



以模流分析、製程特徵萃取與機器學習技術建立快速光彈條紋分佈之預測技術 Establishment of a fast prediction technology for photoelasticity fringes distribution based on mold-flow analysis, process characteristic extraction, and machine learning techniques

柯坤呈^{1*}、張智霆¹、王瑞志¹、陳咨光²

¹ 國立臺灣師範大學機電工程學系

² 國立臺灣科技大學機械工程系

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

摘要

射出成型製程具備大量生產特點，廣泛用於光學、汽車和電子等相關產業。然而，大量生產同時帶來生產品管上的挑戰。傳統光學成型件通常需要進行光彈條紋檢測，以判斷殘留應力分佈，但這種操作不便捷且耗時，不易在線上使用。因此，本文提出了一種基於模流分析的方法，利用熔膠壓力和光彈條紋圖資訊，透過數據處理和機器學習模型建立了一套自動化光彈條紋圖預測系統，提供即時且高精準的光學射出成型件預測結果。首先，本研究以實驗設計法和模流軟體進行模擬實驗，獲得多種成型樣態；其次，透過數據前處理、數據降維和資訊指標化等技術，於原始資訊中萃取出熔膠壓力指標和光彈條紋圖特徵資訊；最後，以機器學習演算法串接熔膠壓力指標和光彈條紋特徵值進行模型建置、學習、優化與測試。結果表明，本研究之推論時間與測試損失值分別低於0.5秒與0.3，具備高精準預測結果。該技術可於多模態資訊中獲得關鍵學習結果，提供射出成型製程生產過程更好的光彈條紋分佈預測狀況，進而實現建立光學品質快速判斷之應用。此技術不僅能即時預測生產品質，同時可大幅減少時間成本、提高生產效率，為射出成型產業提供一種創新的生產方式，也為國內的橡塑膠產業提供一種創新自動化應用方案。

關鍵詞：模流分析，大數據分析，機器學習，光彈條紋、自動化

Abstract

Injection molding is widely used in optics, automobiles, and electronics due to high-volume production, but challenges in production management arise. Traditional inspection methods for residual stress distribution in optical molded parts are inconvenient and time-consuming. To address this, a method based on mold flow analysis, melt pressure, and photoelastic fringe pattern information is proposed. An automated photoelastic fringe pattern prediction system is established through machine learning models to provide real-time and high-precision optical injection. Experimental design methods and mold flow software are used to obtain molding patterns. The machine learning algorithm connects the melt pressure index and the characteristic value of the photoelastic fringe for model building, learning, optimization, and testing. The results show high-accuracy prediction with low inference time and test loss value. This technology provides better prediction of photoelastic fringe distribution in injection molding production, enabling rapid judgment of optical quality.

Keywords: mold flow analysis, big data analysis, machine learning, photoelastic stripes, automation

1. 前言

高分子加工領域中，殘留應力的控制和測量具有極其重要的意義，對產品的性能與使用壽命產生顯著影響。殘留應力的產生原因眾多，包括射出速度、受模具溫度影響的冷卻速度、

高分子材料在高速流動下的剪切力以及流動過程中與模具之間的摩擦力等。殘留應力可能導致射出件出現扭曲、翹曲等缺陷，同時也可能導致機械性質下降，這些問題對產品的外觀品質和耐久性都產生嚴重影響。因此，在高分子加工過程中，對殘留應力進行測量和控制對於提升產品品質至關重要。研究提出，透過機器學習之集成式模型訓練，在不破壞成品的情況下，快速預測出與殘留應力分布相關之光彈圖形。

2. 研究目的

光彈條紋圖檢測，是一種量測材料內部應力殘留應力的非破壞性方法，主要特點是具有非破壞性、高靈敏度、全面檢測、快速量測等優點。相比於其他檢測方法，如X光繞射分析、切割法等，光彈法更適合布局於產線。因此，本研究旨將光彈條紋圖透過人工智慧方法進行特徵萃取，並導入模流軟體壓力感測資訊，達到快速光彈條紋圖預測之研究目標。

在建立人工智慧模型方面，本研究提出了完整的集成式模型學習框架。透過射出成型過程中監測之壓力資訊，即時預測成品光彈條紋圖作為判讀殘留應力依據，以確保後續成品品質是否符合預期之依據。針對壓力訊號進行資料處理，將壓力指標與光彈圖特徵相互擬合，即時預測殘留應力達成智慧製造目的。本研究對於預測光學件殘留應力未來發展有著重要意義，通過數據蒐集與人工智慧建模，有助於準確預測成品品質，增加產品良率、節省成本。

3. 文獻探討

3.1 傳統光學量測

光學量測在工業領域已經被廣泛利用，具有非破壞性且高精度的特質，因此成為許多應用領域的量測方法。在光學方法量測殘留應力E. Bemporad等人[1]比較X射線繞射(X-ray Diffraction)與聚焦離子束(Focused Ion Beam)應用於薄膜殘留應力量測，在陰極弧PVD塗層的情況下，大量金屬微滴的存在對XRD應力測量有顯著影響，研究得出X射線繞射較聚焦離子束不受表面缺陷影響。然而光學儀器的高昂價格，也成為其在工業應用上的一大阻礙，

3.2 智慧製造

智慧製造是一種新興的生產模式，將感測器、雲計算、通訊技術、大數據建模、模擬、人工智慧、預測工程等相互結合，以實現自動化、高效率、高品質、低成本等目的。Monzure-Khoda Kazi等人[2]提出了一種智慧製造的方法，旨在預測目標棉纖維與聚丙烯符合材料的負載與位移曲線，方法為透過人工神經網路(ANN)進行訓練。最後證實預測的特徵與先前實驗結果高度相吻合，可以在實際智慧製造過程中，作為模型預測的控制單元。Seoyeong Lee等人[3]提出了射出成型產品的異常檢測框架，稱為「兩階段異常檢測」。第一階段為數據收集到建模。第二階段為選擇異常值的可視化過程。通過這個框架，決策者可以從射出設備中檢查射出機中潛在缺陷數量。使用LSTM模型達到了超過90%的準確率，證明了實際運行是可行的。智慧工廠目前最活躍的軟硬體為傳感器和人工智慧模型，建立機器異常檢測框架。

3.3 人工智慧於成品檢測應用

人工智慧方法可以有效利用在不同領域，學者[4]提出了一種使用深度學習辦法，由干涉儀擷取的干涉條紋中，提取相位位移圖像，此方法是計算材料折射率的必要方法。為比較深度學習在萃取干涉條紋中相位位移時與傳統方法的差異性，同時將深度學習與傅立葉轉換進行比較。透過模擬所擷取大量干涉條紋圖與其相對應的相位位移，分別為神經網路輸出與輸入。結果證實，類神經網路在從未知干涉條紋圖預測相位差時，表現較傳統的傅立葉轉換擁有更好的性能。即使干涉條紋圖中出現閉合的環狀條紋，深度學習方法仍不降低準確度。

3.4 總結

本研究旨在探討如何透過人工智慧技術將高分子加工領域的壓力資訊和擷取光彈條紋圖

相互擬合，提出一套集成式學習模型，以協助射出成型領域邁向智慧製造、智慧工廠。本研究透過模流軟體，擷取壓力資訊與光彈條紋圖，並使用人工智慧之資料降維、特徵萃取、特徵預測功能，將原先看似不相關的資訊相互擬合，提出一套完整的集成式學習模型，為了實現這個目標，本研究希望藉由目前射出機上常見的壓力感測器，結合人工智慧技術對光學性質進行預測，提出有效預測模型。這將有助於提高生產效率、降低成本和提高產品品質，期待能協助高分子加工實現智慧製造並提高生產效率、降低成本和提高產品品質等優勢。

4. 研究方法

4.1 實驗設計流程圖

本研究的流程圖如圖 1 所示，分為射出成型實驗設計、大數據資料探勘和人工智慧預測訓練三個主要區塊。在射出成型實驗設計中，本研究使用全因子法，模擬共 135 組模次，並從每組中擷取壓力資訊與光彈條紋圖；在大數據資料探勘中，本研究對擷取到的壓力資訊進行資料前處理與指標化，光彈條紋圖則使用自動編碼器進行編碼以降低其特徵維度；在人工智慧預測訓練中，資料集分為訓練集(80%)和測試集(20%)，使用壓力指標與光彈條紋圖特徵值來訓練多層感知器，透過多層感知器預測特徵值，並通過解碼器獲得預測光彈條紋圖，並計算其與原圖的結構相似性指標(Structural Similarity Index)進行驗證。




圖 1 實驗流程圖




圖 2 射出件尺寸與壓力資訊擷取位置

4.2 計算單元與模擬設置

在本研究中，計算單元配置 AMD Ryzen9 6900X 12 核心處理器、Nvidia GeForce RTX 3070i 顯示卡和 64GB RAM。使用 Moldex3D 2022 進行模流分析，分析內容包含溫度、壓力、體積收縮率、位移、熱殘留應力、流動殘留應力、光學分析等。數據處理與人工智慧模型建立部分，使用 MATLAB 2023a 進行資料前處理與模型訓練。模擬射出機為油電式射出機(LA-40, Sodick, Japan)，高分子材料為熱塑性塑膠 Polystyrene (PG-33, CHIMEI, Taiwan)，其具有光澤且透明，同時有良好光學性質。在模擬參數的操作變因，包含射出速度、保壓壓力、材料溫度。

4.3 全因子實驗設計法

全因子法在人工智慧訓練中有重要優點，能夠提供高效、準確的數據集，包含各種操作變因組合，確保模型在不同條件訓練和測試泛化性。全因子法能分析因素之間交互作用，有助於理解模型行為並找出關鍵因素。本研究中，考慮短射、位移、機台最大鎖模力等成型問題，尋找最佳成型參數。透過調整射出速度(60, 70 and 80 mm/s)、保壓壓力(68, 78 and 88 MPa)、料溫(195, 200 and 205°C)，設計三因子三水準的全因子法實驗，以利後續實驗數據蒐集。

4.4 資料前處理與指標化

本研究中，針對圖 2 中，SN1、SN2、SN3、SN4，依序為進澆口、澆口、塑件中央、遠澆口，四點在充填、保壓、冷卻階段進行壓力擷取，其壓力資訊曲線圖如圖 3。本研究中其中一組模內壓力如圖 4 所示，採用兩種壓力指標。壓力峰值指標 (Pp_{index})[5]，充填至保壓階段的最大壓力。在射出成型過程中，壓力扮演驅動熔膠充填模穴的重要角色。最大壓力影響高分子材料充填到模穴的量，決定了射出成型成品的幾何品質。其中 g 表示模內壓力。壓力積分指標 (PI_{index})，充填至冷卻階段，壓力時間曲線隨時間方向積分值。此指標反映整個成型過程中的壓力特徵，在成品重量表現有顯著效果。




圖 3 SN1-SN4 壓力曲線圖




圖 4 模內壓力曲線

4.5 集成式人工智慧建模

4.5.1 自動編碼器

自動編碼器是一種廣泛被使用的神經網路架構，屬於非監督學習模型，用於從輸入資訊中自動萃取特徵。自動編碼器通常由兩部分構成，分別為編碼器與解碼器，如圖 5 所示。透過編碼器將輸入資訊壓縮為低維度特徵資訊，而解碼器則將低維度特徵資訊還原為與輸入相同維度之資訊。其目標在於還原資料與原始資料誤差降低，目標函數如式(1)。其中， N 為資料個數、 x 為輸入實際值、 $\hat{x}$ 為模型預測值、 θ 為訓練參數集合。自動編碼器的應用範圍，降維是其一個重要應用領域。高維度資訊易導致運算時間過長，因此本研究利用自動編碼器將光彈條紋圖降維。通過自動編碼器對光彈條紋圖進行特徵萃取，可有效減少本研究後續計算時間。

$$J_{AE} = \min_{\theta} L(x, \hat{x}) = \frac{1}{N} \sum_{i=1}^N \sqrt{(x_i - f_{\theta}(x_i))^2} \quad (1)$$




圖 5 自動編碼器架構

4.5.2 多層感知器

多層感知器是常見的人工神經網路(Artificial Neural Network, ANN)，屬於監督式學習模型。其由多個神經元組成，包含一層輸入層、多個隱藏層與一層輸出層。每個神經元接收來自上一層的輸出，並進行加權總合與激勵函數計算，輸出層產生最終預測結果。在訓練過程中，一般會設定損失函數用以比較實際值與預測值的誤差，並透過梯度下降法更新權重值，用以降低預測值的誤差，如式(2)。

多層感知器的優點在於，有效擬合複雜的非線性關係與解決高維數據問題。本研究中，使用多層感知器，作為壓力指標與模擬光彈圖特徵資訊的擬合方法。本研究另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，計算預測光彈圖與模擬光彈圖之誤差。計算方法如式(4)所示，其中 $\hat{\theta}$ 為估計量， θ 為被預測參數。

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

$$\rho(A, B) = \frac{1}{N-1} \sum_{i=1}^N \left(\frac{A_i - \mu_A}{\sigma_A} \right) \left(\frac{B_i - \mu_B}{\sigma_B} \right) \quad (3)$$

$$RMSE = \sqrt{E((\hat{\theta} - \theta))^2} \quad (4)$$

4.5.3 集成式人工智慧

本研究提出一結合自動編碼器與多層感知器之集成式人工智慧模型。先利用編碼器對光彈條紋圖特徵進行編碼，編碼後所得光彈圖特徵透過解碼器還原為圖片，其架構如圖6所示，並計算還原光彈圖與模擬光彈圖之SSIM數值在0.9以上，確保其潛在表示法足以表示模擬光彈圖。資料前處理對壓力資訊進行指標化。指標化結果輸入多層感知器模型，並對其對應之光彈條紋圖特徵進行預測。最後預測特徵透過解碼器進行還原，輸出預測光彈條紋圖為最終輸出結果，並以預測光彈圖與模擬光彈圖進行SSIM比較，評估集成式人工智慧模型的預測能力。




圖 6 集成式人工智慧架構

4.5.4 圖片相似度比較方法：SSIM

結構相似性指標法[6](Structural Similarity Index methodology, SSIM)，一種用於測量兩張圖像相似度的指標，透過比較圖像亮度、對比度與結構，量化兩圖像之間的相似度，其計算公式如式(5)所示，其中， $l(x, y)$ 表示亮度相似度、 $c(x, y)$ 表示對比度相似度、 $s(x, y)$ 表示結構相似度，SSIM 值之範圍於[0, 1]之間，其值越接近 1 表示兩張圖像越相似；相對地，其值越接近 0 表示相異，基於此特性，本研究採用 SSIM 評估提出之複合式模型所預測之光彈圖與模擬所得之光彈圖相似度。藉此評估方法，更有效表示集成式人工智慧模型的預測能力。

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (5)$$

5. 結果與討論

5-1. 自動編碼器設置與結果

自動編碼器透過訓練集108張模擬光彈圖訓練模型，測試集27張模擬光彈圖經編碼與解碼後得到還原光彈圖。本研究中，將原40×40的模擬光彈圖透過編碼器資料降維，從1600筆數據，降至20筆數據，其中一組降維結果如圖 7所示，降維程度高達80倍。本研究採用SSIM評估自動編碼器效果，測試集中模擬光彈圖與還原光彈圖比較，SSIM算術平均值為0.892，最大值為0.916，最小值為0.849，全距為0.067。光彈條紋圖通過自動編碼器後，仍然保持了高度相似的結果如圖 8所示，圖中透過SSIM計算其相似度為0.88，實現了良好的特徵萃取與降維目標。






圖 7 編碼器編碼效果



(a)模擬光彈圖



(b)還原光彈圖

圖 8 解碼器還原效果

5-2. 多層感知器預測效果

多層感知器以八個壓力指標作為輸入，模擬光彈圖作為預測對象。模型訓練完畢後，透過測試集27組所預測出每組20個預測光彈圖。所採用相關係數算法如式(3)，其中 N 為每個變量的觀測數， μ_A ， μ_B 與 σ_A ， σ_B 分別為 A 與 B 的平均值與標準差，訓練完成後，其RMSE值為0.25。

5-3. 自動編碼器與多層感知器預測圖片相似度

本研究提出一套集成式模型方法，導入自動編碼器與多層感知器為架構，以完成光彈圖預測。在模型訓練完畢後，隨機挑選測試集中10組預測潛在表示法進行解碼並還原為預測光彈圖，並使用計算其與模擬光彈圖之SSIM數值，評估此集成式模型預測效果。模擬光彈圖與預測光彈圖比較、SSIM數值比較如圖 9所示，10筆預測圖形之SSIM數值算數平均數為0.83，樣本標準差0.028，全距0.082透過集成式模型預測光彈圖，達到良好的預測效果。




圖 9 集成式模型影像重建與圖形相似性

7. 參考文獻

- [1] E. Bemporad, M. Brisotto, L.E. Depero, M. Gelfi, A.M. Korsunsky, A.J.G. Lunt, M. Sebastiani, A critical comparison between XRD and FIB residual stress measurement techniques in thin films, *Thin Solid Films*. 572 (2014) 224–231. <https://doi.org/10.1016/j.tsf.2014.09.053>.
- [2] n modeling to predict the load vs. displacement curves of targeted composite materials for industry 4.0 and smart manufacturing, *Composite Structures*. 258 (2021) 113207.
- [3] S. Lee, Y. Yun, S. Park, S. Oh, C. Lee, J. Jeong, Two Phases Anomaly Detection Based on Clustering and Visualization for Plastic Injection Molding Data, *Procedia Computer Science*. 201 (2022) 519–526.
- [4] D. Kando, S. Tomioka, N. Miyamoto, R. Ueda, Phase Extraction from Single Interferogram Including Closed-Fringe Using Deep Learning, *Applied Sciences*. 9 (2019) 3529.
- [5] K.-C. Ke, M.-S. Huang, Quality Prediction for Injection Molding by Using a Multilayer Perceptron Neural Network, *Polymers*. 12 (2020) 1812.
- [6] Z. Wang, A.C. Bovik, H.R. Sheikh, E.P. Simoncelli, Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*. 13 (2004) 600–612.