



# 應用長短期記憶模型於 建築空調需求預測

施冠群／冠呈能源環控有限公司研發部 經理

詹滢潔／國立臺灣大學土木工程學系營建工程與管理組 助理教授

依據經濟部能源局統計，108 年的用電量較過去十年成長了 11.7% [1]，而台灣除了用電需求增加外，環保意識也逐漸增加，新建電廠一般從規劃、環評、興建到運轉大約需要 8~10 年的時間，也因此讓台電的備轉容量率逐年降低，2016 年 5 月 31 日備轉容量率出現自 2006 年以來的最低紀錄 1.64%。這幾年經濟部努力開源，除了林口、大林新機組加入運轉，老舊機組如協和、興達及再生能源如太陽能和離岸風電等全力支援下，2019 年備轉容量率再次回復到 10% 以上。然而隨著產業發展、老舊電廠的退役及氣候變遷的影響，缺電問題依然會是未來需要面對的必要課題。

缺電問題除了透過新建電廠等開源的方法外，也可透過減少耗能的節流手法達到，而要討論節能，可以先探討能源使用的情況。除了生產所需的製程耗電外，空調耗電是一般商用建築中，耗能量最高的項目，佔建物全年總耗能的 40%~60% 以上 [2]，其次則為照明耗電，佔 30%~40%。為了減少空調系統在白天尖峰時期的運轉耗電，空調產業發展出一種可在夜間儲存冷卻能量，白天再釋放的系統，稱為儲冷空調系統。但儲冷空調系統控制策略複雜，管理人員需具備較高的管理技術水平才能妥善操作維運，且早期儲冷空調系統因採用製造不良之儲冰設備或因儲冷系統之設計不良，儲冷空調系統在多年前百花齊放後即銷聲匿跡。但在今日面臨可能缺電的環境下，利用儲冷空調系統來轉移電力尖峰用電至離峰時段，可以減輕新建電廠的壓力，並提高電廠之運轉效益，也可以用來改善電力尖峰時段，空調冰水機之運轉效益與效率 [3]。

一般而言，為了將大型建築的空調系統維持較佳的運轉效益與效率，會建立中央監控系統協助管理人員監看及控制空調系統設備。對建築物的管理人員而言，若能得知空調系統的負載預測值及耗電預測值，則能在用電契約容量與人員舒適度取得最佳的運轉設定數值 [4]。本研究採用深度學習的方式建立空調需求的預測模型，利用深度學習的複雜性及自適性提供更準確的預測值，期望找出適合建築空調需求預測的輸入參數及深度學習的模型，提升預測的準確度及降低建立空調需求預測模型的成本。

## 研究方法

本研究將對空調預測的輸入參數、深度學習的模型比較及模型預測等方面的相關文獻進行回顧，再總結並規劃本研究架構。

陳俊廷 [5] 提出運用 ASHRAE 第 14 號準則之相關變數（冰水出水溫度、冷卻水進水溫度及製冷量）並輸入 1~3 個月的短期量測數據回歸冰水主機性能方程式，並透過粒子族群演算法求得修正公式的最佳化係數解。實驗結果顯示，冰水主機性能係數（COP）及耗

能誤差要修正到 10% 以內最少要 115.17 筆數據、如要修正到 5% 以內則需要 161.15 筆數據。

蔣星宇 [6] 運用商業數學軟體 MATLAB 和建築模擬軟體 EnergyPlus 開發了一套自動化模型預測控制系統。系統以降低冷卻負載和轉移尖峰用電為切入點採用三種控制策略，分別是自然通風、空調預冷和儲冰槽儲冰。系統採用了天氣預報資料，通過基因演算法結合 EnergyPlus 模擬以預測電費及求解最佳化的控制策略。研究結果，電費節約幅度大約為 29%~33%，但會受到預測天氣與實際天氣之間的誤差而產生不確定性。

Cheng Fan<sup>[7]</sup>提到建築物運轉期間的耗電佔生命週期總能耗的 80%~90%，若對各系統進行適當的控制或及時的故障檢測可以節省大約 20% 的能耗。Cheng Fan 提到建築能源預測分為短期（小於一週）、中期（一週至一年）和長期（超過一年），實驗結果顯示，LSTM 及 GRU 都能有很好的表現，但 GRU 似乎是成本效益更好的選擇。

陳俊廷的研究指出模型誤差要修正到 5% 以內需要 161.15 筆數據，Cheng Fan 證明了使用 LSTM 及 GRU 作為空調預測模型有更好的效果，蔣星宇的預測控制系統結合了天氣預報資料。綜合上述研究成果，本研究預期採用多元複迴歸分析、ANN（類神經網路）、LSTM 及 GRU 建立模型，並結合不同調整參數的設置與天氣預報資料產出 48 小時的短期預測結果後比較其準確度，找出適合的模型及調整參數。

本研究的研究流程分為三個階段，第一階段為收集案場資料、第二階段為資料整理階段、第三階段為資料分析及比較階段。

收集案場資料階段，為了確保收集到的資料具有可信度，必須先使用高精度的儀器對案場的感測器進行對校，之後再從監控系統匯出歷史資料。

資料整理階段，將監控系統匯出的資料整理成資料庫可匯入的格式，再將資料匯入資料庫中，使用資料庫的好處時，可快速將資料進行群組及統計，例如取得不同月份的每日逐時平均數值。

資料分析及比較階段，本研究建立了數種不同的深度學習模型進行測試，將資料庫匯出的資料透過 Python 執行運算，再觀察不同模型的運算結果，最後便可得到本研究的結論及後續的研究目標及改善建議。

## 實驗案場介紹

本研究以南港軟體園區二期（簡稱南軟二期）的監控資料作為訓練資料來源。該建築物位於北市南港區園區街 3 號，該建築物為地下 3 層地上 17 層，主要用途為商業辦公大樓，空調系統為全量儲冰系統，上班時間為 08:30~18:30，中午休息從十二點開始，休息時間約一個半小時，夜間有空調需求，需 24 小時維持空調供給。

## 資料收集及資料前處理

### 氣象資料收集及分析

本研究採用 Dark Sky 的台北市氣象預報資料。Dark Sky 是一個著明的全球氣候預測平台，且能透過 API 下載未來 48 小時，每小時的氣象預測數值，與中央氣象局每 3 小時的氣象預報相比，更適合本研究的預測模型使用。Dark Sky 的預測數值包含溫度、相對溼度、雲量、紫外線、風速等數值。本研究使用溫度及相對溼度做為預測模型的訓練資料使用。為了證明 Dark Sky 的氣象預報數值有一定的準確度，本研究收集了 2019 年 Dark Sky 天氣預報資料及中央氣象局台北市的台北測站觀測資料進行分析。將一整年的資料統計分析後，可以得到全年溫度預測的平均誤差 -3.95%，標準差為 5.27%，將全年誤差值四捨五入取整數，依誤差值範圍累計得到誤差區間累計值。統計的結果如圖 1 所示，預測的誤差並不會出現預測的時間離現在越遠，誤差越大的情況。

### 監控系統對校

由於訓練資料來自南軟二期監控系統的紀錄資料，故在收集資料前，必須先使用校正過的儀器進行量測比對，確定現場的感測器運作正常，才能取出資料進行分析。本次量測比對的執行時間為 108 年 11 月，專案執行到 108 年 12 月結束，故本次取出監控系統 109 年 1~12 月的紀錄資料進行分析。

### 監控系統資料收集及資料前處理

監控數據為二分鐘一筆資料，監控系統因系統維護需求，有資料缺失的現象，電力監控系統及空調監控系統缺失的資料皆不相同，故需並比對同一時間的




圖 1 溫度 48 小時預測誤差堆疊圖

氣像預報資料、電力監控系統及空調監控系統，清除有缺少資料的數據列，產出預測模型訓練用資料。

資料整理結果如下，原始數據量為 262,800 筆，統計後數據量 8,760 筆，清理後的數據量 7,946 筆，可用數據有 90.7%。

## 空調系統特性分析

取得資料並匯入到資料庫後，本研究分析南軟二期空調系統，比較外氣條件與空調需量的關係，以幫助了解數據集的特性。

如圖 2 及圖 3 所示，藉由分析空調負載與外氣條件在不同時間的關係，可以發現空調需求量在上下班時間與外氣條件呈現不同的散佈圖。

因此，訓練參數除了有每小時的逐時平均溫度、相對溼度及對應的小時外，還需包含平均與假日。另外，因考量都市建築物多為高蓄熱量與吸熱表面積大的材料，使得白天增加的溫度，到了晚上就藉由蓄熱材質釋放出來<sup>[8]</sup>，故訓練參數增加前 3 小時、前 6 小時、前 12 小時、前 18 小時、前 24 小時、前 36 小時、前 48 小時的外氣溫度平均值，再藉由特徵值選擇的方法，找出影響預測值最高的幾項特徵。

## 預測模型建置

本研究使用氣象預報及監控系統歷史數據整理原始資料，並透過特徵值選擇方法挑選重要的特徵值建立訓練資料，再將訓練資料丟入預測模型中進行訓




圖 2 外氣條件與空調需量散佈圖（平日 7 點~19 點）




圖 3 氣象條件及空調需量散佈圖（假日）

練。預測模型主要分為兩塊，一是多元複迴歸分析類型，二是類神經網路類型，訓練完的結果再針對訓練時間及預測值與實際值的均方根誤差進行比較。圖 4 顯示預測模型建置架構。

## 訓練資料模型介紹

### 多元複迴歸分析

多元複迴歸分析的分法主要有三種，分別是 OLS (Ordinary Least Squares)、Ridge Regression (以下簡稱 Ridge) 及 Lasso Regression (以下簡稱 Lasso)。

本研究使用 sklearn.linear\_model 的函式庫建立 OLS、Ridge 及 Lasso 模型，OLS 使用預設參數，Ridge 及 Lasso 則比較不同 lambda 的設定。

### ANN (Artificial Neural Network)

本研究使用 keras 函式庫的全連接層 (Dense) 建立 ANN 模型架構，激活函數 (Activation Functions) 使用 Relu (Rectified Linear Units)，優化函數 (Optimizer) 使用 Adam，損失函數 (loss function) 採用均方誤差 (MSE)。模型調整參數將比較 Dense units 數量、Dense layer 的數量，Learning Rate 的設定。

### LSTM (Long Short-Term Memory)

本研究使用 keras 函式庫 LSTM layer 建立模型，優化函數 (Optimizer) 使用 Adam，損失函數 (loss function) 採用均方誤差 (MSE)，並討論不同層數、輸入序列時數之間的影響，而輸入序列格式則如圖 5 所示。

### GRU (Gate Recurrent Unit)

本研究使用 keras 函式庫 GRU layer 建立模型，優化函數 (Optimizer) 使用 Adam，損失函數 (loss function) 採用均方誤差 (MSE)，並討論不同層數、輸入序列時數之間的影響，輸入序列格式則參考 LSTM。

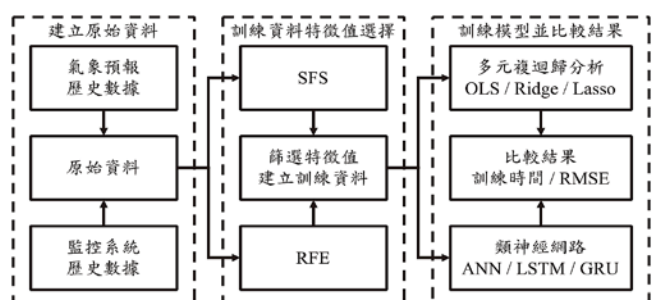


圖 4 預測模型建置架構

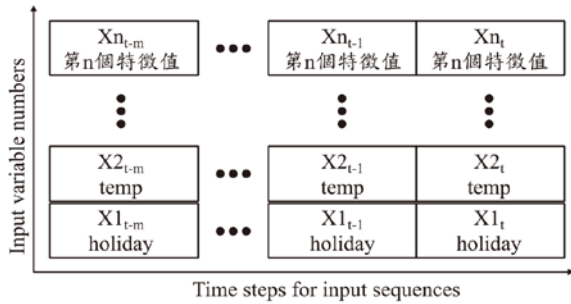


圖 5 LSTM 輸入序列格式

### 特徵值選擇

本研究在空調特性分析後，找到了共 11 特徵值，除了特徵值之間可能存在相關性太高的問題外，特徵值過多也容易造成 overfitting 的現場，因此剔除影響性較小的特徵值，能提高預測模型的準確度，也能減少訓練所需的時間。

本研究採用序列前向選擇 (SFS, Sequential Forward Selection) 及遞迴特徵消除 (RFE, Recursive Feature Elimination) 進行特徵值選擇。

依照 SFS 及 RFE 特徵值選擇的結果，可以找到彼此間的交集為 holiday、temp、temp\_b6avg、temp\_b12avg、temp\_b18avg、temp\_b24avg 及 temp\_b48avg。而因為訓練模型的特徵值一般會盡量避免特徵值彼此間有很高的相關性，因此每項特徵值進行相關性分析，分析結果圖 6 顯示從外氣溫度與每項前 n 小時的外氣溫度平均值有很高的相關性，因此在訓練預測模型時，會先嘗試將這些特徵值逐項輸入到訓練特徵值向量中，再比較訓練的結果。

在比較完特徵值後，將本案 2019 年的資料區分為訓練資料及測試資料，其中 1~8 月作為訓練資料，9~11 月作為測試資料，因 12 月份本案有進行空調改善工程，故不納入本研究的實驗資料中。而針對類神經網路類型的預測模型，則再將 1~8 月的訓練資料亂數排序後，再抽 10% 作為驗證資料。所有的資料都會經過標準化後再丟到模組進行訓練，確保各個特徵值有差不多的權重。

### 不同模型調整參數設定

依據特徵選擇的結果，將特徵矩陣分為 10 種組合，列表如表 1。

依據預測模型類型，定出不同的調整參數內容，調整參數規劃列表如表 2。

表 1 特徵矩陣組合列表

編號	特徵矩陣
組合 1	holiday、temp_b24avg
組合 2	holiday、temp、temp_b24avg
組合 3	holiday、temp、humidity
組合 4	holiday、temp、humidity、temp_b24avg
組合 5	holiday、temp、temp_b18avg
組合 6	holiday、temp、humidity、temp_b18avg
組合 7	holiday、temp、temp_b12avg
組合 8	holiday、temp、temp_b6avg
組合 9	holiday、temp、temp_b48avg
組合 10	holiday、temp、humidity、temp_b3avg、temp_b6avg、temp_b12avg、temp_b18avg、temp_b24avg、temp_b36avg、temp_b48avg

表 2 預測模型調整參數表

多元複迴歸分析		
OLS / Ridge / Lasso		
類神經模型		
ANN	Layers	3 / 4 / 5 / 6
	Units	8 / 16 / 32 / 64
	Learning Rate	/ 0.01 / 0.001 / 0.0001
LSTM / GRU	Timesteps	24 / 36 / 48
	Layers	2 / 3

### 運算時間及準確度比較

各模型結構訓練結果如下圖 7 至圖 10 所示，根據不同變因對預測效能之探討如下：

#### 多元複迴歸分析結果

多元複迴歸分析模型無論是 OLS、Ridge 或是 Lasso，在預測結果的表現上，都沒有顯著的變化，且 RMSE 數值皆超過 1000。將 9 月和 11 月其中一天上班日和假日的預測結果從圖 8 及圖 9 上可以看出，與實際值誤差相當大，且無法區分上班日和假日，因此可以明白多元複迴歸分析無法有效的應用在空調需量預測上。

#### 不同層數對於 ANN 模型之影響

實驗結果顯示預測品質隨著層數增加而有變好的趨勢，但比較特別的是，原本預期較多的層數應該有較高的訓練時間，結果因為層數較多的模型能快速收斂，反而得到較短的訓練時間。但層數增加到第五層後，預測品質就沒有顯著的提升了，故選擇五層作為最佳層數。

#### 不同 Unit 數量對於 ANN 模型之影響

實驗結果顯示，預測品質並無顯著提升，但訓練時間和不同層數造成的影響一樣，較高的 Unit 數能快

	holiday	h	humidity	temp_avg	temp_b3avg	temp_b6avg	temp_b12avg	temp_b18avg	temp_b24avg	temp_b36avg	temp_b48avg
holiday	1.00	0.00	-0.02	0.05	0.05	0.05	0.05	0.05	0.04	0.04	0.03
h	0.00	1.00	-0.23	0.15	0.22	0.24	0.14	-0.01	0.00	0.05	0.00
humidity	-0.02	-0.23	1.00	-0.53	-0.47	-0.38	-0.22	-0.18	-0.24	-0.22	-0.23
temp_avg	0.05	0.15	-0.53	1.00	0.97	0.92	0.85	0.84	0.88	0.86	0.86
temp_b3avg	0.05	0.22	-0.47	0.97	1.00	0.98	0.92	0.88	0.90	0.89	0.87
temp_b6avg	0.05	0.24	-0.38	0.92	0.98	1.00	0.96	0.91	0.91	0.92	0.89
temp_b12avg	0.05	0.14	-0.22	0.85	0.92	0.96	1.00	0.98	0.96	0.96	0.93
temp_b18avg	0.05	-0.01	-0.18	0.84	0.88	0.91	0.98	1.00	0.99	0.98	0.97
temp_b24avg	0.04	0.00	-0.24	0.88	0.90	0.91	0.96	0.99	1.00	0.99	0.98
temp_b36avg	0.04	0.05	-0.22	0.86	0.89	0.92	0.96	0.98	0.99	1.00	0.99
temp_b48avg	0.03	0.00	-0.23	0.86	0.87	0.89	0.93	0.97	0.98	0.99	1.00

圖 6 特徵值相關性分析矩陣圖




圖 7 各類型模型夏季上班日預測結果圖




圖 8 各類型模型冬季上班日預測結果圖




圖 9 各類型模型假日預測結果圖

速收斂，反而得到較短的訓練時間。但當 Unit 數量提升到 128 時，運算時間開始增加，因此選擇 64 個 Unit 數量作為最佳參數。

### 不同 learning Rate 對於 ANN 模型之影響

Learning Rate 變小會讓訓練時間增加及預測品質些微上升，但原本預設的 Learning Rate 數值 0.001 與其他的調整參數相比，有著不高的訓練時間及最佳的預測品質，因此選擇 Learning Rate 數值 0.001 作為最佳參數。




圖 10 各類型預測模型 RMSE 比較

### 不同 time steps 對於 LSTM 及 GRU 模型之影響

輸入時長為 24 小時之模型有最佳之效能。從訓練結果也可證實過多之資訊量，對預測品質並不會有幫助，反而是增加模型運算量。

### 不同層數對於 LSTM 及 GRU 模型之影響

層數增加，訓練品質並無顯著提升，但訓練時間卻大幅增加，因此使用單層 LSTM 或 GRU 模型有著最好的效果。

### ANN、LSTM 及 GRU 於特徵組合、訓練時間及預測品質上之差異

綜合以上結果，特徵組合 6 及 GRU 有著最佳的預測品質，這有可能是隨機性造成的影響，但整體而言，LSTM 及 GRU 的預測品質是優於 ANN，尤其是在天氣較冷或假日的表現，這有可能是因為 LSTM 可以將預測時間近期的資料作為計算依據的原因，所以能得到較高的準確度，若由此想法去調整 ANN 的模型架構也許能改善 ANN 的預測品質。但在運算時間上，GRU 並沒有比 LSTM 少，這可能是模型的複雜度還不足以表現出 GRU 在訓練時間上的優勢，不過兩者的訓練時間皆遠高於 ANN，因此改善 ANN 模型架構來取得更佳的預測品質將有其優勢。

## 研究成果及未來應用

本研究的主要目的為提供空調系統有效之需量預測模型，為此，本研究透過完整且謹慎之資料前處理找出了 10 項特徵組合作為訓練模型輸入參數，並比較傳統多元迴歸模型及類神經模型的差異，以此證明類神經模型較適合用於空調需量預測上。而在類神經模型的比較上，透過設計不同之網路結構及參數調整，進行最佳神經網路結構與參數之搜尋。本報告建議之空調需量預測模型在預測上有不錯之結果。關於本報告之結論與未來研究之建議，如下所述。

### 結論

1. 本研究建議之資料前處理方法，具其合理且有效性，可作為空調需量預測模型之輸入。
2. 本研究建議使用單層 GRU 模型作為空調需量預測模型之架構。
3. 本研究之模型可應用於不同月份之用电量預測，並

作為使用者於空調需量決策判斷之依據。

4. 對 ANN 而言，Layer 及 Unit 增加訓練時間不一定會增加，反而有可能因提早收斂而縮短。
5. ANN 在冬季及非假日的表現較差，因此有著比 LSTM 及 GRU 較差的預測品質。
6. LSTM 及 GRU 在不同神經層數、輸入時長的表現皆有完整之探討。

### 未來展望

1. ANN 的表現雖不如 LSTM 及 GRU，但 ANN 有著訓練時間短的優勢，可試著調整 ANN 模型架構，改善其訓練品質。
2. 預測模型依賴著氣象預報資料的準確性，但無論是氣象預報資料，或是建築物本身的運作上，皆存在很多不確定性，未來應在預測模型中加入預測數值的不確定性分析，藉由考量這些不確定性，可以改善預測模型的精確性及置信度，決策者可以基於量化的置信度選擇最佳控制策略。
3. 本研究完成了空調需量預測的研究，下一步就能研究儲冰系統儲冰及融冰控制策略，期望能有效的發揮儲冰系統效能，降低建築物尖峰負載需求。
4. 本研究可與過去相似外氣環境下之空調負載資料結合，進行未來長時間之空調需量預測，並可作為該案未來參與台電需量競價<sup>[9]</sup>之主模型架構。

### 參考文獻

1. 經濟部能源局，10-11 電力消費（歷年），能源統計月報（2020）
2. 內政部建築研究所，住宅與商業建築耗能總量調查研究（一），（1999）。
3. 台北市空調技師公會，缺電的解方 — 高性價比儲冷空調設計（2018）。
4. Tecuci, G., Building Intelligent Agents. 1998.
5. 陳俊廷，應用粒子族群演算法進行冰水主機性能分析之資料修正與限制，in 能源與冷凍空調工程系碩士班（2016），國立臺北科技大學：台北市。
6. 蔣星宇，實時空調能耗預測模擬與預測控制，in 土木工程學研究所（2018），國立臺灣大學：台北市，第 72 頁。
7. Fan, C., et al., Assessment of deep recurrent neural network-based strategies for short-term building energy predictions. Applied Energy, (2019), 236, pp. 700-710.
8. 陳冠廷，台灣中小型都市熱島效應之觀測解析，in 建築學系（2000），國立成功大學：台南市，第 93 頁。
9. 台電需量競價平台，Retrieved from <https://dbp.taipower-ami.com.tw/>

