

逢甲大學學生報告 ePaper

臺灣類流感週資料分析與預測

Analysis and forecast of weekly Influenza-Like cases in Taiwan

作者：汪芳琦、黃品瑜、廖椿洋、潘昱伶、林信安

系級：統計三甲

學號：D1122524、D1142787、D1142801、D1142981、D1142828

開課老師：陳婉淑

課程名稱：預測分析

開課系所：統計學系

開課學年：113 學年度 第 2 學期

摘要

本研究使用衛生福利部疾病管制署資料開放平台所提供的類流感監測資料，預測 2016 年 1 月至 2025 年 4 月間類流感於「住院」、「門診」與「急診」三類就醫途徑中的每週病例人數。預測模型涵蓋 2016 年 1 月至 2024 年 12 月（共 469 週）之樣本內資料，並針對 2025 年前 18 週進行樣本外預測。所採用的方法包括：具外生變數的自我迴歸整合移動平均模式（ARIMAX）、霍爾特線性趨勢指數平滑法，以及針對重大事件進行的介入分析。考量春節對就醫行為的影響，模型中特別納入春節指標變數。針對急診資料，也額外考慮 COVID-19 Omicron 變異株首次社區流行期間的影響。針對 2016 年霸王級寒流與 Omicron 廣泛傳播等時點亦進行介入分析。本研究採用擴展式預測策略（Expanding approach），逐週更新模型並進行滾動式一步預測。預測表現評估採用四項常見指標：平均絕對誤差（MAE）、均方根誤差（RMSE）、平均絕對百分比誤差（MAPE）與平均絕對比例誤差（MASE）。結果顯示，在「住院」類別中，指數平滑法線性趨勢具有最佳表現；而在「門診」與「急診」資料中，ARIMAX 模式提供最準確的結果。整體而言，春節對類流感病例具有顯著影響，而採用逐週更新的預測策略可有效提升預測準確度。

關鍵字：ARIMAX 分析、霍爾特線性趨勢法、介入分析、樣本外預測、擴展式預測策略、假期效應


Abstract

This study utilizes influenza-like illness (ILI) surveillance data from the Taiwan Centers for Disease Control Open Data Portal to analyze weekly case counts for hospitalizations, outpatient visits, and emergency department encounters. Forecasting models were trained on an in-sample period from January 2016 to December 2024 (469 weeks) and evaluated using out-of-sample forecasts for the first 18 weeks of 2025. The three methods applied include autoregressive integrated moving average model with exogenous input variables (ARIMAX), Holt's linear trend exponential smoothing method, and intervention analysis. Given the influence of the Lunar New Year on healthcare utilization patterns, a specific indicator variable was included to account for this temporal effect. The emergency department model incorporated an additional explanatory variable to capture the impact of the COVID-19 pandemic, as the visits were affected by both the seasonal fluctuation of the Lunar New Year and the shock of the pandemic. Furthermore, for the emergency department data, intervention analysis was specifically performed for the extreme cold wave in 2016 and the widespread Omicron transmission period. An expanding approach was employed, with the models recursively updated on a weekly basis to generate rolling one-step-ahead forecasts. The evaluation criteria include mean absolute error (MAE), root mean square error (RMSE), mean absolute percentage error (MAPE), and mean absolute scaled error (MASE). The results indicate that Holt's linear trend method achieved the best predictive performance for hospitalizations, while the ARIMAX model provided the most accurate forecasts for outpatient and emergency department visits. Overall, the findings underscore the pronounced effect of the Lunar New Year on ILI case volumes and demonstrate that weekly model updating can enhance predictive accuracy.

Keywords: ARIMAX analysis, Holt's linear trend method, intervention analysis, out-of-sample forecasting, expanding approach, holiday effect

目錄

摘要.....	1
Abstract.....	2
第一章 緒論.....	4
第二章 研究模型與方法.....	6
第一節 研究方法.....	7
第二節 預測方法.....	10
第三章 資料描述.....	11
第四章 模型建立與分析.....	16
第一節 自相關與偏自相關分析.....	16
第二節 模型配適.....	18
第三節 預測比較.....	25
第四節 預測結果.....	27
第五章 結論.....	30
參考文獻.....	31



第一章 緒論

類流感 (Influenza-like Illness, ILI) 是指任何病毒引發的疾病，症狀與流行性感
冒 (簡稱流感) 相似，症狀主要為發燒、頭痛、肌肉酸痛，同時出現呼吸道症
狀 (European Commission, 2018)。其傳染途徑亦與流感相似，主要是飛沫及接觸
傳染，通常在症狀出現的前一天至發病後的三到七天皆具一定傳染性。根據美國
疾病管制與預防中心 (Centers for Disease Control and Prevention, CDC, 2025) 對
類流感的定義，患者若同時具有體溫達 37.8°C 以上的發燒，以及咳嗽或喉嚨痛
症狀，即可判定為類流感。Babcock, Merz, and Fraser (2006)指出在 208 位確診病
患中，約有 51%符合 CDC 所訂定的類流感臨床診斷標準。目前临床上普遍使用
流感快篩檢測 A 型流感病毒與 B 型流感病毒，不過 Chartrand et al. (2012)闡明快
篩對 A 型流感之敏感度為 64.6%，對於 B 型流感之敏感度為 52.2%，這表示即使
檢測結果呈陰性，亦無法完全排除確診可能，故醫學上將此類具類似症狀但未確
診流感者統稱為「類流感」。

流感的傳染力極強，在每年冬春交替之際總會出現明顯的流行高峰。根據世
界衛生組織 (WHO) 統計，全球每年約有 29 萬至 65 萬人死於與流感相關的呼
吸道疾病；而在臺灣，雖然多數流感病例屬於輕症，但仍有不少患者因併發症需
接受急診或住院治療，甚至併發重症而導致死亡，由此可見，流感對於現今社會
的影響不容小覷。Marsden-Haug et al. (2007)表明在美國症狀監測系統 ESSENCE
中，類流感疾病監測報告一直是最具效益的組成成分。而 Yang et al. (2019) 進一
步開發綜合流感監測框架，指出在人口稠密的國家，可將政府開放資料結合多家
醫院的電子病歷，當監測變數達警戒值時，便會即時發送警報，可以更準確地進
行電子監測並預測流感疫情。另外，根據疾病管制署多年的類流感就診人次監測
資料顯示，類流感在每年年初皆呈現明顯流行趨勢。由於其病毒傳播速度快，且
感染人數眾多，因此對我國醫療體系造成極大壓力。近年來，政府積極推動流感
疫苗接種政策，自 2025 年 1 月 1 日起，更進一步提供公費流感疫苗給全國尚未
接種流感疫苗之民眾 (衛生福利部疾病管制署，2024a)。此外，醫療院所的通報
與監測機制亦日趨完善，使得長期累積的類流感資料具有高度分析與預測的價值。
另一方面，自 COVID-19 疫情爆發以來，民眾的防疫行為轉變，人們開始習慣性
配戴口罩、保持手部清潔，再加上健康意識的提升，都對流感與類流感疾病的傳
播模式產生影響，進而改變整體就醫行為與病例分布。

有鑑於類流感疫情對醫療資源與公共衛生防疫體系所造成之潛在壓力，如何
掌握其流行趨勢、預測未來可能出現之高峰期，成為現在社會亟需面對的重要課
題。若能透過長期累積之病例資料，進行系統性分析與趨勢判讀，不僅有助於瞭
解其波動與影響因素，更可作為研擬因應對策的科學依據，幫助相關監管部門改
良現有應對措施，提升整體對於此疾病的控制，並降低類流感之確診比例，完善
醫療的穩健性。隨著資料分析與統計建模技術的進步，過往難以量化的趨勢得以

被客觀掌握。因此，透過合適的時間序列分析與預測方法，不僅可追蹤歷年疫情變化趨勢，亦可進一步預測短期未來之病例波動，提升防疫反應的即時性與準確性。此舉不僅對於提升整體公共衛生應變能力、減少傳染病造成的社會成本有所助益，更可作為未來應對其他新興傳染病流行時之重要參考。

本研究旨在探討類流感於住院、門診急診及三個就醫類型中的歷年變化趨勢，分析影響就醫人次的潛在季節性與年度變異因素，並建立有效之預測模型，以推估未來短期內類流感可能的就醫人數，進而提供醫療單位與政策制定機關作為人力與資源配置的參考依據。尤其是在春節、疫情爆發等特殊時期，提早預判醫療壓力，更能提升防疫效率與應變能力。為達成上述目的，本研究蒐集自衛生福利部疾病管制署「資料開放平台」所提供 2016 年 1 月至 2025 年 4 月之類流感週次的公開資料，樣本內資料涵蓋至 2024 年 12 月底，共計 469 週；樣本外預測範圍則為 2025 年前 18 週，用於評估模型之預測效能與穩定性。

在資料分析與模型建立的過程中，本研究結合使用 SAS 與 R 兩套統計軟體進行資料處理與模型評估。利用 SAS 完成所有樣本內資料的整理、差分處理、自相關與偏自相關檢定、模型配適以及殘差分析與診斷等統計分析流程。在樣本外預測階段，則轉由 R 進行操作，進行模型輸入與樣本外資料的預測值計算，並匯出預測結果(包含預測值與信賴區間上下界)，作為後續圖表製作的依據。需特別說明的是，本研究最終預測圖表並非由 R 繪製，而是透過 Excel 進行人工整理與視覺化處理，以強化圖像呈現的一致性。

在方法部分，本研究採用三種時間序列模型進行預測分析。首先介紹 Box and Jenkins (1970)所提出 ARIMA (Autoregressive Integrated Moving Average model) 模型，用於捕捉各類時間序列資料的趨勢與季節性變化，作為後續模型比較的基礎，亦為本研究預測各類流感就診類別變化趨勢之初步架構。該模型透過差分處理、滯後項與移動平均項的結合來捕捉時間序列中的自我相關結構。然而，ARIMA 模型僅考慮內生結構，對於外部變數（如經濟指標、氣候因素等）無法直接納入解釋。為補此不足，後續發展出 ARIMAX 模型(ARIMA model with exogenous input variables)，透過納入外生變數（X）作為額外的解釋變數，使模型能更有效捕捉系統受到外部因素影響的結構性變異，進而提升預測準確性。其次，Holt (2004)提出的霍爾特線性趨勢法（Holt's Linear Trend Method）方法，用於分析具有線性趨勢的時間序列資料，該方法為簡單指數平滑法(Simple Exponential Smoothing)的擴展方法，利用估計時間序列的水準(level)與趨勢(trend)成分，掌握資料隨時間的變動模式，並對時間序列賦予權重，近期觀察值影響較大，過去觀察值則越小，與簡單指數平滑法相比，Holt 模型能更靈活地因應資料起伏，並調整對未來的預測值。

本研究更進一步採用 Box and Tiao (1975)所提出的介入分析（Intervention Analysis）方法，用於處理時間序列資料受到突發外部事件干擾的情況。藉由模型建構，有效分離並量化外生衝擊對觀察值的影響。當某些特定已知事件的發生，

導致時間序列產生短期或持續性影響時，可額外加入一組代表外部事件的介入變數 (intervention variables)，評估該事件對整體序列的影響程度。而此類變數通常為二元型態，設事件發生的時點為 1，其餘為 0，並可依事件特性進一步設定為僅影響單一時點的脈衝函數 (pulse function) 或造成持續性影響的階梯函數 (step function)，以捕捉不同類型的干擾。

為評估整體預測準確性，本研究採用逐週更新資料的擴展式預測策略 (Expanding approach) 進行樣本外一步預測。在預測樣本外預測的績效表現方面，我們使用平均絕對誤差(mean absolute error, MAE)、均方根誤差(root-mean-square error, RMSE)、平均絕對百分比誤差(mean absolute percentage error, MAPE)、預期的平均絕對比例誤差(Mean Absolute Scaled Error, MASE)四種標準來評估預測的準確度，並透過比較並選出最具穩定性與預測力之模型。這些衡量指標各具優勢：MAE 提供直觀且單位一致的誤差解釋，RMSE 對較大誤差更加敏感，特別適合強調降低極端偏差的情境；MAPE 以百分比表達誤差，具備單位無關的 scale-free 特性，雖在零值附近可能失真，但本研究資料不涉及此問題，因此可充分發揮其跨數列比較的便利性；MASE 則在 scale-free 的同時克服了 MAPE 的限制，並能公平比較不同模型與數列的表現。透過這些指標的互補比較，我們得以選出最具穩定性與預測力的模型。

本研究後續內容安排如下：第二章介紹研究所採用的模式與方法，包括常態檢定、ARIMA 時間數列模式、指數平滑法、介入分析及四種預測評估指標；第三章則進行資料描述，介紹資料來源並進行初步統計分析；第四章進行模型的建立與分析，依據預測結果加以評估與比較，選出表現最佳的模式並加以說明；第五章則總結研究成果，並提出本研究的主要結論與可能的應用方向。

第二章 研究模型與方法

常態分配檢定方法在時間數列分析中具有關鍵作用，因為許多統計推論與模型建立皆依賴於常態性假設。透過常態性檢定，研究者能夠確認資料是否符合常態分配，進而決定合適的建模策略與估計方法，確保分析結果的有效性與可靠性。以下將依序說明本研究採用之三種檢定方法。

一、Kolmogorov-Smirnov test

是一種經典的非參數方法，被廣泛應用於分析型數據。該方法無需參數估計，主要比較樣本的經驗分布函數(empirical distribution function, ECDF)與特定理論分佈的累積分佈函數(cumulative distribution function, CDF)之最大絕對差距。用於檢測資料是否符合該理論分佈（如常態分佈）。此檢定對於分佈的形狀與位置非常敏感，但與資料的尺度（X 軸刻度）無關，因此特別適合用於檢測樣本與常態分佈在整體結構上的偏離程度。若樣本分佈與理論常態

分佈差異越大，K-S 統計量也越大，表示樣本分佈與理論常態分佈間的差異愈大，亦即越不符合常態。此外，K-S 檢定不僅適用於單一樣本與理論分佈的比較，也可用於比較兩組樣本的分佈差異，適合初步探索資料特性與驗證模型假設。

二、Cramér-von Mises test

是一種基於累積分佈函數的方法，用於測量樣本分佈與理論分佈之間的整體差異。與 K-S 檢定不同，它不是僅考慮最大差距，而是將整體的平方差異進行加總，提供一個更全面的分佈擬合評估。此外，該方法亦可延伸應用於比較兩個樣本分佈，藉由比較其累積分佈函數的形狀與趨勢，判斷是否存在系統性差異。由於其考量整體分佈差異，因此在樣本量較大時具備穩定性與良好的檢定力，常用於模型驗證與分佈擬合的精細分析。

三、Anderson-Darling test

此種檢定方法是 Cramér-von Mises 的加權改良版本，同樣用於檢定樣本是否來自特定理論分佈。此方法在計算過程中特別對分佈尾端的資料賦予更大權重，因此對分佈兩端的偏離（如極端值）更敏感。與 Cramér-von Mises 檢定不同的是，Anderson-Darling 是一種基於機率密度函數（PDF）的方法，不僅考慮整體擬合度，也強調尾部的偏離行為，提升檢定的靈敏度與檢出力。因此，它被認為在常態分佈檢定中的檢出力更高，特別適用於小樣本或對極端值較為敏感的分析情境。

第一節 研究方法

本研究採用三種時間序列方法，針對不同型態資料設計合適的模型，具體如下：

1. ARIMAX 模型

適用於具有或不具有季節循環趨勢的資料。基於 ARIMA 模型，並加入事件虛擬變數（Dummy variable：受特定事件影響為 1，不受影響則為 0），用以捕捉特定事件對時間序列的影響。

2. Holt's linear trend method

用於類流感確診個案。採取週次加權方式，近期資料給予較高權重，遠期資料則逐漸降低權重，以反映不同時間點對預測的重要性。

3. 介入分析

應用於急診資料。在特定時間點或事件設置介入項，檢驗事件衝擊對整體時間序列的影響。

4. 預測方法

直接預測（Direct forecasting）：使用既有模型直接產生樣本外預測。一步預測（Expanding approach one-step forecasting）：採滾動方式，每次納入前一期觀測值進行下一期預測，持續迭代直至資料結束。

5. 預測績效評估

採用四種指標衡量模型表現：平均絕對誤差 (MAE)、均方根誤差 (RMSE)、平均絕對百分比誤差 (MAPE, scale-free, 便於跨數列比較, 本研究中無零值問題)、平均絕對比例誤差 (MASE, 健全且可跨模型、跨數列比較)。綜合四項準則比較, 選出住院、門診及急診資料中最具穩定性與準確度的模型。

模型介紹

一、ARIMA 模型

ARIMA 模型是一種廣泛應用於時間序列預測的統計模型, 它結合自迴歸 (AR)、差分 (I) 以及移動平均 (MA) 三個成分, 該模型特別適用於具有趨勢但不具季節性的時間序列資料。另外, 若要探討具有季節性變化的資料, 則需使用 SARIMA (Seasonal ARIMA) 模型。相較於其他模型, ARIMA 模型最大的優勢在於它可以透過差分處理一些非平穩狀態的資料, 使許多原本不穩定的時間序列資料得以進行有效分析與預測, 其主要用於單變量時間資料的建模與分析。ARIMA 模式如下所示:

$$\phi(B)(1-B)^d y_t = \theta(B)a_t, \quad a_t \stackrel{i.i.d.}{\sim} N(0, \sigma^2),$$

$$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p), \quad \theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q).$$

雖然 ARIMA 模型在處理單變量的非平穩時間序列方面非常有效, 但它的預測僅依賴於該變數自身的歷史值與誤差項, 未能考慮到其他可能影響其變數有所變化的外部因素。因此, 當已知時間序列的變化會受到其他外部變數影響時, 便需採用 ARIMAX 模型捕捉外部因素對我們欲預測之變數的影響, 進而提升預測準確性及模型解釋力。ARIMAX 模式如下所示:

$$\phi(B)(1-B)^d y_t = \alpha + \theta(B)a_t + \beta^T X_t, \quad a_t \stackrel{i.i.d.}{\sim} N(0, \sigma^2),$$

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p, \quad \theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q,$$

$$X_t = (x_{1,t}, x_{2,t}, \dots, x_{K,t})^T, \quad \beta = (\beta_1, \beta_2, \dots, \beta_K)^T.$$

二、霍爾特線性趨勢法 (Holt's linear trend method)

是一種基於加權平均的時間序列預測方法, 適用於具有明顯線性趨勢但不具

有季節性變化的資料。相較於適用在沒有明顯趨勢與季節性變化的簡單指數平滑法(Simple Exponential Smoothing)，Holt's 方法額外增加趨勢(trend)部分的估計，即為在對水準(level)進行平滑的標準下，同時對趨勢進行估計。此方法透過對近期的觀察值給予較高的權重，並對較早期的觀察值給予較低的權重來進行預測，且這些權重呈現指數性遞減，故霍爾特線性趨勢法更能有效捕捉資料中的線性趨勢變化，並提供預測。

以下將透過水準方程(Level equation, ℓ_t)即時反映趨勢變化，其中 ℓ_t 代表著在 t 時間的平滑水準估計值， y_t 表示 t 時間的實際觀測值，利用 α (水準的平滑係數)控制不同時間資料的權重分配，其值 $\alpha \in (0, 1)$ ，用意在於將最近的資料配給更高的權重，越遠的資料權重越低。接著，則是趨勢方程(Trend equation, b_t)，趨勢(b_t)反映出時間序列在每一期的斜率變化速度，透過 β (趨勢的平滑係數)調整趨勢估計的權重，其值 β 介於0到1之間，即為 $\beta \in (0, 1)$ ，方程式中 $\ell_t - \ell_{t-1}$ 為前後兩期之間的水準變化量，此變化量為更新趨勢估計的重要依據，該趨勢方程用於捕捉資料的穩定成長或下降，亦可將其延伸至未來預測方向。最後，是預測方程(Forecast equation, $\hat{y}_{t+h}$)，該方程由當前水準 ℓ_t 為基礎的情況下，透過 h (預測期數)做為當前趨勢延伸的預測線，最後做為 $\hat{y}_{t+h}$ (當期 t 加上預測期數 h 的預測值)。以下為霍爾特線性趨勢法中水準方程、趨勢方程以及預測方程的模型結構公式：

$$\text{Level equation : } \ell_t = \alpha y_t + (1 - \alpha)(\ell_{t-1} + b_{t-1}),$$

$$\text{Trend equation : } b_t = \beta(\ell_t - \ell_{t-1}) + (1 - \beta)b_{t-1},$$

$$\text{Forecast equation : } \hat{y}_{t+h} = \ell_t + hb_t.$$

三、介入分析：

是一種用於評估特定事件、政策或某措施實行後，是否對該時間序列資料產生顯著影響的統計方法，其作法是在該時間序列模型中引入一個或多個介入的時間點，並評估該時點所造成的影響，此方法能有效區分我們所介入的特定事件發生前後的變化，並依此判斷介入該事件是否會導致顯著的影響。其關鍵在於將觀察值分解為來自內部原有結構（如自我相關、季節波動等）與外部事件影響兩部分，使我們能夠在保留序列原始依賴結構的基礎上，進行額外影響的檢定與量化。介入分析的模型建構，通常會先運用適合的模型捕捉資料本身的自我相關、季節性與趨勢等結構特徵，接著再於模型中納入一組介入變數，用以檢驗外部事件是否於特定時點造成統計上顯著的變化。根據事件性質不同，

該變數可設計為僅短暫造成影響之脈衝函數或會產生持續性影響之階梯函數。於本研究中，我們僅使用脈衝函數分析特定週次，其基本模型形式可表示為：

$$y_t = C_1 P_{1t} + C_2 P_{2t} + \cdots + C_i P_{it} + \varepsilon_t,$$

$$P_{it} = \begin{cases} 1, & t \text{ 時間在 } i \text{ 期間} \\ 0, & \text{其他。} \end{cases}$$


這裡的 P_{it} 是一個脈衝函數，代表外部衝擊發生之時點對時間序列模型的影響。

第二節 預測方法

一、Expanding approach

是一種常見於時間序列模型評估與滾動預測中逐步擴展訓練資料集的策略方法，圖一是 Hyndman and Athanasopoulos (2018)使用的表示方法，首先運用初始訓練集進行模型訓練與預測，並得到下一期的預測值(「期」的單位須依照資料性質設定為週、月或季)，接著，再將實際觀測到的新資料點(紅點)加入訓練集(藍點)中，重新建模並進行下一筆的預測。

此過程會重複進行以上步驟直至整體資料結束。此種預測方法能夠模擬真實應用的情境，並因應每期數值的不同而改變下期的預測結果，其有助於評估模型在未來實際應用時的預測穩定性與準確性。如下圖所示，每次皆將新的一筆實際觀測值納入訓練集(藍點)中，並往後多預測一筆(紅點)，逐步擴展資料集並進行一步預測，直到完成整體序列所有的預測。



圖一 Expanding approach 示意圖

二、預測表現評估準則

為評估模型在樣本外預測的準確性與整體績效表現，我們使用四種常用的評估指標：平均絕對誤差(MAE)、均方根誤差(RMSE)、平均絕對百分比誤差(MAPE)、預期的平均絕對比例誤差(MASE)。這些指標可全面衡量模型預測值與實際觀測值之間的差異，並用以比較利用不同建模方法之下所產生之模型的預測表現結果。我們採用四種指標來評估預測的準確度，判斷何種預測方法具有最佳預測能力。由於以上評估標準皆屬於誤差衡量相關指標，因

此其數值為越小代表模型預測誤差越小，則其預測表現越佳。於各準則的計算公式中， n 代表樣本數， y_t 表示第 t 筆資料的真實值， $\hat{y}_t$ 則表示第 t 筆資料的預測值，計算公式如下：

$$MAE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n},$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}},$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100,$$

$$MASE = \frac{\frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t|}{\frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}|}.$$

MAPE(%)	預測準確度
<5%	非常準確的預測
5%~10%	高度準確的預測
10%~15%	良好的預測
15%~20%	公平的預測
20%~25%	合理的預測
≥25%	預測不準確

表一 Chen, Hsieh, and Chu (2025)MAPE 的評估準則

表一為 Chen, Hsieh, and Chu (2025)對 Lewis (1982)的 MAPE 評估準則更細分的分類設定，主要用途在於衡量預測值與實際值之間的偏差程度，我們將根據 MAPE 的數值(%)來判斷其預測準確度，並透過表一中的分類標準來做判斷。然而，需要特別注意 MAPE 在遇到真實值為 0 時，會因分母為 0 而導致誤判。儘管本研究並無發生此狀況，仍建議在處理真實值可能包含 0 的資料時，應謹慎選擇合適的評估指標。此外，在進行模型比較與預測效能評估時，將特別關注 MAPE 是否小於 10%。因為當 MAPE 低於此一門檻時，代表預測結果具有較高的準確性。至於 $MASE < 1$ ，則表示預測結果優於 Naïve 預測，能夠提供更為可靠的預測資訊。

第三章 資料描述

此研究使用衛生福利部疾病管制署(Taiwan Center for Disease Control, Taiwan CDC)中疾病管制署資料開放平台(<https://data.cdc.gov.tw/>)所提供之類流感統計資

料。該平台定期公開全國性傳染病相關統計資料，具有高度的時效性與公信力。本研究選取其中之「類流感統計資料」，該資料集包含臺灣每週分別來自「住院」、「門診」、「急診」類流感個案資料。這些資料涵蓋全臺灣地區，具備廣泛的代表性與完整性。此資料集不僅能夠用以掌握類流感疫情於各時期的整體變化趨勢，也有助於了解不同就診類別中病患行為與疾病嚴重程度的差異。例如，門診人次可能反映出一般輕症或例行就醫需求，而急診或住院則可能代表較嚴重的感染或高風險個案，因此本研究將分別分析三種就診類別，從不同層面解讀類流感疫情動態，從而反映出類流感在不同就診類別中的病例分布情況。

圖二為 Hyndman and Athanasopoulos (2018) 展示的資料分類方法，我們在其基礎上稍作修改，表示此資料的時間範圍是從 2016 年 1 月至 2025 年 4 月，圖上的每一點皆代表著每一週的數據，其中共有 487 週的週資料。為了更準確地進行分析，本研究使用 2016 年至 2024 年共 469 週(圖二藍點部分)的資料作為樣本內資料，同時使用 2025 年共 18 筆真實資料(圖二紅點部分)作為樣本外資料，這些資料將用於模型評估，對預測準確度進行檢驗。這樣的劃分常用於時間序列預測，目的在於模擬實際應用中「預測未來未知資料」的能力，而非僅評估模型對歷史資料的擬合效果。透過保留未參與模型訓練的樣本外資料作為測試集，能夠有效檢驗所建模型在面對新資料時的泛化能力與穩定性，從而提升研究結果的可靠性與實用性，確保模型對未來類流感趨勢的預測能力，並進一步建構與評估可應用於公共衛生預警與資源調配的類流感預測模型。



圖二 資料說明

一、敘述統計量

表二所顯示的敘述統計量呈現類流感於 2016 至 2024 共 469 筆樣本內資料中，住院、門診以及急診個案各自的敘述統計量，其中門診個案單位為千人。這些資料可以幫助了解不同醫療服務的需求，並展示各項就醫方式的頻率和波動性。以下將進一步分析每一個就醫管道的具體情況，並闡述其所反映的醫療需求特徵。

首先，住院個案的平均數 (Mean) 為 2,252 人，顯示每週大約有 2,252 名患者因為類流感需要住院治療。這個數字相較於門診和急診的人數較低，原因可能在於住院需要較為嚴重的病情，患者需要在醫院接受更長時間的治療或觀察，因此住院人數在所有就診方式中是最少的。此外，住院的標準差 (Std Dev) 為 546.249，這表明住院人次在不同週次間的變動幅度比較穩定。換句話說，住院需求不容易受到其他因素波動的強烈影響，較為平穩，顯示住院的需求主要是依據病情的嚴重性，而不容易受到短期流感高峰或疫情波動的直接影響。住院總人次 (Sum) 為 1,056,108 人，這意味著在 2016 年至

2024 年間，總共有超過一百萬人次因為類流感住院治療。住院人次的最小值為每週 1,000 人，而最大值則達到 3,546 人，顯示出住院需求會隨著流感的高峰期有所增減，尤其是在疫情嚴重時，住院人數可能會急劇上升。

其次，門診個案的每週平均人次約為 54.24 千人，即每週約有 54,240 人次因類流感而前往門診就診。這數字顯示門診是三種就醫管道中需求最頻繁的一個，這是因為大多數類流感患者的病情較輕且不需要住院，許多人選擇在症狀輕微時於門診就診。與住院相比，門診的標準差為 28.08，這表明門診的需求變異性較大，可能受到不同時間疫情差異的影響。例如，在某些月份，流感爆發的程度較輕，門診需求可能會較低。而在流感流行期間，門診需求則會迅速上升。門診的總就診人次為 25,439,000 人次，顯示門診是最常見的流感就診管道。門診最少的單週就診人次為 6,077 人，而最多則達到 164,126 人，這顯示在流感爆發的高峰期，門診的就診需求可能激增。

最後，急診的每週平均人次為 12,896 人，顯示急診是僅次於門診的第二大就醫管道。這表明有許多流感患者的病情較為嚴重，可能需要立即處理。急診的標準差為 6,644，顯示急診的需求波動性很大，尤其在流感的高峰期，急診需求會顯著增加。急診的總人次為 6,048,106 人次，即 2016 年到 2024 年間，總共有超過 600 萬人次因為類流感需要急診治療。急診的最少人次為每週 4,517 人，而最大人次為每週 66,253 人，這表明急診的需求會隨著流感的高峰期而顯著波動，尤其是在流感傳播速率較快或疫情突發時，人數大幅上升，這也代表急診部門的負擔可能會增加，並可能對醫療系統造成壓力。

從整體數據來看，這些敘述統計量顯示出在流感期間，不同就醫管道的需求情況及其波動性。門診是最常見的就診管道，其需求最為頻繁且波動較大，急診次之，住院需求則相對較少且變動較小。這些數據有助於公共衛生政策和醫療資源的規劃之改善，醫療機構可根據這些數據進行合理的資源分配，以應對流感高峰期的就診需求，確保能夠及時處理大量患者。

就診類型	N	Mean	Std Dev	Sum	Minimum	Maximum
住院	469	2,252	546.249	1,056,108	1,000	3,546
門診	469	54.2415	28.0826	25,439	6.077	164.126
急診	469	12,896	6,644	6,048,106	4,517	66,253

表二 敘述統計量

二、常態分佈的適合度檢定結果

本研究為了檢視「住院」、「門診」與「急診」三種就診類型的類流感就診人次是否服從常態分佈，將利用 Kolmogorov-Smirnov(KS)、Cramér-von Mises(W-Sq)和 Anderson-Darling(A-Sq)三種檢定方法來進行分析。其檢定結

果彙整於表三中。我們根據表三可以得知，採用 KS、W-Sq 或 A-Sq 三種檢定方法在「住院」、「門診」與「急診」三種類型的就診人次資料中，結果皆顯示 p-value 小於 0.05，即拒絕常態性假設(H_0)，由此顯示此組資料偏離常態分佈。其中，「門診」與「急診」KS 檢定的 p-value 更是小於 0.01，偏離情形較「住院」更為明顯。

進一步觀察 Anderson-Darling 檢定的結果，由於該檢定對資料尾端的偏離特別敏感，可更有效偵測極端值或厚尾現象的影響，因此可看到「急診」資料的 A-Sq 統計量明顯高於「住院」及「門診」，進一步指出急診資料與常態分佈的偏離程度較大，資料分布可能存在較明顯的偏誤性或是有極端值干擾的情形出現，使得整體分佈明顯偏離常態。整體而言，表三結果反映出三種類型的就診資料皆不適合直接套用依賴常態假設的統計模型，尤其在急診資料中更應特別留意分佈異常與潛在極端事件的影響，後續分析宜考慮資料轉換或採用非參數方法以提升分析的穩健性與準確性。

就診類型	檢定方法		
	KS	W-Sq	A-Sq
住院	0.034	0.005	<0.005
門診	<0.010	<0.005	<0.005
急診	<0.010	<0.005	<0.005



表三 適合度檢定結果

三、年齡分層堆疊圖與時間序列圖

年齡分層堆疊圖與時間序列圖為視覺化分析工具，能有效地呈現資料的結構與變化。堆疊圖可以清楚顯示各年齡層在不同就診類型中的比例分布，協助辨識資料內部結構。而時間序列圖則可追蹤就診人次的時間變化，幫助識別趨勢與異常波動，進而分析外部因素對就醫行為的影響。接下來將透過三種就診類型的年齡分層堆疊圖，分析各類型中不同年齡層的比例分布，並統計各年度之累積就醫人次，藉此觀察人次較高的年份以及特定年齡層的就醫偏好。並經由三種就診類型的時間序列圖，掌握各就類型於不同時間點的變化趨勢，進一步觀察整體就醫行為的動態特性，辨識其波動與外部事件的影響。



(a) 類流感住院年齡分層堆疊圖

(b) 類流感門診年齡分層堆疊圖





(c) 類流感急診年齡分層堆疊圖

(d) 類流感住院人次時間序列圖



(e) 類流感門診人次時間序列圖

(f) 類流感急診人次時間序列圖



圖三 年齡分層堆疊圖與時間序列圖

住院部分的年齡分層堆疊圖依圖三(a)所示，門診則依圖三(b)所示，0-2 歲的黃色區塊以及 3-6 歲的淺綠色區塊屬於幼年期，該時期較青少年時期（24 歲以前）抵抗力較為低下，尤其為身體各項機能逐漸發育之時，故若感染類流感可能出現較為嚴重的病況需就醫或進行住院觀察；另 25-64 歲的藍紫色區塊屬於壯年時期，因壯年人口比例佔據臺灣總人口約 65%，所以此時期住院人口數最多屬於

正常現象；65 歲以上的深藍色區塊屬於老年時期，此時人體機能逐漸退化也導致抵抗力對比年輕人較為低下，感染類流感可能會併發重症，故會有部分比例的老年人選擇住院以進行更全面的醫療照護。

圖三(c)為急診部分，可以先觀察屬於幼年期 0-6 歲的黃色區塊，以及表示 65 歲以上的深藍色區塊屬於老年時期，這兩個區塊因為身體機能比較脆弱，所以容易因為類流感而有較嚴重的症狀發生，而需要到急診尋求治療，因此人數相對多；而 19-64 歲的藍紫色區塊屬於壯年時期，因壯年人口比例本就佔據臺灣總人口約 65%，所以此區塊的類流感急診人數最多。從圖三(d)與圖三(e)類流感住院及門診時間序列圖可看出，於 2020 至 2022 年間住院、門診的人次都有顯著的下降，這是受到當時 COVID-19 疫情影響，臺灣疫情始於 2020 年 1 月 21 日出現確診個案，促使民眾防疫意識提高，再加上政府政策的驅使(例如：出入特定場所必須配戴口罩等相關政策)，有效防範疫情的同時也間接讓類流感個案數相對變低。


接著可從圖三(f)看出 2022 年 5 月類流感急診個案人次衝高，這是因為當時 COVID-19 開始進入社區傳播，使得急診有癱瘓的現象，民眾也可能因為惶恐，而誤以為自己確診 COVID-19，但事實上卻為類流感的病症。在這個時間段 COVID-19 確診人數爆增，就如同一把雙面刃，當民眾病症不太嚴重時就不會那麼緊張，使得住院和門診的病患並沒有因此增加，反而人次達到低點，但倘若病症稍加嚴重，民眾就相對會開始擔心，進而導致急診個案在 2022 年 5 月出明顯增加。

第四章 模型建立與分析


第一節 自相關與偏自相關分析

本節將列出「住院、門診、急診」三類就診人次資料的原始自相關 (ACF) 與偏自相關 (PACF) 圖，可透過原始圖形觀察加以判斷各類別資料是否具趨勢性或非平穩性，進而決定該資料是否需進行一次差分或季節性差分，並據以推估適合的 ARIMA 或 ARIMAX 模型階數。值得一提的是，由於類流感人次會受外部因素，例如：季節變動、天氣、節慶等影響，為提升預測能力與模型解釋性，本研究採用可納入外生變數 (exogenous variables) 的 ARIMAX 模型作為分析工具。除了考量自身時間序列的結構外，更納入春節影響以及 COVID-19 疫情進行建模，捕捉非純粹由時間序列內部波動所解釋的變異，反映其對就醫人次的潛在影響，從而提升對複雜實際現象之解釋與預測能力。

一、住院




圖四 住院資料的 ACF、PACF 圖




圖五 進行一次差分後的 ACF、PACF 圖

二、門診




圖六 門診資料的 ACF、PACF 圖



圖七 進行一次差分後的 ACF、PACF 圖

三、急診




圖八 急診資料的 ACF、PACF 圖

首先，根據圖四所示之「住院」原始 ACF 與 PACF 圖可發現，ACF 呈現緩慢下降的趨勢，顯示資料具明顯趨勢性，非為平穩時間序列，故需進行一次差分以消除趨勢。進行一次差分後，如圖五所示，PACF 在 lag(1)處顯著、其後快速衰減，據此推斷適合的模型形式為 ARIMAX(1,1,0)，即 AR(1)與一次差分的整合模型，並搭配解釋變數。由圖六所示，可看出門診的 ACF 亦呈現與住院資料相似的趨勢性特徵，ACF 緩慢下降，顯示序列同樣非平穩。故進行一次差分，差分過後如圖七所示，其 ACF 在 lag(1)處顯著，PACF 則呈現緩慢衰減之趨勢，符合 MA(1)的結構特性，故後續模型配適為 ARIMAX(0,1,1)。最後，圖八為急診的 ACF、PACF 圖，觀察可見其 ACF 並無明顯趨勢性下降，未呈現典型非平穩序列之特徵，表示資料本身已大致平穩，無需進行一次差分。進一步分析 PACF，可觀察其於 lag(1)顯著，為典型 AR(1)的表現，因此後續模型配適 ARIMAX(1,0,0)。綜合而言，三種就診類型資料之差分需求與模型階數配適如下：住院配適 ARIMAX(1,1,0)、門診配適 ARIMAX(0,1,1)，急診則配適 ARIMAX(1,0,0)。本研究依此模型基礎進行後續參數估計與預測分析，以期待能藉此反映出各就診通路資料特性，提升預測模型之精確性與適用性。

第二節 模型配適


一、住院 ARIMAX(1,1,0)、Holt's linear trend method

(一) 一次差分後診斷圖 ARIMAX



圖九

(二) 模型殘差分析 ARIMAX



圖十

由圖九所示，可透過左上圖看出原始數據經過一次差分後的數值，縱軸為差分後的數值，橫軸為觀測點(共 469 筆)，可以看到數值在 0 附近不斷震盪，且沒有明顯趨勢，表示此資料經過一次差分後已經趨於平穩；且可從左下圖看出 PACF 圖有 lag(1)顯著之情形，綜合前述的圖十，將選擇模型配適為 ARIMAX(1,1,0)。

由圖十所示，配適 ARIMAX(1,1,0)的 ACF、PACF 殘差皆落在兩倍標準差的信賴區間之內，顯示殘差並無明顯結構性自相關。此外，進一步進行 White-noise 檢定以檢視殘差是否符合白噪音（white noise）假設，該假設用於評估時間序列資料是否為白噪音，而白噪音代表著該資料在不同時點的數值為隨機且彼此之間為不相關的，因此白噪音假設檢定在信心水準給定 0.05 的情況下，其虛無假設與對立假設分別為 H_0 :殘差序列為白噪音； H_1 :殘差序列不為白噪音。而住院資料的檢定結果雖有部分檢定 p-value 超出 0.05，但整體而言還在可接受範圍內，我們可以初步判斷 ARIMAX(1,1,0)模型的殘差表現良好，並且符合 White-noise 的基本要求。綜合上述，配適後的 ARIMAX(1,1,0) 模型之殘差表現良好，無顯著違反白噪音假設，表示模型對住院資料的趨勢變化與解釋變數之影響已有效捕捉，殘差近似隨機波動，具備合理的模型擬合與預測要求。

(三)參數估計

1. ARIMAX(1,1,0)

$$y_t = \alpha + \phi_1 y_{t-1} + \beta \cdot D_{1t} + \varepsilon_t,$$

$$y_t = 5.9236 - 0.1192 \cdot y_{t-1} - 110.8416 \cdot D_{1t} + \varepsilon_t,$$

$$\phi_1 = -0.1192, \alpha = 5.9236, \beta = -110.8416, \hat{\sigma}^2 = 24,744.69,$$

$$D_{1t} = \begin{cases} 1, & t \text{ 時間在農曆年間} \\ 0, & \text{其他} \end{cases}.$$

2. Holt's linear trend method

$$\ell_t = 3,522, \quad b_t = 2.4887,$$

$$\alpha = 0.8723, \beta = 0.0010, \hat{\sigma}^2 = 24,908,$$


$$\hat{y}_{t+h} = 3522 + 2.4887 h.$$

本研究在模型建構完成後，針對住院資料進行 ARIMAX 與 Holt's linear trend 模型的參數估計。首先，在配適的 ARIMAX(1,1,0)模型中，納入 AR(1) 以及農曆年間的解釋變數作為外部解釋因子，估計結果顯示模型常數項(α)為 5.9236，自迴歸係數(ϕ_1)為 -0.1192，農曆期間解釋變數(D_{1t})之係數(β)為 -110.8416，這代表 β 加入解釋變數後，對整體模型的平均影響量， $\hat{\sigma}^2$ 估計則為 24,744.69。此結果指出，模型本身帶有輕微的負向自相關結構，而農曆年間的出現則對預測結果造成明顯的負向衝擊。平均而言，春節期間每週住院人次將比平時減少約 111 人。這也反映出春節假期期間因醫療機構調整服務量或民眾就醫行為改變，導致住院人次下降的現象。可看出在住院的 ARIMA(1,1,0)加入解釋變數成為 ARIMAX 後會對整體時間序列模型有負向影響。

另一方面，Holt's linear trend method 則不考慮外部解釋變數，其估計結果顯示水準(ℓ_t)等於 3,522，而趨勢項(b_t)表示 t 時間的估計斜率，其值為 2.4887。另外，平滑係數分別為 $\alpha=0.8723$ 與 $\beta=0.0010$ ，模型的 σ^2 為 24,908。該模型預測未來每增加一週，住院人次將平均增加約 2.49 人。此模型雖能捕捉整體線性成長趨勢，但未納入如春節等短期劇烈變化的影響因素，因此在面對異常波動時，其預測表現可能不如 ARIMAX 模型靈活且精準。總體而言，ARIMAX 模型能更充分考慮內部結構與外部變動，較能貼近實際的就診行為變化，有助於後續的趨勢預測。


二、門診 ARIMAX(0,1,1)、Holt's linear trend method

(一) 一次差分後診斷圖 ARIMAX



圖十一

(二) 模型殘差分析 ARIMAX



圖十二

由圖十一所示，門診資料經過一次差分後，依左上圖看出雖有部分極端動盪產生，且因資料進行單位轉換，極端部分動盪實際上超過 50,000，但差分後數值依舊在 0 附近劇烈震盪，資料已處平穩化；而右上角之 ACF 圖可看出在 lag(1)處有顯著情形，加上圖七所述，ACF 圖之 lag(1)顯著，PACF 圖有 Dies down 情形，符合 MA(1)模型特徵，因此模型選用 ARIMAX(0,1,1)。由圖十二所示，門診所配適的 ARIMAX(0,1,1)，其殘差自相關(ACF)及偏自相關(PACF)有部分略為超出兩倍標準差所構成的信賴區間，代表著殘差可能存在輕微結構性自相關。另外，White-noise 檢定結果顯示，其 p-value 明顯小於 0.05，即為拒絕虛無假設 H_0 (即殘差為白噪音)，顯示該模型的殘差並非完全隨機。雖然理論上應對模型進行調整或重新建構，但在觀察殘差 ACF 及 PACF 圖後，如前面所述，其殘差僅些微超出信賴區間，並無顯著自相關之情形。此外，考量與其他兩組資料模型選擇的一致性，以及門診資料模型配適 ARIMX(0,1,1)解釋力達 0.9115，顯示其具有良好的解釋能力，故我們最終仍採用 ARIMAX(0,1,1)模型作為門診資料的配適模型。

(三) 參數估計

1. ARIMAX

$$y_t = \theta_1 \varepsilon_{t-1} + \beta \cdot D_{1t} + \varepsilon_t,$$

$$y_t = -0.1686 \cdot \varepsilon_{t-1} - 2.6314 \cdot D_{1t} + \varepsilon_t,$$

$$D_{1t} = \begin{cases} 1, & t \text{ 時間在農曆年期間} \\ 0, & \text{其他} \end{cases},$$

$$\theta_1 = -0.1686, \beta = -2.6314, \hat{\sigma}^2 = 73.33.$$

2. Holt's linear trend method

$$\ell_t = 97.5826 \quad b_t = 0.0482,$$

$$\alpha = 0.8337 \quad \beta = 0.0010 \quad \hat{\sigma}^2 = 73.4688,$$

$$\hat{y}_{t+h} = 97.5826 + 0.0482h.$$


依門診資料分別建構 ARIMAX(0,1,1)與 Holt's linear trend method 模型，並進行參數估計，從門診資料配適的 ARIMAX(0,1,1)模型中同樣加入農曆年間的解釋變數(D_{1t})，依圖七所示，可看出門診資料因一次差分後 PACF lag(1)顯著，故在此須納入 MA(1)作為外部解釋因子。從 ARIMAX 模型的參數估計結果可知，其一階移動平均係數(θ_1)為-0.1686，代表模型中殘差的移動平均項具有輕微的負相關，且農曆期間解釋變數之係數(β)為-2.6314， $\hat{\sigma}^2$ 估計則為 73.33，因門診資料是以千人為單位，故加入春節期間影響的解釋變數對觀察值的影響量實際是高達-2,631.4 人次，即為在春節期間每週赴門診就醫的人次相較其他週次減少約 2,631.4 人，表示農曆年期間會對門診造成顯著的負面影響，此結果合理反映春節期間因診所休診或醫療機構調整營運時間，會導致民眾的就醫行有大幅度改變。

相較之下，Holt's linear trend method 為不含外部解釋變數的趨勢型預測模型，其估計結果顯示水準參數(ℓ_t)為 97.5826，趨勢項(b_t)為 0.0482，平滑係數分別為 $\alpha = 0.8337$ 與 $\beta = 0.0010$ ，模型的 $\hat{\sigma}^2$ 估計為 73.4688， h 為未來的期數。此模型可看出未來 h 期的預測值將會呈現穩定線性成長趨勢，每週在 97,582.58 人的基礎量下，隨著週次增加，未來門診就診人次平均每週增加約 48.2 人。雖然在不考慮突發性變異的前提下，Holt's 模型能有效掌握門診資料的整體長期趨勢，但在面對如春節等短期劇烈變動時，其預測彈性與精準度可能不如 ARIMAX 模型。總體而言，ARIMAX 在考量時間序列結構特性與外部因素變化後，能更貼近實際的門診需求變化，對於提升預測準確性與後續政策擬定具更高實用性。另外，我們可從 ARIMAX 以及 Holt's linear trend method 兩種模型的結果可觀察到，因資料單位轉換為千人，其預測誤差的變異值($\hat{\sigma}^2$)變得很小。然而，此單位轉換進影響模型估計值的數值尺度，並不會影響預測結果的準確性與解釋力。


三、急診 ARIMAX(1,0,0)、Holt's linear trend method、介入分析

(一) 一次差分後診斷圖 **ARIMAX**

(二) 模型殘差分析 **ARIMAX**



圖十三



圖十四


在急診資料所配適的 $ARIMAX(1,0,0)$ 中，相較住院及門診資料多納入一個解釋變數，因為急診就診人次除了受到春節假期的季節性波動影響外，亦受到 COVID-19 疫情衝擊。自 2022 年 4 月起，Omicron 變異株於臺灣社區廣泛流行（衛生福利部疾病管制署，2024b），期間出現大量具有發燒及呼吸道症狀等疑似感染症狀之民眾前往急診就醫。此一現象可能與 Omicron 流行所帶來的醫療需求增加有關，同時亦受到當時快篩檢測規範及防疫政策調整，像是就醫分流與抗病毒藥物取得機制的共同影響等。因此，在 2022 年 4 月 24 日至 2022 年 5 月 21 日間可觀察到急診個案數明顯增加。為了更精確捕捉春節假期與該疫情時段對類流感急診個案就診趨勢的影響，我們於急診資料中額外設定兩個解釋變數，將春節假期與該期間的週次設為 1，其餘週次則設為 0。

由圖十三所示，資料並無進行一次差分，且無進行單位轉換，因此左上圖代表著急診資料的時間序列圖，與圖八不同的是，圖十三左上圖之橫軸是以週次為單位，取代圖八所使用的年次；而從右上角的 ACF 圖明顯看出有緩慢下降的情形，加上前述圖八之 PACF 圖有 lag(1) 顯著之情形，綜合兩者，急診資料模型配適 $ARIMAX(1,0,0)$ 。

由圖十四所示，配適兩個解釋變數後的 $ARIMAX(1,1,0)$ 模型，其殘差 ACF、PACF 圖之殘差皆在兩倍標準差之內，未見明顯殘差自相關，表示模型已成功捕捉主要結構性變化。而 White-noise 檢定雖部分超出 0.05，但整體仍處於可接受範圍內，未明顯影響模型之準確性。整體而言，加入 COVID-19 疫情作為解釋變數後，模型能更充分反映急診人次的異常波動，提升預測表現與解釋力。

ACF、PACF 介入分析

White-noise Test 及 Unit Root Test 介入分析



圖十五

圖十六

如圖三(f)急診的時間序列圖所示，急診類流感就診人次在 2016 年 1 月 31 日至 2016 年 2 月 6 日（即霸王級寒流期間）及 2022 年 4 月 24 日至 2022 年 5 月 21 日（COVID-19 Omicron 大規模流行期間）出現明顯高峰，顯示此兩段期間對整體趨勢造成顯著影響，因此本研究針對上述 5 週資料進行介入分析，以更準確掌握突發事件對急診就診行為的影響。依上圖十五所示，可看出介入分析以上 5 個點後，ACF、PACF 殘差皆在兩倍標準差之內，再看其右圖十六所示之 White-noise 檢定結果，可看出其 White-noise 檢定符合標準，符合白噪音假設。此外，單根檢定（Unit Root Test）亦顯示資料已具穩定性，符合後續建模的假設條件。整體而言，此介入模型在統計診斷上通過各項檢定，顯示所配適之模型具備良好的統計性質與實用性。

（三）介入原因

本研究在進行類流感就診趨勢分析時，亦特別考慮重大突發事件作為介入變數，以評估其對就診人次造成的短期影響。根據歷年疫情與公共衛生重大事件，選定兩個具代表性的介入時點：其一為 2016 年初的「霸王級寒流」期間，其二為 2022 年春季 COVID-19 疫情快速升溫期間。第一個介入事件為 2016 年第 5 週（2016 年 1 月 31 日至 2016 年 2 月 6 日，共一週）所發生的霸王級寒流，根據疾病管制署資料顯示，該週新增 108 例流感併發重症確定病例，並有 10 例經審查與流感相關的死亡通報(衛生福利部疾病管制署，2016)，顯示當時寒流所引發之低溫環境與病毒傳播密切相關，導致就診人次與嚴重個案激增，因此我們將此事件被視為重要的短期影響來源，並設定為持續一週的介入分析變數。

第二個介入事件則為 COVID-19 疫情在臺灣於 2022 年 4 月下旬至 5 月中旬的急速爆發期(2022 年 4 月 24 日至 2022 年 5 月 21 日，共四週)。根據中央流行疫情指揮中心公告，當時國內疫情已進入廣泛社區流行，病例數呈

倍數增長，於 2022 年 5 月 5 日單日新增本土確診病例達 30,035 例，並造成 5 例死亡，創下當時單日新高。隨後於 5 月 7 日再創高峰，單日新增病例數上升至 46,536 例，其中本土病例占 46,377 例，死亡人數上升至 11 人。(衛生福利部疾病管制署，2022)。該段期間防疫政策與民眾就醫行為皆出現劇烈變動，包括就醫傾向下降、醫療資源排擠、門診調整等情況，對各類型就診人次皆可能產生明顯干擾，因此本研究將該段時間設為另一介入時段進行分析。

(四) 參數估計

1. ARIMAX(1, 0, 0)

$$y_t = \alpha + \phi_1 y_{t-1} + \beta \cdot D_{1t} + \varepsilon_t,$$

$$y_t = 12788 + 0.7982 \cdot y_{t-1} + 3976.9 \cdot D_{1t} + \varepsilon_t,$$

$$D_{1t} = \begin{cases} 1, & t \text{ 時間在農曆年或 } 2022/04/24 \text{ 至 } 2022/05/21 \text{ 期間} \\ 0, & \text{其他} \end{cases},$$

$$\phi_1 = 0.79816, \alpha = 12,788, \beta = 3,976.9, \hat{\sigma}^2 = 14,687,492.$$

其中，模型中的 $\phi_1 = 0.7982$ ，表示急診就診人次具有高度的自我相關性，即前一期人次的變化對當期有明顯的影響。解釋變數 D_{1t} 則是將農曆年間及 COVID-19 疫情期間作為解釋因子，將這些特殊週次標記為 1，其餘時間為 0。由參數估計結果可看出加入兩個解釋變數後，配適的模型 ARIMAX(1,0,0) 其參數估計式中的 $\beta = 3,976.9$ 為正，代表在這些特殊時段，急診人次平均會額外增加約 3,977 人次。顯示急診就診行為對外在突發事件特別敏感，推測是因民眾在春節假期期間沒有門診選擇又有就醫需求，或在疫情擴散時對疑似症狀感到焦慮而前往急診，這將加劇急診醫療資源的使用。相較之下，住院與門診模型中加入相同解釋變數後呈現負向效果，顯示在特殊時期非急迫性醫療需求反而下降，進一步突顯其於醫療中的角色與特性。

2. Holt's linear trend method

$$\ell_t = 13294, \quad b_t = 0.9759,$$

$$\alpha = 0.8919, \beta = 0.0010, \hat{\sigma}^2 = 16,630,281,$$

$$\hat{y}_{t+h} = 13294 + 0.9759h.$$

根據模型估計結果顯示水準(ℓ_t)為 13,294，趨勢項(b_t)為 0.9759，平滑係數分別為 $\alpha = 0.8919$ 與 $\beta = 0.0010$ ，模型的 $\hat{\sigma}^2$ 為 16,630,281。顯示模型對近期資料的變化反應較為靈敏。由於配適 ARIMAX 以及 Holt's linear trend method 兩個模型的 $\hat{\sigma}^2$ 都極高，可由此可看出該資料波動較大較難預測，若希望降低 $\hat{\sigma}^2$ 數值大小，使模型在評估指標上更穩定且易於解釋，可參考門

診資料進行單位轉換，以每百人或每十人做為轉換單位，即可在不影響其預測準確性的同時達到我們所期望 $\hat{\sigma}^2$ 變小的結果。

3. 介入分析

再進一步探討重大突發事件對急診類流感就診人次的影響時，本研究採用介入因子進行介入分析，設定介入變數 P_{1t} 至 P_{5t} ， P_{1t} 為 2016 年霸王級寒流發生時間， P_{2t} 至 P_{5t} 則是 2022 年 4 月下旬至 5 月中旬臺灣 COVID-19 疫情急速爆發期。每一個變數代表特定一週的介入事件是否發生（發生為 1，否則為 0）。我們所建立的模型如下：

$$y_t = C_1 P_{1t} + C_2 P_{2t} + C_3 P_{3t} + C_4 P_{4t} + C_5 P_{5t} + \varepsilon_t,$$

實際估計後之結果為：

$$y_t = 32283 P_{1t} + 35398 P_{2t} + 24211 P_{3t} + 24206 P_{4t} + 22550 P_{5t} + \varepsilon_t,$$

$$P_{1t} = \begin{cases} 1, & 2016/01/31 \text{ 至 } 2016/02/06 \\ 0, & \text{其他,} \end{cases}$$

$$P_{2t} = \begin{cases} 1, & 2022/04/24 \text{ 至 } 2022/04/30 \\ 0, & \text{其他,} \end{cases}$$

$$P_{3t} = \begin{cases} 1, & 2022/05/01 \text{ 至 } 2022/05/07 \\ 0, & \text{其他,} \end{cases}$$

$$P_{4t} = \begin{cases} 1, & 2022/05/08 \text{ 至 } 2022/05/14 \\ 0, & \text{其他,} \end{cases}$$

$$P_{5t} = \begin{cases} 1, & 2022/05/15 \text{ 至 } 2022/05/21 \\ 0, & \text{其他,} \end{cases}$$

$$\hat{\sigma}^2 = 6715611.$$

C_1 至 C_5 分別代表著每一週介入事件發生時，對急診類流感人次 y_t 的平均影響量。可反映出事件發生後，急診人數上漲或下降多少，藉此評估該事件的影響程度有多大。結果顯示，這五個週次皆導致急診人次增加，其估計值介於 22,550 至 35,398 之間，反映出事件發生後，急診人次大幅上升，特別是在疫情初期與寒流期間，影響程度尤為顯著，即所介入的時間點對類流感急診人次帶來極大影響。此外，介入模型的 $\hat{\sigma}^2$ 下降至 6,715,611，相較於未介入模型，變異數大幅減少，顯示加入上述五項介入變數後，模型確實對類流感急診就診人次有一定的解釋力及影響力。

第三節 預測比較

模式	預測方法	模型績效評估指標
----	------	----------

就診 類型			RMSE	MAE	MAPE	MASE
住院	ARIMAX	Forecast	645.0548	504.0000	12.7896%	1.1424
		Expanding approach	565.279	377.6667	9.7377%	0.8560
	線性趨勢法	Forecast	490.2716	334.2222	8.5875%	0.7576
		Expanding approach	572.7373	368.0556	9.6587%	0.8343
門診	ARIMAX	Forecast	28.0520	21.9389	19.2986%	1.1200
		Expanding approach	29.6809	17.6333	18.0929%	0.9002
	線性趨勢法	Forecast	28.1181	22.0389	19.6353%	1.1251
		Expanding approach	31.2119	18.0056	18.4544%	0.9192
急診	ARIMAX	Forecast	6263.3456	4398.0556	21.3728%	1.6814
		Expanding approach	3507.0020	1956.2778	9.2121%	0.7479
	線性趨勢法	Forecast	6701.0797	4290.7778	20.0041%	1.6404
		Expanding approach	4677.6313	2702.0000	12.5214%	1.0330
	介入分析	Forecast	5915.2020	4054.6110	19.4808%	1.5501
		Expanding approach	4319.1945	2128.8889	9.4070%	0.8139

表四 樣本外預測的績效表現


為評估各預測方法在預測資料上的表現，本研究設計樣本外預測期間，涵蓋 2025 年 1 月至 2025 年 4 月共 18 週。此期間資料未納入模型訓練，僅用於驗證模型之預測能力與泛化效果。表四為針對每一個預測方法做樣本外預測後計算出的績效表現，其中 Forecast 表示直接一次性預測未來 18 期（後面將解釋為直接預測），Expanding Approach 則代表擴展式預測策略之一步預測，相較於直接預測一次性產生全部預測值，Expanding Approach 每預測一期便納入實際值更新模型，因此能有效修正誤差並反映最新資料狀態。表格中以黑色框標示的部分則代表該類別中的最佳模式以及最佳的預測方法，亦為本研究最終採用的預測方法。需要特別說明的是以整體而言，門診的數值會相對低，是因為此部分的人次是以千人為單位。以下將詳細進行說明：

首先是住院的部分，在表中我們可以看到線性趨勢法中的直接預測結果是最好的，使用 Expanding Approach 做一步預測次之，使用 ARIMAX 模型的表現則相對較差。儘管如此，根據第四節的圖十八可見，霍爾特線性趨勢法在一步預測時，其預測線趨勢明顯更貼近實際值。這說明使用 Expanding Approach 做一步預測更能捕捉解釋因子，為更優的預測方法。由表中數據也可以發現兩者的 MAPE 僅相差 1.1%，且皆小於 10%，都是高度準確的預測，另外，兩者的 MASE 亦都小於 1，這表示這兩種方法的預測表現皆較 Naïve 好，這代表模型成功捕捉到資料的趨勢與模式，非僅仰賴過去值，綜合以上，我們將選擇霍爾特線性趨勢法中的 Expanding Approach 作為住院資料的最佳預測模型。


而在門診與急診當中，使用 ARIMAX 再加上 Expanding Approach 會有最佳的預測表現，因為其誤差比率最小，在門診的部分，該方法的 MAPE 為 18.0929%，雖以表一的準則而言，該數值小於 20% 依舊為公平的預測，但相較於其他類別表現相對差，而其 MASE 為 0.9002 僅略小於 1，雖然有成功捕捉到資料的趨勢，但尚有改善空間，這可能與門診資料容易受個人行為、天候、節慶等短期因素影響較大有關，使得模型較難完全掌握其波動模式，這部份是我們日後可以設法改善的方向。另外，在急診的部分，可以看到 MAPE 為 9.2121%、MASE 為 0.7479，這代表在急診當中，這種模式屬於高度準確的預測且優於 Naïve，它能成功捕捉資料的趨勢與模式。

進一步觀察表四可以發現，幾乎所有模型在採用 Expanding Approach 後的預測績效相較於直接預測皆有顯著提升。特別是在急診資料中，ARIMAX 的 MAPE 從 21.3728% 大幅下降至 9.2121%，顯示此策略能夠顯著提升預測效能，並即時反映最新趨勢，在面對變動性較高的醫療需求資料時更具穩定性與彈性。


第四節 預測結果




圖十七 住院資料在霍爾特線性趨勢法的直接預測圖



圖十八 住院資料在霍爾特線性趨勢法的一步預測圖



圖十九 門診資料在 ARIMAX 模式中的一步預測圖



圖二十 急診資料在 ARIMAX 模式中的一步預測圖

根據類流感於「住院」、「門診」、「急診」三個部分的個案人數的預測結果，圖十七為住院資料在霍爾特線性趨勢法中的直接預測結果，而圖十八、圖十九以及圖二十則分別展示「住院」、「門診」、「急診」各自的最佳模式的預測圖，這些模式能夠更準確地反映各類就診人數的變動。圖中使用四條線表示數值趨勢：藍色的線代表實際值，橘色的線代表預測值，灰色的線代表 95%預測區間的下界，黃色的線則代表 95%預測區間的上界。若實際值落在預測區間內，表示模型預測誤差在可接受範圍，具備穩定的預測能力。從圖中可以觀察到，大部分點位皆落在信賴區間內，說明模型具有穩定的預測能力。

關於住院資料，圖十七雖然在表四中績效表現是最好的，但因為 Holt's linear trend method 直接預測無法捕捉解釋因子，即為採用穩定性成長趨勢，並無納入各時間點可能發生的變動並預測下期，此直接預測方法的預測結果可能會與現實層面稍有不符，準確性也理應較低，因此將不建議採用；而在此研究中該直接預測方法會是住院資料中績效表現最好的（誤差最低），我們認為可能是因為住院資料雖加入外部解釋因子，以評估春節期間對類流感住院人次的影響，但實際上住院受到春節影響的人次變化不大，因此才會出現直接預測較一步預測的更為準確的錯覺，實際上應利用一步預測方法去逐步擴展資料集並預測下一期的值，除了能即時掌握現實層面的變動外，也更能因應環境變化而對下期有更精準的預測。

相比之下，圖十八是住院資料在霍爾特線性趨勢法中的一步預測圖，它可以較有效地捕捉解釋變數的影響，因此屬於住院資料中較佳的模式。在圖十八至圖二十中，可以觀察到在春節期間就診人數會發生比較劇烈的變動，這與我們設定的春節變數相符。首先，住院與門診在春節期間會因為醫療機構的休診或改變營業時間而使就診人次相對減少，這同時也造成了住院及門診的就診人次在隔週會有一定比例的報復性增長。反之，急診的就診個案則會因住院及門診的醫療模式改變而於春節期間明顯增加，在隔週住院及門診人次增長的同時，急診人次會逐漸下降，以上結果皆表明，我們的預測方法能夠準確的捕捉春節期間對於個案人數所造成的影響。但需要特別注意的是，在整個一步預測過程中，由於模型在估算時會較依賴前一期數據，導致預測值在時間軸上產生系統性的偏移，表現為整體向左偏移一期。這種現象使得預測結果與實際數據相比，在視覺上呈現時間錯位，尤其在春節前後等數據變動較為劇烈的時期，這種偏移會更加明顯。

第五章 結論

本研究針對類流感在「住院」、「門診」、「急診」三個部分的個案人數歷年資料進行分析。其中我們發現在每年的農曆新年前後，數據資料會發生劇烈變動，其中「住院」以及「門診」在春節期間個案人數會明顯下降，而急診的個案人數會在春節期間有顯著的上升，兩者於春節期間人數變動呈現反比關係。這與春節期間門診暫停開放有關，當門診暫停開放時，病患若有需就醫之情形，就只能至急診尋求幫助，這間接導致急診個案在春節期間明顯上升。因此，我們數據中加入一個解釋變數，設定農曆新年週次為 1，其他週次為 0；另外，急診資料除了春節外，亦受到 COVID-19 影響，自 2022 年 4 月起，Omicron 病毒變異株於國內社區廣泛流行(衛生福利部疾病管制署，2024b)，導致在 2022 年 4 月 24 日至 2022 年 5 月 21 日期間急診個案明顯增加，因此在急診資料中，我們額外設定農曆新年及該期間週次為 1，其他週次為 0，藉此更精確地評估以上因素對類流感個案的影響。

本研究比較兩種時間數列預測方法，結果顯示 Expanding approach 一步預測法在整體表現上具備較高的穩健性與準確性，特別是在樣本外數據的應用上，能有效貼近真實趨勢並提升預測效能。相較於傳統的 ARIMA 預測方式，Expanding approach 透過逐步更新模型，能即時反映最新資訊，降低長期累積誤差，適合用於需持續監測與即時反應的情境。因此，建議未來相關研究與實務操作中可優先考慮此方法，以確保模型的可靠性與延展性。此外，研究發現急診需求在農曆春節期間有顯著增加，顯示季節性與節慶效應在醫療需求預測中不容忽視。這一現象間接反映醫療院所人力需求的提升，對醫療資源配置提出挑戰。為降低醫療現場的壓力與不確定性，建議主管機關應提前進行人力規劃與跨部門協調，並可考慮建立長期的預測機制，將此類高峰需求納入政策決策過程中，以確保醫療服務的順利進行。而本研究在未來發展性主要聚焦於藉由此預測方法與模型進行類流感就診模式的動態分析，若因政策推動或突發事件而使特定就診模式之人次暴增或銳減，可在現有模型中新增解釋變數，提供即時反映並預警，使醫療院所得以提前調派人員與資源，進一步提升整體醫療體系的應變能力。

參考文獻

- Babcock, H. M., Merz, L. R., & Fraser, V. J. (2006). Is influenza an influenza-like illness? Clinical presentation of influenza in hospitalized patients. *Infection control and hospital epidemiology*, 27(3), 266–270. <https://doi.org/10.1086/501539>
- Box, G. E. P., Jenkins, G. M. (1970). Time series analysis: forecasting and control. Holden-Day, San Francisco.
- Box, G. E. P., & Tiao, G. C. (1975). Intervention Analysis with Applications to Economic and Environmental Problems. *Journal of the American Statistical Association*, 70(349), 70–79. <https://doi.org/10.2307/2285379>
- CDC(2025). U.S. Influenza Surveillance: Purpose and Methods. 取自 <https://www.cdc.gov/fluview/overview/index.html> (檢索日期：2025 年 7 月 27 日)
- Chartrand, C., Leeflang, M. M. G., Minion, J., Brewer, T., & Pai, M. (2012). Accuracy of rapid influenza diagnostic tests: A meta-analysis. *Annals of Internal Medicine*, 156(7), 500–511. <https://doi.org/10.7326/0003-4819-156-7-201204030-00403>
- Chen, C.W.S., Hsieh, L.L., and Chu, X.Y. (2025) Structural time series modelling for weekly forecasting of enterovirus outpatient, inpatient, and emergency department visits, *PLOS ONE*, 20(5): eF0323070. <https://doi.org/10.1371/journal.pone.0323070>
- European Commission. (2018). Commission Implementing Decision (EU) 2018/945 of 22 June 2018 on the communicable diseases and related special health issues to be covered by epidemiological surveillance as well as relevant case definitions. *Official Journal of the European Union*, L 170, 1–74. http://data.europa.eu/eli/dec_impl/2018/945/oj
- Holt, C. C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, 20(1), 5-10.
- Hyndman, R.J., and Athanasopoulos, G. (2018) *Forecasting: Principles and Practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- Lewis, C. D. (1982). Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting.
- Marsden-Haug, N., Foster, V. B., Gould, P. L., Elbert, E., Wang, H., & Pavlin, J. A. (2007). Code-based Syndromic Surveillance for Influenza-like Illness by International Classification of Diseases, Ninth Revision. *Emerging Infectious Diseases*, 13(2), 207. <https://doi.org/10.3201/eid1302.060557>

Yang, C. Y., Chen, R. J., Chou, W. L., Lee, Y. J., & Lo, Y. S. (2019). An integrated influenza surveillance framework based on national influenza-like illness incidence and multiple hospital electronic medical records for early prediction of influenza epidemics: Design and evaluation. *Journal of Medical Internet Research*, 21(2), e12341. <https://doi.org/10.2196/12341>

衛生福利部疾病管制署 (2016) 台灣流感速訊。取自 https://www.cdc.gov.tw/En/File/Get/J6rGFoxKqKtY68R_vNWoxA (檢索日期：2025 年 5 月 14 日)

衛生福利部疾病管制署 (2022) 國內外疫情焦點 2022 年第 18–19 週. *Taiwan Epidemiol Bull*, 38, 115-118。取自 <https://www.cdc.gov.tw/File/Get/lhZlbrzdTTiQP86H5uSbh1g> (檢索日期：2025 年 5 月 14 日)

衛生福利部疾病管制署(2024a) 自明(2025)年 1 月 1 日起，公費流感疫苗開放全民接種至疫苗用罄。取自 <https://www.mohw.gov.tw/cp-16-80865-1.html> (檢索日期：2025 年 7 月 30 日)

衛生福利部疾病管制署 (2024b) 《疫起走過：COVID-19 嚴重特殊傳染性肺炎大流行工作紀實》。取自 <https://www.cdc.gov.tw/File/Get/8ECt6c4o71jL8H4Vfci4A>