

# 運用 AI 人工智慧於製造設備健康度預測和管理之研究與發展

## A Survey on Applying Artificial Intelligence in Manufacturing Device Prognostic Health Management

何承遠、王家恩、楊永聖

亞洲大學 資訊工程學系

Cheng-Yuan Ho, Jia-En Wang, Yong-Sheng Yang

Dept. of Computer Science and Information Engineering, Asia University

Email: tommyho@asia.edu.tw, 109121017@gm.asia.edu.tw, 109121014@gm.asia.edu.tw

### 摘要

近年來，人工智慧(Artificial Intelligence, AI)技術越來越成熟，許多人都將 AI 技術運用在製造業上，透過深度學習、機器學習預測產品良率與產線設備健康度來改善產品的品質與產線的效率。這是因為在傳統產業上，關於產線設備的汰換通常不是等故障發生就是透過產線人員的經驗來預估何時應汰換和經驗傳承，但人工預測有極大可能會與實際情形偏差太多；再加上，每位人員的經驗都不盡相同，傳承上不僅無法轉換成統一標準且多少會有所偏差。在本篇文章，我們針對典型製造業研讀七篇相關文獻，調查人工智慧如何運用於製造設備健康度預測和管理，來幫助產線提前預知機台機械目前可能的情形，降低不必要的維護成本以及提升機具與人員的安全。同時，從這七篇文獻觀察到大部分方案是採用影像處理或把問題轉化成影像維度來解決問題。未來我們將試著把此文章的發現用於其他製造產業設備看是否可用以預測其健康度。

**關鍵字：**人工智慧、設備健康度預測和管理、XGBoost、隨機叢林、CNN

### 一、序論

在這個人工智慧(Artificial Intelligence, AI)大時代，許多產業都有重大的改變，尤其是在製造業方面，有了很大的突破：製造業結合 AI 衍生出工業 4.0(Industry 4.0)與智慧製造(Wisdom Manufacturing, WM)等概念，透過大數據分析(Big Data Analysis)、機器學習(Machine Learning, ML)與深度學習(Deep Learning, DL)預測產品良率、產線設備健康度來改善產品的品質與產線的效率。隨著 AI 技術的發展與成熟，甚至可以減少原料使用、降低污染和改善工作環境等。

在傳統產業上，關於設備與機具的健康度通常都是透過產線人員的經驗去預測和傳承。由經驗豐富的前輩教導新進人員在什麼樣的條件和情況下，設備大約還能再使用多久或是設備差不多該需要更換或維修，然而很多時候，產線人員的經驗會偏頗，發現時設備都已經屬於損壞跟故障的狀況，這

是因為產線上有很多影響因子，偶爾會有突發狀況造成。也因為設備與機具突然的損壞跟故障將造成產線生產延遲，嚴重時甚至會導致產品整批報銷，這對於製造業是一個嚴重損失。另外，產品良率也是透過產線人員的經驗判斷現在所生產的產品品質是否良好，無法事先根據材料、配方與製程參數預測目前產出的是否為良品與是否需要更改配方或是檢查機具。若機具與配方在中途出了狀況，產線人員也只能等產品生產出來才能判斷，無法達到即時的評估與預測。

在工業 4.0 時代中，許多製造業透過蒐集大量設備實時資料和相關資訊來達到健康度預測和健康度管理(Prognostic and Health Management, PHM) [8]。近幾年，健康度預測和健康度管理等議題越來越受重視，尤其機器學習和深度學習被大量使用並對所蒐集的產線資料做機具和設備健康度預測或健康度管理。準確的健康度管理不僅可以有效的監控機具健康狀況並即時進行維護，從而保護機具免受故障和資源浪費[6]，對產線生產有很大的幫助。

### 二、問題說明及其重要性

隨著工業的發展，許多工業領域對於健康度管理(PHM)以及剩餘使用壽命(Remaining useful life, RUL)的議題越來越受到關注，對於安全和效率的要求也提高了許多，特別對於停機時間及故障成本較高的組件或系統，預測和健康度管理旨在在設施或系統在發生故障之前的檢修維護，而檢修及維護的時間是透過歷史數據及經驗實時評估風險以及剩餘使用壽命(RUL)[10]，藉由預測健康度來達到系統保護以及人員的安全及不必要的資源損失[6]。

剩餘使用壽命(RUL)，就是設備在正常狀態下還能夠繼續使用的時間，估算 RUL 的方法在於使用的數據類型主要分為三種：(1)使用壽命數據、(2)運行至故障數據和(3)閾值數據。更進一步說明，(1)使用壽命數據意指機具運行到故障所用的時間；(2)運行至故障數據指的是相似機具運行到故障處的歷史數據；(3)閾值數據意指檢測故障所使用的狀態指示，可藉由這些資訊再搭配適當的演算法來達到理想的目標。

健康度管理(PHM)可以區分為三種診斷與預測：(1)模型的故障診斷與預測；(2)狀態信息的故障診斷與預測和(3)知識的故障診斷與預測。這三種

\* 本研究接受科技部編號：MOST 109-2221-E-468 -008 - MY3 研究計畫經費補助

狀態大致能一一對應到剩餘使用壽命(RUL)三種數據類型。圖一秀出剩餘使用壽命(RUL)和健康度管理(PHM)示意圖。




圖 1 剩餘使用壽命(RUL)三種數據類型和健康度管理(PHM)三種診斷與預測

### 三、製造設備健康度預測和管理之研究文獻整理

#### (一) 依使用情境分類

本文章主要研究之七篇文獻[1-7]，依使用情境分類，可分為如圖 2 三種。第一種是針對刀具磨損與磨耗之健康度管理剩餘壽命評估；第二種為輪軸滾輪健康度管理壽命評估；以及最後一種沖頭健康度管理及壽命評估。




圖 2 三種使用情境：刀具、輪軸和沖頭

#### (1) 刀具磨損與磨耗之健康度管理剩餘壽命評估

文獻[1]利用刀具 X、Y、Z 軸的震動做為其數據資料並搭配機器學習中不同演算法找出最適合用於預測 CNC 刀具的磨損以及透過預知磨損程度來提高工作的品質並防止機具的損壞。

文獻[3]透過時頻分析將刀具削力信號轉化為時頻圖像後，透過圖形辨識跟 CNN 方法來達成刀具磨損監控。

#### (2) 輪軸滾輪健康度管理壽命評估

文獻[5]以各種 RNN 和 LSTM 網路方法，如：RNN、Basic LSTM、Deep LSTM，進行機器健康監控並比較何種方法準確性較高。

文獻[6]基於雙卷積神經網路架構 (Double CNN) 將輪軸滾輪震動數據轉化為多個特徵圖來預測剩餘使用壽命。

文獻[7]希望能夠準確預測出軸承的健康度，因此藉由 CNN 結合 LSTM 的方法來當作預測軸承健康度的模型，預知

準確的健康度可減少對組件的損害。

#### (3) 沖頭健康度管理及壽命評估

文獻[2]利用板材厚度、板材周圍面積和沖頭周圍面積做為數據資料並使用多種方法來預測沖頭的使用壽命。除此之外還比較機器學習與神經網路的結果。

文獻[4]透過時序分析提取主軸電流資料為大量特徵值後，透過 CNN 和 BPNN 兩種方法預測沖頭的使用壽命。

#### (二) 依模型和演算法分類

根據文獻[1-7]所採用的預測模型和演算法可以分類為三種如圖 3 所示，第一種為運用多種演算法進行比較和觀察哪個最適合用於預測評估；第二種為使用單一演算法直接進行評估；和最後一種為使用混和演算法，藉由結合兩種或兩種以上演算法達到更好的預測結果。




圖 3 三種預測方法：多種、單一跟混和

#### (1) 多種演算法比較

文獻[1]利用刀具 X、Y、Z 軸的震動做為其數據資料，其中 80% 為訓練資料、20% 為測試資料，之後分別使用 SVM、RF 和 XGBoost 三種演算法執行訓練資料和測試資料。從其結果，文獻[1]的作者認為 RF > XGBOOST > SVM。

文獻[2]則是利用了 ANN、ANFIS 以及 ML 三種模型來做比較，其中 ML 更是結合了 XGBoost、SVM 還有 Linear Regression 三種預測演算法。以板材厚度、板材周圍面積和沖頭周圍面積做為數據資料，最終比較出來的結果 ML 所得到的預測結果比其他二者優越。

文獻[5]以 Regression models、MLP、RNN、Basic LSTM 和 Deep LSTM 等五種方法，進行單一數據集不同演算法演算來達成機器健康監控。從其結果，文獻[1]的作者認為 Deep LSTM 的效果最好。

#### (2) 單一演算法

文獻[3]將刀具削力信號轉換為時頻圖像，再從中提取 70% 資料進入單一 CNN 模型進行運算，就其論文顯示其準

確率高達 99.4%。

### (3) 混和演算法

文獻[4]提取主軸電流資料為大量特徵值後，做歸一化的處理，再從中提取 93%資料進入單一 CNN 模型進行運算。得到結果後再從中提取 80%資料進入單一 BPNN 模型進行第二次運算跟預測。

文獻[6]利用了兩個 CNN 做預測，先利用第一個 CNN 提取特徵，再透過第二個 CNN 進行預測。

文獻[7]利用了先利用 CNN 做運算以集提取特徵，再透過 LSTM 進行預測。並將兩者的結果與單獨 CNN 跟單獨 LSTM 做出的結果比較得到 CNN 合併 LSTM 的結果較佳。

## 四、結論與未來研究議題

根據文獻群[1-10]可以歸納出，健康管理 (PHM)及剩餘壽命評估(RUL)的方法可分類為兩種：第一種運用機器學習中的監督式學習，通過已知的輸入和輸出數據集的模型來推導最佳模型；和第二種透過深度學習中的人工神經網路以及捲積神經網路，利用空間共享權重和空間子採樣作為特徵提取器，並應用堆疊的捲積運算來逐步創建特徵的多層和層次結構，其中所使用的訓練資料幾乎都是震動感測器所蒐集的震動資料，少部分為製造過程資料。

在眾多製造業問題中，本文章未來研究議題將會是「肥料模具健康度分析」。在肥料的製造過程中先將原料進行第一次加溫加濕並將其切碎，然後攪拌完成再加入其他原料進行第二次重複的步驟直到配方完成，最後將攪拌完的配方倒入製粒機當中做製粒的處理。更進一步而言，製粒機中有一個製粒模具，模具中有兩個滾軸，模具會將肥料擠壓出模具，最後裝袋。擠壓肥料的模具在長時間的工作下會造成阻塞，導致肥料阻塞住模具的孔洞，若在阻塞的情況下持續擠壓肥料，會導致孔洞阻塞的情況愈發嚴重，最終可能導致整個模具破裂與模具破裂後的碎片參雜在肥料中，所以本文章希望能透過健康度分析預測，預測該模具目前健康度是否正常，需不需要提前清理或更換。因為，在一定程度上可以進行清理以延長模具的使用時間，但在遇到特定的配方或長時間使用下還是很容易造成模具的破損，導致肥料品質不佳。

未來預期利用現在已知的模具汰換確認損壞的時間往後推至下次汰換模具的時間，用這之間的數值當成 y 值，y 值指的是這筆資料最後的狀態，利用震動感測器的震動資料與製程資料分配應有的 y 值，將重要資料先整理出再放入機器學習模型進行健康度分類。

模型的選擇預計運用 XGBoost 與 RF 決策樹的特性，將溫度、濕度以及配方資料等 X 值進行分類，X 值指的是訓練目標的特徵值，另外利用 CNN

將震動感測資料做成圖表，用圖像辨識的方法看出時段震動差異性，再結合製程資料做更詳細的分類，利用這三種方法觀察哪個方法最有利模具健康度分類和觀察哪個模型所分類出的結果最貼近實際健康度。

## 參考文獻

- [1] S. Park, K. Lee, S. Sung and D. Park, "Prediction of the CNC Tool Wear Using the Machine Learning Technique," 2019 International Conference on Computational Science and Computational Intelligence (CSCI), Las Vegas, NV, USA, 2019, pp. 296-299, doi: 10.1109/CSCI49370.2019.00059.
- [2] S. Salunkhe, P. Vasarla, V. Naranje and D. M., "Prediction of Life of Compound Die Punch Using Machine Learning," 2019 International Conference on Computational Intelligence and Knowledge Economy (ICCIKE), Dubai, United Arab Emirates, 2019, pp. 646-649, doi: 10.1109/ICCIKE47802.2019.9004375.
- [3] H. Zheng and J. Lin, "A Deep Learning Approach for High Speed Machining Tool Wear Monitoring," 2019 3rd International Conference on Robotics and Automation Sciences (ICRAS), Wuhan, China, 2019, pp. 63-68, doi: 10.1109/ICRAS.2019.8809070.
- [4] G. Li, X. Yang, D. Chen, A. Song, Y. Fang and J. Zhou, "Tool Breakage Detection using Deep Learning," 2018 IEEE International Conference on Big Data, Cloud Computing, Data Science & Engineering (BCD), Yonago, 2018, pp. 37-42, doi: 10.1109/BCD2018.2018.00014.
- [5] R. Zhao, J. Wang, R. Yan and K. Mao, "Machine health monitoring with LSTM networks," 2016 10th International Conference on Sensing Technology (ICST), Nanjing, 2016, pp. 1-6, doi: 10.1109/ICSensT.2016.7796266.
- [6] B. Yang, R. Liu and E. Zio, "Remaining Useful Life Prediction Based on a Double-Convolutional Neural Network Architecture," in IEEE Transactions on Industrial Electronics, vol. 66, no. 12, pp. 9521-9530, Dec. 2019, doi: 10.1109/TIE.2019.2924605.
- [7] W. Du and Y. Wang, "Stacked Convolutional LSTM Models for Prognosis of Bearing Performance Degradation," 2019 Prognostics and System Health Management Conference (PHM-Qingdao), Qingdao, China, 2019, pp. 1-6, doi: 10.1109/PHM-Qingdao46334.2019.8943063.
- [8] J. Deutsch and D. He, "Using Deep Learning-Based Approach to Predict Remaining Useful Life of Rotating Components," in IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 48, no. 1, pp. 11-20, Jan. 2018, doi: 10.1109/TSMC.2017.2697842.
- [9] Y. Feng, L. Liu and J. Shu, "A Link Quality Prediction Method for Wireless Sensor Networks Based on XGBoost," in IEEE Access, vol. 7, pp. 155229-155241, 2019, doi:

10.1109/ACCESS.2019.2949612.

- [10] Z. Zhao, B. Liang, X. Wang and W. Lu, "Remaining useful life prediction of aircraft engine based on degradation pattern learning", *Rel. Eng. Syst. Safety*, vol. 164, pp. 74-83, 2017.