

國立清華大學 電機工程學系

實作專題研究成果摘要

**Residual Interferometric Processing for Efficient  
Photonic Neural-Network Computing**

光子殘差干涉應用於高效率光子類神經網路計算架構

組別：B582

指導教授：李明昌 教授

組員姓名：李冠儒、邱子宸

研究期間：2025 年 2 月至 2025 年 12 月，共 10 個月

## 摘要

本專題旨在提出一種基於  $4 \times 4$  干涉器與光電非線性回授的新型光子類神經網路架構——**M-Block** 殘差干涉模組。雖然傳統 Clements 或 Reck 型干涉網路具有通用性，但在實際規模化時常面臨可調參數數量龐大、訓練不穩定、損耗高與堆疊困難等問題，因此如何在降低參數量的同時維持可學習性及穩定性，為光子神經網路的重要挑戰。

為了解決傳統模型可能遇到的問題，本專題提出的 **M-Block** 以「線性干涉器 + 非線性光電活化 + 殘差回授」為核心結構。首先， $4 \times 4$  干涉器負責線性單元運算；接著透過光電轉換得到幅值型非線性，使模型具備必要的非線性表現能力；最後藉由殘差路徑維持訊號穩定與梯度流動，使整體形成一個收斂性的動態迭代系統，進而在不增加大量參數的情況下進行深度學習後並堆疊。

在實驗部分，本專題以 3 層與 5 層 **M-Block** 堆疊架構，於 Vowel 4-Class 資料集上驗證其表現。結果顯示：兩種深度皆可快速收斂至 99% 以上的分類正確率，且僅需數百個可調參數即可達到近乎完美的辨識性能。此結果不僅展示了 **M-Block** 具備良好的表示能力，也證實其在大幅降低參數量的同時仍保持穩定的訓練行為與可擴展性。

綜合而言，本專題所提出的殘差干涉式光子網路架構，能在降低硬體複雜度與光損的條件下，提供可堆疊、可學習且具有高擴展性的光子神經運算單元。在未來的應用則將朝向：**M-Block** 與卷積式架構整合、更多非線性動態應用研究、以及在矽光平台上進行硬體實作等方向發展，以推動可擴展之光子運算系統的實現。

## 1. 背景與動機

近年來，光子計算因具備高速傳輸、低延遲與天然並行化的特性，逐漸成為人工智慧硬體加速領域的重要發展方向。其中，光子類神經網路（**Photonic Neural Network, PNN**）利用干涉、相位調控與光電轉換等機制，可藉由物理方式直接實現矩陣乘法與神經元運算，具備突破傳統電子計算瓶頸的潛力。然而，現有常見的光子神經架構大多採用大規模通用干涉網路（如 **Clements** 或 **Reck mesh**），其可訓練參數眾多、梯度敏感度高，且在深度堆疊時容易產生不穩定的訓練行為，使得光子神經網路在演算法設計、模型收斂與架構擴展上仍存在挑戰。

在此背景下，本專題希望從「運算單元本身」重新思考光子神經網路的構建方式，並嘗試設計一個具可堆疊性、訓練穩定性與非線性整合能力的光子網路模組。基於此目標，我們提出一種結合 **4×4 干涉器（interferometer）**、光電非線性（**optoelectronic nonlinearity**）與殘差回授（**residual feedback**）的 **M-Block 殘差干涉運算架構**，用以作為光子神經網路的核心模組。

與傳統 **mesh** 強調「通用性」不同，**M-Block** 更聚焦於：

1. **可堆疊（stackable）**：模組輸出具有穩定性，允許多層疊加不易發散。
2. **可訓練（trainable）**：殘差結構改善深度光子網路常見的梯度問題，使訓練能順利收斂。
3. **具非線性整合能力**：藉由光電轉換的實現方式，建立起與電子神經網路類似的活化操作。

本專題的主要動機在於建立一個具備可堆疊性、可訓練性與非線性整合能力的光子神經網路運算模組。傳統光子網路在深度堆疊時常面臨梯度不穩定、參數量龐大等限制，使得其在設計與訓練上都存在瓶頸。因此，我們透過整合 **4×4 干涉器**、光電非線性與殘差回授所組成的 **M-Block** 架構，驗證其是否能形成穩定、可疊加且具學習能力的光子計算單元。我們期望 **M-Block** 能改善光子神經網路在訓練中容易出現的不收斂問題，使其能如電子神經網路中的殘差模組般具備深度擴展潛力。

藉由 **M-Block** 的模組化設計，提供光子神經網路另一種更接近深度學習架構的建構方式，並作為後續光電混合計算、光子類神經網路拓展與光子硬體實作的重要基礎。

## 2. 研究目的

我們的目標是建立一套基於  $4 \times 4$  干涉器的光子類神經網路運算模組，並驗證其在深度堆疊下的可訓練性與分類性能。現有光子神經網路多採用大型通用干涉網路（如 Clements Mesh），雖具備任意 unitary 變換能力，但在深度增加時常面臨相位失真、梯度不穩定以及缺乏非線性整合等問題，使模型難以有效擴展。為改善這些限制，提出結合干涉運算、光電非線性與殘差回授的 M-Block 架構，期望能以模組化方式建構出穩定且可堆疊的光子神經網路基本單元。

在架構上先是以 Python 上建置 M-Block 模型，透過殘差結構確保深度堆疊，並以光電非線性彌補傳統光學網路缺乏激勵函數（Activation Function）的問題。在模型訓練上，也將以 Vowel 4-Class 資料集進行前向推論與參數更新，並比較三層與五層 M-Block 的分類準確率、收斂速度與穩定性，評估其作為光子神經元模組的可行性。

最終目標是證明：在不依賴大型光學網路的情況下，利用干涉器為核心、結合殘差與非線性的模組化架構，亦能達成良好的學習能力與實際資料集的分類效果，作為未來光電混合運算與光子深度神經網路架構設計的重要基礎。

## 3. 研究方法

為驗證 M-Block 在深度堆疊下的可行性，我們以 Python 建立其線性干涉運算、光電非線性與殘差回授等核心機制。透過將這些運算單元整合成可訓練的模型，並在 Python 中反覆執行資料輸入、干涉轉換、非線性處理與參數更新的流程，進一步評估 M-Block 作為光子神經網路的基礎模組的穩定性與擴展性。

### 3.1. 干涉器架構與線性轉換設計




Fig. 1: M-Block Architecture

M-Block 模組以 4x4 干涉器 (interferometer) 作為線性運算核心，干涉器內部由多個 2x2 分束器與相位控制元件所組成，能實現任意的 4x4 酉矩陣 (unitary matrix) 運算。線性單元的輸入向量經由干涉器後，可得到矩陣轉換：

$$y = xU^T$$

$U$  是由多組  $T_{a,b}(\theta, \phi)$  所組成：

$$U = \prod_{(a,b)} T_{a,b}(\theta, \phi)$$

其中的  $T_{a,b}$  為 SU(2) 的分束器 (beam-splitter) 矩陣。

$$T_{a,b}(\theta, \phi) = \begin{bmatrix} e^{-i\phi} \cos\theta & -\sin\theta \\ e^{-i\phi} \sin\theta & \cos\theta \end{bmatrix}$$

設計原則如下：

- (1) 使用 2x2 SU(2) 基本旋轉單元模擬光學耦合行為
- (2) 4x4 干涉器組合可產生不同的線性映射
- (3) 參數  $\theta, \phi$  為可訓練參數，可透過梯度下降更新

最終形成可學習的線性轉換單元。

### 3.2. 非線性光電轉換與激勵函數

光子系統的運算過程本質上是線性的，因此為了模擬深度學習所需的非線性行為，進而引入光電轉換 (Photodetection) 作為非線性來源。干涉器輸出向量  $y$  經由光電轉換後，其光場會被轉換成強度訊號：

$$|y|^2 = \Re(y)^2 + \Im(y)^2$$

在這次專題中所採用的激勵函數為：

$$f(|y|^2) = w \cdot \tanh(|y|^2 - c)$$

其中  $w$  為可調縮放參數， $c$  為偏移量，而  $\tanh(\cdot)$  則是用以模擬可實作的類神經網路激勵函數。

### 3.3. 殘差回授路徑與穩定堆疊方法

為避免深度光子網路在多層堆疊時容易發散，本研究在非線性單元後加入殘差回授 (Residual Pathway)。殘差運算定義如下：

$$x_{next} = \Re(y) + f(|y|^2)$$

此設計具有三項優點：

- (1) 提升訓練穩定性：殘差使梯度更容易傳遞，避免深層網路的梯度消失問題。
- (2) 保持相位資訊：以  $\Re(y)$  作為殘差部分，保留干涉器重要的相位結構。
- (3) 可重複堆疊：殘差結構能確保網路在多層堆疊後仍不失真

此殘差流程為 M-Block 的第二階段核心設計，使干涉器具備高度擴展能力。

### 3.4. M-Block 模組化架構組合與運算流程




Fig. 2. M-Block Layer Construction

一個完整的 M-Block 包含：

- (1) 線性干涉器運算（4×4 干涉器）
- (2) 光電非線性單元
- (3) 殘差回授單元

實際運算流程如下：

- (1) 輸入向量  $x$  經干涉器產生線性映射  $y = xU^T$
- (2) 光電轉換產生  $|y|$  並進入非線性函數
- (3) 殘差單元將  $\Re(y)$  與非線性輸出相加
- (4) 輸出  $x_{next}$  成為下一層 M-Block 的輸入

這樣的模組化結構允許多個 M-Block 以堆疊方式形成深度網路，彌補傳統光子網路難以深度堆疊的限制。

## 4. 研究結果




Fig. 3. Training convergence of 3-layer and 5-layer M-Block stacks. Accuracy saturates near 100%.

為了評估 M-Block 架構的表現能力，本研究以 Python 建立三層與五層的 M-Block 堆疊模型，並使用 Vowel 4-Class 資料集進行訓練與測試。資料輸入後會依序通過各層包含干涉轉換、光電非線性與殘差回授的運算流程，藉由多層疊加來觀察模型是否能有效學習複雜的分類邊界。實驗結果顯示，三層與五層的 M-Block 皆能快速收斂至接近 100% 的準確率，說明模組化的干涉式結構即使在參數量遠少於傳統深度網路的情況下，仍具備良好的表示能力。

在模擬過程中可觀察到，深度堆疊比單純增加干涉器規模更能提升模型性能，符合殘差回授架構的理論預期。相較於依賴大型干涉網路的方式，在研究過程則是透過多層 M-Block 的堆疊即可近似複雜的分類界線，並保持優良的訓練穩定性與參數效率。此結果不僅證實 M-Block 能以低參數量達成具代表性的學習能力，也顯示其在光子神經網路架構中具備良好的可組合性與擴展潛力。

此結果證實 M-Block 能以低參數量達成良好的學習能力，並且展現其在可擴展光子計算與模組化光學神經網路上的應用潛力。

## 5. 結論

本專題提出結合線性干涉運算、光電非線性與殘差連接的光子類神經網路架構 (M-Block)，藉由 4×4 干涉器提供線性轉換能力，並利用光電轉換實現非線性響應，使模型具備深度學習所需的基本運算特性。透過殘差結構整合線性與非線性結果，M-Block 在多層堆疊時仍能維持輸出界限性與穩定性，形成可組合的光子運算單元。

本專題使用 Python 實作三層與五層的 M-Block 堆疊架構，並以 Vowel 4-Class 資料集驗證其可訓練性。實驗結果顯示，兩種深度皆能快速收斂至接近 100% 的分類準確率，且在參數量遠少於傳統光子或電子網路的情況下仍具備良好的表示能力。此結果證實深度堆疊較增加干涉器規模更能有效提升性能，也展現 M-Block 在參數效率與訓練穩定度上的優勢。

整體而言，M-Block 展現了作為光子神經網路基礎運算單元的高度潛力。透過干涉運算、光電非線性與殘差結構的結合，此架構具備明確的模組化特性，使其在設計上易於組裝、在訓練上具穩定性、在未來硬體實作上亦具可延伸性。與傳統以大型干涉網路為核心的設計相比，本研究以較小規模的模組進行深度堆疊，不僅更符合光電混合系統的特性，也為未來的光子類神經網路提供另一種具實用性與可擴展性的設計方向。

## 6. 心得與感想

在這次的專題研究中，我們以兩人團隊的方式共同投入 M-Block 光子類神經網路架構的設計與驗證。由於此主題橫跨干涉運算、光電非線性與深度學習等內容，對我們而言是一個需要不斷探索與理解的跨領域挑戰。從最初確認架構原理，到逐步完成線性單元、非線性處理與殘差連接的整合，每個階段都伴隨大量討論與反覆推敲，也讓我們在合作中逐漸累積對光子計算架構更深入的理解。

在團隊合作的過程中，我們採用「分工但不分割」的方式進行。雖然各自負責不同部分的程式架構與模型設計，但每當遇到數學推導不一致、非線性行為不如預期，或干涉轉換結果需要重新驗證時，我們都會一起檢查參數設定、逐層追蹤運算結果，避免因個別理解上的差異而造成整體模型的偏誤。這種反覆驗證的過程，不僅提升了我們對 M-Block 結構的掌握，也使團隊對整體架構的理解逐漸趨於一致。

在訓練模型的階段，我們共同經歷了試誤與調整的過程，包括非線性強度的設定、輸出範圍的控制、初始條件對收斂速度的影響等。當模型終於在三層與五層堆疊下達到接近 100% 的分類準確率時，我們都能明顯感受到架構本身的可行性，也理解文獻中強調的「深度堆疊比增大干涉器規模更有效」的含義。這些從資料到模型的觀察，讓我們更深刻地體會到光子神經網路設計的核心思維，而不僅是軟體模擬的結果。

回顧整個專題，我們都在技術能力與團隊合作上獲得了重要的成長。在設計光子計算架構的過程中，我們學習到如何從物理行為推導數學模型、如何判斷架構是否合理，以及如何在訓練過程中調整參數以維持穩定。在團隊合作方面，我們透過討論互補彼此觀點，在遇到瓶頸時能共同找到前進方向，使研究能持續推進。

總結而言，這次的專題不僅讓我們對光子計算與深度學習有更深入的认识，也讓我們學會如何以團隊方式面對複雜的研究問題。未來若有機會延伸此研究，我們期待能在硬體實現與更複雜的光子架構上持續探索，並將此次專題的成果作為往後研究的基礎。