



大數據集成式學習技術建立射出件多品質目標預測之開發

Development of Big Data Ensemble Learning Techniques for Establishing Multi-Quality Target Prediction in Injection Molding

孫執恆¹、黃家祐²、鄭廷裕³、張權緯³、柯坤呈^{1*}

¹ 國立臺灣師範大學機電工程學系

² 國立臺灣科技大學智慧製造科技研究所

³ 科盛科技股份有限公司

*E-mail: kcke@ntnu.edu.tw

摘要

現今智慧製造技術中感測資訊是核心關鍵。然而大量多模態測試增加時間和成本，成為產業升級的主要挑戰。透過高效率之資料探勘技術能提高製程和產品品質，滿足客戶需求且減少試模時間和人力成本。本研究旨在利用關鍵領域知識和人工智慧技術，縮小品質預測之誤差。透過全因子實驗設計法對實機射出和模擬操作進行設置，擷取多維度感測資訊，並利用數據分析建立大數據資料庫。以自動編碼器萃取壓力特徵作為模型輸入資訊，及產品尺寸和重量為輸出資訊，達到關鍵成型資訊之正確預測。本研究提出集成式模型在相同機台參數設置下，使模擬資訊預測結果更貼近實機品質。研究發現，即使減少50%之實機數據量，仍能將模擬與實機間品質差異降低50%，並且成品長度與實際值預測線性度(R^2)達0.83，顯示此大數據整合技術確能提高預測準確性並大幅減少實機資料收集之成本和時間。此研究成果深化學術與產業界應用結合，落實模擬與實際數據間之高度預測一致性，有助於提升製造業競爭力、縮短產品開發周期、降低生產成本，更可為高分子產業之智慧製造奉獻一份心力，提供產業界乙套高效之智慧化應用。

關鍵詞：智慧製造、射出成型、模流分析、集成式學習、大數據

Abstract

The core challenge in modern smart manufacturing technologies lies in the centrality of sensor information. However, conducting extensive multimodal tests increases time and costs, becoming a major obstacle to industrial upgrades. Utilizing efficient data mining techniques can enhance process and product quality, meet customer demands, and reduce testing time and manpower costs. This study aims to reduce the error in quality prediction by leveraging domain knowledge and artificial intelligence techniques. Through full factorial experimental design, both real injection molding and simulated operations are set up to capture multidimensional sensor information. Data analysis is then employed to establish a big data database. Pressure features are extracted using autoencoders as model input information, while product dimensions and weight serve as output information, achieving accurate prediction of critical molding information. This study proposes an integrated model that, under the same machine parameter settings, brings simulated information prediction closer to real machine quality. Findings reveal that even with a 50% reduction in real machine data, the difference in quality between simulation and actual machines can be reduced by 50%. Furthermore, the linear correlation (R^2) between predicted and actual values for product length reaches 0.83, demonstrating the significantly enhanced prediction accuracy and substantial reduction in cost and time for real machine data collection. The outcomes of this research deepen the integration of academia and



industry applications, ensuring a high degree of prediction consistency between simulation and actual data. This contributes to enhancing manufacturing competitiveness, shortening product development cycles, lowering production costs, and making significant strides in smart manufacturing for the polymer industry, providing an efficient set of intelligent applications for the industry.

Keywords: Smart Manufacturing, Injection Molding, Mold Flow Analysis, Ensemble Learning, Big Data

1. 前言

在射出成型中，模擬軟體與實機射出的整合，以及實機品質的預測具有重要意義，對於業界生產有著極高的影響力。射出成型過程中影響產品品質的因素眾多，例如射出速度、保壓壓力和冷卻時間，這些參數都會對產品的外觀和重量產生顯著影響，特別是在精密射出成型中更是重要考量。因此，本研究提出了一種透過數化整合技術配合集成式模型的方法，以達到高效率且準確地預測射出件的多品質。數位化整合結合人工智慧技術不僅提高了模型預測的準確性，還大大減少了試錯成本和時間，對於生產效率和產品質量的提升具有重要作用。這種創新方法有望成為業界標準，促進塑膠加工行業的技術進步和競爭力提升。

2. 文獻探討

2.1 射出成型與模流分析

射出成型具有高精度、生產高效率與產品品質高等優點，所以不只在工業上有許多高精度應用，甚至在日常生活中也隨處可見，且塑膠產品又以射出成型為最大宗。在射出成型大致分為射出、保壓、冷卻、開模與頂出，而每個階段都對產品的最終品質有著關鍵影響。例如，射出階段的溫度和壓力控制，保壓階段的持續壓力，冷卻階段速度，開模與頂出的精確度等，都直接影響到成品的尺寸穩定性和表面品質。學者L.-S. Turng等人[1]介紹了射出成型的製程，顯示射出成型在產品品質有一定要求與改善技術，故優化產品品質是一大挑戰。

模流分析是基於電腦輔助工程方法(Computer Aided Engineering, CAE)所建構的一種先進技術，已被廣泛運用於模擬射出成型的結果。學者F. M. Mwema等人[2]提到此技術通過在電腦上對射出成型過程進行詳細的模擬，提供實際射出前的模擬結果，使整體製程更為高效。模流分析可以幫助工程師在產品開發的早期階段預測和解決潛在的製程問題，例如材料流動不均、氣泡、翹曲等，避免在生產過程中出現缺陷產品。此舉不僅能顯著減少試模和調整時間，並大幅降低工業上所需的時間成本，提高生產效率和產品品質。最終，模流分析技術不僅提升產業價值，使企業能更快速地將產品推向市場，增強競爭力。模流分析應用範圍廣泛，涵蓋汽車、電子、醫療等多個行業，進一步顯示出其在現代製造業中的重要性和潛力。

2.2 大數據與數位化整合系統

大數據(Big Data)早已成為現今科技上重要技術，不僅廣泛應用於工業，且深入日常應用。而學者K. Vassakis等人[3]提到，大數據資料庫建立是一種複雜且龐大資訊量的技術，有著數據規模巨大、結構複雜等，因此在面臨了數據是否多樣性、如何整合與分析和數據安全與管理之挑戰。大數據技術的廣泛應用，不僅促進了工業和商業領域的發展，也推動了整個社會的數位化進程，提高了各行各業的運營效率和創新能力。數位化整合系統(Digital Integrated System, DIS)的核心關鍵為降低開發成本和時間，學者P. Hehenberger等人[4]提到可以透過將虛擬模型與實際設備相連接，實現生產過程的虛擬仿真、數位孿生(Digital Twin)等應用，虛擬化使得在開發的不同階段更加靈活且成本更低。這種系統通常由嵌入式感測器與自動化系統轉變為數位化整合系統與物聯網(Internet of Thing, IoT)，可以實現實時監控、數據分析、預測維護等功能。



2.3 智慧製造

智慧製造技術是一種創新的生產技術，隨著通訊與網路、高速運算等高科技的迅速發展，創造許多顛覆世界的技術，而透過通信網路等技術結合數化整合的方法讓工業生產的第四階段，即工業4.0的來臨。而學者P. Zheng等人[5]提出了涉及智慧設計、智慧加工、智慧控制、智慧監測和智慧排程等創新方法，透過人工智慧(Artificial Intelligence, AI)、大數據分析、數化整合、通訊網路等，實現高效率、低成本的工業生產目標，並探討應用於工業4.0智慧製造系統的可能性。

2.4 集成式學習模型

集成式學習模型(Ensemble Learning Model)相較於傳統機器學習方法，具備處理更複雜且高維數據能力。Z. Yu等人[6]提出集成式學習模型通過多種數據轉換技術來提取一組特徵，然後結合使用多個學習算法來預測結果。這種方法不僅能夠整合多個模型的優勢，還能通過多樣化的算法來提高預測的準確性和穩定性。集成式學習模型可以結合深度學習、機器學習和強化學習等技術，擴展模型的複雜度和適應性。例如深度學習可以通過其多層神經網絡結構來捕捉數據中的非線性關係和複雜模式，而機器學習算法如隨機森林和支持向量機則能提供穩定的基準性能。強化學習則可以通過學習最佳行動策略來進一步優化模型性能。最後，集成式學習模型透過整合多種算法和技術，具備了處理複雜高維數據的強大能力。不僅提高知識挖掘深度，還大幅提升模型的預測性能，為各領域的數據分析和應用提供強有力的支持。

2.5 人工智慧應用於射出成型

在射出成型中，因為整個射出製程屬於黑箱過程，故利用許多感測器技術來監測產品生產的過程狀態。學者K. Saini等人[7]提出利用安裝於料筒之溫度感測器與模內壓力感測器所擷取之資訊，用來訓練人工智慧模型，並達到預測產品品質保持一致性。再利用此模型即時監控射出成型之過程，分析可能導致產品缺陷之因素。故將感測技術結合人工智慧模型，達到射出成型之產品品質更好且大幅降低發生產品缺陷之情況。學者Y. Lockner等人[8]提出，因為訓練數據的龐大需求阻礙機器學習在射出成型中的應用，而透過基於神經網路的遷移學習，可減少數據收集需求，進行參數優化。僅需4個樣本點即可達到高準確度且高準確度且 R^2 為0.92。兩位學者都達到利用人工智慧方法來預測射出成型品質結果，不只可以即時監控產品之缺陷，還可以減少龐大數據的收集量，真正達成AI應用於射出成型。

2.6 總結

本研究旨在應對實際收集射出成型數據所需的時間和成本高昂的挑戰，進而利用模流分析軟體Moldex3D獲取模擬數據，以降低時間和成本開支，以加速且準確達到所需的產品品質水平。具體目標包括利用壓力特徵來預測產品的長度、寬度和重量，以及基於少量實機數據和大量模擬數據實現產品品質的預測。此外，該研究還探索了實機和模擬數據集的相互結合，以改善單一數據集的模型品質，同時提出了一個集成式模型，以達成多個品質目標的預測。

3 研究方法

3.1 實驗流程圖

本研究流程圖如圖 1所示，大致分為大數據資料庫建立、模擬與實機單一之人工智慧訓練、80%模擬+20%實機混合資料集人工智慧訓練和50%模擬+50%實機混合資料集人工智慧訓練。在大數據資料庫建立中，使用全因子實驗設計法，模擬設置與實機射出各81模次，並各自擷取出壓力資訊，再進行自動編碼器的壓力特徵萃取，建構成模擬與實機之大數據資料庫；在模擬與實機單一之人工智慧訓練中，將資料集分為訓練集(80%)和測試集(20%)，使用壓力特徵訓練多層感知器，透過多層感知器預測射出件品質；在混合資料集中，將模擬與實機分為80%+20%和50%+50%的混和資料集訓練多層感知器，透過多層感知器來預測射出件品質。

並透過計算原始值與預測值之RMSE來驗證各個人工智慧模型。

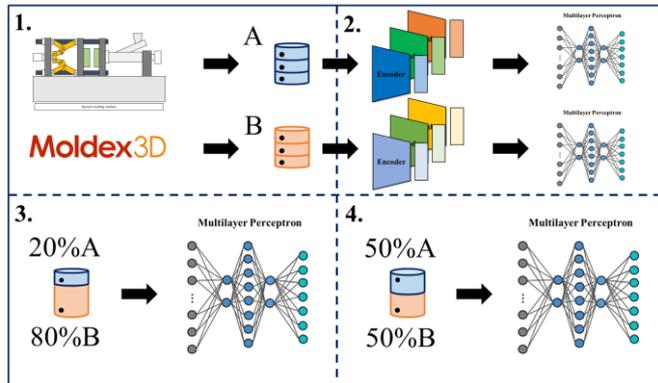


圖 1 實驗流程圖

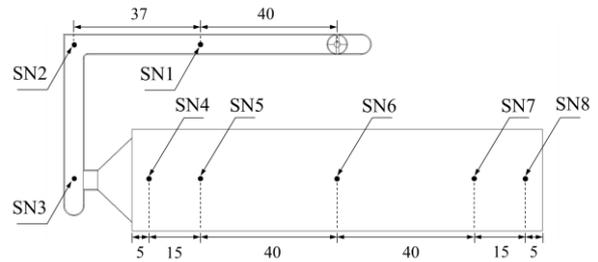


圖 2 射出件尺寸與壓力感測點

3.2 實驗設備與軟體

本研究使用油電式射出成型機(LA-40, Sodick, Japan)作為實際射出之機台，此機台具有高精度與高穩定度的優勢，適合用在高穩定之產品。高分子材料使用PS，為一種非結晶材料，具有光學特性，製造商為CHI-MEI，材料型號為POLYREX PG-33。模流分析軟體使用Moldex3D 2023作為分析軟體，模擬設置與實際機台參數相同。使用MATLAB R2023a作為資料前處理、大數據資料庫建立與人工智慧模型建構。計算單元為AMD Ryzen 9 7900X 12核心、Nvidia GeForce RTX 3070i顯示卡和64GB RAM，作為軟體高速運算之平台。

3.3 實驗設計與大數據資料庫建立

本研究採用全因子實驗法，分別調整射出速度(5~15 mm/sec)、保壓壓力(70~90 MPa)、材料溫度(200~210°C)與模具溫度(55~65°C)來當作因子，此方法可以分析對於所有因素與交互作用對產品品質的影響，有利於大數據資料庫的建立，但同時造成需要花費更多的時間和成本來收集較多的實驗數據。在智慧製造技術中，建立大數據資料庫尤為重要，不僅可以用來處理大規模且多樣性的先進工業資料，還可用於人工智慧技術應用中，同時保持高彈性、可擴充性的分析功能。本研究將透過全因子實驗法所擷取的實機與模擬數據建立各別之大數據資料庫，感測資訊擷取位置如圖 2所示。並將20%、50%實機資料與80%、50%模擬資料整合成全新大數據資料庫，透過此方法讓人工智慧訓練過程更有效率且有著高精確度。

3.4 人工智慧模型

3.4.1 自動編碼器

本研究所使用自動編碼器(Autoencoder, AE)，為一非監督式學習模型(Unsupervised Learning Model)，分為編碼器與解碼器。普遍應用於壓縮人工智慧訓練時之輸入資訊，而其訓練的目標為將重建數據與原始數據之間的差異最小化，其目標函式如式(1)，其中 J_{AE} 為最小化給定資料集的重建損失， x 為輸入實際值， \hat{x} 為模型預測值， θ 為訓練參數集合。將資訊輸入編碼器，並學習找到原始數據中的特徵，再利用這些特徵重建數據。透過這樣的方法，不僅可以將多維且複雜的資訊降維並簡易化，用來增加人工智慧訓練效益，還可以擴增數據多樣性，達到人工智慧訓練更好的泛化程度。因此本研究利用自動編碼器將壓力曲線壓縮成壓力特徵，來減少人工智慧訓練所需運算時間。

$$J_{AE} = \min_{\theta} L(x, \hat{x}) \quad (1)$$

3.4.2 多層感知器

多層感知器(Multilayer Perceptron, MLP)為一監督式學習模型(Supervised Learning Model)，

由向前傳遞神經網路(Feedforward Neural Network)所組成，具有多層結構且可以學習非線性之關係。在訓練過程中，利用梯度下降法更新權重值，用以找出最佳解，方程式如式(2)，其中 η 為學習率， W 為權重值， b 為偏差值。多層感知器在機器學習裡是強大的工具，可以有效地解決複雜的輸入資訊，並達到很好的預測效果。常被應用在工業與學術，用來解決困難之問題。本研究採用損失函數均方根誤差(Root Mean Square Error, $RMSE$)評估多層感知器模型，計算預測產品品質與原始產品品質之誤差。計算方程式如式(3)所示，其中 \hat{y}_i 為預測值， y_i 為原始值。

$$\theta_{t+1} = \theta_t - \eta \frac{\partial}{\partial \theta_t} J(\theta), \quad \theta \in \{W, b\} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (3)$$

3.5 集成式模型

集成式模型為將多個獨立的模型組合，來達到更好的效能與預測結果。而本研究將自動編碼器與多層感知器結合為一集成式模型，如圖 3所示。透過利用自動編碼器所萃取出壓力特徵，當作多層感知器之輸入資訊，最後達到寬度、長度和重量的品質預測，並以 $RMSE$ 當作模型評估標準。此集成式模型不僅提高預測線性度，還減少人工智慧模型訓練之時間。

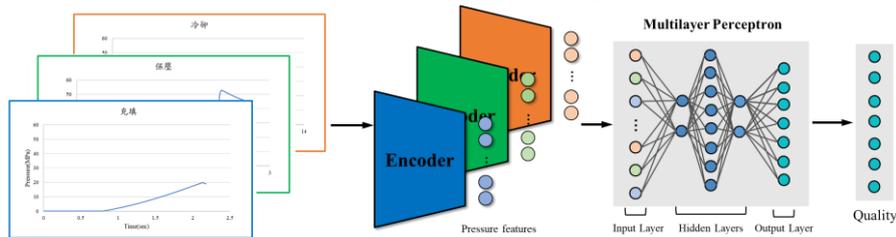


圖 3 集成式模型架構

4 結果與討論

4.1 自動編碼器效果

自動編碼器透過模擬與實機各別的訓練集65模次之8個壓力資訊訓練模型，各別的測試集16模次之8個壓力資訊訓練模型進行編碼與解碼，而圖 4到圖 6為測試集之 $RMSE$ 算數平均值，並繪製成圖表。本研究將實機的單一感測器壓力資訊從60000筆數據降維成160個壓力特徵，模擬的單一感測器壓力資訊也從800個降維成160個壓力特徵，降維程度在實機達到375倍，在模擬達到5倍都大幅縮減原始數據量。本研究使用 $RMSE$ 來評估自動編碼器效果，透過解碼器將萃取之壓力特徵還原成原始數據並比較，可以看出在充填、保壓階段實機的 $RMSE$ 值都小於4 MPa，在冷卻階段都小於3 MPa，而模擬在三個階段更是都小於1 MPa。將壓力資訊透過自動編碼器萃取出壓力特徵後，仍能保持高的還原結果且實現了資料降維。

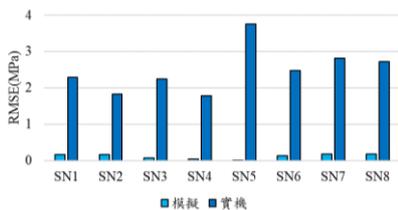


圖 4 充填階段解碼 $RMSE$ 比較圖

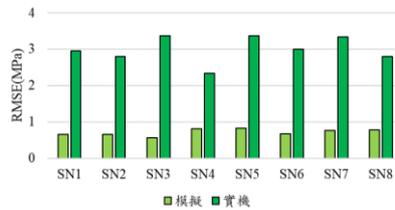


圖 5 保壓階段解碼 $RMSE$ 比較圖

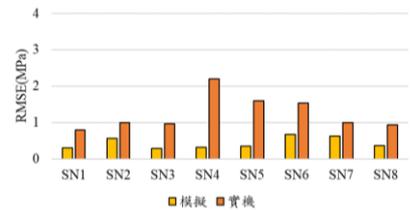


圖 6 冷卻階段解碼 $RMSE$ 比較圖

4.2 多層感知器效果

本研究各別將模擬與實機的三個製程階段的壓力特徵做為多層感知器之輸入，模擬與實

機單一模次共480個壓力特徵，三個寬度、兩個長度、總重量與產品重量為預測之目標。本研究共分為100%模擬資料集、100%實機資料集、80%模擬+20%實機混合資料集與50%模擬+50%實機混合資料集所訓練之多層感知器，其預測效果在100%模擬資料集之長度預測達到平均RMSE為0.014 mm，有著好的預測效果。

4.3 100%模擬資訊之集成式預測效果

將81模次之100%模擬的資料集進行本研究所提出集成式模型訓練與測試，將自動編碼器與多層感知器結合，達到模擬射出件多品質的預測。在輸入資料為全部來自模擬之結果的模型下，將模擬與預測值之寬度、長度和總重量繪製出散佈圖，如圖 7、圖 8和圖 9所示。而模擬射出件多品質預測又以總重量表現最優， R^2 約為0.93的預測高度密集程度。可以知道在輸入為100%模擬的資料集加上集成式模型，達到良好的預測效果。

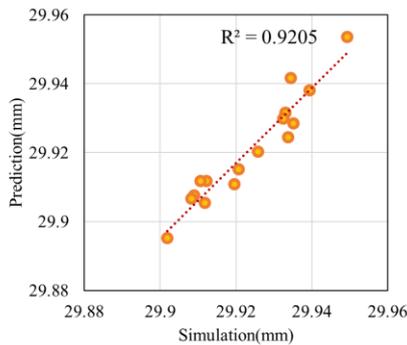


圖 7 100%模擬資料集
預測寬度散佈圖

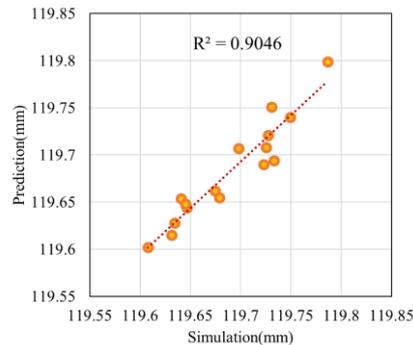


圖 8 100%模擬資料集
預測長度散佈圖

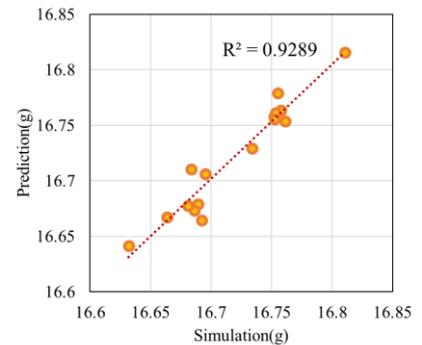


圖 9 100%模擬資料集
預測總重量散佈圖

4.4 100%實機資訊之集成式預測效果

將81模次之100%實機的資料集進行本研究所提出集成式模型訓練與測試，將自動編碼器與多層感知器結合，達到實機射出件多品質的預測。輸入資料為全部來自實機之結果的模型下，將實際與預測值之寬度、長度和總重量繪製出散佈圖，如圖 10、圖 11和圖 12所示。而實機射出件多品質預測又以W2表現最優， R^2 約為0.07。可以知道在輸入為100%實機的資料集加上集成式模型，可以達到預測品質的效果，但預測結果較為不佳。

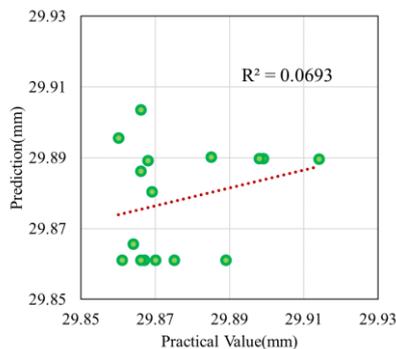


圖 10 100%實機資料集
預測寬度散佈圖

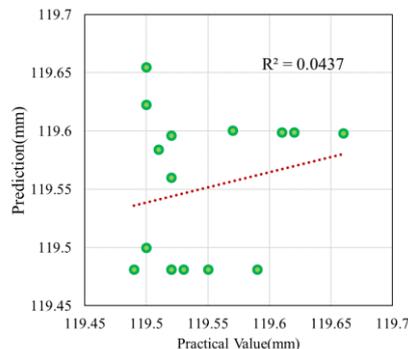


圖 11 100%實機資料集
預測長度散佈圖

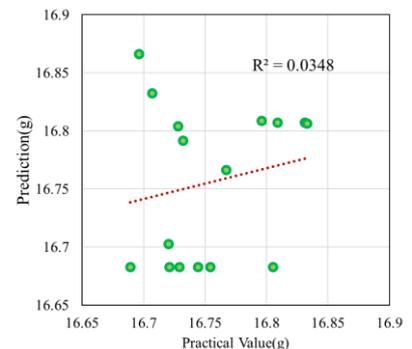


圖 12 100%實機資料集
預測總重量散佈圖

4.5 80%模擬+20%實機資訊之集成式預測結果

本研究所提出混合資料集的技术，將80%的模擬資料集為64模次結合20%的實機資料集為16模次，共80模次的混合資料集進行集成式模型的訓練，也將剩餘未被選取之17模次的模擬資料當作此模型的輸入進行測試，將模擬與預測值之寬度、長度和產品重量繪製出趨勢圖，如圖 13、圖 14和圖 15所示。可以看出將模擬資料透過此混合資料集訓練之集成式模型進行品質預測，其預測值較為靠近模擬值，因模型訓練之輸入為模擬較實機多模次所導致。而在

產品重量上有著好的預測效果， R^2 約為0.67。透過本研究所提出之方法，不僅減少了80%的實機資料，也達到預測射出件多品質。

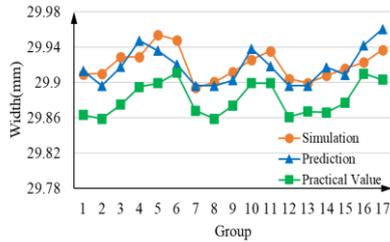


圖 13 80%模擬+20%實機混合資料集預測寬度趨勢圖

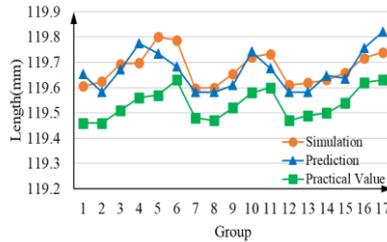


圖 14 80%模擬+20%實機混合資料集預測長度趨勢圖

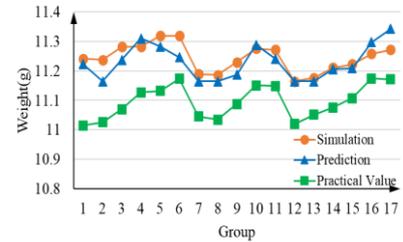


圖 15 80%模擬+20%實機混合資料集預測產品重量趨勢圖

4.6 50%模擬+50%實機資訊之集成式預測結果

本研究所提出混合資料集的技術，將50%的模擬資料集為40模次結合50%的實機資料集為40模次，共80模次的混合資料集進行集成式模型的訓練，也將剩餘未被選取之41模次的模擬資料當作此模型的輸入進行測試，將模擬、實機與預測值之寬度、長度和產品重量趨勢繪製程圖表，如圖 16、圖 17和圖 18所示。可以看出將模擬資料透過此混合資料集訓練之集成式模型進行品質預測，其預測值較介於模擬值與實機值之間，因模型訓練之輸入為模擬與實機模次各半所導致。且在L2上有著好的預測效果， R^2 約為0.7。透過本研究所提出之方法，使預測值介於模擬與實際值之間，不僅減少了50%的實機資料收集，還減少了50%的模擬品質結果差異，並達到數位化整合之技術。

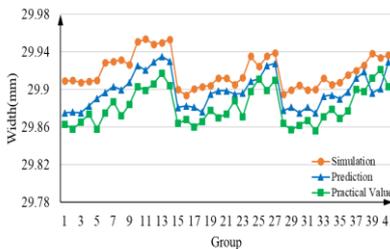


圖 16 50%模擬+50%實機混合資料集預測寬度趨勢圖

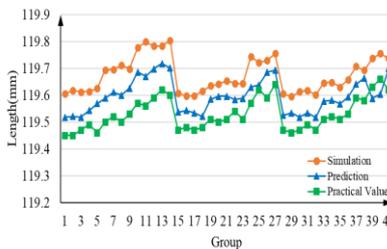


圖 17 50%模擬+50%實機混合資料集預測長度趨勢圖

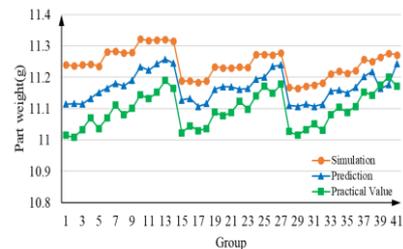


圖 18 50%模擬+50%實機混合資料集預測產品重量趨勢圖

5 結論

本研究透過數位化整合的技術配合集成式模型，達到了減少模擬與實機之間的差異，還減少了實機數據的收集。在20%實機訓練集+80%模擬資料集訓練之多層感知器，預測出之品質介於實機與模擬品質之間，且預測品質結果較相似於模擬之品質。以50%實機訓練集+50%模擬資料集訓練之多層感知器，預測出之品質介於實機與模擬品質之間，且品質預測結果較模擬品質更接近實機品質大約50%。透過本研究所提出之50%模擬與50%實機混合資料集訓練的集成式模型，達到透過輸入為模擬之壓力特徵，預測出多品質減少了與實機品質50%的差異，與減少實機數據的收集在模型訓練上，最終達到數位化整合技術與實機數據減量，對於減少時間與人力成本上達到傑出的效果，希望對射出產業有著實際的應用。

6 誌謝

本論文為國科會計畫編號NSTC-112-2221-E-003-021-MY2之計畫，由於國科會的支持，使本計畫得以順利進行，特此致上感謝之意。



7 參考文獻

- [1] J. Gim, C.-Y. Lin, L.-S. Turng, In-mold condition-centered and explainable artificial intelligence-based (IMC-XAI) process optimization for injection molding, *Journal of Manufacturing Systems* 72 (2024) 196–213. <https://doi.org/10.1016/j.jmsy.2023.11.013>.
- [2] S.O. Otieno, J.M. Wambua, F.M. Mwema, E.T. Mharakurwa, T.-C. Jen, E.T. Akinlabi, A predictive modelling strategy for warpage and shrinkage defects in plastic injection molding using fuzzy logic and pattern search optimization, *J Intell Manuf* (2024). <https://doi.org/10.1007/s10845-024-02331-4>.
- [3] K. Vassakis, E. Petrakis, I. Kopanakis, Big Data Analytics: Applications, Prospects and Challenges, in: G. Skourletopoulos, G. Mastorakis, C.X. Mavromoustakis, C. Dobre, E. Pallis (Eds.), *Mobile Big Data: A Roadmap from Models to Technologies*, Springer International Publishing, Cham, 2018: pp. 3–20. https://doi.org/10.1007/978-3-319-67925-9_1.
- [4] P. Hehenberger, B. Vogel-Heuser, D. Bradley, B. Eynard, T. Tomiyama, S. Achiche, Design, modelling, simulation and integration of cyber physical systems: Methods and applications, *Computers in Industry* 82 (2016) 273–289. <https://doi.org/10.1016/j.compind.2016.05.006>.
- [5] P. Zheng, H. wang, Z. Sang, R.Y. Zhong, Y. Liu, C. Liu, K. Mubarak, S. Yu, X. Xu, Smart manufacturing systems for Industry 4.0: Conceptual framework, scenarios, and future perspectives, *Front. Mech. Eng.* 13 (2018) 137–150. <https://doi.org/10.1007/s11465-018-0499-5>.
- [6] X. Dong, Z. Yu, W. Cao, Y. Shi, Q. Ma, A survey on ensemble learning, *Front. Comput. Sci.* 14 (2020) 241–258. <https://doi.org/10.1007/s11704-019-8208-z>.
- [7] R. Kumari, K. Saini, Artificial Intelligence and Predictive Analytics: A Novel Approach for Molded Product Quality Improvement, *International Journal of Intelligent Systems and Applications in Engineering* 12 (2024) 652–660.
- [8] Y. Lockner, C. Hopmann, Induced network-based transfer learning in injection molding for process modelling and optimization with artificial neural networks, *Int J Adv Manuf Technol* 112 (2021) 3501–3513. <https://doi.org/10.1007/s00170-020-06511-3>.