

基於聲音特徵訊號以機械學習進行風力發電機葉片損傷檢測

本研究開發基於聲學的結構感測與即時監測技術，利用機器學習演算葉片聲音訊號統計特徵的變化來偵測風力發電機葉片表面的損傷。在風機不停機的狀況下，擷取風機運轉的葉片氣動聲音訊號，以短時傅立葉轉換對風機葉片轉動週期性的音訊進行時頻分析，由脈衝訊號的頻譜質心以及對應的三個葉片頻譜質心的變異為識別特徵進行機器學習，建立高斯混和分類模型。經測試結果顯示，此方法的準確度可達到 98 %。此外，從可視化的的高斯混和分類模型中，可以觀察葉片進入損傷狀態的趨勢，提早進行維修保養，避免葉片損壞，維持風機的穩定運轉。

■ 郭淑芬、鄭泗東

關鍵詞：風機葉片、短時傅立葉轉換、頻譜質心、機器學習、高斯混和模型

一、研究緣起

由於人類面臨日益嚴重的能源危機以及全球暖化的環境問題，因此推廣再生能源的利用，改善能源結構，降低二氧化碳的排放，儼然已是全球的議題。台灣地理位置四周環海，風況非常適合發展風力發電，因此在全球風機技術日益成熟且快速成長下，以及政府積極推動潔淨的再生能源，風機的建置也從陸域推展到離岸。隨著風機設置容量的增加，風機故障率也隨之提高，而一般風機設置的區域，環境條件惡劣，風能的來源雖然充足，但風速及風向的變化會在風機運行時產生交變的負荷，作用在風力發電機組上，可能損壞機組部件，風機葉片也容易因複雜和不規則的負載而損傷 (Chou et al., 2013)，導致災難性的損壞，甚至倒塌，對風場現場工作人員的生命造成威脅，另一方面也對電力的穩定性產生極大的影響。為避免風機機組產生故障停機，台電公司目前除

了設置有風機運轉監控中心進行遠端監控，尤其風機葉片 (Wind turbine blade) 的造價占了整個機組約 20 % (Liu et al., 2015)，維護成本相當高，為避免龐大的維修費用，也會定期進行現場巡檢，由有經驗的巡檢人員以耳朵的聽覺感受，或者停機目測檢視葉片受損的狀況，進行維護保養，保持風機良好的運轉，維持穩定的發電。


二、研究目的

本研究利用聲學麥克風感知風機葉片運轉狀態的氣動噪音，在不影響風機運轉的狀況下，收集風機葉片正常與損傷的聲音訊號，藉由短時傅立葉轉換 (Short-Time Fourier Transform, STFT) (Peeters, 2004)，分析葉片運轉隨時間的變化，並對聲音訊號進行預處理，以濾波、移動平均等方式提高訊噪比，獲得風機葉片接近感測器時的特徵訊號，包括音壓位準 (Sound pressure level)、

頻譜質心 (Spectral centroid) 以及頻譜分散度 (Spectral spread) 等參數，分析風機葉片轉動約兩個周期時間的各項特徵參數的分布，以二維的高斯混和模型 (Gaussian Mixture Model, GMM) (Reynolds, 2009) 進行風機葉片正常與損傷的分類訓練，並由可視化的分類模型，判斷葉片的損傷程度，作為即時監控及故障分析，解決人耳聽覺感受不同的缺點，達到人工智慧的目的，減少維修成本和停機時間，降低非預期性損壞所造成的龐大損失，維持風機的穩定運轉。

研究方法

研究方法的流程架構如圖一，是在風機運轉的狀況下，利用非接觸式的聲學麥克風感知風機葉片運轉狀態的氣動噪音，進行聲音訊號的蒐集，經由聲音訊號預處理、特徵訊號分析，以及資料集的擴增，將無標記的資料集透過機器學習 (Machine learning) (Mahesh, 2020) 訓練建立可視化的高斯混和分類模型，再由賦予標記的聲音訊號驗證模型的準確度，最後藉由未經過訓練的特徵資料集進行模型的測試，評估模型的預測結果。



圖一 研究方法流程架構

一、聲音訊號收集

本研究量測的風機是位於彰化線西鄉的彰濱工業區內，共有 31 座丹麥 Vestas 公司製的 V80/2000 風機 (Vestas, 2019)，額定功率為 2 MW，機輪鼓的高度為 67 m，葉片數目為 3 片，轉子直徑為 80 m，啟動風速為 4 m/s，是風機產生電力所需最低的風速，額定風速為 15 m/s，為風機產生額定功率 2 MW 所需的風速，截止風速為 25 m/s，則是為了避免風機轉速過快而造成機組故障的最高運轉風速，在運轉的條件下轉子最低轉速為 9 轉 / 分鐘 (6.67 s / 轉)，轉子最高轉速為 19 轉 / 分鐘 (3.16 s / 轉)。

通常聲音的傳播會因為與音源距離的增加，聲壓會逐漸降低，若傳播路徑有阻礙時，聲壓也會受到影響，為了提高訊噪比，選擇於距離風機較近的機艙下的地面進行風機葉片運轉聲音的收集。以聲音感測器在風機機艙正下方離地面高 80 cm，距風機塔柱表面 4 m 處 (如圖二)，擷取風機運轉時的聲音訊號，包括葉片正常及損傷風機的運轉聲音。當風機葉片轉動與聲音感測器距離越接近時，音量越大，訊噪比提高，風機三葉片的氣動噪音將呈現週期性的脈衝訊號，每個脈衝訊號對應一個葉片的氣動噪音，三個脈衝訊號構成一個完整風機葉片旋轉一圈的周期。




圖二 風機葉片轉動聲音的量測位置

二、聲音訊號預處理

以錄音的形式收集風機轉動時的聲音訊號，音訊規格為 WAVE 格式，取樣頻率為 48 kHz，由原始訊號（如圖三 (a)）很難分辨風機轉動時的脈衝聲音，與實際在現場人耳聽覺可清晰地分辨風機葉片轉動接近及遠離


時的脈衝聲音不同，因此在原始訊號中加上符合人耳聽覺感受的 A 特性頻率加權 (IEC 61672-1, 2013) (如圖三 (b))，獲得 A 特性頻率加權訊號 (如圖三 (c))，則可較清楚分辨葉片轉動的脈衝週期。




圖三 風機運轉聲音的 A 特性頻率加權處理

因為實際量測葉片運轉的聲音訊號，其具有非平穩性，因此將訊號透過短時傅立葉轉換，進行時頻分析，正常風機葉片的脈衝時頻譜震幅較小，10 kHz 以上高頻訊號較

少，如圖四 (a)；圖四 (b) 顯示風機葉片有損傷的脈衝訊號時頻譜震幅較大，頻率分布的較廣，高頻訊號較多。



(a) 正常風機葉片的脈衝時頻譜



(b) 風機葉片損傷的脈衝時頻譜

圖四 實際量測葉片運轉聲音訊號的短時傅立葉轉換時頻圖

三、聲音特徵訊號分析

根據 V80/2000 風機規格顯示轉子每轉一圈約 3.16 s 至 6.67 s，為確保資料的可信度，採用風機葉片轉動 10 s (約風機轉動二個周期的時間) 的聲音訊號，由風機運轉狀況下正常與損傷葉片的聲音訊號時頻圖中顯示聲音的特徵除了振幅 (音壓的大小)，還有頻率的分布，因此從時頻圖中提取音壓位準、頻譜質心以及頻譜分散度做為特徵訊號，提取的特徵訊號隨時間的變化趨勢圖 (如圖五) 中顯示在風機葉片有損傷的狀態下，各特徵訊號的峰值會偏高，且變異較大，因此採用特徵訊號峰值的平均值以及標準差作為機器學習的訓練資料集。

(一) 音壓位準

音壓是聲音在空氣中傳播時，由振動所產生的壓力變化，由於空氣粒子的疏密程度會隨聲波而改變，因此聲波是一種縱波，又

稱疏密波，音壓的單位為 Pascal。在進行聲音訊號的擷取是利用麥克風將擷取的音壓轉換為電壓訊號，透過麥克風的靈敏度以及擷取的電壓，可以依式 (1) 計算音壓值。一般人耳聽覺對於聲音的感受，基於統計評估最小的可聽音壓為 20 μPa ，而使人耳感覺到痛的音壓約為 100 Pa，若以音壓來度量聲音的大小，最大與最小音壓相差約 500 萬倍，不論在計算及表示上都相當不便。因此目前常用音壓位準來表示聲音的大小，其計算如式 (2)。


$$\text{Sound level [Pa]} = \frac{V_{rms}}{S} \quad (1)$$

V_{rms} : 擷取的電壓訊號, V

S : 麥克風靈敏度, mV/Pa

$$\text{Sound level [dB]} = 20 \log \frac{V_{rms} / S}{P_o} \quad (2)$$

P_o : 人耳可聽的最小音壓 (20 μPa)



圖五 聲音特徵訊號隨時間的變化，損傷葉片特徵訊號的頻率值會偏高，且變異較大

(二) 頻譜質心

頻譜質心是描述聲音屬性的一個重要的物理參數，是聲音訊號頻率成分的重心，包含頻率與能量分布的訊息，其計算如式 (3) 是將頻譜每個頻帶的能量乘以頻率，再除以頻譜總能量。

$$\text{Spectral centroid [Hz]} = \frac{\sum_{i=1}^n f_i P_i^2}{\sum_{i=1}^n P_i^2} \quad (3)$$

P_i : 音壓, Pa

f_i : 頻率, Hz

(三) 頻譜分散度

頻譜分散度則是描述頻率在頻譜質心的分布，通常與訊號的帶寬有關。當聲音訊號為寬頻時具有較大的頻譜分散度，而聲音

訊號有孤立峰值時，頻譜分散度則較小，其計算如式 (4) 是將頻譜每個頻帶與頻譜質心的差值平方乘以頻帶能量，再除以頻譜總能量。

$$\text{Spectral spread [Hz]} = \sqrt{\frac{\sum_{i=1}^n (f_i - SC)^2 P_i^2}{\sum_{i=1}^n P_i^2}} \quad (4)$$

四、機器學習模型訓練與驗證

模型的訓練及驗證資料集採用 170 筆損傷葉片及 210 筆正常葉片以 0.45 : 0.55 的比例資料進行機器學習，將所有提取的聲音特徵資料，先以無標記的特徵資料進行 GMM 模型的訓練，再將特徵資料賦予標記進行模型驗證，評估每個模型的性能，建立最佳的


GMM 分類模型。由於分析的特徵資料中，其不同的變數有不同的數值範圍，會因為變數之間尺度的不同，影響分析的結果，因此採用 Z-score 將原始資料標準化後，再進行分析比較。經資料標準化結果之數據分布並不會改變資料的原始分布，但各變數之間的尺度相近，使變數間具有可比較性，不會因為尺度的大小影響變數之間的貢獻度，使機器學習模型表現結果趨於穩定。

機器學習後衡量模型的效能，則是透過混淆矩陣 (Confusion Matrix) (Heydarian et al., 2022) 評估模型的分類效果，混淆矩陣是一個 2×2 的矩陣，將樣本的實際與預測結果區分為幾類進行比較，依據混淆矩陣中各參數可計算多種不同的評估指標，例如準確率 (Accuracy)、精確率 (Precision)、召回率 (Recall) 以及 F1 score，本研究綜合考慮了精確度和召回率，以 F1 score 評估模型的準確性。

GMM 模型訓練及驗證結果如圖六所示，當以每二個由無標記的特徵資料建立的

GMM 分類模型，經由人工判讀賦予標記的特徵資料進行模型性能的驗證，驗證結果以 F1-score 評估模型性能達 99 % 以上的有當輸入特徵為音壓位準平均值 (a)、頻譜質心標準差 (d)，以及輸入特徵為頻譜質心平均值 (c)、頻譜質心標準差 (d)，訓練模型經評估結果 F1-score 可達 99.7 %。

為了解多個輸入特徵訓練資料對模型建立的影響，因此以每三個無標記的特徵為輸入資料集作為機器學習的訓練資料集進行模型的建立，藉由主成分分析 (Principal Component Analysis, PCA) (Smith, 2002) 將三維資料降至二維，再進行模型訓練，訓練結果以附有標記的資料進行驗證，F1-score 達 99 % 以上的有當輸入特徵為音壓位準平均值 (a)、頻譜質心平均值 (c)，頻譜質心標準差 (d) 所建立的模型，F1-score 達 99.7 %；輸入特徵為頻譜質心平均值 (c)、頻譜質心標準差 (d)、頻譜分散度平均值 (e) 所建立的模型，F1-score 為 99.1 %。




圖六 GMM 模型訓練與驗證結果，以 F1 score 評估模型的準確性

結果與討論

最後為確認 GMM 模型預測的準確性，透過沒經過訓練的資料集，包括損傷葉片 102 筆及正常葉片 126 筆，作為輸入資料集進行模型的測試。由模型驗證結果以 F1-Score 評估達 99 % 以上的二維 GMM 模型中，以沒經過訓練的資料集進行模型的測試，討論四種驗證結果達 99 % 以上之 GMM 模型，藉由模型驗證及測試結果的表現，分析可能造成的影響，並獲得最佳的輸入特徵資料。

一、兩個特徵資料 (SL_mean、SC_std) 建立的 GMM 模型

將音壓位準平均值、頻譜質心標準差兩個無標記的特徵資料經 GMM 訓練建立的模型，當將訓練資料集賦予標記進行驗證時，驗證結果以混淆矩陣評估 F1-score 為 99.7 %；當以沒經過訓練的資料集，輸入建立的 GMM 模型中，F1-score 從 99.7 % 下降至 78.6 %，由圖七之 GMM 模型、模型驗證及測試結果的資料分佈顯示，GMM 模型可能由於訓練時過度的擬合，反而降低預測能力。




圖七 兩個特徵資料 (SL_mean、SC_std) 建立之 GMM 模型

二、兩個特徵資料 (SC_mean、SC_std) 建立的 GMM 模型

將無標記的頻譜質心平均值、頻譜質心標準差輸入特徵資料所訓練建立的 GMM 模型，以具有標記的輸入特徵資料進行驗證，驗證結果可知由不同的評估指標評估結果都

可達到 99 % 以上的準確率。當以沒經過訓練的輸入特徵資料集進行測試時，F1-score 仍可達到 98 % 的準確度，如圖八顯示由頻譜質心平均值及標準差兩個特徵訊號建立風機葉片損傷偵測的 GMM 模型，其穩定性相當高。




圖八 兩個特徵資料 (SC_mean、SC_std) 建立之 GMM 模型

三、三個特徵資料 (SL_mean、SC_mean、SC_std) 建立的 GMM 模型

將音壓位準平均值、頻譜質心平均值、頻譜質心標準差三個無標記的特徵資料訓練建立之 GMM 模型，當將訓練資料集賦予標記進行驗證時，預測結果 F1-score 可為 99.7 %；但當以沒經過訓練的資

料集，輸入建立的 GMM 模型中，F1-score 從 99.7 % 下降至 90.9 %。由圖九之 GMM 模型、模型驗證及測試結果的資料分佈顯示，多個特徵資料進行機器學習訓練，可以得到不錯的預測結果，但建立的 GMM 模型可能由於訓練時過度的擬合，反而降低預測能力的穩定性。




圖九 三個特徵資料 (SL_mean、SC_mean、SC_std) 建立之 GMM 模型

四、三個特徵資料 (SC_mean、SC_std、SS_std) 建立的 GMM 模型

另外由驗證結果 F1-Score 評估達 99 % 以上的特徵資料，還有頻譜質心平均值、頻譜質心標準差以及頻譜分散度平均值三個無標記的特徵資料訓練建立之 GMM 模型，將無標記的輸入特徵資料所訓練建立的 GMM

模型，以具有標記的輸入特徵資料驗證結果，F1-score 可達到 99.1 % 的準確率。但當以沒經過訓練的資料集，輸入建立的 GMM 模型中，F1-score 從 99.1 % 下降至 96 %，評估結果顯示當增加不適合的特徵資料，對機器學習訓練預測結果的提高有限。



圖十 三個特徵資料 (SC_mean、SC_std、SS_std) 建立之 GMM 模型

以上結果顯示驗證結果達 F1-Score 99 % 以上建立之 GMM 模型中，當以沒經過訓練的輸入特徵資料集進行測試時，除了採用頻譜質心平均值、頻譜質心標準差為特徵資料輸入時，仍可達到 98 % 以上的準確度，其餘特徵資料均有較大的下降趨勢，尤其當採用音壓位準平均值作為輸入特徵資料時，測試結果 F1-score 下降比例偏高。

因此在進行機器學習時，若採用多個特徵資料雖然在模型訓練時，可以得到不錯的預測結果，但可能由於訓練時過度的擬合，當以沒經過訓練的資料集進行測試時，反而降低了預測能力的準確性；另外當採用不適當的特徵資料，也會降低測試結果的準確性。本研究顯示頻譜質心平均值、頻譜質心標準差為特徵資料建立風機葉片損傷偵測的 GMM 模型，其穩定性相對高。

結論

本研究採用風機運轉的氣動聲音訊號，以短時傅立葉轉換對風機葉片轉動週期性的脈衝訊號進行分析，由脈衝訊號的頻譜質心以及對應的三個葉片頻譜質心的變異為特徵訊號進行分類，建立之高斯混和模型，以 F1-score 評估模型性能，可達到 98 % 以上的準確度。

由高斯混和模型訓練結果顯示，採用多個特徵資料進行機器學習訓練，可以得到不錯的預測結果，但可能由於訓練時過度的擬合，反而降低了預測能力的穩定性，因此當以新的沒訓練過的資料進行測試評估時，模型的準確率就下降了。本研究顯示頻譜質心平均值、頻譜質心標準差為特徵資料建立風機葉片損傷偵測的 GMM 模型，其穩定性相對高，並由可視化的分類模型中可以得知葉片將進入損傷狀態的趨勢，提早進行維修保養，避免葉片損壞對風機運轉的影響，確保風機的穩定運轉。

由於風機葉片損傷的資料取得不易，本研究中獲得風機葉片損傷的氣動噪音訊號有限，可能無法涵蓋所有的損傷的聲音訊號，未來期望能對更多的風機實施這項研究的結果，另外也可透過遠端監控的方式，即時獲得風機葉片運轉時的氣動噪音資料，並將其輸入到二維 GMM 模型中的特定位置，透過這種方式可以顯示風機葉片損傷狀態的趨勢，並及時採取必要的維修措施，避免葉片發生不預期的損傷，造成龐大的經濟損失。

參考文獻

1. Chou, J. S., Chiu, C. K., Huang, I. K., & Chi, K. N. (2013). Failure analysis of wind turbine blade under critical wind loads. *Engineering Failure Analysis*, 27, 99-118.
2. Heydarian, M., Doyle, T. E., & Samavi, R. (2022). MLCM: Multi-label confusion matrix. *IEEE Access*, 10, 19083-19095.
3. IEC 61672-1 (2013), *Electroacoustics – Sound level meters – Specifications*.
4. Liu, W. Y., Tang, B. P., Han, J. G., Lu, X. N., Hu, N. N., & He, Z. Z. (2015). The structure healthy condition monitoring and fault diagnosis methods in wind turbines: A review. *Renewable and Sustainable Energy Reviews*, 44, 466-472.
5. Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], 9, 381-386.
6. Peeters, G. (2004). A large set of audio features for sound description (similarity and classification) in the CUIDADO project. *CUIDADO 1st Project Report*, 54(0), 1-25.
7. Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of biometrics*, 741(659-663).
8. Smith, L. I. (2002). A tutorial on principal components analysis. Cornell University, USA.
9. Vestas (2019), 2 MW Platform.

作者簡介

郭淑芬 / 國立陽明交通大學 精密與自動化工程

鄭泗東 / 國立陽明交通大學 精密與自動化工程 / 指導老師

