



# 氣候變遷下的空氣污染分布： 地理人工智慧技術之應用

吳治達／國立成功大學測量及空間資訊學系 副教授

曾于庭／國立成功大學測量及空間資訊學系 研究助理

工業化的過程中所排放的溫室氣體不僅會增強全球暖化，石化燃料燃燒所產生的空氣污染亦會嚴重衝擊人類健康，因此正確的估計國人在氣候變遷影響下之空氣污染暴露情形，實為當前環保單位的重要挑戰。受限於現有空氣品質監測站空間分布不均、數量不足等問題，我們需要一個更有效、更快速、更準確的模擬方法，以正確評估都市居民每個人的空氣污染暴露程度。近年來結合衛星、航照、無人機影像及地理資訊系統（Geographic Information System, GIS）等空間資訊技術（Geo-Spatial Technologies）以獲取環境監測樣本，並搭配機械學習（Machine Learning）及集成學習（Ensemble Learning）等人工智慧（Artificial Intelligence, AI）演算法進行高準確度推估模型擬合之「地理人工智慧（Geo-AI）」技術，已逐漸成為當代空氣污染模擬的主流方法學。基於此，本文綜整近年來有關 Geo-AI 在空氣污染模擬上的研究成果及應用案例，依據使用的空間推估模型方法學，分為：(1) 空間內插（Spatial Interpolation）；(2) 土地利用迴歸（Land-use Regression, LUR）；(3) 機械學習與集成學習；(4) 新興空間資訊科技之應用等四個面向進行介紹。本文之統整成果可做為未來在評估氣候變遷影響下都市防災與空氣污染影響之重要佐參。

## 前言

工業的快速發展燃燒大量化石燃料，除了會造成溫室氣體排放而增強氣候暖化、破壞地球氣候系統與生態系統平衡；同時排出的懸浮微粒（Particulate Matter,  $PM_{10}$ ）、細懸浮微粒（Fine Particulate Matter,  $PM_{2.5}$ ）、二氧化氮（Nitrogen Dioxide,  $NO_2$ ）、二氧化硫（Sulfur Dioxide,  $SO_2$ ），甚至是透過其它污染物與太陽光進行光化反應後產生的臭氧（Ozone,  $O_3$ ）等空氣污染物，亦會造成人類心血管、呼吸道等多重健康危害。同時，氣候的變化與空氣污染之間亦會產生交互作用影響，例如美國環保署指出，由於全球暖化導致都市溫度上升、改變區域氣象條件與地表輻射，進而可能造成臭氧與懸浮微粒的濃度提升。加上人類生存的每個時刻都需要空氣，並且只能呼吸當地當時的空氣，因此正確的估計每個國人在氣候變遷影響下之空氣污染暴露情形、進而分析其可能導致的健康效應，實為當前環保機關面臨的重要挑戰。

在行政院環境保護署的努力下，目前國內在台灣本島的部份已設置有約七十餘個固定的空氣品質監測站（簡稱空品站），這些座落於不同縣市的空品站可提供各個區域空氣污染的重要監測資訊，然而現存的空品測站系統仍有一些不足之處，例如以筆者所在的台南市之幅員面積約為 2,192  $km^2$ ，然而整個大台南地區當前僅有六個空品站；另一方面，現有的空品站多座落於西部都會區，台灣東部當前只有五個測站，東西部測站數目具有極大差異。受限於空間分布不均、數量不足等問題，直接以空品測站量測到的數據來代表都市居民每個人的空氣污染暴露程度，其代表性似乎仍有所不足。有鑑於此，築基於空品站的監測數據，搭配具有代表性的空污排放源環境因子發展預測模型，進而模擬全台灣每個角落的空污濃度梯度變化，並據以連結至個人在氣候變遷影響下的空氣污染暴露程度，實為都市防災與全民公共衛生當前所需面臨的重要挑戰。

近年來空間資訊技術 (Geo-Spatial Technologies) 被廣泛被應用在不同領域，衛星、航照、無人機影像及地理資訊系統 (Geographic Information System, GIS) 圖層提供了快速獲取大範圍土地利用 / 土地覆蓋的有效方法；另一方面，由於電腦軟硬體及運算效能的快速演進，原本需要仰賴高規格計算資源方能運行的人工智慧 (Artificial Intelligence, AI)、機械學習 (Machine Learning) 及集成學習 (Ensemble Learning) 演算法，如今已可在個人電腦上流暢的運作，並且提供更良好解釋性 / 非線性複雜關係的模型建置方法學。有鑑於這二項先進技術幾為各自領域最佳且最先進方法之一，故有學者結合二者之優勢，提出創新的「地理人工智慧 (Geo-AI)」的概念，並將其應用在空氣污染模擬上，亦即透過空間資訊技術以快速取得地理空間排放源分布資料，再搭配測站量測的空污觀測數據，藉由機械學習及集成學習演算法進行高準確度推估模型擬合，最後再結合地理資訊系統平台，視覺化展示高時空解析度的空污濃度梯度分布模擬成果。這樣的方法與流程，已逐漸成為當代空氣污染模擬的主流方法學。

本文綜整近年來有關 Geo-AI 在空氣污染模擬上的研究成果及應用案例，依據使用的空間推估模型方法學，分為：(1) 空間內插 (Spatial Interpolation)；(2) 土地利用迴歸 (Land-use Regression, LUR)；(3) 機械學習與集成學習；(4) 新興空間資訊科技之應用等四個面向進行介紹。本文之統整成果可做為未來在評估氣候變遷影響下都市防災與空氣污染影響之重要佐參。

## 空間內差

空間內插法是一種空間統計方法學，主要透過已知點位的數據，以不同組成函數進行空間內插運算後獲得未知點可能數值的方法，過去多用來進行地理、氣候因子或是人口密度等資料的視覺化展現。時至今日發展出的空間內插方法學已有非常多種，常見者包含

距離反比加權法 (Inverse Distance Weighting, IDW)、自然鄰點內插法 (Natural Neighbor Interpolation, NNI)、不規則三角網 (Interpolation Based on a Triangulated Irregular Network, TIN)、樣條內插 (Spline Interpolation, Spline) 以及克利金內插法 (Kriging Interpolation, Kriging) 等。其中 IDW、NNI 與 TIN 等三項方法主要是在一般規則圖形 (包含正方形以及三角形等)、三角網以及沃羅諾伊圖 (Voronoi Diagram) 等限制距離下的幾何範圍內，進行反距離上的加權或是各圖形頂點平均而得出空間內插的可能資料數值分布；樣條內插係透過多項式函數，讓通過曲線之差值呈現平滑分布；克利金法在各種空間內插法中，被譽為最具貼近真實狀況的空間內插方法學，克利金係在變異函數理論及結構分析理論基礎上，考量已知點與估計點、估計點與鄰近估計點彼此的空間距離關係以及數值大小，進而推估數值在趨勢面上的可能變化狀況。根據內部參數以及分析類型的不同，又可再細分為一般克利金 (Ordinary Kriging, OK)、分層克利金 (Stratified Kriging)、普遍克利金 (Universal Kriging, UK)、非線性克利金 (Non-linear Kriging)、指標克利金 (Indicator Kriging, IK) 以及補克利金 (Co-Kriging) 等。圖 1 係利用不同空間內插方法進行區域二氧化氮分布推估之示意。

在研究應用上，我們蒐集了過去有關空間內插於空氣污染應用之相關研究如表 1。綜合而論，在各種空間內插法來說以 Kriging 為最被廣為使用之方法。例如 Pan *et al.*<sup>[1]</sup> 應用一般克利金推估 PM<sub>2.5</sub> 於澎湖以及台灣長期時空變異，並據以進一步探討 PM<sub>2.5</sub> 暴露與受試者罹患肝癌之間的關聯性；Shukla *et al.*<sup>[2]</sup> 的研究中分別使用了距離反比加權法以及一般克利金兩項空間內插法，以視覺化推估印度德里之 PM<sub>2.5</sub> 濃度分布，結果發現 OK 相較於距離反比加權法誤差較小，更適合用來預測 PM<sub>2.5</sub> 的空間變異。除了上述單純應用 Kriging 進行空間推估的研究之外，亦有研究基於 Kriging 以結




圖 1 空間內插成果示意：(a) 站點濃度分布圖；(b) IDW；(c) NNI；(d) Spline；(e) Kriging。



表 1 空間內插在空氣污染研究上之應用案例

| 研究文獻                     | 研究試區            | 研究方法       | 研究亮點                                                                                  |
|--------------------------|-----------------|------------|---------------------------------------------------------------------------------------|
| Pan <i>et al.</i> [1]    | 台灣全島<br>(含澎湖地區) | OK         | 長期暴露在 PM <sub>2.5</sub> 濃度下會增加罹患肝癌的風險。                                                |
| Zhan <i>et al.</i> [3]   | 中國地區            | RF-STK     | 結合機器學習、空間內插以及遙測影像資料，進而推算地面 NO <sub>2</sub> 濃度空間變異。                                    |
| Shukla <i>et al.</i> [2] | 印度德里            | OK 以及 IDW  | 除視覺化 PM <sub>2.5</sub> 在印度德里之時空變異外，經由交叉驗證比較兩項空間內插方法應用在印度德里 PM <sub>2.5</sub> 空間推估之成效。 |
| Rahman <i>et al.</i> [4] | 中國長沙            | LSTM 以及 OK | 即時且快速預測未來 PM <sub>2.5</sub> 濃度變化，視覺化 PM <sub>2.5</sub> 空間變異以達到更直覺的預警成效。               |

合其他方法學進行研究分析，例如 Zhan *et al.* [3] 發展了隨機森林時空克利金（Random-Forest-Spatiotemporal-Kriging, RF-STK）方法，結合遙測影像中的對流層 NO<sub>2</sub> 垂直柱密度以及其他環境地理因子，進一步視覺化反演地面 NO<sub>2</sub> 濃度的時空分布；Rahman *et al.* [4] 透過長短期記憶（Long Short-Term Memory, LSTM）機器學習演算法，針對部分測站過去 PM<sub>2.5</sub> 以及 PM<sub>10</sub> 觀測數據進行訓練，進一步預測未來 PM<sub>2.5</sub> 以及 PM<sub>10</sub> 之濃度變化後，再應用一般克利金視覺化推估兩者之空間變異，對於空污大範圍預警更可以達到即時的成效。

由以上結果可以發現，Kriging 等空間內插技術迄今仍被國際間廣泛使用以推估不同空氣污染物之空間變異。然而影響空污的生成來源種類繁多，空間內插僅仰賴測站點位間之空間位置關係，於推估過程中，未能考量諸如氣象、污染排放源分佈以及周邊土地利用型態等影響空污濃度變化之因子效應，基於此，後續亦發展出其他推估及模型方法學，以改良這些不足之處。

土地利用迴歸

LUR 的概念最早被提及可追溯到 Briggs *et al.* [5] 的研究，該研究在當時為歐洲聯盟（簡稱歐盟，European Union）於 1993 年所資助的 SAVIAH 研究中的一環，目的主要在透過模式模擬的方法，以提供受試者兒童二氧化氮的暴露濃度，以幫助健康風險評估團隊進一步探討兒童呼吸道疾病與二氧化氮暴露間的關聯。當時較常被用以進行空氣污染物空間推估之方法包含上文提到的空間內差、暴露指標（Indicator-based Methods）以及擴散模型（Dispersion Modelling）等，然而這些方法在估算多數人口之精細個人暴露濃度上仍有不足且困難之處，例如空間內差主要仰賴測站數量多寡以及點位間的分布位置進行模擬；暴露指標僅透過空污排放源資訊代表個人暴露濃度；而擴散模型則需要精確的大氣物

理、化學、氣象、汙染排放量等繁瑣的模型參數，但這些參數往往不易取得。而在當時，地理資訊系統技術已在不同領域的學術界越發嶄露頭角，基於此，Briggs *et al.* [5] 應用 GIS 技術裡的空間分析（Spatial Analyst）與環域分析（Buffer Analysis）功能，計算各個空品測站點周遭 300 m 內的土地排放源分布資訊，像是車流量、建物分布密度等，除此之外亦透過數值地形模型（Digital Terrain Model, DTM）以代表海拔高、坡度及坡向等地形因子後，透過多元線性迴歸，以建立 NO<sub>2</sub> 與上述土地排放源因子間的統計關係，並用以推估 NO<sub>2</sub> 之空間變異。LUR 模型計算公式如下：

$$\text{Air pollution} = \beta_0 + \beta_1 \times \text{LU}_1 + \beta_2 \times \text{LU}_2 + \dots + \beta_n \times \text{LU}_n$$

(1)

式中：

Air pollution：測站量測的空污濃度； $\beta_0$ ：迴歸模型常數項； $\beta_{1 \sim n}$ ：土地排放源因子之迴歸係數； $\text{LU}_1 \sim \text{LU}_n$ ：土地排放源因子。

時至今日，GIS 技術已臻非常成熟的地步，能夠使用的地理圖資亦更加多元且豐富，因此後續研究在進行 LUR 建模時，除了增加所分析的環域範圍（像是測站周遭 50 m、100 m、250 m 甚或 5,000 m 等）種類外，並透過多樣的 GIS 與衛星遙測圖資，以在模型中更完整考量土地排放因子之影響（圖 2）；同時進一步結合迴歸分析中如向前選擇法（Forward Selection）、向後刪除法（Backward Selection）或是逐步迴歸法（Stepwise Regression）等變數篩選方法，以找出最佳之土地排放解釋因子組合。相關成果對於釐清須優先關注之污染排放源、以及提供大範圍空氣污染空間濃度變異資訊來說，均具有重要的參考價值。由於 LUR 操作簡單、耗時短，且可以完成大尺度且精細的空氣污染空間濃度推估，因此亦為廣被使用的空氣污染模擬方法之一 [6-19]。




圖 2 利用 GIS 技術獲取 LUR 建模過程中之土地排放源資訊

筆者研究團隊長年一直專注於空間資訊在空氣污染模擬推估之應用，過去亦已發表多篇應用 LUR 模型之研究成果（表 2）。在 Wu *et al.* [20] 中，我們以大台北地區（包含台北市及新北市）為研究試區，探討細懸浮微粒之時空變異。考量到亞洲與歐美國家在文化以及生活習慣上的差異，故不同地區細懸浮微粒的污染源亦會有所差別，像是在亞洲地區，人們至寺廟中燒香拜拜及燒金紙、以及街坊間常見的中式餐飲大火快炒等，都是亞洲國家頻繁發生、與空污排放有關的日常活動，因此筆者團隊特別於模型中納入這兩項亞洲特有污染源；除此之外，植物綠地亦具有改善空品的

效益，因此本研究亦納入長期植生遙測影像資料進行分析，最後整體模型效能 ( $R^2$ ) 亦高達 0.9，代表透過本研究所建立的模型進行細懸浮微粒空間分布模擬的成果，具有九成的準確度。另一方面，本團隊亦嘗試在 LUR 模型中，加入經由留一克利金法 (Leave-One-Out Kriging) 模擬之空氣污染初步估值，做為模型中的一項解釋變數，以提高模型推估成效，複搭配其它土地利用排放源資訊，以完成發展混合式 Kriging-LUR 推估模型，並用以估計台灣本島月平均及年平均細懸浮微粒 [21] 及二氧化氮 [22] 的時空分布，結果亦獲得頗佳的成效。

表 2 LUR 空污模擬之研究成果

| 研究文獻                     | 研究試區                 | 空氣污染物                               | 研究價值                                                                                              |
|--------------------------|----------------------|-------------------------------------|---------------------------------------------------------------------------------------------------|
| 台灣地區研究成果                 |                      |                                     |                                                                                                   |
| Wu <i>et al.</i> [20]    | 台灣大台北地區<br>(新北市及台北市) | PM <sub>2.5</sub>                   | 國際首篇考量亞洲特有污染源之 LUR 模型，推估成果更符合「在地化」特性。                                                             |
| Wu <i>et al.</i> [21]    | 台灣全島                 | PM <sub>2.5</sub>                   | 首例結合空間內插與 LUR 發展混合式 Kriging-LUR 推估模型。                                                             |
| Hsu <i>et al.</i> [23]   | 台灣全島                 | PM <sub>2.5</sub> 組成物質              | 國內首例以台灣全島為研究試區，建置十餘種 PM <sub>2.5</sub> 組成物質之 LUR 推估模型。                                            |
| Hsu <i>et al.</i> [24]   | 台灣全島                 | O <sub>3</sub>                      | 國內首篇以台灣全島為研究試區，建置 O <sub>3</sub> 之 LUR 模型。                                                        |
| Chen <i>et al.</i> [22]  | 台灣全島                 | NO <sub>2</sub>                     | 國內首篇以台灣全島為研究試區，建置 NO <sub>2</sub> 之 LUR 模型。                                                       |
| 與國外研究團隊合作                |                      |                                     |                                                                                                   |
| Widya <i>et al.</i> [25] | 台灣台北市以及<br>印尼雅加達     | PM <sub>2.5</sub>                   | 釐清並比較不同生活型態城市之 PM <sub>2.5</sub> 空間熱點分布。                                                          |
| Widya <i>et al.</i> [26] | 印尼泗水地區               | PM <sub>10</sub> 以及 NO <sub>2</sub> | 以印尼泗水地區為研究試區，建置 PM <sub>10</sub> 以及 NO <sub>2</sub> 之 LUR 模型，並視覺化 PM <sub>10</sub> 以及 NO 之空間熱點分布。 |



逐基於上述研究經驗，筆者團隊亦陸續完成了台灣全島 PM<sub>2.5</sub> 組成物質<sup>[23]</sup> 及臭氧<sup>[24]</sup> 污染的 LUR 模型分析。此外，研究團隊亦與印尼學者（Department of Geomatics Engineering, Institut Teknologi Sepuluh Nopember）共同研究，透過 LUR 的方法學以比較台北、雅加達以及泗水地區細懸浮微粒、懸浮微粒以及二氧化氮等污染物質之重要排放源與空間熱點<sup>[25,26]</sup>。

## 機械學習與集成學習

機器學習（Machine Learning, ML）為人工智慧（Artificial Intelligence, AI）中的一種資料科學技術。機械學習著重於讓電腦透過大量的資料進行學習，同時藉由分析過程中的經驗進行模型改進，而不是僅依照已經寫好的程式碼逐行運作而已。過程中演算法經由反複學習並找到資料分布的趨式與規則，進而建置具準確度推估能力的預測模型，並根據所建立的機械學習模型做出推理和預測。有鑑於機械學習具有良好解釋自變數與解釋變數間線性 / 非線性複雜關係之優勢，故在近年亦廣泛被用以分析空氣污染濃度與周邊土地利用排放源間的關聯，例如 Ren *et al.*<sup>[27]</sup> 藉由多種機器學習模型與迴歸模型，模擬美國每日臭氧最高濃度，結果顯示，機器學習演算法比線性迴歸所建置之模型，具有有更好的空氣污染變異解釋性，其中又以強學習器如隨機森林（Random Forest）與極端梯度提

升（Extreme gradient boosting, XGBoost）兩項演算法的成果最佳。

筆者團隊近年亦嘗試基於環保署過去二十餘年每日空品監測站的空污濃度監測數據，透過土地利用迴歸中的逐步變數挑選法（Stepwise variable selection）進行重要解釋變數篩選後，再應用深度神經網路（Deep Neural Network）、隨機森林與 XGBoost 等演算法進行模型擬合，以推估過去二十年台灣本島每日的細懸浮微粒<sup>[28]</sup>、二氧化氮<sup>[29]</sup>、一氧化碳<sup>[30]</sup>，以及大高雄地區家戶內細懸浮微粒的室內濃度<sup>[31]</sup>之時空變化，相關研究成果及主要發現如表 3。整體來說在經過多項模型驗證，各項演算法中仍以 XGBoost 演算法之模型呈現最好的推估能力，其預測準確度幾乎都在 90% 上下不等。

更進一步者，亦有研究提出「集成學習（Ensemble Learning）」之概念，經由系統化的方式組合多個基礎模型或演算法，以產生一個效能更佳、更為強大的解釋模型，進而提升模型預測準確率。實際操作集成學習時，係先以各個單一機器學習演算法個別先行獨立擬合推估模型後，並做出各自的預測，之後再一次藉由演算法的運算，將這些單一演算法的預測結果進行再擬合，以結合各個演算法的優勢，進而獲得優於任何獨立機器學習演算法推估成果之「集成式預測」。在空氣污染的應用上，例如 Shahriar *et al.*<sup>[36]</sup> 基於孟加拉 2013 年 1 月至 2019 年 5 月懸浮微粒之觀測資

表 3 空氣污染機械學習 / 集成學習模型研究成果

| 方法學  | 研究成果                   |             |               |                                                                                                                | 主要成果                                                                |
|------|------------------------|-------------|---------------|----------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------|
|      | 污染物                    | 研究地區        | 時間解析度         | 著作發表                                                                                                           |                                                                     |
| 機械學習 | PM <sub>2.5</sub>      | 台灣本島        | 日平均           | Wong and Wu* <i>et al.</i> <sup>[28]</sup><br>Environmental Pollution                                          | 主模型 R <sup>2</sup> =0.94<br>(驗證 R <sup>2</sup> =0.87~0.94)          |
|      | PM <sub>2.5</sub> (室內) | 高雄市         | 日平均           | Wong and Wu* <i>et al.</i> <sup>[31]</sup><br>Building and Environment                                         | 主模型 R <sup>2</sup> =0.85<br>(驗證 R <sup>2</sup> =0.38~0.85)          |
|      | NO <sub>2</sub>        | 台灣本島        | 日平均           | Wong and Wu* <i>et al.</i> <sup>[29]</sup><br>Journal of Cleaner Production                                    | 主模型 R <sup>2</sup> =0.84<br>(驗證 R <sup>2</sup> =0.80~0.84)          |
|      | CO                     | 台灣本島        | 日平均           | Wong and Wu* <i>et al.</i> <sup>[30]</sup><br>Environmental Modelling & Software                               | 主模型 R <sup>2</sup> =0.85<br>(驗證 R <sup>2</sup> =0.84~0.86)          |
|      | BTEX                   | 高雄林園臨海石化工業區 | 月平均           | Hsu and Wu* <i>et al.</i> <sup>[32]</sup><br>International Journal of Environmental Research and Public Health | 主模型 R <sup>2</sup> =0.61~0.79<br>(驗證 R <sup>2</sup> =0.50~0.77)     |
| 集成學習 | PM <sub>2.5</sub>      | 台灣本島        | 日平均 / 白天及晚上平均 | Wong and Wu* <i>et al.</i> <sup>[33]</sup><br>Science of the Total Environment                                 | 主模型 R <sup>2</sup> =0.88~0.90<br>(驗證結果與主模型 R <sup>2</sup> 差距少於 0.1) |
|      | O <sub>3</sub>         | 台灣本島        | 日平均 / 白天及晚上平均 | Babaan and Wu* <i>et al.</i> <sup>[34]</sup><br>Journal of Hazardous Materials                                 | 主模型 R <sup>2</sup> =0.88~0.91<br>(驗證結果與主模型 R <sup>2</sup> 差距少於 0.1) |
|      | 苯                      | 台灣本島        | 日平均           | Hsu and Wu* <i>et al.</i> <sup>[35]</sup><br>Chemosphere                                                       | 主模型 R <sup>2</sup> =0.92<br>(驗證 R <sup>2</sup> =0.44~0.91)          |

料，比較二大類統計—機械學習混合模型在空污模擬的成效，第一類是結合統計上時間序列分析常用的自迴歸模型（Autoregressive Integrated Moving Average, ARIMA）與類神經網路（Artificial Neural Network）以及支援向量機（Support Vector Machine, SVM）的混合模型；第二類則是以主成份迴歸（Principle Component Regression, PCR）為基礎，搭配決策樹（Decision Tree）與類別提升演算法（CatBoost）所發展的深度學習模型，結果指出，以類別提升演算法為基礎之混合建模方法具最佳的模型預測能力。

同樣的，筆者團隊亦已具有應用集成學習模型進行台灣空氣污染模擬之豐富成果。例如在 Hsu *et al.* [35] 的研究報告中結合本文所介紹的空間內插、土地利用迴歸、機械學習與集成學習演算法，以發展台灣本島苯（Benze）污染的集成混合空間模型（Ensemble Mixed Spatial Model），實務上係基於環保署全台十餘個光化測站過去十餘年每日的苯污染監測資料，除了遙測及 GIS 的土地排放源解釋變數外，首先亦導入克利金空間內插模擬的苯污染初步推估濃度，做為演算法解釋變數之一；其次如同先前機械學習方法一節所述，亦經由土地利用迴歸之逐步迴歸方式篩選重要變數後；利用 Python 中 AutoML 套件之隨機森林、梯度提升、XGboost、輕度梯度提升（Light Gradient Boosting Machine, LGBM）及 CatBoos 等五項演算法，分別進行模型超參數自動配適與模型擬合後；再次以上述演算法的空污模擬數據做為自變數，重新再進行一次模型擬合，以完成最後的集成混合空間模型，並據以估計苯污染在台灣本島的每日濃度空間分布狀況，相關推估成果如圖 3 之示意。本團隊所建模型會於研究期間的每一天均輸出一張全台空污模擬圖，並且其網格解析度為 50 m × 50 m，亦即當我們把台灣劃分成數百萬個 50 m × 50 m 大小的網格時，每個 50 m × 50 m 的格子都會有模型模擬之空污濃度模推估數值。

本團隊亦將相同方法學應用於推估細懸浮微粒 [33] 與臭氧 [34] 的日夜濃度分布。上述集成混合空間模型之準確度幾乎都到九成以上，並且經由多項模型驗證方法亦證明所建模型穩定可靠。最後利用本團隊發展的模型，以模擬台灣空氣污染的時空變化，雖然各別污染物受到其排放源及污染特性，使得其分布與熱區有些微不同，但整體來說，台灣空氣污染仍以南部最為嚴重、中部北部次之，東部相對來說空污對空氣品質的影響較




圖 3 應用集成混合空間模擬推估台灣本島苯污染之空間分布

小。上述研究成果可以模擬長期、大範圍且細緻網格解析度（50 m × 50 m）之空氣污染物空間變異。而在實務應用上，本團隊長期參與國科會及國家衛生研究院之研究計畫，以進行空污模擬研究，相關成果亦提供給國內許多大專院校及研究單位，以分析空污對國人健康之影響效應。同時，亦經由與國衛院的合作，進而得以將研究上的科學發現傳達給衛福部及環保署，做為有關單位在空污減量及空污法規調整等施政上之依據，對於國內空污防治政策之發展具實際影響力。

## 新興空間資訊技術於空氣污染之應用

除了上述介紹的 Geo-AI 建模技術的演進外，各種創新的空間資訊資料蒐集技術亦陸續被發展且實際應用於環境監測上，例如將環境感測器結合網路傳輸功能、使得監測所得的高時間解析度數據，可透過網路直接回傳至使用者之物聯網（Internet of Things, IoTs）；或者是更進一步，將物聯網感測器掛載於無人航空載具（Unmanned Aerial Vehicle, UAV）或無人機上，以進行更機動性的大範圍、三維空間之環境數據蒐集等技術，當前均已被蓬勃運用於氣候變遷及空氣污染監測與模擬實務上（表 4），相信未來這些新興技術的導入，必能使氣候與空污研究更上一層樓。



表 4 新興空間資訊技術於空氣污染應用實例文獻整理

| 研究文獻                        | 研究試區  | 空氣汙染物                                                          | 新興監測技術                                                          | 研究亮點                                                                                                            |
|-----------------------------|-------|----------------------------------------------------------------|-----------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------|
| Dhingra <i>et al.</i> [37]  | 印度    | 一氧化碳 (carbon monoxide, CO)、甲烷以及空氣品質指標 (air quality index, AQI) | IoT (Arduino Uno、MQ-7、MQ-2、MQ-135、Android、ESP8266 以及 Ubidots 等) | 開發 IoT-Mobair 應用軟體，可以即時得知 google 地圖上的污染濃度狀況，並且可預測未來的 AQI 變化。                                                    |
| Wonohardjo and Kusuma [38]  | 印尼雅加達 | 一氧化碳 (carbon monoxide, CO)                                     | IoT (Arduino Mega 2560、MQ-7、LCD、GSM 以及 GPS 等)                   | 在交通要道比較基於時間 (每 9 秒一筆) 以及距離為 (每 100 公尺一筆) 基礎的採樣方式，結果顯示，整體來看基於距離的採樣方式更符合此篇研究預期的成果。                                |
| Zheng <i>et al.</i> [39]    | 中國上海  | 懸浮微粒汙染物 (particulate matters, PM) 以及一氧化碳 (carbon monoxide, CO) | 無人機監測 (DJI Matrice M600)                                        | 探討都市交通要道空氣污染垂直以及水平濃度變化，提供後續減緩交通排放汙染物策略重要之參考。                                                                    |
| Pochwała <i>et al.</i> [40] | 波蘭    | 懸浮微粒汙染物                                                        | 無人機監測 (DJI Matrice 200)                                         | 透過較低成本空污感測器採集懸浮微粒汙染物樣本，發現 PM <sub>10</sub> 的最佳監測高度為 30 m，而粒徑較小的 PM <sub>1</sub> 以及 PM <sub>2.5</sub> 為 40~50 m。 |

## 結論及未來展望

氣候變遷的同時連帶亦造成許多環境負效應，空氣污染即是其中一項廣被重視的全球環境議題，Geo-AI 技術的發展與掘起為氣候變遷及空氣污染模擬研究提供了更多的可能性，結合各種地理空間與人工智慧之軟硬體技術，我們可以更準確、更快速、更有效的評估長時期大範圍居民的空氣污染暴露濃度，這樣的資訊對於未來在分析氣候變遷可能帶來的健康影響，將至為重要。

## 誌謝

筆者團隊承蒙行政院國家科學委員會、行政院環境保護署以及國家衛生研究院長期之研究經費補助，方得以發展文中介紹之空污模擬方法學，謹致謝忱。

## 參考文獻

- Pan, W.C., Wu, C.D., Chen, M.J., Huang, Y.T., Chen, C.J., Su, H.J., and Yang, H. I. (2016), Fine Particle Pollution, Alanine Transaminase, and Liver Cancer: A Taiwanese Prospective Cohort Study (REVEAL-HBV). JNCI: Journal of the National Cancer Institute, 108(3).
- Zhan, Y., Luo, Y., Deng, X., Zhang, K., Zhang, M., Grieneisen, M.L., and Di, B. (2018), Satellite-Based Estimates of Daily NO<sub>2</sub> Exposure in China Using Hybrid Random Forest and Spatiotemporal Kriging Model. Environmental Science & Technology, 52(7), 4180-4189.
- Rahman, M.H., Agarwal, S., Sharma, S., Suresh, R., Kundu, S., Vranckx, S., ... and Batra, S. (2022), High-Resolution Mapping of Air Pollution in Delhi Using Detrended Kriging Model. Environmental Modeling & Assessment, 1-16.
- Shukla, K., Kumar, P., Mann, G.S., and Khare, M. (2020), Mapping Spatial Distribution of Particulate Matter Using Kriging and Inverse Distance Weighting at Supersites of Megacity Delhi. Sustainable Cities and Society, 54, 101997.
- Briggs, D.J., Collins, S., Elliott, P., Fischer, P., Kingham, S., Lebre, E., ... and Van Der Veen, A. (1997), Mapping Urban Air Pollution Using GIS: A Regression-Based Approach. International Journal of Geographical Information Science, 11(7), 699-718.
- Beelen, R., Hoek, G., Vienneau, D., Eeftens, M., Dimakopoulou, K., Pedeli, X., ... and de Hoogh, K. (2013), Development of NO<sub>2</sub> and NO<sub>x</sub> Land Use Regression Models for Estimating Air Pollution Exposure in 36 Study Areas in Europe—The ESCAPE Project. Atmospheric Environment, 72, 10-23.
- Bertazzon, S., Johnson, M., Eccles, K., and Kaplan, G.G. (2015), Accounting for Spatial Effects in Land Use Regression for Urban Air Pollution Modeling. Spatial and spatio-temporal epidemiology, 14, 9-21.
- Dons, E., Van Poppel, M., Kochan, B., Wets, G., and Panis, L.I. (2013), Modeling Temporal and Spatial Variability of Traffic-Related Air Pollution: Hourly Land Use Regression Models for Black Carbon. Atmospheric Environment, 74, 237-246.
- Eeftens, M., Beelen, R., De Hoogh, K., Bellander, T., Cesaroni, G., Cirach, M., ... and Hoek, G. (2012), Development of Land Use Regression Models for PM<sub>2.5</sub>, PM<sub>2.5</sub> Absorbance, PM<sub>10</sub> and Pmcoarse in 20 European Study Areas; Results of The ESCAPE Project. Environmental science & technology, 46(20), 11195-11205.
- Kim, Y., and Guldman, J. M. (2015), Land-Use Regression Panel Models of NO<sub>2</sub> Concentrations in Seoul, Korea. Atmospheric Environment, 107, 364-373.
- Lee, J.H., Wu, C.F., Hoek, G., de Hoogh, K., Beelen, R., Brunekreef, B., and Chan, C.C. (2014), Land Use Regression Models for Estimating Individual NO<sub>x</sub> and NO<sub>2</sub> Exposures in a Metropolis with a High Density of Traffic Roads and Population. Science Of The Total Environment, 472, 1163-1171.
- Lee, J.H., Wu, C.F., Hoek, G., de Hoogh, K., Beelen, R., Brunekreef, B., and Chan, C.C. (2015), LUR Models for Particulate Matters in the Taipei Metropolis with High Densities of Roads and Strong Activities of Industry, Commerce and Construction. Science of the Total Environment, 514, 178-184.
- Liu, W., Li, X., Chen, Z., Zeng, G., León, T., Liang, J., ... and Lai, M. (2015), Land Use Regression Models Coupled with Meteorology to Model Spatial and Temporal Variability Of NO<sub>2</sub> and PM<sub>10</sub> in Changsha, China. Atmospheric Environment, 116, 272-280.

14. Liu, C., Henderson, B.H., Wang, D., Yang, X., and Peng, Z.R. (2016), A Land Use Regression Application into Assessing Spatial Variation of Intra-Urban Fine Particulate Matter ( $PM_{2.5}$ ) and Nitrogen Dioxide ( $NO_2$ ) Concentrations in City of Shanghai, China. *Science of the Total Environment*, 565, 607-615.
15. Tunno, B.J., Michanowicz, D.R., Shmool, J.L., Kinnee, E., Cambal, L., Tripathy, S., ... and Clougherty, J.E. (2016), Spatial Variation in Inversion-Focused Vs 24-H Integrated Samples of  $PM_{2.5}$  And Black Carbon Across Pittsburgh, PA. *Journal of Exposure Science & Environmental Epidemiology*, 26(4), 365-376.
16. Wang, R., Henderson, S.B., Sbihi, H., Allen, R.W., and Brauer, M. (2013), Temporal Stability of Land Use Regression Models for Traffic-Related Air Pollution. *Atmospheric Environment*, 64, 312-319.
17. Wang, M., Beelen, R., Bellander, T., Birk, M., Cesaroni, G., Cirach, M., ... and Brunekreef, B. (2014), Performance of Multi-City Land Use Regression Models for Nitrogen Dioxide and Fine Particles. *Environmental Health Perspectives*, 122(8), 843-849.
18. Wang, M., Gehring, U., Hoek, G., Keuken, M., Jonkers, S., Beelen, R., ... and Brunekreef, B. (2015), Air Pollution and Lung Function in Dutch Children: A Comparison of Exposure Estimates and Associations Based on Land Use Regression and Dispersion Exposure Modeling Approaches. *Environmental health perspectives*, 123(8), 847-851.
19. Weichenthal, S., Van Ryswyk, K., Goldstein, A., Shekarzifard, M., and Hatzopoulou, M. (2016), Characterizing the Spatial Distribution of Ambient Ultrafine Particles in Toronto, Canada: a Land Use Regression Model. *Environmental pollution*, 208, 241-248.
20. Wu, C.D., Chen, Y.C., Pan, W.C., Zeng, Y.T., Chen, M. J., Guo, Y.L., and Lung, S.C.C. (2017), Land-Use Regression with Long-Term Satellite-Based Greenness Index and Culture-Specific Sources to Model  $PM_{2.5}$  Spatial-Temporal Variability. *Environmental Pollution*, 224, 148-157.
21. Wu, C.D., Zeng, Y.T., and Lung, S.C.C. (2018), A Hybrid Kriging/Land-Use Regression Model to Assess  $PM_{2.5}$  Spatial-Temporal Variability. *Science of the Total Environment*, 645, 1456-1464.
22. Hsu, C.Y., Wu, C.D., Hsiao, Y.P., Chen, Y.C., Chen, M.J., and Lung, S.C.C. (2018), Developing Land-Use Regression Model to Estimate  $PM_{2.5}$ -bound Compound Concentrations. *Remote Sensing*, 10, 1971.
23. Hsu, C.Y., Wu, J.Y., Chen, M.J., Chen, Y.C., Pan, W.C., Lung, S.C.C., Guo, Y. L., and Wu, C. D. (2019), Asian Culturally-Specific Predictors in a Large-Scale Land Use Regression Model to Predict Spatial-Temporal Variability of Ozone Concentration. *International Journal of Environmental Research and Public Health*, 16, 1300.
24. Widya, L.K., Wu, C.D., Zeng, Y.T., Handayani, H.H., and Jaelani, L.M. (2019),  $PM_{2.5}$  Pollutant in Asia Metropolis Cities – A Comparison Between Indonesia and Taiwan. *International Journal of Environmental Research and Public Health*, 16, 4924.
25. Widya, L.K., Hsu, C.Y., Lee, H.Y., Jaelani, L.M., Lung, S.C.C., Su, H.J., and Wu, C.D. (2020). Comparison of Spatial Modelling Approaches on  $PM_{10}$  and  $NO_2$  Concentration Variations: A Case Study in Surabaya City, Indonesia. *International Journal of Environmental Research and Public Health*, 17(23), 8883.
26. Chen, T.H., Hsu, Y.C., Zeng, Y.T., Lung, S.C.C., Su, H.J., Chao, H.J., and Wu, C.D. (2020), A Hybrid Kriging/Land-use Regression Model with Asian Culture-Specific Sources to Assess  $NO_2$  Spatial-Temporal Variations. *Environmental Pollution*, 259, 113875.
27. Ren, X., Mi, Z., and Georgopoulos, P.G. (2020), Comparison of Machine Learning and Land Use Regression for Fine Scale Spatiotemporal Estimation of Ambient Air Pollution: Modeling Ozone Concentrations Across the Contiguous United States. *Environment International*, 142, 105827.
28. Wong, P.Y., Lee, H.Y., Chen, Y.C., Zeng Y.T., Chern, Y.R., Chen, N.T., Lung, S.C.C., Su, H.J., and Wu, C.D.. (2021a), Using a Land Use Regression Model with Machine Learning to Estimate Ground Level  $PM_{2.5}$ . *Environmental Pollution*, 277(15), 116846.
29. Wong, P.Y., Su, H.J., Lee, H.Y., Chen, Y.C., Hsiao, Y.P., Huang, J.W., ... and Spengler, J. D. (2021b). Using Land-Use Machine Learning Models to Estimate Daily  $NO_2$  Concentration Variations in Taiwan. *Journal of Cleaner Production*, 317, 128411.
30. Wong, P.Y., Hsu, C.Y., Wu, J.Y., Teo, T.A., Huang, J.W., Guo, H.R., ... and Spengler, J.D. (2021c). Incorporating Land-Use Regression into Machine Learning Algorithms in Estimating the Spatial-Temporal Variation of Carbon Monoxide in Taiwan. *Environmental Modelling & Software*, 139, 104996.
31. Wong, P.Y., Lee, H.Y., Chen, L.J., Chen, Y.C., Chen, N.T., Lung, S.C. C., ... and Spengler, J.D. (2022), An Alternative Approach for Estimating Large-Area Indoor  $PM_{2.5}$  Concentration—A Case Study of Schools. *Building and Environment*, 109249.
32. Hsu, C.Y., Zeng, Y.T., Chen, Y.C., Chen, M.J., Lung, S.C.C., and Wu, C.D. (2020), Kriging-based Land-use Regression Models that Use Machine Learning Algorithms to Estimate the Monthly BTEX Concentration. *International Journal of Environmental Research and Public Health*, 17, 6956.
33. Wong, P.Y., Su, H.J., Lung, S.C.C., and Wu, C.D. (2023), An Ensemble Mixed Spatial Model in Estimating Long-Term and Diurnal Variations of  $PM_{2.5}$  in Taiwan. *Science of The Total Environment*, 161336.
34. Babaan, J., Hsu, F.T., Wong, P.Y., Chen, P.C., Guo, Y.L., Lung, S.C.C., Chen, Y.C., and Wu, C.D. (2023), A Geo-AI -based Ensemble Mixed Spatial Prediction Model with Fine Spatial-Temporal Resolution for Estimating Daytime/Nighttime/Daily Average Ozone Concentrations Variations in Taiwan. *Journal of Hazardous Materials*, 446, 130749.
35. Hsu, C.Y., Xie, H.X., Wong, P.Y., Chen, Y.C., Chen, P.C., and Wu, C.D. (2022), A Mixed Spatial Prediction Model in Estimating Spatiotemporal Variations in Benzene Concentrations in Taiwan. *Chemosphere*, 301, 134758.
36. Shahriar, S.A., Kayes, I., Hasan, K., Hasan, M., Islam, R., Awang, N.R., Hamzah, Z., Rak, A.E., and Salam, M.A. (2021), Potential of Arima-Ann, Arima-SVM, Dt and Catboost for Atmospheric  $PM_{2.5}$  Forecasting in Bangladesh. *Atmosphere*, 12(1), 100.
37. Dhingra, S., Madda, R.B., Gandomi, A.H., Patan, R., and Daneshmand, M. (2019), Internet of Things Mobile–Air Pollution Monitoring System (IoT-Mobair). *IEEE Internet of Things Journal*, 6(3), 5577-5584.
38. Wonohardjo, E.P. and Kusuma, G.P. (2019), Air Pollution Mapping Using Mobile Sensor Based on Internet of Things. *Procedia Computer Science*, 157, 638-645.
39. Zheng, T., Li, B., Li, X.B., Wang, Z., Li, S.Y., and Peng, Z.R. (2021), Vertical and Horizontal Distributions of Traffic-Related Pollutants Beside an Urban Arterial Road Based on Unmanned Aerial Vehicle Observations. *Building and Environment*, 187, 107401.
40. Pochwa a, S., Anweiler, S., Deptu a, A., Gardecki, A., Lewandowski, P., and Przysię niuk, D. (2021), Optimization of Air Pollution Measurements with Unmanned Aerial Vehicle Low-Cost Sensor Based on an Inductive Knowledge Management Method. *Optimization and Engineering*, 22(3), 1783-1805. 