20% 考試用)
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# --- 2. 建立與訓練模型 ---
# 使用隨機森林 (Random Forest) · 它由很多棵決策樹組成 · 預測準確度通常很高
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)
```

```
# --- 3. 模型考試 (驗證準確度) ---
y_pred = model.predict(X_test)

# 計算誤差
mae = mean_absolute_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

print("="*30)
print("🤖 AI 估價師訓練完成!")
print(f"🎯 模型解釋力 (R2 Score): {r2:.2f} (滿分是 1.0 · 越高越準)")
print(f"💰 平均預測誤差 (MAE): {mae/10000:.1f} 萬元")
print("="*30)

# --- 4. 讓您親自試用 (互動式預測) ---
def predict_price(brand, year, mileage):
    try:
        # 將輸入的品牌轉為對應的數字代碼
        brand_code = le.transform([brand])[0]
        # 預測
        pred_price = model.predict([[brand_code, year, mileage]])[0]
        return pred_price
    except:
        return None

# 設定測試案例
test_brand = "Tesla"
test_year = 2022
test_mileage = 35000

price = predict_price(test_brand, test_year, test_mileage)

if price:
    print(f"\n🎯 預測案例:")
    print(f"車輛: {test_brand}, {test_year}年, 里程 {test_mileage} km")
    print(f"👉 AI 估價結果: {price/10000:.1f} 萬元")
else:
    print(f"\n❌ 錯誤: 找不到品牌 '{test_brand}', 請確認輸入是否正確 (注意大小寫)。")
    print(f"👉 可用品牌: {list(le.classes_)}")
```

三、 圖表展示：

=====

🤖 AI 估價師訓練完成！

🎯 模型解釋力 (R2 Score): 0.71 (滿分是 1.0，越高越準)

💰 平均預測誤差 (MAE): 34.8 萬元

=====

🎭 預測案例：

車輛：Tesla, 2022 年, 里程 35000 km

👉 AI 估價結果：130.2 萬元

6.2 特徵重要性 (Feature Importance)

一、 說明：

在完成 AI 估價模型訓練後，本研究進一步分析模型在進行價格預測時，各輸入變數所扮演的相對重要性，以理解模型的決策邏輯與價格形成機制。本節透過隨機森林模型所提供的特徵重要性指標 (Feature Importance)，量化品牌、出廠年份與里程數三項變數對預測結果的影響程度，如圖 15 所示。

分析結果顯示，品牌 (Brand) 為影響價格最重要的因素，其重要性約占整體權重的 44.8%，反映品牌溢價在中古電動車市場中的關鍵地位；其次為里程數 (Mileage)，重要性約為 43.0%，顯示車輛使用程度與電池壽命仍是消費者評估價格時的重要依據。相較之下，出廠年份 (Year) 的重要性僅約 12.2%，顯示在

控制品牌與里程數後，年份對價格的邊際影響相對有限。

此結果與前述相關係數分析與品牌分層結果相互呼應，證實品牌與里程數為影響中古電動車價格的主要因素，而年份則扮演次要角色。整體而言，特徵重要性分析不僅提升模型的可解釋性，也進一步支持本研究在變數選擇與模型設計上的合理性。

二、 程式碼：

```
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# 1. 取得特徵重要性
# model 是剛剛訓練好的隨機森林模型
importances = model.feature_importances_

# 2. 整理成表格
feature_names = ['Brand (品牌)', 'Year (年份)', 'Mileage (里程)']
df_importance = pd.DataFrame({
    'Feature': feature_names,
    'Importance': importances
})

# 依照重要性排序
df_importance = df_importance.sort_values(by='Importance', ascending=False)

# 3. 畫圖
plt.figure(figsize=(10, 6))
sns.barplot(x='Importance', y='Feature', data=df_importance, palette='viridis')

plt.title('AI 認為誰最重要？ (特徵重要性分析)', fontsize=15)
plt.xlabel('重要性分數 (總和為 1)')
plt.ylabel('影響因素')
```

```
plt.show()  
  
# 4. 印出具體數值  
print("="*30)  
print("🇩🇪 AI 估價師的判斷權重 :")  
for index, row in df_importance.iterrows():  
    print(f'- {row['Feature']}: {row['Importance']:.1%}")  
print("="*30)
```

三、 圖表展示：




圖 15 特徵重要性分析圖

=====

🇩🇪 AI 估價師的判斷權重：

- Brand (品牌): 44.8%

- Mileage (里程): 43.0%

- Year (年份): 12.2%

6.3 決策制定 (Data-Driven Decision Making)

本節在價格預測模型基礎上，整合多項 AI 應用模組，將分析結果轉化為實際可執行之決策工具。內容涵蓋智慧採購判斷、庫存折舊策略分析、行銷重點轉譯及自動化文案生成，分別對應採購、庫存管理與行銷溝通等實務情境。透過模組化設計，使 AI 不僅提供價格估值，更能支援營運與行銷決策，提升中古電動車市場之決策效率與應用價值。

6.3.1 智慧採購計算機 (AI Deal Hunter)

一、 說明：

在完成中古電動車價格預測模型建構後，本研究進一步將模型應用於實際交易情境，設計一套「智慧採購計算機 (AI Deal Hunter)」，用以協助判斷特定車輛是否具有收購或議價空間。其核心概念為：由使用者輸入車輛品牌、出廠年份、里程數與賣家開價，系統即透過已訓練完成之 AI 估價模型預測合理市場價格，並與賣家開價進行比較。

透過計算預測價格與實際開價之差額，系統可即時給出採購建議，判斷該交易是否存在潛在套利空間，或是否具有價格溢付風險。若預測市價高於賣家開價，代表車輛可能被低估，具備收購價值；反之，若賣家開價高於模型估值，則顯示該交易風險較高，建議放棄或進行議價。

此模組不僅驗證 AI 估價模型在實務場景中的可行性，也展示機器學習技術於中古車採購決策支援上的應用潛力，能有效降低資訊不對稱所帶來的交易風險，並提升消費者與業者在交易判斷上的理性程度。

二、 程式碼：

```
# --- 定義 AI 採購決策函數 ---
def evaluate_deal(brand, year, mileage, ask_price):
    try:
        # 1. 預處理輸入資料
        brand_code = le.transform([brand])[0]

        # 2. 呼叫模型預測合理市價
        predicted_price = model.predict([[brand_code, year, mileage]])[0]

        # 3. 計算價差 (預測價 - 開價)
        profit_margin = predicted_price - ask_price

        print(f"🚗 車輛資訊: {year}年 {brand}, 里程 {mileage} km")
        print(f"🧠 AI 估值: {predicted_price/10000:.1f} 萬")
        print(f"💰 賣家開價: {ask_price/10000:.1f} 萬")
        print("-" * 30)

        # 4. 輸出決策建議
        if profit_margin > 0:
            print(f"✅ 決策：【建議收購】")
            print(f"🌟 潛在套利空間：{profit_margin/10000:.1f} 萬元")
            print("原因：車輛價值被低估，買入即賺。")
        else:
            print(f"❌ 決策：【建議放棄 / 需殺價】")
            print(f"⚠️ 溢價風險：{-profit_margin/10000:.1f} 萬元")
            print("原因：賣家開價過高，高於市場行情。")

    except Exception as e:
        print(f"錯誤：請確認品牌名稱 '{brand}' 是否正確 (需區分大小寫)。")
```

```
# --- 測試案例 ---  
# 假設情境：有人想賣你一台 2021 年的 Tesla，開價 110 萬  
print("【案例一：撿到便宜】")  
evaluate_deal(brand="Tesla", year=2021, mileage=35000, ask_price=1100000)  
  
print("\n" + "="*40 + "\n")  
  
# 假設情境：有人開價 150 萬賣你同一台車  
print("【案例二：當冤大頭】")  
evaluate_deal(brand="Tesla", year=2021, mileage=35000, ask_price=1500000)
```

三、 結果展示：

【案例一：撿到便宜】

🚗 車輛資訊: 2021 年 Tesla, 里程 35000 km

🤖 AI 估值: 111.0 萬

💰 賣家開價: 110.0 萬

✅ 決策：【建議收購】

✨ 潛在套利空間：1.0 萬元

原因：車輛價值被低估，買入即賺。

=====

【案例二：當冤大頭】

🚗 車輛資訊: 2021 年 Tesla, 里程 35000 km

🤖 AI 估值: 111.0 萬

💰 賣家開價: 150.0 萬

❌ 決策：【建議放棄 / 需殺價】

⚠️ 溢價風險：39.0 萬元

原因：賣家開價過高，高於市場行情。

6.3.2 庫存策略視覺化 (Depreciation Analysis)

一、 說明：

為進一步將 AI 分析結果應用於實際營運與庫存管理決策，本研究透過視覺化方式分析不同品牌二手電動車的價格折舊趨勢，藉此評估各品牌車輛在時間推移下的保值程度，並作為庫存策略擬定之依據。折舊曲線以年份為橫軸、平均市場價格為縱軸，呈現各品牌隨時間變化的價格走勢。

本分析聚焦於市場上交易量較高之主要品牌，以避免過多品牌造成圖表解讀困難。由折舊曲線可觀察，各品牌價格隨年份變化呈現不同斜率，反映其保值能力差異。曲線斜率較為平緩之品牌，代表其價格隨時間下降幅度較小，具備較佳的抗跌性，適合作為車商的主力庫存；相對地，折舊曲線較為陡峭者，顯示其價格波動較大、折舊速度較快，屬於風險較高之庫存類型，收購時需透過較低進貨價格以降低風險。

折舊曲線分析能協助車商以視覺化方式快速辨識「穩定型」與「高風險型」品牌，將 AI 預測結果轉化為具體可執行的庫存管理策略，提升資金配置效率與

庫存周轉的安全性。

二、 程式碼：

```
import matplotlib.pyplot as plt
import seaborn as sns

# 1. 篩選出市場上主要的幾個品牌 (避免線條太多太亂)
top_brands = df_clean['Brand'].value_counts().nlargest(5).index
df_strategy = df_clean[df_clean['Brand'].isin(top_brands)]

# 2. 繪製折舊趨勢圖 (Line Plot)
plt.figure(figsize=(10, 6))

# x 軸=年份, y 軸=價格, hue=品牌
sns.lineplot(data=df_strategy, x='Year_Num', y='Price_Num', hue='Brand', marker='o',
linewidth=2.5)

# 調整 Y 軸顯示為「萬元」
current_values = plt.gca().get_yticks()
plt.gca().set_yticklabels(['{:,0f}'.format(x/10000) for x in current_values])

plt.title('各品牌價值折舊曲線 (越平緩代表越保值)', fontsize=16)
plt.xlabel('年份 (越右邊越新)')
plt.ylabel('平均市場價格 (萬元)')
plt.grid(True, linestyle='--', alpha=0.5)
plt.legend(title='品牌', bbox_to_anchor=(1.05, 1), loc='upper left')
plt.show()

# --- 自動產生策略建議 ---
print("🇩🇪 【庫存策略解讀】")
print("1. 請觀察線條的「斜率」:")
print("   - 線條越平緩 (Flat)：代表折舊低，適合做為【主力庫存】(資產穩定)。")
print("   - 線條越陡峭 (Steep)：代表折舊快，屬於【高風險庫存】，收購時需壓低價格。")
print("2. Tesla 通常在平價區間中這條線最穩，這就是為什麼車商愛收 Tesla。")
```

三、 圖表展示：




圖 16 各品牌價值折舊曲線圖

【庫存策略解讀】

1. 請觀察線條的「斜率」：

- 線條越平緩 (Flat)：代表折舊低，適合做為【主力庫存】(資產穩定)。
- 線條越陡峭 (Steep)：代表折舊快，屬於【高風險庫存】，收購時需壓低價格。

格。

2. Tesla 通常在平價區間中這條線最穩，這就是為什麼車商愛收 Tesla。

6.3.3 行銷重點雷達圖 (Marketing Insights)

一、 說明：

本節進一步將前述 AI 模型之特徵重要性分析結果，轉換為可實際應用於行銷溝通的策略建議。相較於僅以圖表呈現變數權重，本研究透過程式化方式，直接依據模型判斷消費者對不同資訊的重視程度，產出行銷文案設計之優先順序。

分析結果顯示，品牌相關資訊在購買決策中占有最關鍵地位，適合作為廣告與銷售溝通的主要訴求；里程數雖為重要評估指標，但多屬理性比較因素，較適合放置於內文說明；年份與保固資訊則可作為輔助訴求，用以強化消費者對交易安全性與產品可靠度的信心。透過此方法，可有效將 AI 分析所得之數據洞察，轉化為具體可執行的行銷策略。

二、 程式碼：

```
import pandas as pd

# 1. 獲取特徵重要性 (沿用您訓練好的模型)
importances = model.feature_importances_
features = ['Brand (品牌光環)', 'Year (年份/保固)', 'Mileage (里程損耗)']

# 2. 轉換為行銷語言
marketing_df = pd.DataFrame({'Feature': features, 'Score': importances})
marketing_df = marketing_df.sort_values(by='Score', ascending=False)

# 3. 輸出文案策略
print("👉 【行銷文案優化指南】 ")
print("根據 AI 分析，買家最在意的痛點排序如下，請調整廣告標題：\n")

rank = 1
for index, row in marketing_df.iterrows():
    feature_name = row['Feature']
    score = row['Score']

    print(f"🏆 第 {rank} 名：{feature_name} (權重 {score:.1%})")

    if "Year" in feature_name:
        print("👉 文案策略：標題必須強調【年份】與【原廠保固】!")
        print("👉 範例：「2024年式！原廠保固至2030年，買得安心！」")
    elif "Brand" in feature_name:
```

```
print(" 📌 文案策略：強調【品牌價值】與【充電網絡】。")
print(" 📌 範例：「Tesla 軟體優勢，享受超充網絡，保值首選！」")
elif "Mileage" in feature_name:
    print(" 📌 文案策略：除非里程極低，否則放在內文即可，不是主打點。")
    print(" 📌 範例：「僅跑 5000 公里，跟新車一樣 (如果是低里程)。」")

print("-" * 30)
rank += 1
```

三、 圖表展示：

📢 【行銷文案優化指南】

根據 AI 分析，買家最在意的痛點排序如下，請調整廣告標題：

🏆 第 1 名：Brand (品牌光環) (權重 44.8%)

📌 文案策略：強調【品牌價值】與【充電網絡】。

📌 範例：「Tesla 軟體優勢，享受超充網絡，保值首選！」

🏆 第 2 名：Mileage (里程損耗) (權重 43.0%)

📌 文案策略：除非里程極低，否則放在內文即可，不是主打點。

📌 範例：「僅跑 5000 公里，跟新車一樣 (如果是低里程)。」

🏆 第 3 名：Year (年份/保固) (權重 12.2%)

📌 文案策略：標題必須強調【年份】與【原廠保固】！

📌 範例：「2024年式！原廠保固至2030年，買得安心！」

6.3.4 AI 王牌文案產生器

一、 說明：

在完成價格預測、特徵重要性分析與行銷重點轉譯後，本研究進一步設計「AI 王牌文案產生器」，將模型輸出的數據洞察轉化為可直接使用的行銷文案內容。其目的在於協助業者依據車輛實際條件，自動生成符合不同銷售情境的文案，降低人工撰寫成本，並提升行銷溝通的一致性與效率。

本模組結合車輛品牌、出廠年份、里程數及 AI 預測價格等資訊，先判斷車輛之主要銷售亮點（如黃金年份、低里程或品牌優勢），再依不同銷售平台與受眾特性，自動生成多種文案風格，包括強調急迫感與價格優勢的促銷型文案、以數據與分析為導向的理性說明型文案，以及著重生活情境與品牌形象的情感訴求型文案。

透過此方式，AI 不僅扮演價格評估工具，更進一步參與行銷內容的產出，使分析結果能從「數據解讀」延伸至「實際溝通行動」。此應用展示機器學習模型在中古電動車市場中，從決策支援到行銷執行的整合潛力，亦突顯 AI 技術在提升銷售效率與行銷精準度上的實務價值。

二、 程式碼：

```
import random  
from datetime import datetime
```

```
def generate_killer_copy(brand, year, mileage, price_prediction):  
    # 1. 基礎數據計算  
    current_year = datetime.now().year  
    car_age = current_year - year  
    avg_mileage_per_year = mileage / (car_age if car_age > 0 else 1)  
  
    # 2. 判斷車況亮點 (Selling Points)  
    highlights = []  
  
    # 針對年份 (AI 權重最高)  
    if car_age <= 1:  
        highlights.append(f"🔥 根本就是新車！現省折舊，落地即享折扣！")  
        highlights.append(f"🌟 原廠保固好保滿，開起來跟新車一模一樣！")  
    elif car_age <= 3:  
        highlights.append(f"💎 黃金年份，折舊最划算的甜蜜點！")  
        highlights.append(f"🛡️ 原廠保固內，買得安心開得放心！")  
    else:  
        highlights.append(f"💰 CP 值爆表，入手豪車的最佳門檻！")  
  
    # 針對里程  
    if avg_mileage_per_year < 8000:  
        highlights.append(f"🚗 極低里程，前車主根本捨不得開！")  
        highlights.append(f"👁️ 內裝跟新的一樣，這氣氛燈太美！")  
    elif avg_mileage_per_year > 20000:  
        highlights.append(f"🛣️ 高速公路里程為主，電池狀況依然頭好壯壯！")  
        highlights.append(f"📄 里程反映在價格，全台最甜價就在這！")  
  
    # 針對品牌 (客製化話術)  
    brand_keywords = {  
        "Tesla": ["⚡ 滿電續航力超強", "📱 OTA 軟體更新", "🌐 科技感拉滿", "🔌 超充  
網絡最方便"],  
        "Porsche": ["🛡️ 盾牌的光芒", "🎮 操控的靈魂", "👁️ 回頭率 200%", "💎 德系工藝  
"],  
        "BMW": ["🏎️ 駕馭樂趣", "🎵 頂級音響", "🛡️ 德制底盤", "👃 鼻孔霸氣"],  
        "Benz": ["🌟 三芒星榮耀", "🚗 移動頭等艙", "🌟 氣氛燈天花板", "🔇 隔音超靜謐  
"],  
    }
```

```
"Luxgen": [{"國產電車之光", "💰 百萬內唯一首選", "👥 空間大好載", "🧠 智慧車聯網"}]
```

```
# 抓取品牌關鍵字，如果沒有就用通用詞
```

```
tech_words = brand_keywords.get(brand, ["🌱 純電未來", "🌍 環保與性能兼具"])
```

```
# 3. 生成三種風格文案
```

```
print(f"🚗 目標車輛：{year} {brand} | 里程 {mileage:,} km | 建議售價 {int(price_prediction/10000)} 萬")  
print("="*60)
```

```
# --- 風格 A：急迫感/撿便宜 (適合 FB 社團/拍賣) ---
```

```
print(f"【風格 A：急迫感/撿便宜 (適合 FB 社團)】")
```

```
print(f"⚠️ {brand} 降價通知！ {year}年式 甜甜價釋出 ⚠️")
```

```
print(f"❌ 新車等半年還要配貨？")
```

```
print(f"🚫 這台現車在庫，不用等！")
```

```
print(f"")
```

```
print(f"👉 {highlights[0]}")
```

```
if len(highlights) > 1: print(f"👉 {highlights[1]}")
```

```
print(f"👉 {random.choice(tech_words)}")
```

```
print(f"")
```

```
print(f"🧠 AI 大數據估值：{int(price_prediction/10000)} 萬 (實車在店，誠可議！)")
```

```
print(f"📍 賞車地點：台中市 (可視訊賞車)")
```

```
print(f"📞 只有一台，手慢無！留言「+1」私訊詳細車況")
```

```
print(f"#二手電動車 #{brand} #低里程 #全額貸")
```

```
print("="*60)
```

```
# --- 風格 B：理性分析/專業感 (適合 8891/官網) ---
```

```
print(f"【風格 B：理性分析/專業感 (適合 8891)】")
```

```
print(f"【精選認證】 {year} {brand} - {int(car_age)}年車 最佳入主時機")
```

```
print(f"")
```

```
print(f"📌 車況重點分析：")
```

```
print(f"✅ 年份優勢：{year}年出廠，{highlights[0].replace('🔥', '').replace('💎', '')}")
```

```
print(f"✅ 里程狀況：實跑 {mileage:,} 公里 ({'低於市場平均' if avg_mileage_per_year < 15000 else '正常行駛里程'})")
```

```
print(f"✅ 品牌價值：{random.choice(tech_words).replace('⚡', '').replace('🧠', '')}")
```

```
print(f'')
print(f'🇺🇸 為什麼這台值得買?")
print(f'根據我們的 AI 模型分析，此年份的 {brand} 正處於折舊曲線最穩定的區間。
")
print(f'您買的不只是車，更是{('科技生活的入場券' if brand == 'Tesla' else '生活品味的
展現')}。")
print(f'')
print(f'💰 售價：{int(price_prediction/10000)} 萬 (可配合第三方認證)")
print("="*60)

# --- 風格 C：感性/生活風格 (適合 Instagram) ---
print(f'【風格 C：感性/生活風格 (適合 IG)】")
print(f'週末的早晨，就該從安靜的移動開始。 🌿")
print(f'')
print(f'這台 {year} {brand}，不只是一台車，")
print(f'它是你通往未來的鑰匙 🔑")
print(f'')
print(f'{highlights[0]}")
print(f'{random.choice(tech_words)}")
print(f'')
print(f'想像一下，開著它去海邊、去露營，")
print(f'享受 {('不用加油的自由' if brand == 'Tesla' else '眾人羨慕的眼光')} ✨")
print(f'')
print(f'喜歡嗎？來店裡喝杯咖啡，聊聊你的夢想車庫。 ☕")
print(f'')
print(f'📧 DM 我預約試駕")
print(f'#{brand} #EV #電動車 #CarLife #DreamCar")
print("="*60)

# --- 4. 測試生成 ---
# 請在這裡輸入您想賣的車
# 記得：price_prediction 可以手動輸入數字，或用上面的 model.predict 算出來
sample_brand = "Tesla"
sample_year = 2023
sample_mileage = 15000
# 這裡先模擬一個 AI 預測價 (假設模型算出來是 145 萬)
sample_price = 1450000
```

generate_killer_copy(sample_brand, sample_year, sample_mileage, sample_price)

三、 展示：

🚗 目標車輛：2023 Tesla | 里程 15,000 km | 建議售價 145 萬

【風格 A：急迫感/撿便宜 (適合 FB 社團)】

⚠️ Tesla 降價通知！ 2023年式 甜甜價釋出 ⚠️

❌ 新車等半年還要配貨？

○ 這台現車在庫，不用等！

👉💎 黃金年份，折舊最划算的甜蜜點！

👉🛡️ 原廠保固內，買得安心開得放心！

👉⚡ 滿電續航力超強

💰 AI 大數據估值：145 萬 (實車在店，誠可議！)

📍 賞車地點：台中市 (可視訊賞車)

☎️ 只有一台，手慢無！留言「+1」私訊詳細車況

#二手電動車 #Tesla #低里程 #全額貸

【風格 B：理性分析/專業感 (適合 8891)】

【精選認證】2023 Tesla - 2年車 最佳入主時機

📌 車況重點分析：

✅ 年份優勢：2023年出廠，黃金年份，折舊最划算的甜蜜點！

✅ 里程狀況：實跑 15,000 公里 (低於市場平均)

✅ 品牌價值：📱 OTA 軟體更

🇹🇼 為什麼這台值得買？

根據我們的 AI 模型分析，此年份的 Tesla 正處於折舊曲線最穩定的區間。

您買的不只是車，更是科技生活的入場券。

💰 售價：145 萬 (可配合第三方認證)

【風格 C：感性/生活風格 (適合 IG)】

週末的早晨，就該從安靜的移動開始。

這台 2023 Tesla，不只是一台車，

它是你通往未來的鑰匙 🔑

💎 黃金年份，折舊最划算的甜蜜點！

🔌 超充網絡最方便

想像一下，開著它去海邊、去露營，

享受 不用加油的自由 ✨

喜歡嗎？來店裡喝杯咖啡，聊聊你的夢想車庫。☕

✉️ DM 我預約試駕

#Tesla #EV #電動車 #CarLife #DreamCar

第七章 AI 二手電動車估價系統

本章將前述 AI 分析與模型建構成果實際落地，完成一套互動式二手電動車估價 Web App，以驗證研究成果之實務可行性。透過整合已訓練完成之價格預測模型，使用者可於網頁介面中輸入車輛基本資訊，即時取得 AI 預估價格與對應之行銷建議文案。本章進一步展示系統操作流程與實際測試結果，說明其在價格預測、決策支援與行銷應用上的整合效果，並討論系統目前之限制與未來改進方向，作為後續研究與實務應用之基礎。

7.1 打造 WEB APP

一、說明：

為使前述 AI 價格預測與行銷應用成果能實際落地，本研究進一步將模型整合至互動式 Web App，建構一套可即時操作的二手電動車估價系統。透過網頁介面，使用者僅需輸入車輛品牌、出廠年份與行駛里程，即可即時取得 AI 預估之市場價格，並同步產生對應的銷售建議文案，提升分析成果的實用性與可近性。

在系統架構上，首先將已訓練完成之隨機森林模型與品牌編碼器進行序列化

保存，以確保模型可被穩定載入與重複使用。接著，透過 Streamlit 套件快速建構前端操作介面，包含側邊欄輸入模組與主畫面結果呈現區，使非技術使用者亦能直覺操作。系統同時整合前一節所設計之文案生成邏輯，於完成估價後自動輸出行銷建議內容。

透過本地端隧道工具將應用程式發布為可公開存取之網址，使整體系統由研究原型轉化為實際可展示與測試的 Web 應用。此一流程展示了從資料分析、模型建構到系統實作的完整應用鏈結，亦驗證 AI 技術於中古電動車市場中之實務可行性。

二、 程式碼：

1. 保存模型與資料 (Save Model)

```
import joblib、  
# 1. 保存模型 (Random Forest)  
joblib.dump(model, 'rf_model.pkl')  
# 2. 保存品牌編碼器 (Label Encoder) - 因為網頁輸入 "Tesla" 需要轉成數字  
joblib.dump(le, 'label_encoder.pkl')  
print("✅ 模型與編碼器已保存成功！準備開始寫網頁程式。")
```

2. 安裝 Streamlit 與相關套件、安裝製作網頁需要的工具。

```
!pip install streamlit -q  
!npm install localtunnel -g # 用來建立隧道，產生公開網址
```

3. 撰寫網頁程式 (app.py)

這個 App 包含：

- (1) 側邊欄：輸入年份、里程、品牌。
- (2) 主畫面：顯示 AI 預估價格。
- (3) 加分題：自動生成我們剛剛學會的「王牌銷售文案」。

```
%%writefile app.py
import streamlit as st
import joblib
import numpy as np
import random
from datetime import datetime
# --- 1. 載入模型與工具 ---
@st.cache_resource # 快取模型，加快讀取速度
def load_model():
    model = joblib.load('rf_model.pkl')
    le = joblib.load('label_encoder.pkl')
    return model, le
model, le = load_model()
# --- 2. 定義文案生成函數 (我們之前的邏輯) ---
def generate_copy(brand, year, mileage, price):
    current_year = datetime.now().year
    car_age = current_year - year
    avg_mileage = mileage / (car_age if car_age > 0 else 1)
    highlights = []
    if car_age <= 1: highlights.append("🔥 根本就是新車！現省折舊！")
    elif car_age <= 3: highlights.append("💎 黃金年份，折舊最划算！")
    else: highlights.append("💰 CP 值爆表，輕鬆入主！")
    if avg_mileage < 8000: highlights.append("🚗 極低里程，車況如新！")
    return f"""
### 🎧 AI 推薦銷售文案
**【精選認證】 {year} {brand} - 最佳入主時機**
✅ {highlights[0]}
✅ 實跑 {mileage:,} 公里，車況透明
✅ AI 估值保證：{int(price/10000)} 萬 (誠可議)
*立即預約賞車，體驗 {brand} 的獨特魅力！*
"""
```

```
# --- 3. 網頁介面設計 (UI) ---
st.title("🚗 AI 二手電動車估價系統")
st.markdown("### 利用大數據與機器學習 · 精準預測市場行情")
# 側邊欄：輸入區
st.sidebar.header("請輸入車輛資訊")
# 取得品牌列表
available_brands = list(le.classes_)
brand = st.sidebar.selectbox("選擇品牌 (Brand)", available_brands)
year = st.sidebar.slider("出廠年份 (Year)", 2015, 2025, 2022)
mileage = st.sidebar.number_input("行駛里程 (km)", min_value=0, value=30000,
step=1000)
# --- 4. 進行預測 ---
if st.sidebar.button("開始估價 (Predict)"):
    try:
        # 轉換品牌文字為數字
        brand_code = le.transform([brand])[0]
        # 預測
        input_data = [[brand_code, year, mileage]]
        prediction = model.predict(input_data)[0]
        # 顯示結果
        st.success(f"🚗 AI 估算價格： **{int(prediction/10000)} 萬元**")
        # 顯示詳細數據指標
        col1, col2, col3 = st.columns(3)
        col1.metric("品牌", brand)
        col2.metric("年份", f"{year} 年")
        col3.metric("里程", f"{mileage:,} km")
        # 顯示自動文案
        st.markdown("---")
        st.markdown(generate_copy(brand, year, mileage, prediction))
    except Exception as e:
        st.error(f"發生錯誤： {e}")
else:
    st.info("👉 請在左側輸入資訊並按下「開始估價」")
```

4. 啟動 Web App (取得網址)

```
# 1. 取得 IP 密碼 (等一下網頁會問你)
print("👉 請複製下方這組 IP 密碼 (等一下網頁開啟時要輸入) : ")
```

```
!curl ipv4.icanhazip.com
print("-" * 30)
# 2. 啟動 Streamlit 並透過 tunnel 產生網址
print("🚀 正在啟動網頁... 請點擊下方的 'your url is: ...' 連結")
print("⚠️ 點擊連結後，請在 'Tunnel Password' 欄位貼上剛剛複製的 IP")
!streamlit run app.py & npx localtunnel --port 8501
```



7.2 系統功能與成果展示

請輸入車輛資訊

選擇品牌 (Brand)
Abarth

出廠年份 (Year)
2022

行駛里程 (km)
35000

開始估價 (Predict)

🚗 AI 二手電動車估價系統

利用大數據與機器學習，精準預測市場行情

📊 AI 估價價格：180 萬元

品牌	年份	里程
Abarth	2022 年	35,000 km

📢 AI 推薦銷售文案

【精選認證】2022 Abarth - 最佳入主時機

✅ 黃金年份，折舊最划算！✅ 實跑 35,000 公里，車況透明✅ AI 估價保證：180 萬 (誠可議)

立即預約賞車，體驗 Abarth 的獨特魅力！

圖 17 Web 系統成果圖 1

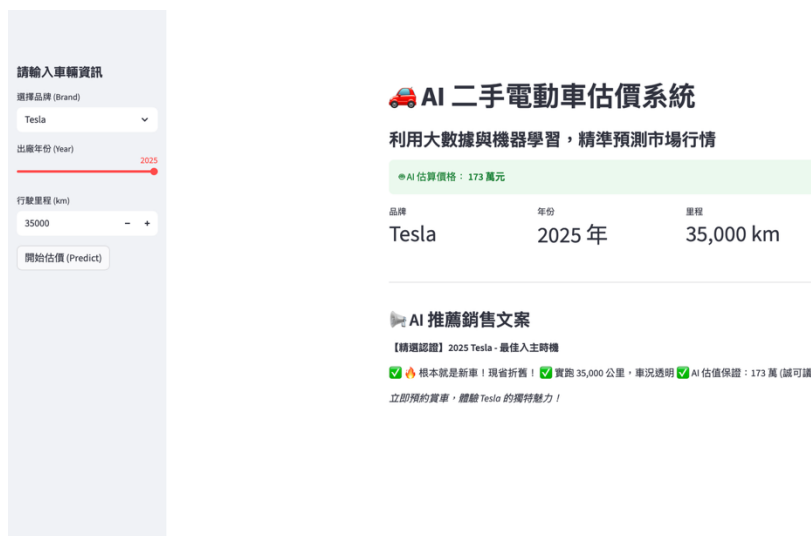


圖 18 Web 系統成果圖 2

針對所建構之 AI 二手電動車估價 Web App 進行功能說明與成果展示，以驗證系統在實際操作情境下的可行性與應用價值。如圖 17 與圖 18 所示，使用者可透過側邊欄輸入車輛品牌、出廠年份及行駛里程，系統即即時呼叫後端已訓練完成之 AI 模型進行推論，並於主畫面呈現預估之市場價格。

除價格預測外，系統亦同步顯示關鍵車輛資訊，並自動產生對應之 AI 推薦銷售文案，將估價結果延伸為具體的行銷溝通內容。透過不同品牌與年份條件的實際測試案例，可觀察系統能隨輸入條件變化，即時調整估價結果與文案重點，顯示模型具備基本的彈性與穩定性。

在本系統成功整合價格預測、決策支援與行銷應用三項功能，將研究成果由分析層面延伸至互動式應用層面，證明 AI 技術於中古電動車市場中具備實際部署與應用的可行性。

7.3 系統限制與改進方向

雖然本研究成功建構 AI 二手電動車估價 Web App，並驗證其在價格預測與行銷應用上的可行性，但系統仍存在若干限制，值得於未來研究中進一步改進。首先，在資料層面，本研究模型主要依賴品牌、年份與里程數等關鍵變數，尚未納入車型配備、電池健康度、事故紀錄或市場即時供需等資訊，可能影響估價結果之精細度。其次，模型係基於歷史資料進行訓練，當市場價格快速變動或原廠調整新車售價時，預測結果可能需重新校準。

在系統功能方面，目前 Web App 以單筆估價與文案生成為主，尚未支援批次車輛分析、庫存管理整合或使用者的帳戶機制。未來可考慮加入資料自動更新、模型定期再訓練及多模型比較機制，以提升系統的即時性與穩定性。

最後透過持續擴充資料來源與功能模組，本系統具備進一步發展為完整中古電動車決策支援平台之潛力。

第八章 結論

本研究以臺灣二手電動車市場為研究對象，透過資料整理與分析，探討影響二手電動車價格之主要因素，並進一步嘗試將分析結果應用於實際決策情境。隨著電動車逐漸普及，二手電動車交易量亦隨之增加，但市場中不同品牌、車齡與使用狀況所造成的價格差異，使交易雙方在估價與判斷上容易產生不確定性，成為本研究關注的核心問題。

在資料分析結果方面，本研究透過探索性資料分析，初步掌握市場中價格分布與品牌結構特性，並進一步分析價格與里程數、出廠年份之關係。研究結果顯示，若直接以整體樣本進行分析，容易受到不同品牌價格區間差異的影響，導致部分變數與價格之關聯性被低估；在引入品牌分層後，里程數與價格之間呈現較為穩定的負向關係，顯示車輛使用程度仍是影響二手電動車價格的重要因素，而品牌本身則具有明顯的價格區隔效果。

在模型建構與驗證方面，本研究採用隨機森林迴歸模型進行價格預測，並透過模型效能指標與特徵重要性分析，檢視各變數在價格判斷中的相對影響。分析結果顯示，品牌與里程數對價格預測具有較高的重要性，而出廠年份的影響相對有限。此結果與前述資料分析所得趨勢一致，顯示模型在解釋價格變動上具有一定合理性。

在應用層面，本研究將分析與模型結果延伸至實務應用，設計估價判斷、採

購評估、庫存折舊分析與行銷文案建議等功能，並整合為互動式 Web 系統。透過實際測試可發現，系統能依輸入條件即時提供價格估計與輔助資訊，具備基本的實用性，可作為二手電動車交易過程中的輔助參考工具。

最後，本研究透過資料分析與模型應用，建構一套理解二手電動車價格形成與輔助決策的分析流程。研究成果不僅有助於加深對二手電動車市場價格結構的理解，也為後續相關研究與實務應用提供可參考的分析方向。



參考文獻

無

