



以壓力特徵映射與神經知識轉移實現射出成型之跨材料品質預測

Cross-Material Quality Prediction in Injection Molding through Pressure Feature Mapping and Neural Knowledge Transfer

周希謠、官曉芸、沈宸緯、王靜嫻、柯坤呈*

國立臺灣師範大學機電工程學系

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

摘要

在射出成型製造過程中，壓力曲線為判斷產品品質的關鍵依據之一。傳統上，品質分析多依賴專家經驗判讀，然而此方式不僅具主觀性，且在面對大量生產數據時效率低落，難以因應現代智慧製造對即時性與自動化的需求。隨工業4.0及人工智慧技術的快速發展，建立一套客觀且可自動化執行的品質預測系統，已成為製造領域的重要課題。本研究運用Moldex3D模流分析軟體，針對聚丙烯(Polypropylene, PP)與聚苯乙烯(Polystyrene, PS)材料進行模擬射出實驗。藉由田口實驗法進行參數設計，並透過調整模具溫度進行增量擾動實驗，以獲取多樣化資料，進而提升人工智慧模型的學習效率與泛化能力。研究中先針對PP材料的壓力曲線進行編碼與特徵萃取，建立其與成品品質之間的對應模型，實現智慧品質預測。隨後進一步建構跨材料的特徵轉換模型，透過神經網路學習PP與PS壓力特徵之間的關聯性，使得模型能在無需重新訓練的情況下，延伸應用至其他材料。此方法不僅提高了模型的可遷移性，也展現出在實驗資料受限的情況下，仍具備良好的預測準確性與實用價值。

關鍵詞：智慧製造、射出成型、模流分析、品質預測

Abstract

In the injection molding process, the pressure curve serves as a key indicator for assessing product quality. Traditionally, quality analysis relies heavily on expert interpretation, which is subjective and inefficient, especially when handling large volumes of production data. Such limitations make it difficult to meet the real-time and automation demands of modern smart manufacturing. With the rapid advancement of Industry 4.0 and artificial intelligence (AI) technologies, developing an objective and automated quality prediction system has become a critical challenge in the manufacturing field. This study utilizes Moldex3D simulation software to conduct virtual injection molding experiments using polypropylene (PP) and polystyrene (PS) materials. The Taguchi method is applied for parameter design, and incremental disturbance experiments are conducted by adjusting mold temperature to obtain diverse datasets, thereby enhancing the learning efficiency and generalization of the AI model. The research first focuses on encoding and extracting features from PP pressure curves to establish a predictive model correlating these features with product quality. Subsequently, a cross-material feature transformation model is developed, where a neural network learns the relationship between pressure features of PP and PS. This enables the model to extend its predictive ability to other materials without retraining. The proposed method not only improves model transferability but also demonstrates high prediction accuracy and practical value, even with limited experimental data.

Keywords: Smart Manufacturing, Injection Molding, Mold Flow Analysis, Quality Prediction

1. 前言



射出成型為塑膠加工中應用最廣泛的製造技術之一，因其具備高效率與高重複性的特性，廣泛應用於各產業。然而，成型品質受多項製造參數影響，參數控制之偏差即可能導致成品缺陷並增加製造成本。其中，壓力曲線作為反映整個射出週期中物理行為的重要指標，與產品品質有很高的相關性，因此常被用作製造監控與品質評估的重要依據。傳統品質分析方式多仰賴專家經驗進行壓力曲線判讀，不僅具高度主觀性，且在面對大量生產數據時效率低落，難以因應智慧製造中對於即時性與高自動化的高標準需求。隨著工業4.0與人工智慧技術的發展，如何將AI技術導入製造分析，以實現客觀與自動化的品質預測，成為當前的研究方向。近年已有研究探討將神經網路應用於射出成型製造來預測產品品質，但大多聚焦於單一材料，缺乏跨材料條件下的泛化能力。因此本研究以模流分析模擬結合AI技術為基礎，探討多材料壓力特徵的學習與遷移，在有限的實驗條件下實現更具彈性與實用性的品質預測系統。

2. 文獻探討

2.1 智慧製造

智慧製造是融合資訊科技、通訊技術與製造工程的整合性製造模式，旨在強化製造流程的彈性、效率與智慧化。隨著工業4.0的推動，智慧製造已逐漸取代傳統仰賴經驗與人力的製造流程，轉向數據驅動與自動決策發展[1]。透過即時資料收集、感測器監控、雲端運算與人工智慧技術，實現即時監控、預測性維護以及製程最佳化，大幅提升產品品質並降低資源浪費。在射出成型等精密製造中，智慧製造的導入不僅有助於提升製造的速度與穩定性，還可強化品質的一致性[2]。尤其面對多樣化、小量化的生產需求，智慧製造提供了更具彈性與可調整性的技術基礎。這種轉變也促使相關研究朝向整合模擬技術與AI模型，以實現更智慧與高效率的製造管理模式。

2.2 射出成型與模流分析

射出成型是一種廣泛應用於塑膠製品生產的加工技術，其優點包括高效率大量生產與高精度產品製造。透過加熱塑膠原料使其熔融，再以高壓注入模具中，冷卻固化後脫模即完成成品。成型過程可分為充填、保壓與冷卻三個階段：充填階段負責將熔料注入模具；保壓階段維持壓力以補償材料收縮並確保模具充滿；冷卻階段則使塑料在模內固化以利脫模。此過程中，塑料的流動行為、壓力分佈與冷卻速率等因素，皆對成品品質有顯著影響[3]。

為提升射出成型的穩定性與成品的一致性，模流分析扮演重要的角色。模流分析是一種利用電腦模擬的工程工具，主要以有限元素法(FEM)為基礎，模擬熔融塑料於模具腔內的流動、壓力與溫度變化等行為，呈現完整射出週期的物理現象。模流分析對製造過程具有多項幫助。透過模擬產品實際射出前的成型過程，可預先掌握可能出現的缺陷風險，如短射、翹曲、氣泡與熔接線等問題，進而提前改善設計或製造條件。藉由模擬結果，工程師可從機台參數、模具設計與冷卻系統配置，到成品結構等各層面進行改善，有效降低試模次數與材料浪費，並縮短產品開發時間，不僅提升射出成型的良率，也有助於製造流程的系統化與智慧化。模流分析的應用代表從經驗導向轉為數據驅動的決策模式，提升產品開發更具科學依據與效率。目前業界已廣泛將模流分析應用於電子、汽車與醫療等多種產業，進一步顯示其在提升效率與產品品質方面的重要性[4]。



2.3 人工智慧應用於射出成型領域

人工智慧技術如機器學習與深度學習可以透過大量製造數據，建立預測模型並預測成品品質。例如，利用多層感知器對壓力曲線進行學習，可有效預測如尺寸或重量等產品指標。近年來，已有研究提出整合感測器收集的壓力數據與人工智慧模型，建立一套可即時預測射出成型成品之多項品質指標的系統[5]。此方法不僅可涵蓋尺寸與重量等品質類型，也能處理殘留應力等傳統難以量測的物理特性。此應用顯示人工智慧技術具備在射出成型過程中進行品質分析的潛力，有助於降低量測成本並提升效率。透過人工智慧，不僅可以縮短開發時間、降低試模次數，也可以提升良率與生產穩定性，實現由經驗導向轉向數據驅動的智慧射出成型。隨感測器與資料擷取技術的進步，人工智慧在射出成型領域的重要性將日益提升，為產業帶來新的競爭優勢。

3. 研究方法

3.1 實驗設備與軟體

本研究之模流軟體使用Moldex3D 2024進行模擬射出實驗分析，並提取模擬的壓力數據與其對應的產品品質結果，作為後續提取壓力特徵與人工智慧模型訓練的數據來源，其成品品質量測與感測擷取位置如圖1所示，對成品之三個寬度與兩個長度品質進行量測。模擬實驗之機台使用油電式射出機(LA40, SODICK, Japan)，此機台具備高精度與優異穩定性，適合用於對穩定性要求較高的產品製造。材料使用聚丙烯PP(TAIRIPRP K1035, FC&F Corp., Taiwan)。其以輕量化、抗化學性與良好的加工性著稱，常用於包裝材料及日用品的製造。使用MATLAB_R2023b進行數據前處理、自動編碼器編碼與多層感知器模型訓練。計算單元為AMD Ryzen 9 7900X 12核心、NVIDIA GeForce RTX 4060顯示卡和64GB RAM，作為實驗運算平台。

3.2 實驗流程圖

如圖2所示，本研究針對聚丙烯與聚苯乙烯兩種材料進行模擬實驗，建立壓力特徵與產品品質之間的預測模型。首先針對PP，使用四因子三水準之田口實驗法進行實驗設計，並透過擾動實驗建立85組實驗配置，擷取其壓力曲線資料與品質結果。接著以自動編碼器進行壓力特徵萃取，並將其特徵作為輸入，使用多層感知器建立品質預測模型。在PS部分，同樣進行模擬實驗並萃取壓力特徵，以PP特徵為輸入，PS特徵為輸出建立PP與PS之間的特徵對應關係，訓練一特徵生成模型，實現特徵轉換。完成後，反向使用PS特徵作為輸入，生成與PP特徵相似的「偽特徵」，並輸入至PP品質預測模型取得對應的「偽品質」。最後以PS特徵與「偽品質」建立初步的PS品質預測模型，並透過實際之PS品質數據進行微調，以提升模型預測性能。

3.3 實驗設計與資料擴增

本研究採用田口實驗法進行實驗設計，並利用L9正交表配置四因子三水準之參數組合。田口實驗法能在時間與成本受限的情況下，快速找出穩定且效果良好之條件組合的優勢[6]。所選用的四因子分別為射出速度、保壓壓力、材料溫度與模具溫度，藉由成型參數的調整，探討其對壓力曲線與產品品質的影響。實驗初期共進行兩次L9田口實驗，第一次先透過四因子三水準設計，以找出初步的最佳參數組合；再根據第一次實驗結果，將參數範圍縮小並進行第二次田口實驗，進一步探索最佳化參數設定，兩次實驗共可獲得18組實驗配置與其結果。然而在分析實驗結果時，發現一組別因材料溫度與模具溫度設定較低，導致冷卻階段無壓力數據，因此剔除該組別，最終保留17組作為標準配置。為了進一步擴充資料量並提升模型訓練時的泛化能力，本研究在17組標準配置為基礎，針對模具溫度進行擾動調整，分別設定為原設定值的+2.5%、-2.5%、+5%、-5%，最終建立共85組完整實驗配置。此擾動實驗有效提升數據的多樣性，為後續自動編碼器之特徵萃取與多層感知器模型訓練提供可靠性的資料基礎。

3.4 積分排序

本研究使用兩種不同材料進行模擬實驗，因兩材料採用不同參數配置，無法直接以相同配置進行材料之間的對應。因此，本研究設計一種基於壓力曲線積分的排序對應方法，以建立兩種材料之間的對應關係。首先對每組實驗所獲得之完整射出週期壓力曲線進行數值積分。並採用梯形法(Trapezoidal Rule)做積分計算，方程式如式(1)。針對兩種材料，分別計算各實驗配置之壓力積分值，並依照其大小進行排序，獲得各自的排序名次。由於PP的實驗組數為85組，PS則為81組，為使兩材料有所對應，本研究將PP依照積分排序後分四等分，並剔除每等分中的最後一組，最終保留與PS相同的81組。隨後將PP與PS依各自排序名次進行對應。此排序對應關係將作為後續訓練特徵生成模型數據來源，以建立PP與PS壓力特徵之間的映射關係。

3.5 人工智慧模型

3.5.1 自動編碼器

本研究中應用自動編碼器(Autoencoder, AE)進行壓力曲線特徵萃取，自動編碼器是一種常見的神經網路架構，屬於無監督式學習模型(Unsupervised Learning Model)，主要應用於資料降維與特徵提取[7]。其基本架構包含編碼器與解碼器，透過最小化重建誤差，使模型在保留關鍵資訊的同時，盡可能讓重建資料接近原始輸入數據，其公式如式(2)，其中 W_e 和 b_e 分別為編碼器的權重與偏置項， f 為非線性的激勵函數。本研究將模擬實驗中獲得的壓力曲線依充填、保壓與冷卻三階段進行分段處理，並針對各階段分別進行特徵萃取。每階段之壓力曲線皆壓縮為20個特徵資訊，作為後續品質預測模型的輸入，藉此簡化數據維度、提升模型訓練效率，有助於建立具代表性且高效的資料，為後續機器學習模型提供穩固的基礎。

3.5.2 多層感知器

本研究使用多層感知器(Multilayer Perceptron, MLP)建立壓力特徵與產品品質之間的預測模型。MLP為一種常見的神經網路，屬於監督式學習模型(Supervised Learning Model)，廣泛應用於回歸與分類任務[3]。其目標為學習輸入數據與對應目標輸出之間的非線性映射關係，以實現數據的預測能力。其方程式如式(3)， $W^{(l)}$ 為該層權重， $b^{(l)}$ 為偏置項， f 為非線性激勵函數。透過反向傳播演算法(Backpropagation)與梯度下降法，模型可以根據損失函數的誤差逐步更新權重，達到最小化預測誤差。在本實驗中，模型以壓力特徵作為輸入，預測模擬射出實驗之產品品質，並採用均方根誤差(Root Mean Square Error, RMSE)作為損失函數，以衡量預測值與實際值之間的差異，方程式如式(4)， y_i 為原始輸入值， y'_i 為模型預測值。PS品質預測模型初步建立後，實驗使用PS模擬品質數據進行微調(Finetune)，分別使用20、40、60與80筆數據做模型調整訓練，對25%、50%、75%與100%的微調數據量，探討資料量對模型性能影響。

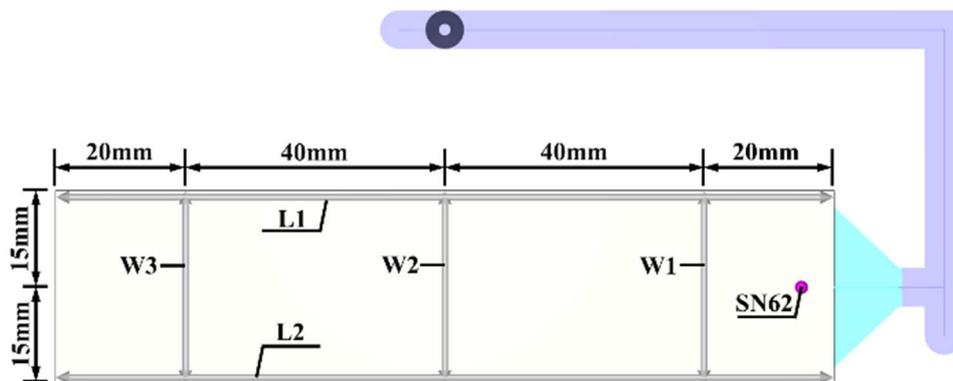


圖1 成品品質量測與壓力感測擷取位置

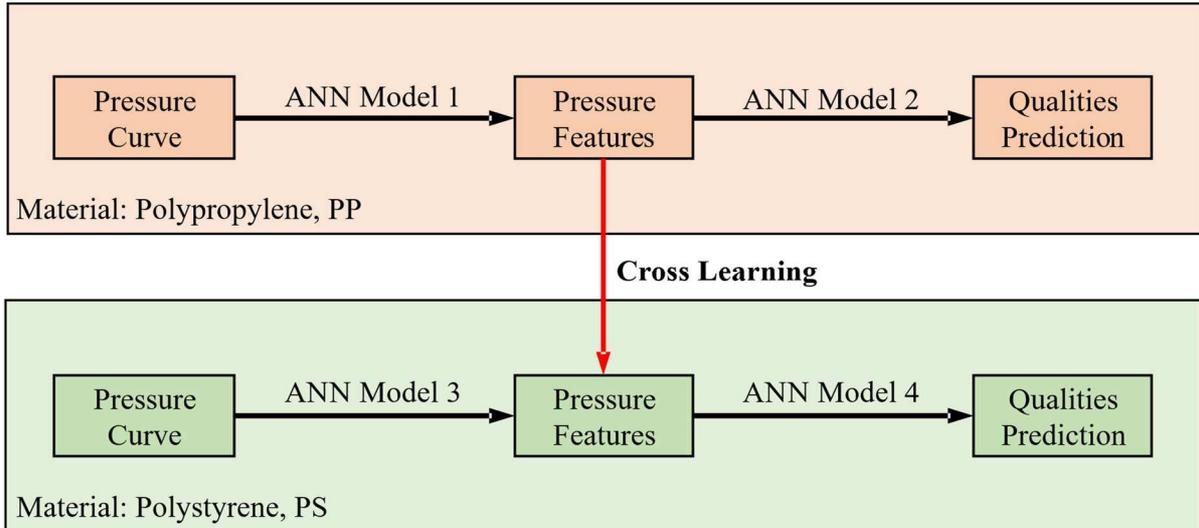


圖2 實驗流程圖

$$I = \sum_{i=1}^{n-1} \frac{(x_{i+1} - x_i)}{2} \times (y_i + y_{i+1}) \quad (1)$$

$$h = f(\mathbf{W}_e x + \mathbf{b}_e) \quad (2)$$

$$h^{(l)} = f(\mathbf{W}^{(l)} x^{(l-1)} + \mathbf{b}^{(l)}) \quad (3)$$

$$L = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (4)$$

4. 結果與討論

4.1 自動編碼器之壓力編碼結果

實驗針對81模次之三階段射出成型壓力數據，使用自動編碼器進行特徵壓縮與還原分析。每階段的2000筆壓力數據透過自動編碼器壓縮至20個特徵數據，再進行資料重建，並將還原數據與原始模擬壓力進行RMSE誤差計算。各階段的平均RMSE值與標準差結果如表1所示。根據結果，充填階段之RMSE誤差較小，如圖3(a)所示，主要因其壓力變化相對平緩且波動幅度較低，自動編碼器在進行特徵壓縮與還原時，能較為準確地保留主要特徵資訊；保壓與冷卻階段的壓力變化幅度較大且變化較為複雜，導致自動編碼器在還原時產生較高的誤差。如圖3(b)、(c)所示。但整體而言，各階段的RMSE平均值均低於0.8 MPa，顯示自動編碼器能夠準確且有效地學習並重構主要的壓力趨勢，確保所提取的壓力特徵具備代表性，為後續品質預測提供有利的數據支持。

4.2 PP多層感知器之品質預測結果

透過分段編碼建立多層感知器模型，以進行產品品質預測。模型輸入為單一模次所萃取之60個壓力特徵，預測目標為三個寬度品質與兩個長度品質。模型經訓練後，如表2所示，其寬度品質預測之RMSE均低於0.012 mm；長度品質預測部分之RMSE均低於0.016 mm。依結果



所示，各品質之平均相對誤差均低於0.04%，R-Square均高於0.95的高線性度，顯示其定且可靠的預測能力。除了驗證在PP品質預測中的可行性與準確性外，亦可為後續產生「偽品質」提供可靠依據。

4.3 PS多層感知器使用原始模擬數據微調之品質預測結果

PS品質預測模型在使用「偽品質」初步建立MLP模型後，使用原始PS模擬品質進行微調。在不同微調數據量下的RMSE結果如圖4(a)所示，以W1使用20筆數據微調為例，RMSE降至0.0091 mm，相比未微調下降約72%，顯示微調可有效降低誤差提升模型性能；全距結果如圖4(b)所示，以L1使用20筆數據微調為例，全距降至0.2738 mm，降低約67%，預測之跳動量顯著下降；標準差結果如圖4(c)所示，以W1使用20筆數據微調為例，標準差下降至0.0115 mm，降低約69%，顯示預測結果更加穩定。綜合上述結果可得知，透過少量實際資料進行微調，能夠顯著改善品質預測模型之預測表現。

表 1 充填、保壓與冷卻階段壓力編碼之 RMSE

	RMSE 平均值(MPa)	RMSE 標準差(MPa)
Filling Stage	0.0407	0.0005
Packing Stage	0.7730	0.0855
Cooling Stage	0.5158	0.0730

表 2 PP 品質預測模型之結果

預測品質	平均 RMSE 值(mm)	平均相對誤差(%)	R-Square
W1	0.0120	0.0400	0.9693
W2	0.0063	0.0209	0.9936
W3	0.0058	0.0194	0.9948
L1	0.0123	0.0102	0.9981
L2	0.0160	0.0134	0.9968

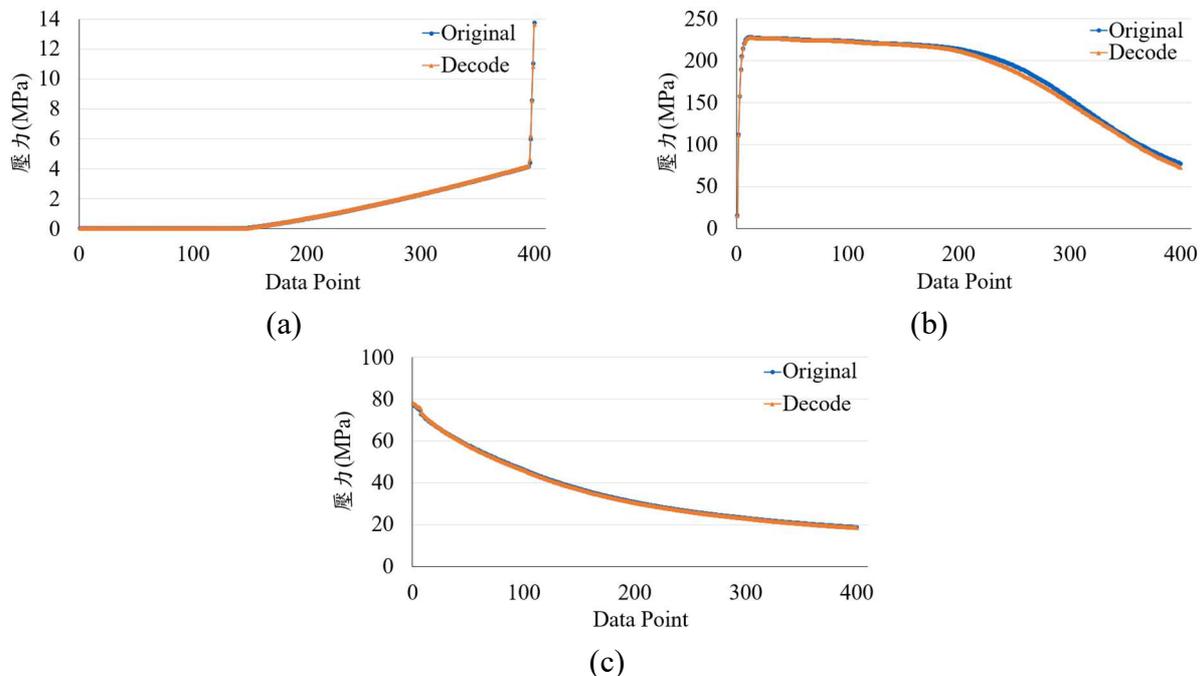


圖 3 各階段編碼(a)Filling Stage、(b)Packing Stage 與(c)Cooling Stage 之模擬壓力值與預測值比較

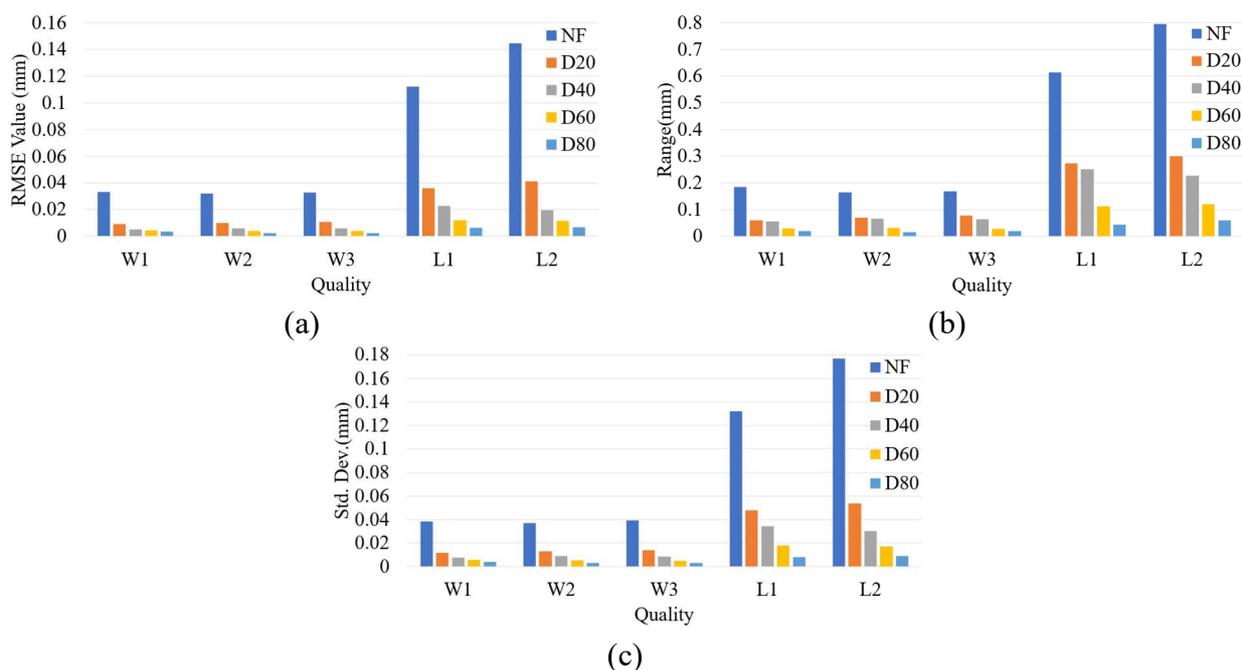


圖 4 不同微調數據量之預測品質(a)RMSE 比較圖、(b)全距比較圖與(c)標準差比較圖

5. 結論

本研究提出一套結合自動編碼器與多層感知器的跨材料品質預測系統，成功驗證在缺乏目標材料之完整品質數據的情況下，仍能透過特徵生成模型與少量數據微調達成準確預測。研究中以PP材料建立初步品質預測模型，並建立特徵生成模型以實現PP與PS間的特徵對應，進一步以「偽品質」訓練PS預測模型，並透過少量的實際成品品質資料進行微調，有效提升模型性能。實驗結果顯示，即使僅使用20筆資料進行微調，亦能顯著降低預測誤差與跳動量，證明此方法於跨材料知識遷移之可行性與實用價值。此研究方法除了展現良好的預測能力外，同時也具備實務應用潛力。未來在實際射出成型時，僅需針對新材料進行少量品質量測，即可進行模型微調，快速建立適用於該材料的品質預測模型，降低資料收集成本，提升智慧製造的靈活性與效率。後續可以延伸至其他材料，進一步拓展應用範圍，實現跨材料且高效率的品質預測。

6. 誌謝

感謝科盛科技與國科會(計畫編號：112-2221-E-003 -021 -MY2與113-2622-E-003-003)的計畫支持，也感謝實驗室同仁在實驗與資料處理上的協助，讓本研究得以順利完成。

7. 參考文獻

- [1] M.R. Khosravani, S. Nasiri, T. Reinicke, Intelligent knowledge-based system to improve injection molding process, *Journal of Industrial Information Integration* 25 (2022) 100275. <https://doi.org/10.1016/j.jii.2021.100275>.
- [2] H. Lee, K. Ryu, Y. Cho, A Framework of a Smart Injection Molding System Based on Real-time Data, *Procedia Manufacturing* 11 (2017) 1004–1011. <https://doi.org/10.1016/j.promfg.2017.07.206>.
- [3] K.-C. Ke, M.-S. Huang, Quality Prediction for Injection Molding by Using a Multilayer



- Perceptron Neural Network, *Polymers* 12 (2020) 1812. <https://doi.org/10.3390/polym12081812>.
- [4] I. Matin, M. Hadzistevic, J. Hodolic, D. Vukelic, D. Lukic, A CAD/CAE-integrated injection mold design system for plastic products, *Int J Adv Manuf Technol* 63 (2012) 595–607. <https://doi.org/10.1007/s00170-012-3926-5>.
- [5] K.-C. Ke, P.-W. Wu, M.-S. Huang, Multi-quality prediction of injection molding parts using a hybrid machine learning model, *Int J Adv Manuf Technol* 131 (2024) 5511–5525. <https://doi.org/10.1007/s00170-023-12329-6>.
- [6] F. Hentati, I. Hadriche, N. Masmoudi, C. Bradai, Optimization of the injection molding process for the PC/ABS parts by integrating Taguchi approach and CAE simulation, *Int J Adv Manuf Technol* 104 (2019) 4353–4363. <https://doi.org/10.1007/s00170-019-04283-z>.
- [7] K.-C. Ke, J.-C. Wang, S.-C. Nian, Data-driven quality prediction in injection molding: An autoencoder and machine learning approach, *Polymer Engineering & Science* 64 (2024) 4520–4538. <https://doi.org/10.1002/pen.26866>.