

結合顯微干涉影像及卷積神經網路(CNN) 進行薄膜表面粗糙度快速檢測

Surface Roughness Measurement Using Microscopic Interferometer Images and Convolutional Neural Networks

指導教授：田春林 特聘教授
學生：郭光祐、張俊鴻、羅淙博

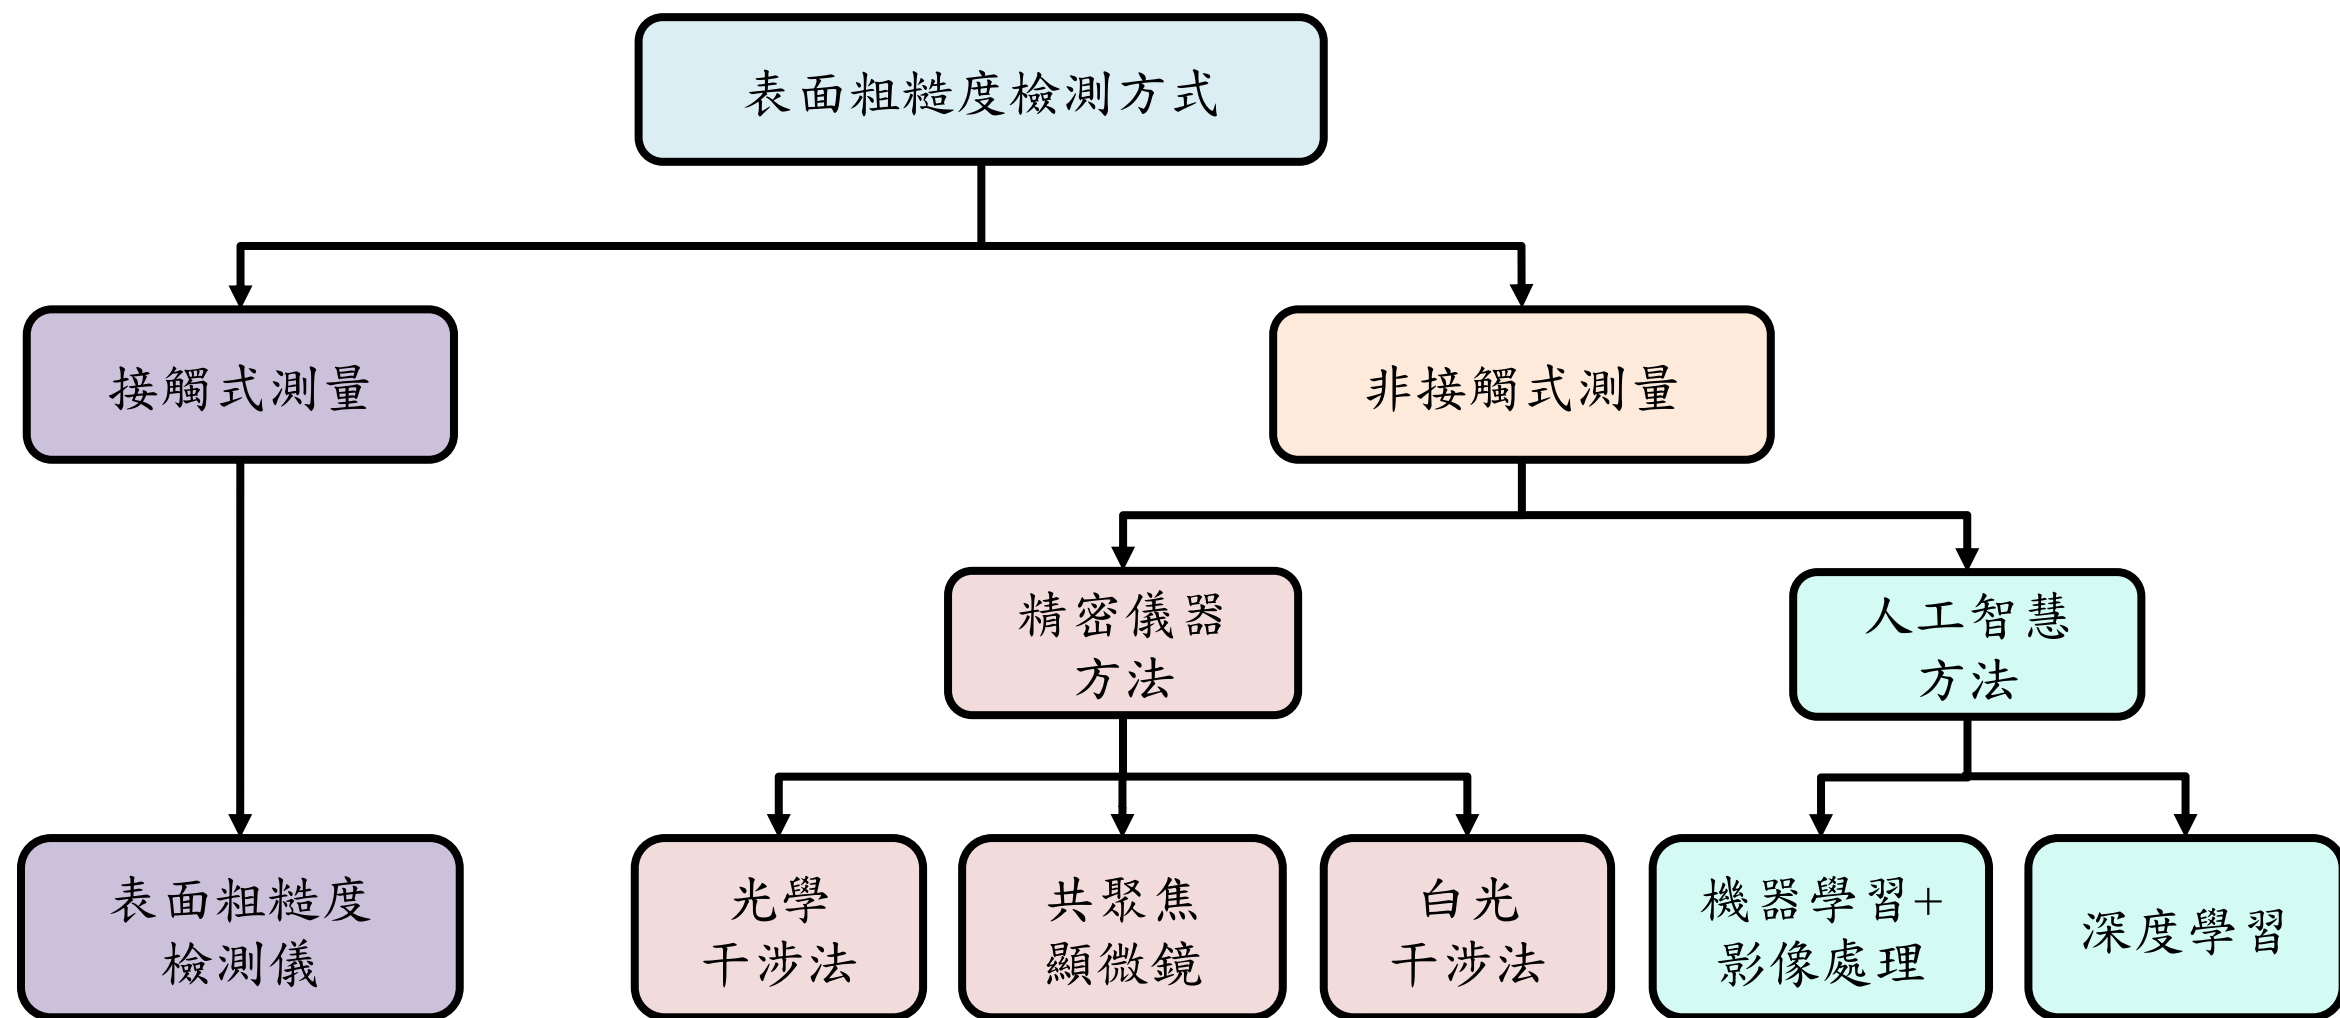


一、摘要

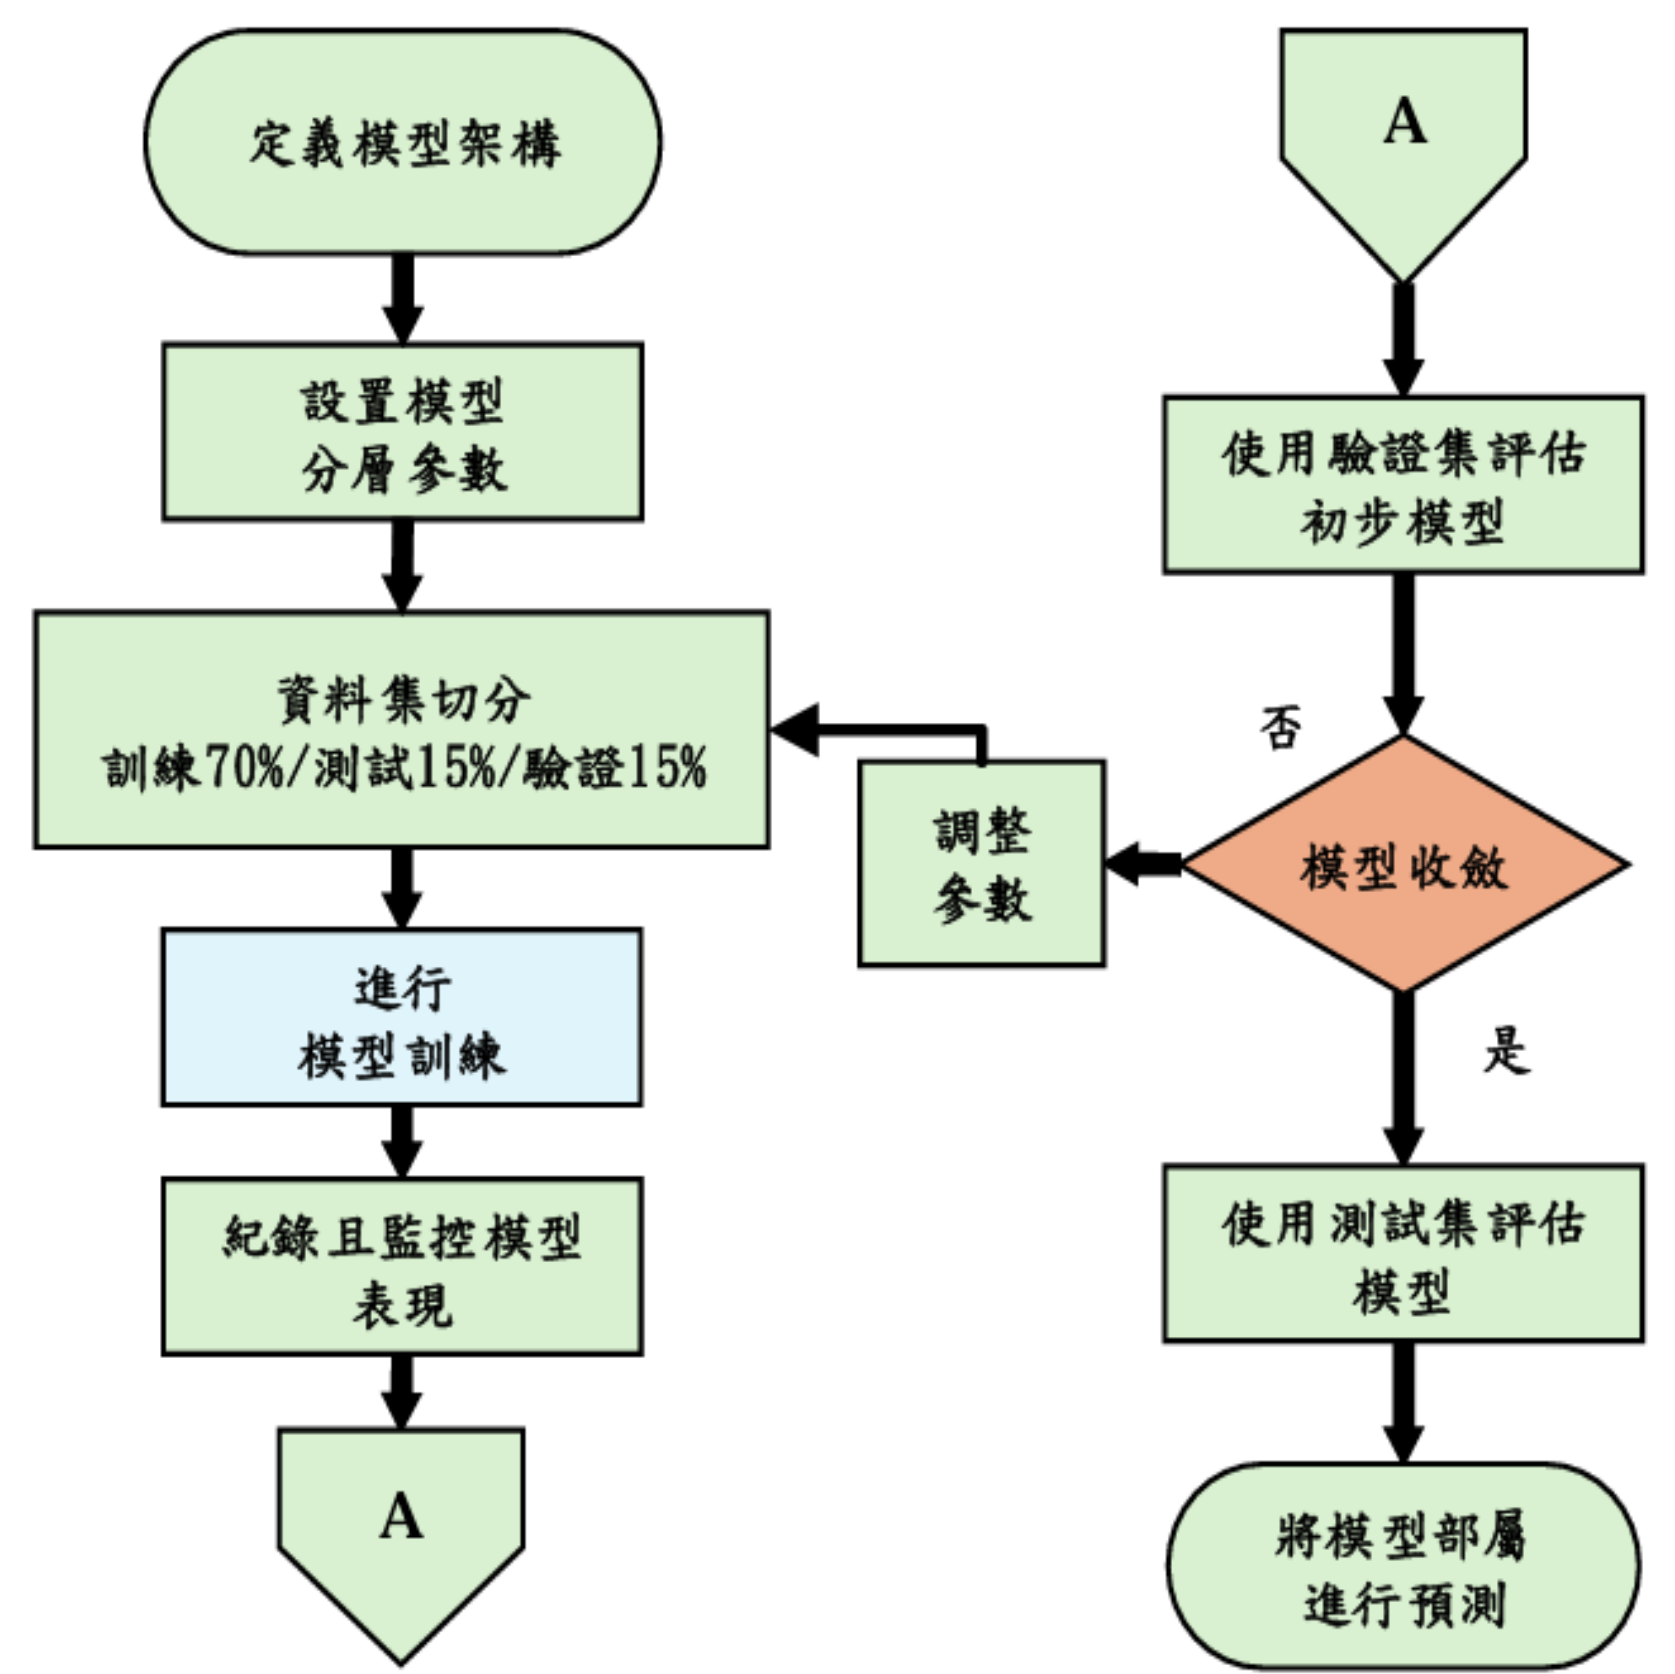
本研究結合顯微干涉儀與深度學習技術開發自動預測系統。透過自製 Michelson 與 Linnik 顯微干涉儀量測多種薄膜樣品，由 CCD 擷取干涉圖像，透過自撰 Matlab FFT 程式取得標準粗糙度 R_q ，並以 Python 建構改良式 CNN、ResNet-18 與 VGG-16 迴歸模型。結果顯示 ResNet-18 於 Michelson 影像表現最佳 (MAE 0.06 nm、RMSE 0.083 nm、 R^2 0.94)，跨儀器 Δ MAE 僅 0.037 nm，預測精度可達亞 0.1 nm，具良好穩定性與實用性，對薄膜表面粗糙度光學自動化檢測系統具有發展潛力。

二、研究目的與方法

針對奈米級光學薄膜表面粗糙度量測之不足，開發一套快速、非接觸的預測系統。



圖一 表面粗糙度檢測方式



圖二 模型訓練流程圖

三、結果

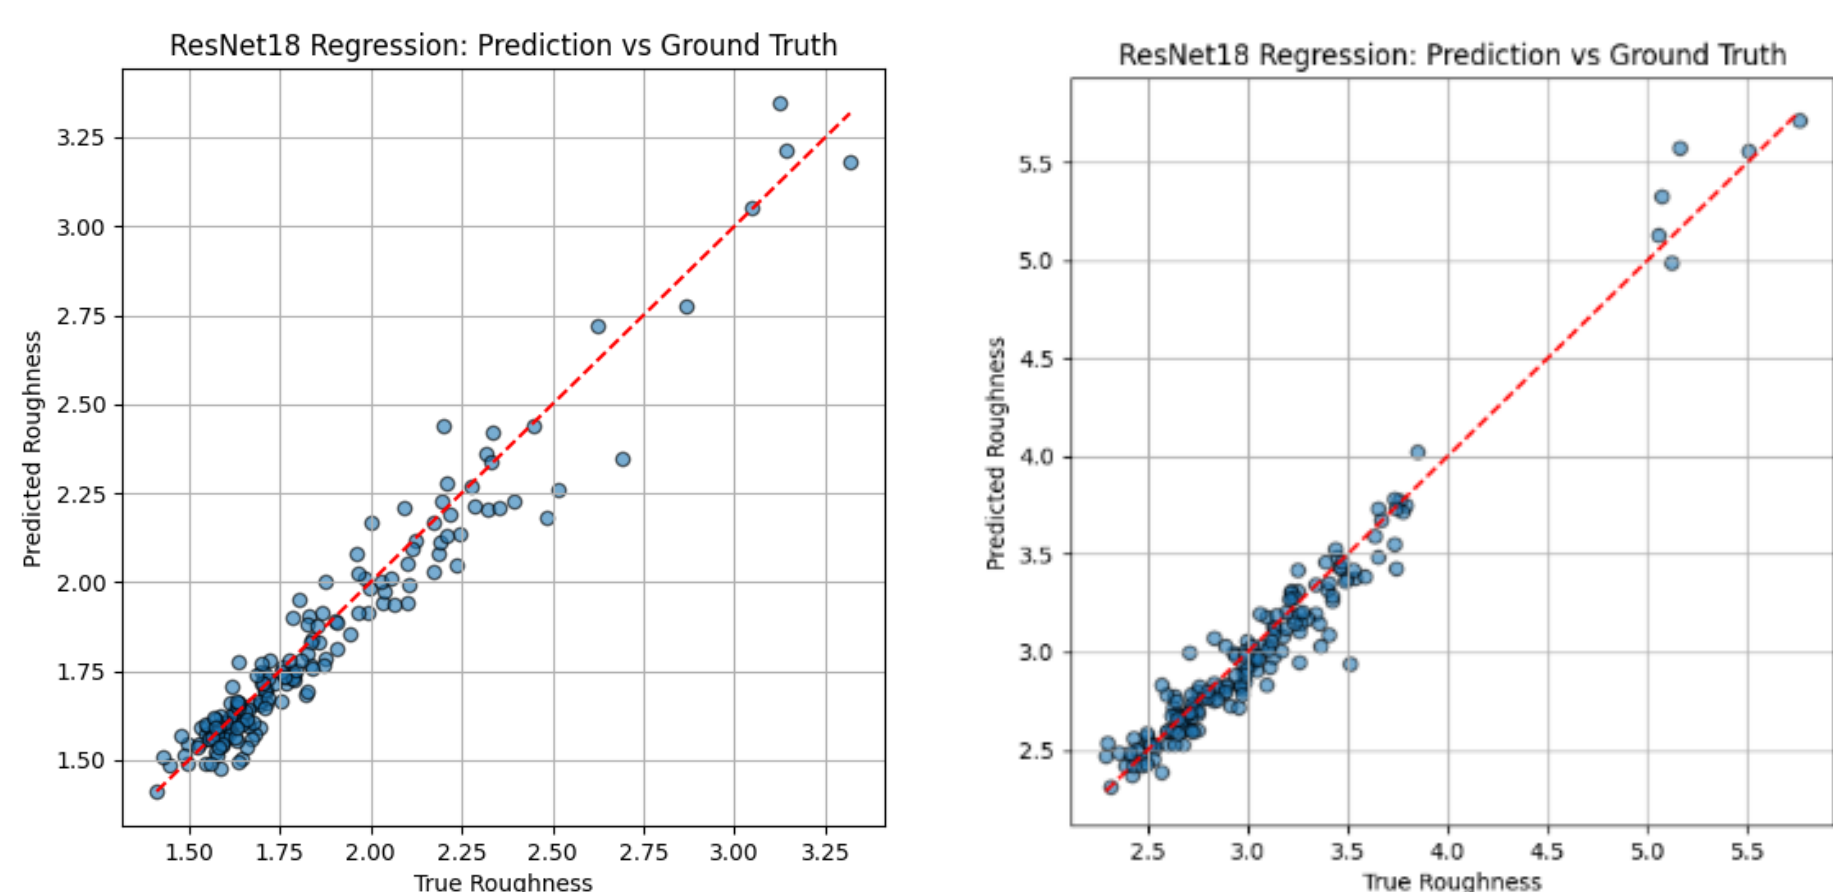
表一 Michelson 與 Linnik 干涉影像之粗糙度(R_q)預測表現比較

Model	Equipment type	Input Size	MAE(nm)	RMSE(nm)	R-square
Improved CNN	Michelson	365x365	0.1245	0.1865	0.7551
Improved CNN	Linnik	365x365	0.3049	0.4145	0.3508
ResNet-18	Michelson	365x365	0.0604	0.0831	0.9407
ResNet-18	Linnik	365x365	0.0981	0.168	0.8683
VGG-16	Michelson	365x365	0.1417	0.1859	0.7344
VGG-16	Linnik	365x365	0.1687	0.2235	0.8002

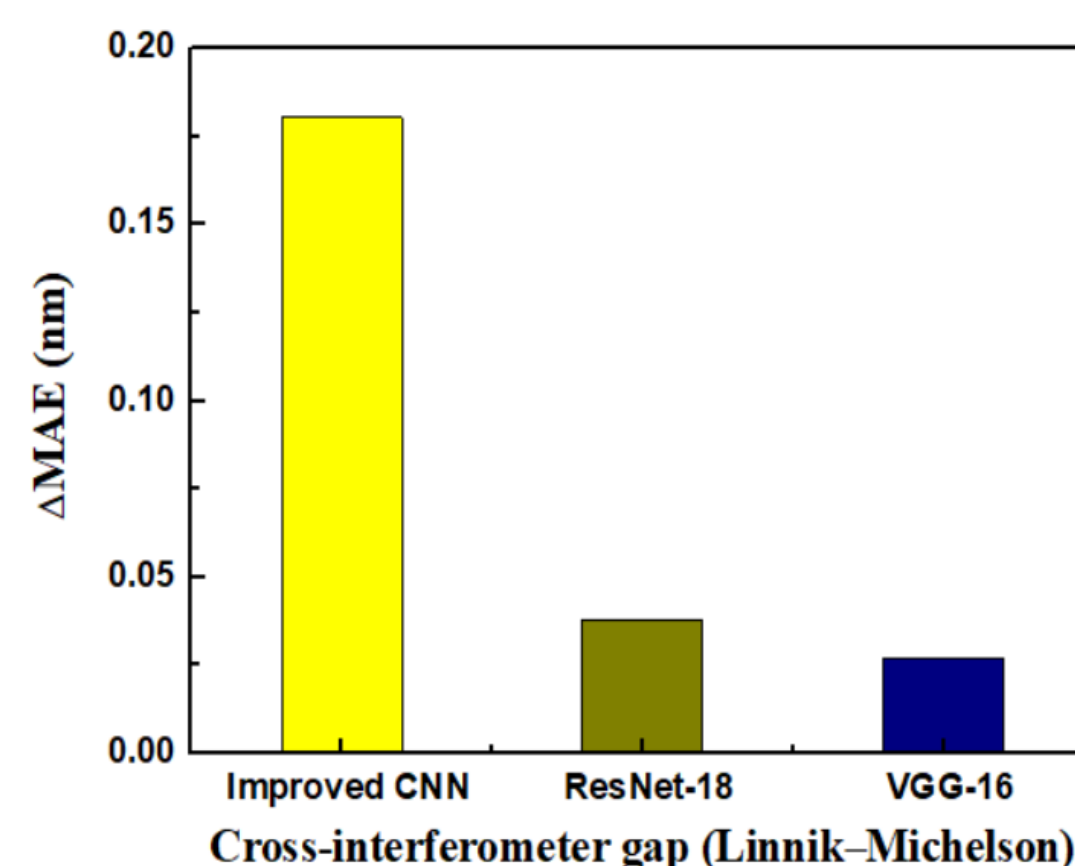
四、結論

由實驗結果發現，ResNet-18 模型表現為三者最佳，由於其殘差結構可緩解深層網路的梯度消失，使特徵學習在有限資料下仍能穩定收斂。

結果說明深度學習可以在圖像高度相似的干涉圖形中預測出粗糙度數值，為未來開發及時辨識系統奠定基礎。



圖三 ResNet-18 真實值與預測值散佈圖
(a) Michelson 架構; (b) Linnik 架構



圖四 各模型之跨儀器量測MAE差值 (Δ MAE, 單位 nm)

五、成本評估

專題名稱	結合顯微干涉影像及卷積神經網路(CNN)進行薄膜表面粗糙度快速檢測	
	時間	成本(元)
製作前預估	70天	5000
實際完成後	90天	4800

