

——溫慧菱、郭俊良——

機器學習演算法建立船舶主機預兆式健康管理模型

提要

- 一、工業4.0的時代，以物聯網和智慧系統為基礎核心，預測技術與智慧演算法交織，對產品之主動維護產生積極的影響。
- 二、預兆式健康管理模型的最終目標是可靠地偵測異常及預測故障時間，以便系統自主地進行有效的維護計畫，透過優化的預測方法，以提升補保後勤作業。
- 三、本研究透過高效率機器學習演算法，以船舶主機預測性維護之異常偵測為例，可望顯著改進傳統維護方案，以供維保人員與決策者於裝備維護之決策參考。

關鍵詞：預兆式健康管理、預測性維護、異常偵測、機器學習演算法

圖片來源：美國國防部

壹、前言

德國領先進入工業4.0的時代，¹ 物聯網 (Internet of Things, IoT) 開啟製造創新時代，隨著裝備和系統中嵌入式的智慧集成，預測技術進一步與智慧演算法交織，運用於預測產品性能下降、自主管理並優化產品需求。² 工業4.0以IoT技術和智慧製造為基礎核心：生產系統的監控與即時性能數據的收集及共用，對改善主動維護產生積極的影響。預兆式健康管理 (Prognostics and Health Management, PHM) 是藉由精確監控來減除檢查和基於時間的維護，進行初期故障檢測和預測即將發生的故障，以支持系統生命週期的方法，³ 其最終的目標是可靠地預測系統故障時間，以便系統自主進行有效的維護

計畫。⁴ 自21世紀以來，PHM的發展反映在集成系統的應用中，提高故障診斷和預測的精度，也獲得西方軍事的高度關注、普及與應用，PHM成為飛機、輪船和軍艦領域不可缺少的系統，亦廣泛應用於發動機和傳動裝置。為降低機器與設施的高成本要求，可用性和可靠性是關注的焦點，如發生輕微故障時未及時實施維護或容錯控制，則對其它組件的附帶損害將帶來巨大損失。⁵ 現今技術的蓬勃發展，裝備隨之越益複雜，同時需要更高層次的品質與可靠性，因此PHM成為未來的發展趨勢，對提升裝備的維保能力十分重要，能掌握各武器裝備之完整戰力並可參考作為未來裝備汰除、重新設計與改良之用途，以持續部隊戰力之有效。⁶

船舶的機動性是安全航行的重要保證，

- 1 Kagermann, H., Helbig, J., Hellinger, A., & Wahlster, W. (2013). Recommendations for implementing the strategic initiative INDUSTRIE 4.0: Securing the future of German manufacturing industry; final report of the Industrie 4.0 Working Group: Forschungsunion.
- 2 Lee, J., Kao, H.-A., & Yang, S., "Service innovation and smart analytics for industry 4.0 and big data environment," *Procedia CIRP*, Vol. 16 (2014), p. 3-8.
- 3 Kalgren, P. W., Byington, C. S., Roemer, M. J., & Watson, M. J. (2006). Defining PHM, A Lexical Evolution of Maintenance and Logistics. Paper presented at the 2006 IEEE AUTOTESTCON.
- 4 McDonnell, D., Balfe, N., Al-Dahidi, S., & O'Donnell, G. E., "Designing for human-centred decision support systems in PHM," Paper presented at the Proc. Euro. Conf. Prognostics Health Manag. Soc. 2014.
- 5 Tavner, P. J., Xiang, J., & Spinato, F., "Reliability analysis for wind turbines," *Wind Energy*, Vol. 10, Iss. 1 (2007), p. 1-18.
- 6 Jardine, A. K., Lin, D., & Banjevic, D., "A review on machinery diagnostics and prognostics implementing condition-based maintenance," *Mechanical Systems and Signal Processing*, Vol. 20, Iss. 7 (2006), p. 1483-1510.

若船舶主機及其系統發生故障，則嚴重影響船舶安全營運，甚至可能肇生重大的海損事故。柴油主機是船舶的最大耗能設備，現有的監視與警報系統僅針對各項基本的運轉狀態進行偵測及警示故障等基礎的安全保護，面對越益複雜的設計，需要更具智慧性的分析系統來監控運轉效率，並當故障發生時需能有效分析出故障的根源以進行有效的故障因應及後續處理，降低人為誤判使情勢惡化的機率。⁷ 柴油發動機是船舶平臺最關鍵之設備，因此其可靠性優化對船舶可用性，安全性和生命週期成本具有巨大之影響。發動機的故障會限制任務達成或阻止船舶可用性，更可能使船員身陷危險，故維修手段已從傳統基於糾正的措施演變為當前趨勢的預測行動，以利提高發動機的可靠及可用性。⁸ 由於在船舶應用中，柴油發動機通常使用壽命長且設備組件複雜，因此幾乎無法以完整的生命週期數據來即時預測剩餘使用壽命，及涵

蓋基於現有操作的整體物理故障條件，⁹ 因此檢測潛在異常的技術或系統非常重要。船舶主推進裝置或輔助裝置的任何故障都可能衍生嚴重後果，影響船舶的安全性和可靠性，為此引入並應用船用柴油發動機的狀態監測與故障檢測的各種技術和系統。¹⁰ 現有柴油發動機大多為機械系統，在一定時間的運行後，事實上都可預期會出現異常，故應在發動機的故障影響性能或造成損壞之前，早期階段實施檢測與識別，以縮減系統的停機時間，提高可靠性並優化生命週期成本。

由於科技日新月異，武器裝備的集成度、複雜度及智慧化程度急劇增加，而數據資料的生成方式、特徵維度、監控方法及資訊精準度與時效性亦大幅升級，推動人們對於演算法的創新發展與運用。通常一個好的演算法須具有以下屬性，包括預測準確性：模型正確預測新數據；速度：產生與運用模型所涉及之計算成本；穩定性：模型在雜訊

- 7 黃道崙、黃健瑋，〈船用渦輪增壓系統的性能監視與故障診斷〉《船舶科技》（臺北），第50期，西元2018年4月，頁59-65。
- 8 Rubio, J. A. P., Vera-García, F., Grau, J. H., Cámara, J. M., & Hernandez, D. A., "Marine diesel engine failure simulator based on thermodynamic model," *Applied Thermal Engineering*, Vol. 144, No. 5 (2018), p. 982-995.
- 9 Wei, M., Qiu, B., Jiang, Y., & He, X. (2016). Multi-sensor monitoring based on-line diesel engine anomaly detection with baseline deviation. Paper presented at the 2016 Prognostics and System Health Management Conference (PHM-Chengdu).
- 10 Lamarinis, V., & Hountalas, D., "A general purpose diagnostic technique for marine diesel engines—Application on the main propulsion and auxiliary diesel units of a marine vessel," *Energy conversion and management*, Vol. 51, Iss. 4 (2010), p. 740-753.

或遺漏值的情況下，可正確預測的能力；可解釋性：模型提供的理解水準。¹¹傳統的統計分類演算法，運算成本高且準確度提升有限，故本研究採用具高準確率的機器學習演算法，可望顯著改進傳統維護方案，使裝備維保人員能優化維保計畫和最小化設備停機時間。主戰裝備良窳是國軍戰力發揮的基礎，本文藉由研究來建立準確與迅速的異常偵測系統，使維保人員具備正確安全處置觀念，發現異常立即反應及妥處，以提升整體妥善率，方能維持裝備妥善與航行安全，確保部隊戰力充分發揮。

貳、預兆式健康管理

預兆式健康管理 (Prognostics and Health Management, PHM) 為有效的系統方法，用於評估系統在實際運行下的可靠性、預測故障進展及透過管理手段降低營運風

險；¹²預兆式健康管理旨在提供機器或系統健康狀態的綜觀，「預兆」可解釋為健康評估和過程預測，包括初期故障檢測和剩餘壽命預測，「健康管理」則是採取及時與適當的維護措施，做出準確的預測決策、可用資源和作業需求，以降低風險、提高可靠與安全性，從而實現近乎零的停機時間，以優化維護計畫、防止停機和最大化利潤。¹³預兆式健康管理方法是基於狀態維護 (Condition-Based Maintenance, CBM) 功能的擴展，以提高操作可用性、降低生命週期成本並提高目標系統的安全性。¹⁴

關於預兆式健康管理實施的重要性，已明確於美國國防採辦指南¹⁵指出「計畫管理者應優化作業整備使其具有可擴展、集成、嵌入式診斷與預測、嵌入式訓練與測試、自動化識別技術及反覆運算技術更新」。而預兆式健康管理概念已被廣泛應用於系統開發包括經驗趨勢、損害累積、失效故障進展和

- 11 Han, J., Kamber, M. & Pei, J., *Data Mining: Concepts and Techniques*, 3/e. (Burlington: Morgan Kaufmann, 2011).
- 12 Pecht, M., *Encyclopedia of Structural Health Monitoring: Prognostics and health management of electronics*. (New Jersey: Wiley, 2009).
- 13 Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., & Siegel, D., "Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications," *Mechanical systems and signal processing*, Vol. 42, Iss. 1-2 (2014), p. 314-334.
- 14 Sheppard, J. W., Kaufman, M. A., & Wilmering, T. J. (2008). IEEE standards for prognostics and health management. Paper presented at the 2008 IEEE AUTOTESTCON.
- 15 *Performance Based Logistics: DoD 5000.2 Policy Document*. (2004). *Defense Acquisition Guidebook* (Department of Defense), ch. 5.3.

失效物理建模等，如應用預兆式健康管理方法預測電源器故障，建立整體可靠性預測供應系統，包括電路板元件退化及供電系統失效可能性預測；¹⁶基於管道腐蝕退化結構的預兆式健康管理模型，討論腐蝕退化率的影響因素，可以計算出使用壽命（可靠性）的最佳估計值。¹⁷

預兆式健康管理的未來趨勢是在系統進一步增加複雜度與不確定性的情況下，應該開發必要的自我維護能力、彈性系統和工程免疫系統；自我維護是指能夠透過機器本身，執行定期的品質和安全檢查，以進行異常檢測並即時維修；彈性系統為跨多種可能狀態的管理功能，逐步解決不同類型的障礙使系統回到穩定狀態；而工程免疫系統則是透過適應性地學習與保留記憶，以利系統未來有自主控制能力，可解決在高度不確定和複雜環境中的機器維護問題，¹⁸其中自我維

護能力包含預測性維護的概念。

參、預測式維護

「預測」主要聚焦在失敗模式的演變，對未來行為的估計，然後定義出允許故障風險評估和控制的故障模式。¹⁹在工業4.0的推波助瀾之下，眾多領域裝備的智慧診斷與預測性維護（Predictive Maintenance, PdM）觀點陸續提出，預測式維護不僅能優化裝備運作的效能，並降低預防性維護（Preventive Maintenance, PM）耗用的時間、人力及物力成本，進而提升安全。²⁰預測式維護是一種趨勢導向的策略，首要確定設備中每個組件的狀態，並依賴工程技術和統計工具來處理數據和分析健康狀況，以預測可能的設備故障。²¹提出隨著智慧設備的發展，高智慧維護系統成為關注的焦點，為能在工業4.0時代實

- 16 Nasser, L., & Curtin, M. (2006). Electronics reliability prognosis through material modeling and simulation. Paper presented at the 2006 IEEE Aerospace Conference.
- 17 Chookah, M., Nuhi, M., & Modarres, M., "A probabilistic physics-of-failure model for prognostic health management of structures subject to pitting and corrosion-fatigue," *Reliability Engineering & System Safety*, Vol. 96, Iss. 12 (2011), p. 1601-1610.
- 18 同註14。
- 19 Guillén, A. J., Crespo, A., Macchi, M., & Gómez, J., "On the role of Prognostics and Health Management in advanced maintenance systems," *Production Planning & Control*, Vol. 27, Iss. 12 (2016), p. 991-1004.
- 20 郭至恩、沈育霖、曹常成、張純明、高振山、許世希等，〈應用於石化業關鍵設備之集成式智慧預知維護系統〉《勞動及職業安全衛生研究季刊》（新北市），第26卷第3期，西元2018年9月，頁141-150。
- 21 Lee, J., Ardakani, H. D., Yang, S., & Bagheri, B., "Industrial big data analytics and cyber-physical systems for future maintenance & service innovation," *Procedia CIRP*, Vol. 38 (2015), p. 3-7.

現預測性維護，首先，需要應用先進的數字技術來提升生產力和價值創造；其次，基於即時應用大數據分析，為據以進行控制和制定決策的專家提供策略支援；第三，對於品質管理的預測式維護，應透過制定系統的條件，測量因果分析的方式及預測結果來提出具體實施方法，²²因此工業4.0的工具和技術已經將預測式維護從抽象概念轉變為實際解決方案。

預測式維護是一種維護方法，涉及監控裝備的運作情形並應用預測建模技術，以預測裝備可能的故障和可能發生的時間估計，²³它是透過評估系統的當前和未來健康狀況，自動檢測故障前退化或惡化的發生，從而提供機會採取預防手段來調查並隨後消除因果因素。²⁴故障檢測和狀態監測是

預測式維護的組成關鍵，可以有效消除工業製造中的災難性設備故障。²⁵而預測式維護和預防性維護之間的區別主要在於，預防性維護是以平均壽命統計數據來確定維護週期，預測式維護則監控設備的實際情況來評估最佳維護時間。

預測式維護可以準確預測可能演變為災難性故障的初期問題，並應用基於預測結果的有效措施以避免這些故障，不僅可最大限度地減少維護成本，還可延長裝備使用壽命，²⁶預測式維護側重於利用預測的資訊來正確安排未來的維護操作，因此部署預測式維護以確保操作安全十分重要。Creehan²⁷學者認為從提高產能的角度來看，預測式維護是任何裝備的理想維護方法，因為它可以最大限度地縮減裝備的停機時間，透過對重

- 22 Lee, S. M., Lee, D., & Kim, Y. S., "The quality management ecosystem for predictive maintenance in the Industry 4.0 era," *International Journal of Quality Innovation*, Vol. 5 Article No. 4 (2019).
- 23 Shetty, R. B. (2018). *Predictive Maintenance in the IoT Era. Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things*, p. 589-612.
- 24 Sullivan, G., Pugh, R., Melendez, A. P., & Hunt, W. (2010). *Operations & Maintenance Best Practices-A Guide to Achieving Operational Efficiency (Release 3)*, Prepared for the U.S. Department of Energy under Contract DE-AC05-76RL01830.
- 25 Yu, W., Dillon, T. S., Mostafa, F., Rahayu, W., & Liu, Y., "A Global Manufacturing Big Data Ecosystem for Fault Detection in Predictive Maintenance," *IEEE Transactions on Industrial Informatics*, Vol. 16, Iss. 1 (2020), p. 183-192.
- 26 Qiao, W., & Lu, D., "A survey on wind turbine condition monitoring and fault diagnosis—Part I: Components and subsystems," *IEEE Transactions on Industrial Electronics*, Vol. 62, Iss. 10 (2015), p. 6536-6545.
- 27 Creehan, K. D., "Establishing optimal maintenance practices in a traditional manufacturing environment," *Journal of the Chinese Institute of Industrial Engineers*, Vol. 22, Iss. 1 (2005), p. 11-18.

要參數的即時觀察，確定導致災難性故障發生的條件，並在發生故障前採取補救措施。預測式維護的基礎是監控設備的狀況，以偵測何時出現異常並知道何時需要執行維護操作。²⁸

肆、異常偵測

異常偵測 (Anomaly detection) 是指在數據中找到不符合預期行為模式的問題，異常偵測的重要性，是數據異常的事實可轉化為各應用領域重要且關鍵的可操作訊息，²⁹如來自航空傳感器的異常讀數可能表示太空船組件的故障。³⁰異常偵測旨在檢測從使用壽命到磨損期的過渡點，而故障預測則是試圖預測磨損期的剩餘使用壽命 (Remaining Useful Life, RUL)。³¹基於數據的工業過程，異常偵

測常採用統計過程的監控技術，此異常表示廣義的故障，即過程中至少一個特徵或變數發生異常偏離。³²異常偵測技術已廣泛運用於工業領域，機具因連續使用或正常磨損而受損，異常偵測技術在此領域中監控電機等工業組件的性能，檢測可能由於磨損或其他無法預見的情形而發生的缺陷。³³綜上所述，異常偵測是事前找出系統裝備異常狀態，即過程中的特徵或變數發生異常偏離，並對系統可靠性與設備可維修性產生影響者，而非事後檢測其失效後現況。

現有異常偵測方法包括從簡易歷史故障數據模型到高度專業物理模型；根據預測方式的類型差異，所需要的訊息包括：工程模型和數據、歷史失效紀錄、歷史使用條件、當前狀態、可識別故障模式、失效變化曲線、歷史維修紀錄、系統退化及失效模式。³⁴異常偵測

- 28 Rubio, J. A. P., Vera-García, F., Grau, J. H., Cámara, J. M., & Hernandez, D. A., "Marine diesel engine failure simulator based on thermodynamic model," *Applied Thermal Engineering*, Vol. 144, No. 5 (2018), p. 982-995.
- 29 Chandola, V., Banerjee, A., & Kumar, V., "Anomaly detection: A survey," *ACM Computing Surveys (CSUR)*, Vol. 41, No. 3 (2009), p. 15.
- 30 Fujimaki, R., Yairi, T., & Machida, K. (2005). "An approach to spacecraft anomaly detection problem using kernel feature space," *Proceedings of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining*, p. 401-410.
- 31 Jin, X., Sun, Y., Que, Z., Wang, Y., & Chow, T. W., "Anomaly detection and fault prognosis for bearings," *IEEE Transactions on Instrumentation and Measurement*, Vol. 65, Iss. 9 (2016), p. 2046-2054.
- 32 周東華、魏慕恆、司小勝，〈工業過程異常檢測、壽命預測與維修決策的研究進展〉《自動化學報》（北京），第39卷第6期，西元2013年6月，頁711-722。
- 33 同註29。

方法的分類最常見可分為3種：「模型技術」是建立物理模型進行偵測；「數據驅動技術」是基於測試或傳感器數據進行偵測；而「概率統計技術」則是從歷史故障數據的統計特性角度進行偵測。³⁵

選擇對數據實例進行分類演算法的問題並非直接，應用領域的不同對異常的觀點亦不同。囿於現今異常偵測技術的趨勢發展，依靠單一智慧技術的異常偵測已難以滿足複雜裝備異常偵測的全部任務要求，將多種異常偵測方法有效地集成，可克服各預測方法的侷限性，發揮各預測方法的自身優點，以增強機器學習，提高系統的智慧預測表現，有效地解決複雜系統和過程的預測問題。³⁶

伍、機器學習演算法

分類是資料探勘與機器學習中重要的演算法，也是屬於監督式學習 (Supervised

Learning) 的演算法，監督式學習是搜索從外部提供的實例推理，產生一般假設，然後對未來的實例做出預測的演算法，³⁷分類可分為兩種用法—分析與預測，預測是根據資料的特徵及模型，以預測未來新的資料走向；換句話說，分類是用來將資料做區分並判斷資料所屬類別，從原有資料集的類別進行學習，用來判斷新進未知類別的資料。以下列舉當前資料探勘中具代表性的分類演算法及其特性：

一、支援向量機

支援向量機 (Support Vector Machine, SVM)³⁸為支援向量網路用於分類問題的學習機。該演算法在概念上實現以下思想：輸入向量由非線性映射到非常高維度的特徵空間，在該特徵空間中，構造線性決策平面，進行線性分類。這裡將最佳超平面定義為線性決策函數，在兩個類的向量之間具有最大餘量，使其可以完美區隔開來，當構造最佳超平面時，只需要考慮落在邊界上 (在容忍邊界

- 34 趙春宇、馬倫、呂豔軍、呂雷、王友強，〈基於狀態維修過程中的故障預測問題分析〉《計算機與數字工程》(武漢)，第40卷第1期，西元2012年1月，頁129-131。
- 35 馬碩、焦現煒、田柯文、呂世樂、趙陽、鄭善軍，〈故障預測技術發展與分類〉《四川兵工學報》(重慶)，第34卷第2期，西元2013年2月，頁92-95。
- 36 左憲章、康健、李浩、唐力偉，〈故障預測技術綜述〉《火力與指揮控制》(山西)，第35卷第1期，西元2010年1月，頁1-5。
- 37 Kotsiantis, S. B., Zaharakis, I., & Pintelas, P., "Supervised machine learning: A review of classification techniques," Emerging artificial intelligence applications in computer engineering, Vol. 160 (2007), p. 3-24.
- 38 Cortes, C., & Vapnik, V., "Support-Vector Networks," Machine learning, Vol. 20, No. 3 (1995), p. 273-297.

內)少量的訓練數據,即所謂的支援向量,來確定邊界;訓練向量通過最佳超平面的分離而沒有錯誤,則在測試實例上提交錯誤概率的期望值,受到支援向量數量與訓練向量數量之間期望值的比率限制。

Bakhshipour等學者研究基於形狀特徵的支援向量機演算法進行雜草的檢測應用,總體準確度為95%;³⁹另Poorinmohammad等學者使用支援向量機演算法來預測抗人類免疫缺乏病毒(Human Immunodeficiency Virus, HIV),預測準確度達96.76%;⁴⁰Huang等學者提出以支援向量機方法應用機器視覺技術來檢測甘蔗螟病,正確率為96%,經驗證該方法可有效檢測甘蔗螟病。⁴¹雖然支援向量機傾向於處理高維度與連續特徵時表現較好,然而相較於基於邏輯演算法的解釋性高,支援向量機的解釋性差,難以理解其內部運作的複雜性。

二、極限梯度提升

極限梯度提升(eXtreme Gradient

Boosting, XGBoost)⁴²是使用提升樹(Tree Boosting)的方法,為一種執行效率高且過程直覺的監督式機器學習法,提升弱分類器的方法是使用梯度下降架構,XGBoost是透過系統優化和演算法增強改進基礎梯度提升樹框架,主要透過貪婪演算法,在建構樹狀層次過程中優化目標函式的最大增益,尋找分割點的標準是最大化增益,對損失函數進行二階泰勒展開,運用兩階導數作近似來加速求解過程。XGBoost的主要核心概念如下:

- (一) 可運用分布式加權分位數草圖算法,有效在加權數據集中找到最佳分割點。
- (二) 透過正規化懲罰複雜的模型,來避免過擬合問題。
- (三) 引入稀疏數據感知演算法,可有效處理各類型數據的稀疏模式,透過訓練損失自動學習最佳遺漏值,自然接受輸入的稀疏特徵。
- (四) 分配每個線程中內部緩衝區,來儲存梯度統計訊息的快取記憶體感知結

39 Bakhshipour, A., & Jafari, A., "Evaluation of support vector machine and artificial neural networks in weed detection using shape features," Computers and Electronics in Agriculture, Vol. 145 (2018), p. 153-160.

40 Poorinmohammad, N., Mohabatkar, H., Behbahani, M., & Biria, D., "Computational prediction of anti HIV-1 peptides and in vitro evaluation of anti HIV-1 activity of HIV-1 P24-derived peptides," Journal of Peptide Science, Vol. 21, Iss. 1 (2015), p. 10-16.

41 Huang, T., Yang, R., Huang, W., Huang, Y., & Qiao, X., "Detecting sugarcane borer diseases using support vector machine," Information processing in agriculture, Vol. 5, Iss. 1 (2018), p. 74-82.

42 Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. Paper presented at the Proceedings of the 22nd ACM SIGKDD International Conference.

構，用於核外學習，進一步優化可用硬碟空間。

(五) 使用多個CPU核心，系統平行計算使學習加快。

Lei等學者提出基於狀態監控測量液壓閥出入口壓力信號的數據，採用主成分分析縮減維度後的主要特徵集，以XGBoost構建液壓閥故障診斷模型，結果表示該模型精確平均值為96.9%，召回率平均值為96.7%，具更高準確性。⁴³ D. Zhang等學者提出XGBoost演算法在軟體定義網路雲端系統控制器中的阻斷服務攻擊檢測，模型表現具更高準確性(98.5%)、更低誤報率，檢測速度快、適應高速物聯網環境且具有可擴展性。⁴⁴

陸、實驗設計與演算法評估

一、實驗設計

本研究對象是某單位兩艘船舶四具德國製MTU船用柴油主機，所蒐集資料為自2015年6月至2018年12月間之歷史維保資料及監控數據7,551筆數，監控數據特徵計有22項，如表一所示。本研究主要探討與運用MTU主機運轉時的監控變數和主機狀態的目標特徵變數關連性，針對主機裝備進行預測式維護之異常偵測，以機器學習演算法建立船舶主

機的預兆式健康管理模型，於主機運轉效率下降或發生初期故障前，及時與準確地預測診斷出異常徵候。

針對維保單位所提供之主機歷史維修保養資料及主機監控紀錄，進行資料彙整及處理，再依研究分析所需進行資料標記，新增主機狀態的欄位，基於考量裝備異常前都會有故障演變或徵兆，因此將資料分成為異常、示警與正常等3類，以符合分析目的，使研究數據更趨完整並利於分析，研究過程中會進行資料前處理，接著探討傳統的支援向量機與高效率的XGBoost機器學習演算法技術建構之分類模型比較，最後產出實驗結果說明結論，以供維保人員與決策者決策及未來研究之參考。研究架構如圖一所示。

本研究以皮爾森相關分析(Pearson Correlation, Pearson's r)探討兩連續變數之間的線性相關，即兩組變數向量之間的關聯性，相關係數的值介於1與-1之間，越靠近1代表正相關程度越高，反之越靠近-1則代表負相關程度越高，若兩變數之間的相關係數 r 絕對值較大，則表示彼此相互共變的程度較大， r 絕對值介於0~0.25表示兩者缺乏相關，介於0.25~0.50表示兩者相關性不強，介於0.50~0.75表示兩者適度相關，介於0.75~1.0代表兩者相關性強；在圖二中上三角區塊

43 Lei, Y., Jiang, W., Jiang, A., Zhu, Y., Niu, H., & Zhang, S., "Fault Diagnosis Method for Hydraulic Directional Valves Integrating PCA and XGBoost," *Processes*, Vol. 7, No. 9 (2019), p. 589.


44 Zhang, D., Qian, L., Mao, B., Huang, C., Huang, B., & Si, Y., "A data-driven design for fault detection of wind turbines using random forests and Xgboost," *IEEE Access*, Vol. 6 (2018), p. 21020-21031.

表一 監控變數表


代碼	變數名稱	單位	資料型態
V1	主機轉速	rpm	數值
V2	排煙溫度最高溫	°C	數值
V3	排煙溫度最低溫	°C	數值
V4	滑油壓力	bar	數值
V5	增壓機滑油壓力	bar	數值
V6	滑油濾心壓力	bar	數值
V7	活塞冷卻油壓力	bar	數值
V8	燃油壓力	bar	數值
V9	燃油濾器壓差	bar	數值
V10	淡水壓力	bar	數值
V11	海水壓力	bar	數值
V12	控制空氣壓力	bar	數值
V13	啟動空氣壓力	bar	數值
V14	供油齒桿位置	mm	數值
V15	主機滑油溫度	°C	數值
V16	燃油溫度	°C	數值
V17	淡水溫度	°C	數值
V18	海水溫度	°C	數值
V19	進氣空氣溫度	°C	數值
V20	減速機控制油壓力	bar	數值
V21	減速機滑油壓力	bar	數值
V22	齒輪油溫度	°C	數值

以不同顏色和大小的圓形表示相關性大小，其中藍色表示正相關，而紅色表示負相關；顏色越深、圓形越大代表相關性越高，反之越


小；下三角區塊則是各相關係數的數值大小，圖中各變數間正相關係數值最高僅有0.7，未達顯著相關性，表示彼此獨立，不足以相互影



圖一 研究架構圖 (資料來源: 本研究繪製)



圖二 各變數皮爾森相關係數矩陣 (資料來源: 本研究繪製)



圖三 主成分分析累積貢獻率百分比 (資料來源：本研究繪製)

響，共變效應不高，因此所有變數均同步納入建模分析。

另本研究將資料進行主成分分析，可見前13個主成分累積貢獻率百分比及特徵值如圖三所示，由圖可知第1個主成分貢獻率為23.7%，是所有主成分中貢獻率最大者，之後各主成分累積貢獻率緩慢增加，直到第13個主成分累積貢獻率僅為79.5%，有高達20.5%的監控資訊未能表達，且由各個主成分的特徵值看來均未大於1，經由本研究分析後得知，不論採用以標準差累積貢獻率 $\geq 85\%$ 以

上為標準或以特徵值 ≥ 1 為選擇標準，均無法取得足夠有力的主成分作為特徵變數進行建模，故本研究後續將不降低資料維度，會保留完整變數納入建模分析，以利資訊能充分表達。

二、XGBoost與支援向量機機器學習演算法比較

本研究資料筆數共計7,551筆，將資料分割70%樣本作為訓練資料集來訓練模型，其餘30%樣本做為測試資料集，依預測與實際之結果，可以得出各分類模型的混淆矩陣⁴⁵

45 Deng, X., Liu, Q., Deng, Y., & Mahadevan, S., "An improved method to construct basic probability assignment based on the confusion matrix for classification problem," *Information Sciences*, Vol. 340 (2016), p. 250-261.


表二 各分類模型混淆矩陣

XGBoost混淆矩陣				
True condition Predicted condition	實際為異常	實際為示警	實際為正常	第n類的預測總數
預測為異常	36	2	1	39
預測為示警	2	58	4	64
預測為正常	59	102	2001	2162
第n類的實際總數	97	162	2006	所有總數 2265
支援向量機混淆矩陣				
True condition Predicted condition	實際為異常	實際為示警	實際為正常	第n類的預測總數
預測為異常	14	3	9	26
預測為示警	1	18	11	30
預測為正常	82	141	1986	2209
第n類的實際總數	97	162	2006	所有總數 2265

資料來源：本研究繪製

如表二，混淆矩陣斜對角的紅色數字部分係顯示實際為某類別且預測為某類別的數量；機器學習演算法的評估指標，可由混淆矩陣所計算出的整體準確率（Accuracy）、精準率（Precision）、召

回率（Recall）與綜合評估指標（F1）來衡量，取值範圍均為0到1之間，分類結果越準確則值越大，在透過混淆矩陣計算後，在圖四中得出各分類模型整體準確率比較，以XGBoost的



圖四 各分類模型整體準確率比較圖（資料來源：本研究繪製）

整體準確率92.49%為最高，與支援向量機的整體準確率89.09%相比，高出3.4%。

在圖五可見各分類模型的Precision、Recall與F1評估指標比較，由圖可知XGBoost


在各類別的各項評估指標中表現亦優於支援向量機；綜上所述，本研究可以得知XGBoost的分類模型，整體預測表現均優於支援向量機分類模型，顯示XGBoost演算法執行效率更高。XGBoost演算法本身考量在建立弱分類器時加入梯度下降法之修正機制，使得整體預測表現均優於傳統的支援向量機演算法。藍色表示為異常類別的指標、橘色為示警類別的指標，而灰色為正常類別的指標。

七、結論與建議

經實驗證明，運用高效率機器學習演算法可進一步有效提升與優化預測的分析效率，更加準確及迅速地預測診斷出異常徵候，建立早期失效預警系統，有利及時提供維保人員與決策者於主機裝備維護之決策參

考，以縮減裝備的停機時間並提高可靠性。預兆式健康管理模型透過優化的預測維護，可提升維保人員後勤作業的效率，有助於管理者全面優化4M（即人員Man、材料Material、方法Method及設備Machine），不僅可於故障發生初期前，及時實施維護控制，降低對其它組件之附帶損害造成的巨大損失，亦可避免由於過度頻繁或謹慎的預防維護作業，可能導致之維護成本浪費，如提早更換尚未損壞的零組件、消耗的油料能源及冗餘的人力工時等，進而優化後勤人力能量、零組件（含能源）存量估算及裝備使用壽命。

此外，為精進整體國防實力，國軍持續購置新式主要作戰武器裝備，由於裝備獲得十分不易，且非計畫性維修作為的成本相當高，各軍應積極導入預兆式健康管理系統，透過智慧資訊化的監控機制，以防範突發性



圖五 各分類模型Precision、Recall與F1評估指標比較圖

（資料來源：本研究繪製）

的失效發生，可使裝備整體生命週期的維運成本大幅降低，並提高裝備妥善率，使裝備持續發揮戰力；另值得省思的是，國軍未來新式武器的接裝，隨之而來的是日新月益的後勤補保管理作為，如何使舊有裝備的補保系統與之整合與銜接，為避免管理歧異，唯有導入預兆式健康管理系統，未來才能全般性同步提升各式武器裝備的後勤維保能力，掌握各式武器裝備的完整戰力，並可供國軍刻正進行中的「國艦國造」及「國機國造」等專案參考，作為未來裝備汰換、重新設計與改良之用途。

在未來研究建議上，如國軍開始規劃導入IoT，可將現行使用的批次檔數據轉由各零組件感測器所收集到的即時性數據取而代之，朝向發展即時性預兆式健康管理系統，如此一來可持續獲得大量資料進行監控分析，並可將該資料用於識別參數和優化模型，以大幅提升模型的分析效率；其次，在結合IoT之概念後，大幅增加資料獲得的便利性與擴展性，因此在特徵工程方面可做進階的探討，如特徵降維、選取、轉換及合併等歸納考量，將原始資料轉化為更加充分表達問題本質的特徵，進而提高模型預測的精度與效率；另本文所運用之船舶資料的特徵屬性（即表一）為原始引擎製造廠所提供，建議與問題本質相關的內外在因素均可全般考量，如外部船舶航行時的天氣、海象及風向等特徵變數，以及船員年資及操作經驗（習慣）等

皆可做為未來相關領域研究的參考。再者，本研究所建立的預兆式健康管理系統，除建立早期異常偵測的預警功能外，建議亦可結合剩餘壽命估算模型，將資料及訊號傳送至該模型，以同步計算出裝備的剩餘壽命，可提供基礎的維護決策資訊，使決策者與維保人員決定立即的維修決策或未來的維護計畫作為，以人工智慧科技進行資料預測的軍事決策，可使國軍在未來的作戰裡取得先發制人的優勢。另未來在實驗平臺上導入IoT後產生的巨量資料規模，建議可以運用雲端系統及邊緣運算（Edge Computing）來因應短期大量的數據運算與分析需求，在雲端架構下部署預兆式健康管理系統作為運算的基礎，可使分析結果相對標準化並且加快運算速度，以達到整體效益的穩定、泛化及效率之需求。

作者簡介

溫慧菱少校，國軍專業軍官班99年班，陸軍後勤訓練中心正規班103年班，國防大學管理學院運籌管理學系碩士班109年班，現任職陸軍兵工整備發展中心兵工參謀官。

作者簡介

郭俊良上校，國立成功大學資訊管理研究所博士，現任職國防大學管理學院運籌管理學系助理教授。