

國立臺灣師範大學跨域科技產業創新研究學院

AI 跨域應用研究所

碩士論文

Graduate Institute of AI Interdisciplinary Applied Technology

College of Interdisciplinary Industry-Academia Innovation

National Taiwan Normal University

Master's Thesis

用於反射式電子紙顯示器色彩校正的 AI 模型：邊緣實現  
的即時方法

AI Models for Color Correction of Reflective E-Paper  
Displays: A Real-Time Approach for Edge Implementation

童培軒

Pei-Hsuan Tung

指導教授：王偉彥 博士

呂成凱 博士

Advisor: Wei-Yen Wang Ph. D.

Cheng-Kai Lu Ph. D.

中華民國 114 年 7 月

July 2025

## 誌 謝

感謝王偉彥教授在我求學的路上給予我非常多的支援和學術上的建議，常常會提供我沒有設想到的問題，也讓我在求學階段不只自己的相關研究，也更加了解自動控制和機器人相關領域。然後很感謝老師為實驗室買進了很多 AI 運算平台和邊緣運算設備，讓我的研究可以更順利的進行，沒有因為硬體而受限。

感謝呂成凱教授在學術上提供相當多的建議，也願意時常撥空和我討論研究方向，在執行產學計畫期間積極的協助連絡廠商和和廠商溝通所需要的相關研究設備事宜，在前往美國參加 Conference 前也撥空幫我練習英文口說並模擬 Conference 的問答情境，讓我在行前做了充分的準備。

感謝彭正偉教授在上課時教導了許多類神經網路的知識，下課後願意以一個學長的身分，跟我分享自己人生的經歷，也願意花自己寶貴的時間來指導我論文的方向給予了我很多實質的改進方向，在出發前往美國參加 Conference 前，不厭其煩的幫我練習英文口說和給予我內容上面的建議和鼓勵，讓我在與會時更加的有信心。

此外也很感謝林忠謀學長帶給我許多電子紙和色彩學相關研究的啟發，在研究的路上給與我相當多的幫助。也很感謝李賢文大方的為人給予我很多的幫助，同時也感謝黃聖威在 IC 設計這塊帶著我一起學習，讓我多一分專業知識，同時也感謝實驗室的允喆、冠宇、詠孺、純淙、凱鈞在日常研究上的陪伴讓實驗室充滿歡樂。最後也很感謝我的爸媽和家人生活上給我相當我的鼓勵和幫助，讓我在研究所求學過程中可以無後顧的好好求學。

童培軒 謹誌

中華民國一百一十四年

# 用於反射式電子紙顯示器色彩校正的 AI 模型：邊緣實現的即時方法

學生：童培軒

指導教授：王偉彥 教授

呂成凱 教授

國立臺灣師範大學跨域科技產業創新研究學院碩士班



本研究旨在解決反射式彩色電子紙的非線性色彩失真與色偏問題。為此本研究提出了一套基於深度學習的色彩校正架構和基於過往方法開發的半色調演算法，以有效提升色彩還原的準確度與空間連續性，克服傳統方法的限制。為驗證本方法在邊緣運算裝置上的可行性與即時性，我們將模型部署於 NVIDIA Jetson Orin NX，並採用訓練後量化策略將模型由全精度轉換為 INT8 精度。實驗結果顯示，量化後模型在推論速度上提升近五倍，同時僅有輕微的影像品質減損，大幅降低了記憶體與運算資源需求。本研究提供了一套低成本、高效率且無需額外色彩量測的 AI 調色方案，證實其具備高度的實用性與延展潛力。

關鍵字：電子紙、色調再現、深度學習、顏色校正、半色調演算法，邊緣運算。

# AI Models for Color Correction of Reflective e-Paper Displays: A Real-Time Approach for Edge Implementation

Student: Pei-Hsuan Tung

Advisor: Dr. Wei-Yen Wang  
Dr. Cheng-Kai Lu

College of Interdisciplinary industry-Academia Innovation  
National Taiwan Normal University

## ABSTRACT

This study aims to address the issues of non-linear color distortion and color deviation in reflective printed color e-paper. To this end, this research proposes a deep learning-based color correction framework and a halftoning algorithm developed from previous methods to effectively enhance the accuracy of color reproduction and spatial continuity, overcoming the limitations of traditional approaches. To validate the method's feasibility and real-time performance on edge computing devices, we deployed the model on an NVIDIA Jetson Orin NX and employed a post-training quantization strategy to convert the model from full precision to INT8 precision. Experimental results demonstrate that the quantized model achieved a nearly five-fold increase in inference speed with only a slight degradation in image quality, significantly reducing memory and computational resource requirements. This research provides a low-cost, high-efficiency, and measurement-free AI color tuning solution.

Keywords: E-paper, Tone Reproduction, Deep Learning, Color Correction, Halftoning Algorithm, Edge Computing.

# 目 錄

誌 謝 .....	i
摘 要 .....	ii
ABSTRACT .....	iii
目 錄 .....	iv
表 目 錄 .....	vii
圖 目 錄 .....	viii
第一章 緒論 .....	1
1.1 研究背景 .....	1
1.2 研究動機 .....	2
1.3 論文架構 .....	3
第二章 文獻探討 .....	5
2.1 半色調演算法 .....	5
2.1.1 向量擴散誤差 .....	6
2.1.2 直接二元搜索 .....	9
2.1.3 多重色彩搜索法 .....	12
2.1.4 真實色彩半色調演算法 .....	14
2.2 彩色電子紙色彩校正 .....	16
2.2.1 色彩校正矩陣 .....	17
2.2.2 色域映射 .....	18
第三章 研究方法 .....	20
3.1 網路架構設計 .....	20
3.1.1 深度可分離卷積模組 .....	22
3.1.2 損失函數 .....	23

3.1.3 訓練策略與技術.....	23
3.1.4 性能指標.....	24
3.2 空間約束半色調演算法.....	26
3.2.1 色彩混合與印刷塗佈率.....	27
3.2.2 亮度映射.....	28
3.2.3 印刷彩色濾光片排列.....	30
3.2.4 混合誤差抖色法.....	30
3.3 訓練後量化.....	36
3.4 資料集.....	37
3.4.1 電子紙製造商資料集.....	37
3.4.2 空間約束半色調資料集.....	41
第四章 實驗結果.....	43
4.1 實驗環境與設備.....	43
4.2 消融實驗.....	45
4.2.1 電子紙製造商資料集的消融實驗.....	45
4.2.2 空間約束半色調資料集的消融實驗.....	50
4.3 印刷彩色電子紙顯示結果.....	57
4.3.1 色彩校正演算法的顯示結果.....	57
4.3.2 ColorCorrectionNet 推理的顯示結果.....	63
4.3.3 色彩誤差比較.....	69
4.4 訓練後量化結果.....	72
第五章 結論與未來展望.....	74
5.1 結論.....	74
5.2 未來展望.....	74
Reference.....	75

自 傳 .....	78
學術成就 .....	80



## 表目錄

表 3-1 資料集詳細配置.....	42
表 4-1 電子紙製造商測試資料集的結果 .....	46
表 4-2 空間約束半色調測試資料集的結果 .....	57
表 4-3 D65 光源下的 32 色色卡 sRGB 值.....	70
表 4-4 ORIN 與 GPU 在 EPAPER DATASET 推理結果的比較.....	72
表 4-5 ORIN 與 GPU 在 SCH DATASET 推理結果的比較 .....	73
表 4-6 ORIN 與 GPU 壓力測試的比較.....	73



## 圖目錄

圖 1-1 EPD STRUCTURE .....	1
圖 1-2 PCEP 顯示原理(左)顯微鏡下畫面(右) .....	2
圖 1-3 PCEP 的色域與 SRGB 色域的差異示意圖 .....	3
圖 2-1 VED 演算法流程圖 .....	7
圖 2-2 DBS 流程圖 .....	10
圖 2-3 LIN 提出的多重色彩搜索法流程圖 .....	12
圖 2-4 LIN 提出的真實色彩半色調演算法流程圖 .....	15
圖 2-5 LIN 提出的真實色彩半色調演算法顯示於 PCEP 上的畫面(左)、為原始 SRGB 32 色 COLOR CHECKER(右) .....	16
圖 2-6 CHEN 提出的 CCM 彩色電子紙影像處理流程 .....	17
圖 2-7 像素顏色校準範例 .....	18
圖 2-8 HONG 提出的多粒子彩色電子紙色彩重現流程 .....	18
圖 3-1 COLORCORRECTIONNET 架構流程圖 .....	21
圖 3-2 PCEP 的印刷色彩及留白 .....	26
圖 3-3 空間約束半色調演算法流程圖 .....	27
圖 3-4 LIN 提出的色彩混合計算示意圖 .....	28
圖 3-5 未進行亮度映射(左)、經過亮度映射後(右)顯示在 PCEP 的畫面 .....	29
圖 3-6 PCEP 的兩種 CFA 排列 .....	30
圖 3-7 過往半色調演算法和本研究提出的方法顯示在 PCEP 的畫面 .....	31
圖 3-8 TED 演算法流程圖(A)、TOGGLE 計算流程(B) .....	32
圖 3-9 PTQ 後實際部署到 JETSON ORIN 流程圖 .....	37
圖 3-10 影像經過半色調演算法後顯示在彩色電子紙上 .....	38
圖 3-11 SAMSUNG QD-OLED 文字彩邊 .....	39
圖 3-12 SAMSUNG QD-OLED 像素點排列 .....	39

圖 3-13 原始影像(左)、半色調後的原始影像(右).....	40
圖 3-14 原始 SRGB 影像(左)、電子紙製造商調色後顯示在 PCEP 的畫面(中)、 半色調後的原始影像(右).....	40
圖 3-15 原始 SRGB 影像(左)、電子紙製造商調色後顯示在 PCEP 的畫面(中)、 半色調後的原始影像(右).....	41
圖 4-1 NVIDIA RTX 4090 (左)、AMD R9 7950X (右).....	44
圖 4-2 E INK KALEIDO 彩色電子紙(左)、NVIDIA JETSON ORIN NX 16G(右).....	44
圖 4-3 CANON MG4270 掃描機(左)、X-RITE I1 PRO 分光光度計.....	45
圖 4-4 電子紙製造商資料的消融實驗.....	47
圖 4-5 電子紙製造商資料集的訓練狀況.....	48
圖 4-6 電子紙製造商資料集的驗證狀況.....	49
圖 4-7 空間約束半色調資料集的消融實驗.....	50
圖 4-8 空間約束半色調資料集的訓練狀況 1.....	52
圖 4-9 空間約束半色調資料集的驗證狀況 1.....	53
圖 4-10 空間約束半色調資料集的訓練狀況 2.....	55
圖 4-11 空間約束半色調資料集的驗證狀況 2.....	56
圖 4-12 原始影像與六種方法顯示在 PCEP 上之 1.....	58
圖 4-13 原始影像與六種方法顯示在 PCEP 上之 2.....	59
圖 4-14 原始影像與六種方法顯示在 PCEP 上之 3.....	60
圖 4-15 原始影像與六種方法顯示在 PCEP 上之 4.....	61
圖 4-16 原始影像與六種方法顯示在 PCEP 上之 5.....	62
圖 4-17 EPAPER TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下)分別顯示在 PCEP 上之 1.....	63
圖 4-18 EPAPER TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下)分別顯示在 PCEP 上之 2.....	64

圖 4-19 EPAPER TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下)分別顯示在 PCEP 上之 3 .....	65
圖 4-20 SCH TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下) 分別顯示在 PCEP 上之 1 .....	66
圖 4-21 SCH TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下) 分別顯示在 PCEP 上之 2 .....	67
圖 4-22 SCH TARGET (上)、GPU INFERENCE (中)、JETSON ORIN INFERENCE (下) 分別顯示在 PCEP 上之 3 .....	68
圖 4-23 輸入 PCEP 上的 32 色色卡 .....	69
圖 4-24 PCEP 顯示 32 色色卡的色彩誤差 .....	71



# 第一章 緒論

隨著全世界對環保議題日益的重視，使得電子紙這種擁有超省電特性的顯示器被更多的人關注，應用也越來越廣泛，例如：戶外的超大型廣告看板、車站的告示板、貨架標籤甚至是跟汽車品牌合作將電子紙包覆在汽車板金上等，因為電子紙是採用反射原理，所以就像一般的紙一樣，戶外光線越強畫面就看得越清楚，並具備著低功耗、可捲曲的特性，比起傳統的液晶顯示器(LCD)不同的是，電子紙只有更新畫面的時候才需要通電。應用在零售業者也可以透過物聯網的方式更換貨架標籤顯示的內容，可以大量的節省人力成本也不會浪費紙張，展現環保永續發展和省時省力的商業價值。

## 1.1 研究背景

電子紙的顯示機制係將帶電彩色粒子懸浮於透明液體中，再以微膠囊 (microcapsule) 或微杯 (micro-cup) 方式封裝，並與薄膜電晶體 (TFT) 背板貼合，驅動 IC 施加電場後，即可形成所需的像素圖樣。本研究聚焦於印刷式彩色電子紙 (Print Color ePaper, PCeP)。




圖 1-1 EPD Structure

在 PCeP 架構裡，黑白雙色粒子組成的微膠囊可透過電場切換，實現 16 階灰階顯示。若再覆彩色濾光陣列 (Color Filter Array, CFA)，便能運用 RGB 混色機制，將單純的黑白畫面擴展為 4,096 種顏色，PCeP 顯示原理如圖 1-2 所示。




圖 1-2 PCeP 顯示原理(左)顯微鏡下畫面(右)[1]

## 1.2 研究動機

PCeP 顯示器比起 LCD 顯示器相對色域較窄如圖 1-3 所示，所以必須透過半色調演算法或是色彩校正演算法對要輸入到 PCeP 的彩色影像做前處理，而過往研究出來的半色調演算法，都是序列式的演算法，在一般的個人電腦運算一張  $1872 \times 1404$  的影像就需要等待 5 分鐘以上的運算時間，而在過往的解決方法會設計出一顆針對一種演算法做加速運算的 FPGA，雖然這個 FPGA 可以把運算做的很快很好，但是製造一顆 IC 的成本動輒需要上千萬甚至是上億，且如果有更好的演算法被設計出來，就可能需要再付出一次龐大的成本，顯然不太實際，所以本論文提出了利用深度學習的方式訓練 AI 調色模型如何調色，未來在電子紙設備上只須要有一顆 GPU 就能做加速運算，而且當深度學習架構有迭代時，只要做一次的軟體或韌體更新就可以讓舊設備也能使用最新的調色模型。




圖 1-3 PCEP 的色域與 sRGB 色域的差異示意圖

### 1.3 論文架構

本論文研究架構分為五個章節，各章節內容概要說明如下：

#### 第一章 緒論

說明研究背景與動機，包含電子紙架構及其應用領域論文架構等內容。

#### 第二章 文獻探討

首先綜覽當前與電子紙相關的色彩校正策略、半色調演算法，並從演算法、色彩校正架構和視覺效果三個維度歸納各方案的優缺點，作為後續改進的切入點。

#### 第三章 提出本研究的創新解決方案

說明本論文中所使用到的資料集來源，接著說明本論文提出的色彩校正模型架構和半色調演算法，利用深度學習來學習 PCeP 彩色電子紙的色彩調整，並說明其理論基礎與設計思路，包括模型架構的設計，最終實現完整的輕量化模型架構，並部屬在邊緣運算裝置上。

#### 第四章 實驗環境及實驗結果

首先介紹本實驗所用到的環境與設備，接著展示兩個模型進行消融實驗的結果。最後實際將本研究所開發的色彩校正模型和半色調演算法顯示在電子紙上，並以 PSNR、SSIM、平均色差 ( $\Delta E$ )、推論時間與 FPS 等客觀指標，全面比較本方法與現有技術在色彩準確度、運算效能與畫質上的差異。

#### 第五章 結論與未來展望

總結本研究的重要發現與貢獻，說明仍待克服的限制，並展望未來於更高解析度電子紙、可穿戴顯示及本研究所開發的色彩校正架構其應用與擴充方向。

## 第二章 文獻探討

本章旨在回顧與彩色電子紙影像品質提升密切相關的兩大研究面向：2.1 節中探討半色調處理 (Halftone Processing) 如何讓窄色域的電子紙顯示器能夠顯示出連續色調影像的效果。接著在 2.2 節中介紹色彩校正 (Color Correction) 說明它們對提升電子紙色域覆蓋率、飽和度與視覺一致性的影響。透過系統化的文獻整理，本章為後續提出的空間約束半色調演算法奠定理論基礎與改進動機。

### 2.1 半色調演算法

半色調 (Halftoning) 技術為數位影像處理中將連續色調影像轉換為有限色階 (通常為二值) 的關鍵方法，其目的在於輸出設備的顯示或列印限制下，盡可能保留原影像的視覺特性。根據其運算方式與視覺品質表現，半色調演算法可大致分為三大類：逐點法 (point-wise methods)、基於鄰域的方法 (neighborhood-based methods) 與迭代法 (iterative methods)。

第一類為逐點法，代表性技術如閾值篩選 (screening) 與抖色 (dithering)。此類演算法會將每個像素的強度值與預先設計之閾值矩陣進行比較，若像素值高於閾值則對應為白，反之則為黑。抖色之設計著重於空間頻率分佈與視覺錯覺的應用，常利用 Bayer matrix 或 ordered dither matrix 進行低計算成本的快速處理。然而，其色彩處理往往僅針對 R、G、B 通道獨立進行，較難保留色彩間相依性。

第二類為基於鄰域的方法，代表為誤差擴散法 (Error Diffusion)，進一步延伸至彩色影像則為向量誤差擴散 (Vector Error Diffusion, VED)。傳統單通道誤差擴散以 Floyd-Steinberg 演算法為代表，對灰階影像進行量化，並將誤差依權重

分散到相鄰未處理像素，達到藍噪雜訊分佈效果[2]，但彩色影像通常包含 CMYK、RGB 等多個通道，若分別對每通道獨立誤差擴散 (scalar)，會忽略通道間的相關性，造成色彩失真、對比度不一致等問題[3]，向量誤差擴散可將誤差向量同時作用於各通道，維持色彩搭配的協調，並可在空間頻譜上進行雜訊塑形 (noise shaping)，以符合人眼對不同色度的敏感度[4, 5]。

第三類為迭代法，此類演算法會在整張影像上反覆進行像素調整，以最小化視覺誤差或達成特定品質準則。代表性技術為直接二元搜尋法 (Direct Binary Search, DBS)。DBS 通常透過定義成本函數，配合點擴散函數 (Point Spread Function, PSF) 模擬人眼的低通濾波特性，逐點進行像素切換 (toggle) 與交換 (swap) 操作。其最終目標為在可接受的視覺品質下取得最佳化的二值化影像。雖 DBS 能提供極高品質的輸出結果，但其運算複雜度遠高於其他方法，實作上常需平衡效能與品質需求。

上述三類半色調演算法各具優劣，逐點法雖計算效率高，但品質有限，鄰域法在品質與效率間達成良好折衷，而迭代法則以計算資源為代價，追求最佳的視覺重建效果。

### 2.1.1 向量擴散誤差

向量擴散誤差 (Vector Error Diffusion, VED) 演算法最早由 Haneishi 等人提出[6]，其核心在於將每像素的量化誤差視為向量，並以矩陣形式的濾波器同時向多個色彩通道分配誤差，以保留通道間的關聯性並優化視覺品質。

如圖 2-1 所示，VED 演算法的第一步為將輸入的連續色調影像  $f[m]$ ，其中  $m$  為像素位置，從 *Linear sRGB* 色彩空間轉換至 *CIE L\*a\*b\** 色彩空間。此色彩

模型具備接近人眼視覺特性的感知均勻性，所以要比較任意兩個顏色的感知差異，直接計算他們之間的歐幾里得距離就可以得到。

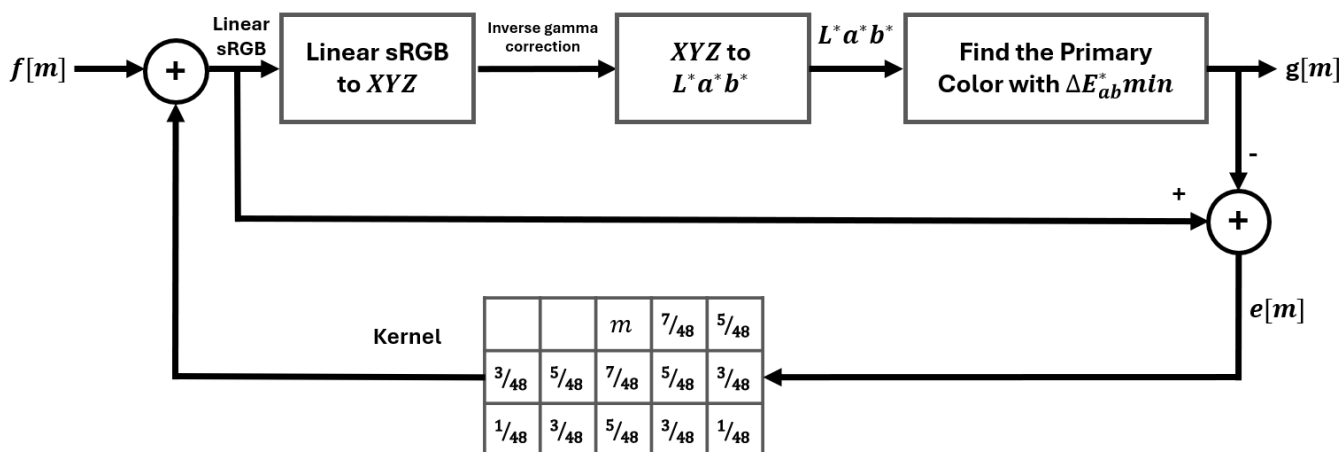


圖 2-1 VED 演算法流程圖

相較於 sRGB 空間中，線性或非線性皆不具感知均勻性，數值等距不代表人眼可感知的等距明度或色差， $L^*a^*b^*$  模型的設計目標是模仿人眼感知，因此更適合作為量化與誤差擴散的操作基礎。

如圖 2-1 流程圖上半所示，將 sRGB 轉換至 CIE  $L^*a^*b^*$  因為沒有直接轉換的公式，所以需要先轉換至 Linear sRGB 如式 2.1，移除 gamma 後轉換至 CIE XYZ 如式 2.2，接著才能轉換至 CIE  $L^*a^*b^*$ ，轉換公式如式 2.3 - 2.6。首先將 8-bit 的 sRGB 值 (0-255) 正規化到 [0-1] 的範圍，然後應用 sRGB 標準的反函式（伽瑪解碼函式）將其轉換為線性光強度值。這個函式大致相當於一個約 2.2 次方的冪函數，但它在暗部是一個線性區段，以避免在接近黑色的地方出現無限大的斜率。

$$C_{linear} = \begin{cases} \frac{C_{sRGB}}{12.92} & \text{if } C_{sRGB} \leq 0.04045 \\ \left(\frac{C_{sRGB} + 0.055}{1.055}\right)^{2.4} & \text{if } C_{sRGB} > 0.04045 \end{cases} \quad (2.1)$$

*Linear sRGB* 轉換至 *CIE XYZ* 的轉換公式如式 2.2，透過一個標準化的 3x3 矩陣乘法來完成。這個矩陣定義了 *sRGB* 的紅、綠、藍三個原色在 *CIE XYZ* 空間中的座標。

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4124 & 0.3576 & 0.1805 \\ 0.2126 & 0.7152 & 0.0722 \\ 0.0193 & 0.1192 & 0.9505 \end{bmatrix} \begin{bmatrix} R_{linear} \\ G_{linear} \\ B_{linear} \end{bmatrix} \quad (2.2)$$

$$L^* = 116 \left( f\left(\frac{Y}{Y_n}\right) - 16 \right) \quad (2.3)$$

$$a^* = 500 \left( f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad (2.4)$$

$$b^* = 200 \left( f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right) \quad (2.5)$$

$$f(t) = \begin{cases} t^{-3}, & \text{if } C_{sRGB} \leq 0.04045 \\ \frac{1}{3}t \left(\frac{6}{29}\right)^{-2} + \frac{4}{29} & \text{otherwise} \end{cases} \quad (2.6)$$

向量誤差擴散計算誤差的公式為 *CIE*  $\Delta E_{ab}^*$  如式 2.7，這是最早期、最基礎的色差公式，它直接計算兩種顏色在 *CIE*  $L^*a^*b^*$  色彩空間中的歐幾里德距離。當處理到像素  $m$  時，該像素的輸入值  $f[m]$  會加上來自已量化鄰近像素所擴散

而來的累積誤差總和  $e[m]$  會與所有基本色彩進行  $\Delta E_{ab}^*$  比較，找出最接近的目標色彩並做為其量化結果  $g[m]$ 。

$$\Delta E_{ab}^* = \sqrt{(L_i^* - L_p^*)^2 + (a_i^* - a_p^*)^2 + (b_i^* - b_p^*)^2} \quad (2.7)$$

此方法的主要優勢在於透過使用三維向量形式的誤差擴散，可同時考慮色彩成分間的相互關係，避免傳統以 R、G、B 通道為單位獨立擴散所可能引起的色偏或結構性瑕疵。但採用  $CIE \Delta E_{ab}^*$  直接用直線距離計算最小化誤差，這意味著  $CIE L^*a^*b^*$  空間中任意兩個點的距離很近，但顏色可以是不同的，同樣是  $\Delta E_{ab}^* = 1$  的差距，在灰色區域可能很明顯，但在高飽和度的藍色或綠色區域，人眼可能根本看不出差別，在本研究中會證明這件事。

### 2.1.2 直接二元搜索

Direct Binary Search (DBS) 為一種高品質的半色調演算法，最早由 Analoui 等人於 1992 年提出[7]。該方法透過最小化視覺誤差來產生視覺上更接近原始連續色調影像的二值化輸出。儘管 DBS 所生成的半色調影像品質優異，然而其本質上為一種基於像素調整的迭代式最佳化演算法，需進行大量的計算與重複更新，因此在運算資源有限的一般家用列印裝置中難以實用化。因此後來也有人提出更優化的 Truncation of Monotonically Non-Decreasing Swap Condition [8]。

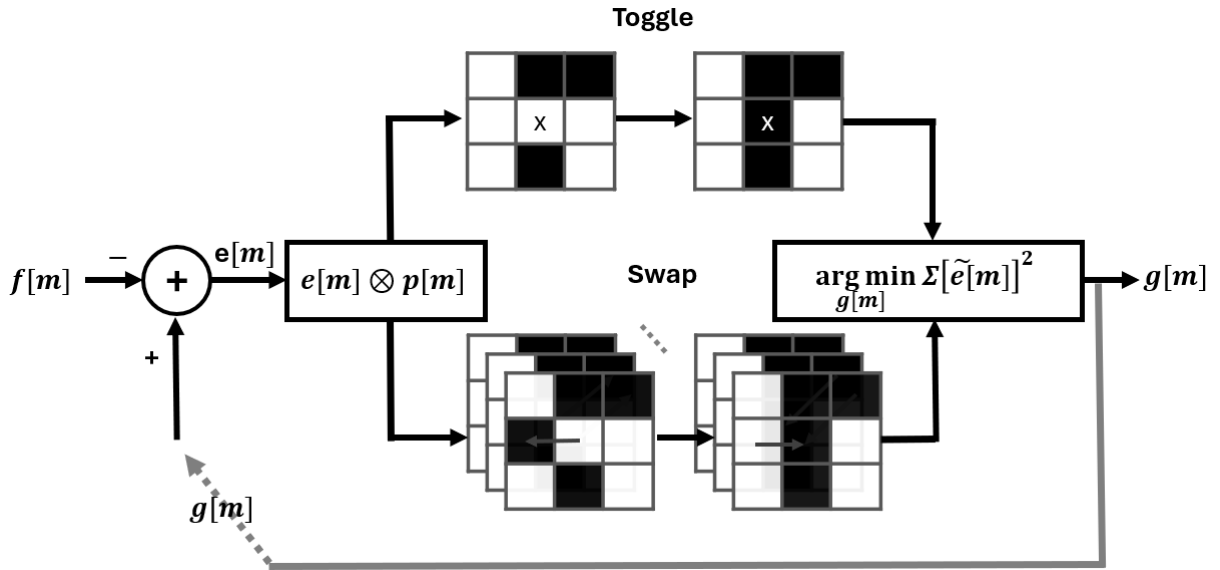


圖 2-2 DBS 流程圖

DBS 的核心目標為最小化原始影像  $f[m] \in [0,1]$  與對應半色調影像  $g[m] \in \{0,1\}$  之間的視覺差異，其中  $m$  為影像中某一像素位置。DBS 流程圖如圖 2-2 所示。

在開始迭代前，先計算原始影像  $f[m]$  與半色調影像  $g[m]$  之每個像素點的誤差  $e[m]$ ，如下方式 2.8 所示：

$$e[m] = g[m] - f[m] \quad (2.8)$$

為模擬人眼對影像的視覺感知，DBS 引入點擴散函數 (Point Spread Function, PSF) 計算公式如下方式 2.9 所示，用以模擬人眼的低通濾波特性。人眼感知誤差  $\tilde{e}[m]$  是誤差  $e[m]$  與點擴散函數  $p[m]$  進行卷積後的結果，如下方式 2.10 所示：

$$p[m] = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (2.9)$$

$$\tilde{e}[m] = e[m] * p[m] \quad (2.10)$$

最後計算感知誤差  $\tilde{e}[m]$  的均方誤差 (Mean Square Error, MSE) 作為整體視覺品質誤差  $E$ ，而最終的目標是讓這個成本函數  $E$  越小越好，如下方式 2.11 所示：

$$E = \sum_m \tilde{e}^2[m] \quad (2.11)$$

Toggle 操作，將某個像素點  $g[m_t]$  的值從 0 切換為 1，或從 1 切換為 0。計算切換前後對誤差的影響，切換操作會導致誤差  $\Delta\tilde{e}[m]$  的變化，如下方式 2.12 所示：

$$\Delta\tilde{e}[m] = \begin{cases} -2 \cdot p[m - m_t], & \text{if } g[m_t]: 0 \rightarrow 1 \\ +2 \cdot p[m - m_t], & \text{if } g[m_t]: 1 \rightarrow 0 \end{cases} \quad (2.12)$$

Swap 操作交換兩個像素  $m_t$  和  $m_s$  的值，計算視覺誤差的差異，其誤差變化如下方式 2.13 所示：

$$\Delta\tilde{e}[m] = (g[m_s] - g[m_t]) \cdot (p[m - m_t] - p[m - m_s]) \quad (2.13)$$

更新成本函數，計算操作後成本函數的變化  $\Delta E$  如下方式 2.14 所示：

$$\Delta E = \sum_m (\tilde{e}[m] + \Delta\tilde{e}[m])^2 - \sum_m \tilde{e}^2[m] \quad (2.14)$$

DBS 透過上述步驟，不斷微調半色調影像，使其在視覺感知上盡可能接近原始影像。其優勢在於高品質的視覺輸出，但缺點為計算成本高，需多次遍歷影像資料。

### 2.1.3 多重色彩搜索法

為進一步擴展 DBS 於彩色半色調領域中的應用，Lin 提出了多重色彩搜尋法 (Multiple Color Search, MCS) [9]，相較於傳統 DBS 會先將影像拆成 R、G、B 三通道分別計算，這樣做的結果會造成 RGB 三通道在色彩上的調整並沒有交互關係，只是單純的在尋找單通道某個像素點的最小值而已，而 MCS 將色彩視為三維向量，操作於 RGB 空間中，並以最小化連續色調影像與半色調影像在三維色彩空間中的均方誤差為目標，MCS 將此操作推廣至離散的多基色集合中。

MCS 同樣延續 DBS 的交換 (swap) 機制，針對像素點  $m_t$  與其鄰近像素點  $m_s$ ，若兩者所屬色彩不同，則交換其在 RGB 三個通道上的色彩分量，形成新的候選畫面。透過此交換，不僅能調整局部色彩結構，也能探索較廣泛的組合空間以降低總體感知誤差。在評估操作成效時，MCS 會先將色彩空間轉換到 CIE  $L^*a^*b^*$ ，並針對每一個通道分別計算成本變化量  $\Delta E_R, \Delta E_G, \Delta E_B$ ，再將其加總得到  $\Delta E_{sum}$ 。Lin 提出的 MCS 整體流程圖如圖 2-3 所示。

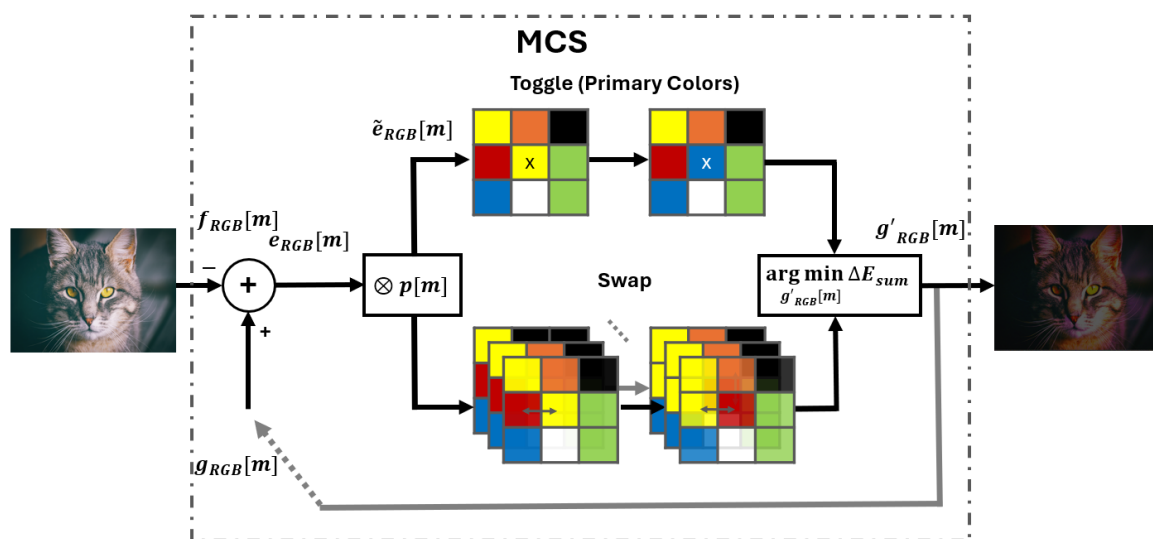


圖 2-3 Lin 提出的多重色彩搜索法流程圖

當執行 toggle 時，將半色調值  $g_{R,G,B}[m_t]$  切換為基本色彩  $Col_{pR,G,B} \circ a_{tR,G,B}$  和  $a_{sR,G,B}$  定義如下方式 2.15 所示：

$$a_{tR,G,B} = Col_{pR,G,B} - g_{R,G,B}[m_t], \quad a_{sR,G,B} = [0 \ 0 \ 0]^T \quad (2.15)$$

交換操作中，MCS 會將操作點  $a_{tR,G,B}$  與其鄰近像素  $g_{R,G,B}[m_s]$  的三通道色彩值進行交換。此時，係數  $a_{tR,G,B}$  與  $a_{sR,G,B}$  的更新方式則定義於下方式 2.16：

$$a_{tR,G,B} = g_{R,G,B}[m_s] - g_{R,G,B}[m_t], \quad a_{sR,G,B} = -a_{tR,G,B} \quad (2.16)$$

無論是切換或交換操作，都會影響誤差分布，因此需針對每個通道重新計算誤差  $e_{R,G,B}[n]$  並與視覺模型中預設的點擴散函數（Point Spread Function, PSF） $p[m]$  進行卷積，得出感知誤差  $\tilde{e}_{R,G,B}[m]$  如下方式 2.17 - 2.18：

$$\tilde{e}_{R,G,B}[m] = \sum_n e_{R,G,B}[n] \cdot p[m-n] \quad (2.17)$$

$$\Delta \tilde{e}_{R,G,B}[m] = a_{tR,G,B} \cdot p[m-m_t] + a_{sR,G,B} \cdot p[m-m_s] \quad (2.18)$$

此感知誤差反映人眼對於像素誤差的實際感受。成本函數（Cost Function）則定義為所有像素的感知誤差平方和，如下方式 2.19 - 2.20 所示：

$$E_{R,G,B} = \sum_m |\tilde{e}_{R,G,B}[m]|^2 \quad (2.19)$$

$$\Delta E_{R,G,B} = \sum_m |\tilde{e}'_{R,G,B}[m]|^2 - \sum_m |\tilde{e}_{R,G,B}[m]|^2 \quad (2.20)$$

在每次操作後，MCS 分別計算各通道的成本變化量  $\Delta E_R$ 、 $\Delta E_G$ 、 $\Delta E_B$ ，並求其總和以獲得操作總成本變化量  $\Delta E_{sum}$ ，每次操作都會和前一次的操作相比，操作必須要能讓成本函數下降才能選擇該操作，接著用選擇後產生的最小  $\Delta E_{sum}$  來更新  $g_{R,G,B}[m]$ ，更新後的該像素顏色表示為  $g'_{R,G,B}[m]$ ，公式如下方式 2.21 所示：

$$\Delta E_{sum} = \Delta E_R + \Delta E_G + \Delta E_B \quad (2.21)$$

該過程會重複進行，直至所有像素的調整不再帶來成本函數的下降，亦即演算法收斂為止。在迭代過程中，同一像素可被多次更新以逐步逼近最小成本解。

相較於原始的 Direct Binary Search (DBS) 方法，MCS 同時考慮基本色彩之間的切換與色彩向量的交換，避免了 DBS 需分別對 R、G、B 三通道進行三次獨立二元搜尋的冗餘操作。這使得 MCS 對於固定色彩數量的彩色半色調問題具更高的效率與整體一致性。

#### 2.1.4 真實色彩半色調演算法

為提升 PCeP 在實際觀察環境中的色彩再現能力，Lin 進一步提出一種以真實觀察色彩 (True Color) 為基準之半色調流程[9]，該方法特別針對具備色彩濾光片 (Color Filter Array, CFA) 排列特性的 PCeP 設計，並針對標準 *sRGB* 影像進行色彩調適與處理。整體演算法架構如圖 2-4 所示，核心理念為利用裝置實際可顯示的色彩作為基本色彩集。

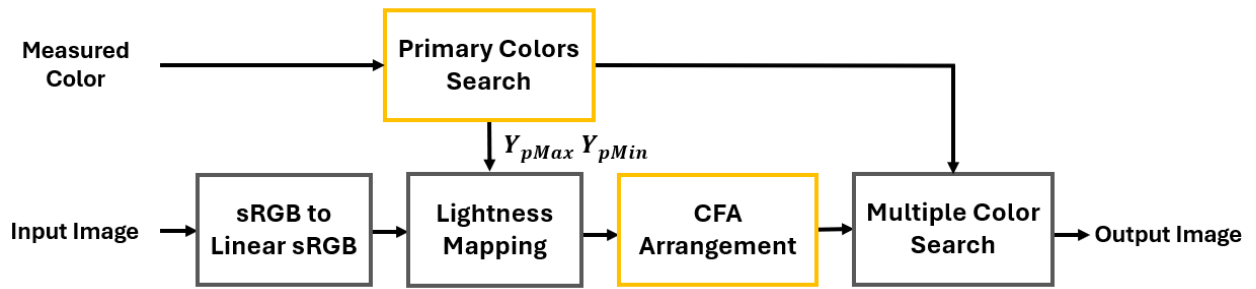


圖 2-4 Lin 提出的真實色彩半色調演算法流程圖

首先利用分光光度計對 PCeP 進行量測，取得在特定照明與觀看角度下 PCeP 能顯示的最佳化色彩數值，並作為半色調演算法中選用的基本色彩（Primary Colors）。

由於分光光度計所輸出之色彩空間屬於 *Linear sRGB* 色彩空間，而常見影像來源則使用 *sRGB*，因此須對輸入影像進行色彩線性化處理（inverse gamma correction），以對應分光光度計量測的色彩空間。接著，為了確保輸入影像有確實使用到 PCeP 完整的亮度動態範圍，所以需要進行亮度映射，將輸入影像的亮度映射到 PCeP 的亮度範圍，亮度映射實際的作法會在後續 3.2.2 小節做完整的介紹。

此演算提出了可以用量測的方式得到電子紙的每一個灰階的色彩，將 PCeP 能顯示的 4096 色都量出來後，再透過 MCS 演算法做半色調處理將每一個 pixel 計算誤差最小化後，理論上所顯示的顏色都應該是 PCeP 電子紙能顯示最正確的色彩，但此方法並不是將電子紙能顯示的 4096 色都量測出來並作為基本色彩使用，而是先進一步的限縮量測的色彩成 *RGBCMYK*，這樣只需要量測 7 色各 16 灰階的 112 色，然後再透過 Lin 所提出的基本色彩的量測與搜索法[10]，得到這 112 色最常用到的 RGB 三通道各別的 16 階，也就是 48 色的數值做為基本色彩。

首先是透過最佳化演算法從 112 色中搜尋得到 PCeP 的 48 個基本色彩來做 4096 色的色彩校正事實上還是有困難的，再加上先前在 2.1.1 小節有提到的使用  $CIE \Delta E_{ab}^*$  這種在色彩空間找到任意兩點最近的直線距離本身就是有疑慮的，如果是色彩飽和度較高的綠或藍色，人眼可能分不太出來，但在暗部區域就會出現明顯的色偏如圖 2-5 所示。




圖 2-5 Lin 提出的真實色彩半色調演算法顯示於 PCeP 上的畫面(左)、為原始 sRGB 32 色 Color Checker(右)

## 2.2 彩色電子紙色彩校正

雖然過去已有多項研究針對具印刷彩色濾光片 (Color Filter Array, CFA) 結構之彩色電子紙提出各類影像處理技術，包括色彩增強、半色調與錯視補償等方法，但針對彩色電子紙進行精確色彩校正 (color correction) 的研究仍相對稀少。由於彩色電子紙具有低反射率、窄色域以及色彩重現非線性等特性，傳統應用於液晶顯示器 (LCD) 或印刷輸出裝置的校正方法未必能直接適用。

Lee 等人曾針對一般輸出設備提出一套標準化的色彩校正流程[11]，其核心包含三個主要階段：(1) 對輸入訊號進行線性調整；(2) 透過線性  $3 \times 3$  色彩校正矩陣或三維查找表 (3D Lookup Table, 3D-LUT) 進行色域映射；(3) 根據設備特

性加入非線性補償（如 gamma 校正或分段式校正）。該流程已被廣泛應用於顯示器與列印設備的色彩一致性調整。

### 2.2.1 色彩校正矩陣

色彩校正矩陣是一種透過線性變換來校正色彩表現的直接方法，Chen 提出的影像處理流程如圖 2-6 [12]，該流程首先對輸入影像進行色彩校正（Color Calibration），即透過最佳化演算法計算得到的  $3 \times 3$  色彩校正矩陣（Color Correction Matrix, CCM），將輸入影像的色彩轉換至更接近原始色域。接著進行色調重現（Tone Reproduction），將具有寬廣動態範圍的場景亮度與顏色，映射至電子紙有限動態範圍輸出，並透過色彩增強（Color Enhancement）調整影像的飽和度和對比度，最後再經由半色調處理（Halftoning）利用人眼的空間整合特性，讓 PCeP 這種窄色域的顯示器模擬出連續灰階或彩色階調的視覺效果。



圖 2-6 Chen 提出的 CCM 彩色電子紙影像處理流程

PCeP 使用 CCM 做色彩校正前，需要先透過量測的方式得到電子紙上 24 色的色彩值，接著對量測數值做縮放後，最後透過最佳化演算法出得到一個  $3 \times 3$  的 CCM，此方法的顯著優勢在於其計算效率，因為 CCM 實際上就是對色彩進行矩陣運算，易於平行化處理，但用這種簡單的矩陣運算來解決非線性的色彩問題事實上並不合理，通過最佳化 CCM 計算後的參數往往會出現極大極小值如圖 2-7 所示這會導致部分像素校正後的 RGB 值超出  $[0, 255]$  的有效範圍，通常遇到這種極大極小值就會採用裁減（Clipping）到 0 或 255，但仍然會嚴重損失高光或暗部區域的色彩細節。




圖 2-7 像素顏色校準範例

## 2.2.2 色域映射

Hong 提出了一套基於色域映射的非線性色彩重現流程如圖 2-8 [13]，此流程的核心目的是將輸入影像的 *sRGB* 色域映射到 *PCeP* 的色域內。其具體步驟如下：首先，流程圖的上方色域前處理的部分，先透過量測得到電子紙在 *XYZ* 色彩空間的色域進行正規化後再轉換至 *OKLab*，接著將電子紙原始色域的白點對齊到 *OKLab* 空間 *L* 的最大值，然後將電子紙原始色域透過旋轉矩陣讓黑點對齊 *OKLab* 的中性軸。隨後，將輸入的 *sRGB* 影像轉換至 *OKLab* 色彩空間，再透過色域映射，映射到 *PCeP* 的色域內，接著進行色域後處理，將色域前處理時改變的色域還原回電子紙的真實量測色域，最後透過向量誤差擴散，對影像作半色調處理後顯示到電子紙上。

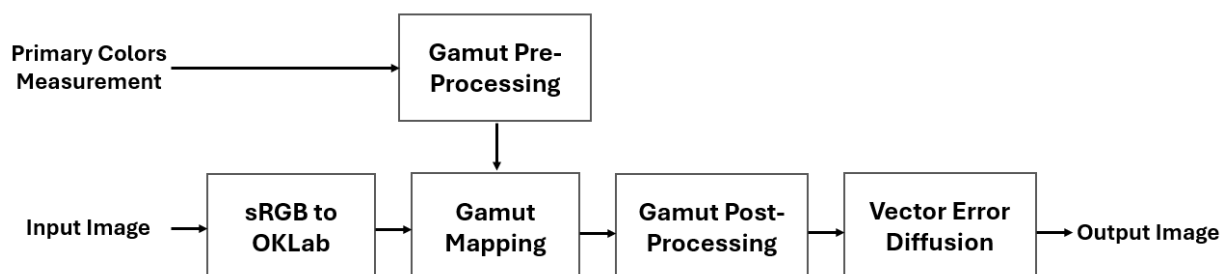


圖 2-8 Hong 提出的多粒子彩色電子紙色彩重現流程

在 Hong 提出的方法中，色域前處理的部分，將整個電子紙色域跟著  $L$  值直接貼齊到  $OKLab$  空間  $L$  的最大值 1，這個操作本身會極大地影響對比度，如果整個色域的  $L$  值被不成比例地拉高，意味著所有顏色都會變得更亮，黑色的部分會看起來像深灰色。



## 第三章 研究方法

本章將完整說明本研究所提出之彩色校正方法的整體流程與技術細節。首先介紹本研究所提出了一個名為 ColorCorrectionNet 的色彩校正架構，這個架構是針對電子紙顯示器開發，在本研究中不只有提出核心架構設計，總共訓練了兩個模型運用在不同的場景，也成功部署到 Jetson Orin NX 上進行效能測試；接著介紹所提出的半色調演算法、影像處理流程和介紹一個不同於過去，一個新的量化演算法效能的指標；最後介紹資料集來源、資料前處理，並說明訓練與測試樣本如何配置。

### 3.1 網路架構設計

本研究提出一個名為 ColorCorrectionNet 基於深度可分離卷積 (Depthwise Separable Convolution) 的神經網路架構，其架構類似 U-Net 的編碼器-解碼器結構，但沒有使用下降採樣與上採樣層，因為上採樣會使影像引入偽影[14]，而下採樣則會導致特徵細節丟失[15]。ColorCorrectionNet 在整個特徵提取過程中維持完整的解析度，此設計旨在保留影像的精細紋理與空間細節，這對於像素級的色彩校正任務至關重要。網路的核心組件為深度可分離卷積塊 (Depthwise Separable Convolution Block)，並透過兩層跳躍連接 (Skip Connections) 融合不同深度的特徵，這樣設計的好處可以比 U-Net 架構在訓練時減少更多的 Vram 使用量，但侷限性是只能應用在固定的解析度。

ColorCorrectionNet 的整體結構如圖 3-1 所示。輸入為 3 通道 RGB 影像首先通過一系列深度可分離卷積塊進行特徵提取，網路通道數依序從 64、128 擴展至

256，以捕捉從低階到高階的語義特徵。隨後網路再將通道數逐層降回，並在此過程中引入了兩條關鍵的跳躍連接。

跳躍連接將淺層網路的輸出特徵圖，即 Conv Block 1 和 Conv Block 2 與深層網路對應的輸出特徵圖 Conv Block 5 和 Conv Block 4 進行元素級相加 (element-wise addition)。此設計它能有效降低梯度消失問題，讓梯度能更順暢地反向傳播至淺層網路，而且它會將含空間細節的淺層特徵與經過深度處理的抽象語義特徵相結合，有助於模型重建高質量的影像。最後融合後的 64 維特徵圖通過一個標準的 3x3 卷積層，將通道數降維至 3，並經由 Sigmoid 激活函數將輸出值壓縮至  $[0, 1]$  區間，對應標準化的 RGB 影像。

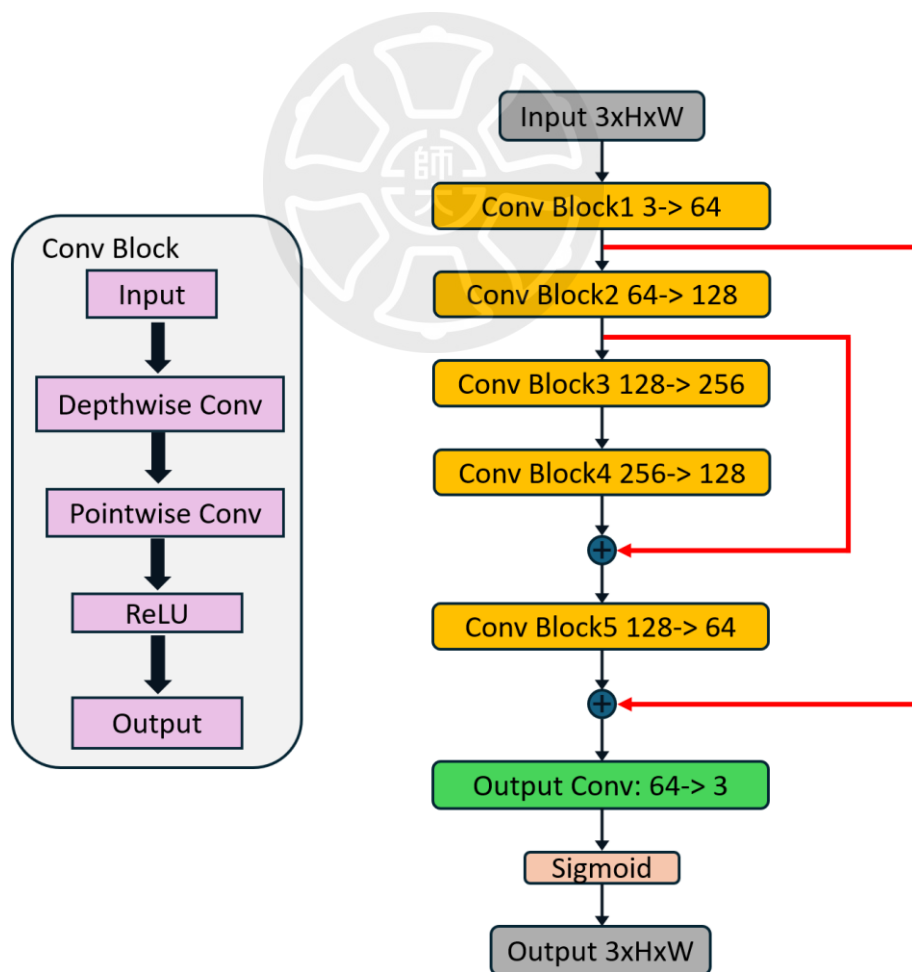


圖 3-1 ColorCorrectionNet 架構流程圖

### 3.1.1 深度可分離卷積模組

為減少模型參數並提升推論效率，本研究採用深度可分離卷積（Depthwise Separable Convolution, DSC）來取代傳統卷積操作。深度可分離卷積由兩個連續的操作組成一個為 Depthwise convolution 針對每一輸入通道分別進行空間卷積另一個為 Pointwise convolution 使用 1x1 卷積整合所有通道資訊。Depthwise Convolution 計算公式如下方式 3.1 所示：

$$G_{(i,j,k)} = \sum_{u=0}^{D_K-1} \sum_{v=0}^{D_K-1} K_{d(u,v,k)} \times F_{(i+u,j+v,k)} \quad (3.1)$$

其中  $F \in \mathbb{R}^{D_F \times D_F \times M}$  為輸入特徵圖， $K_d \in \mathbb{R}^{D_k \times D_k \times M}$  為  $M$  個深度卷積核，每個核只有一個通道， $G \in \mathbb{R}^{D_F \times D_F \times M}$  為中間輸出特徵圖， $k \in \{0, 1, \dots, M-1\}$  為通道索引，輸入特徵圖的空間維度為  $D_F$ ，卷積核的空間維度為  $D_K$ 。Pointwise Convolution 計算公式如下方式 3.2 所示：

$$Y_{(i,j,n)} = \sum_{m=0}^{M-1} W_{(m,n)} \times G_{(i,j,m)} \quad (3.2)$$

其中  $W \in \mathbb{R}^{M \times N}$  為點卷積權重矩陣， $Y \in \mathbb{R}^{D_F \times D_F \times N}$  為最終輸出特徵圖， $n \in \{0, 1, \dots, N-1\}$  為輸出通道索。最後，將兩個步驟結合，完整的深度可分離卷積可表示為下方式 3.3：

$$Y_{(i,j,n)} = \sum_{m=0}^{M-1} W_{(m,n)} \times \left[ \sum_{u=0}^{D_K-1} \sum_{v=0}^{D_K-1} K_{d(u,v,k)} \times F_{(i+u,j+v,k)} \right] \quad (3.3)$$

### 3.1.2 損失函數

本研究採用加權組合損失函數，使模型可以兼顧結構與像素精度，L1 損失與結構相似度 (SSIM) 損失如下方式 3.4，其中  $\lambda_1$  為 L1 Loss 的權重，而  $\lambda_2$  為 SSIM Loss 的權重，這兩個的權重需要根據任務得目標調整權重，如果強調的是結構一致性，視覺品質要以 SSIM 為主時， $\lambda_2$  的占比就可以拉高，相對的如果任務需要以數值準確地像素重建，這時候就應該以  $\lambda_1$  的權重佔比較重，在本研究中比較著重在於結構一致的視覺品質，所以 SSIM Loss 的權重設為 1，L1 Loss 為輔，所以設定為  $\lambda_2 = 0.1$ ：

$$\mathcal{L}_{total} = \lambda_1 \cdot \mathcal{L}_{L1} + \lambda_2 \cdot \mathcal{L}_{SSIM} \quad (3.4)$$

其中 L1 loss 的公式和 SSIM loss 的公式如下方式 3.5 – 3.6：

$$\mathcal{L}_{L1} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.5)$$

$$\mathcal{L}_{SSIM}(y, \hat{y}) = 1 - SSIM(y, \hat{y}) \quad (3.6)$$

### 3.1.3 訓練策略與技術

為有效提升模型性能與收斂效率，本研究採取多項訓練技術策略以穩定優化流程，並充分發揮模型的學習潛力。

本研究優化器選用 AdamW (Adaptive Moment Estimation with decoupled Weight Decay) 作為模型參數的優化器[16-19]。該方法在傳統 Adam 演算法的基礎上，將權重衰減項 (Weight Decay) 與梯度更新機制解耦，能有效防止過擬合并提升泛化能力。初始學習率設為  $1e-4$ ，L2 正則化係數設為 0.01，以促進參數穩定學

習。為進一步提升模型在不同階段的學習效率，結合 ReduceLROnPlateau 學習率調度器，當驗證集損失在連續數輪未見改善時，動態調降學習率（衰減因子為 0.5），以便模型進一步細緻地擬合輸出。

為有效利用 GPU 記憶體資源並加速反向傳播計算，本研究導入 PyTorch 所提供的自動混合精度模組混合精度訓練技術（Mixed Precision Training）。該模組可於前向傳播與反向傳播期間，動態選擇使用 FP16 或 FP32 精度，透過 GradScaler 管理梯度放大機制，以防止梯度過小導致的精度流失，同時維持數值穩定性。此技術能顯著降低 VRAM 使用量並提升訓練速度，對於高解析度彩色影像的處理特別有效。

模型總訓練週期設為 300 個 Epoch，並設有條件式學習率更新機制，若驗證損失於連續 10 個 Epoch 都沒有下降，則啟動學習率調整以避免模型陷入局部最小值。該策略間接達成 early stopping 效果，能有效減少過擬合現象並加速訓練流程。

### 3.1.4 性能指標

為客觀評估模型於彩色影像色彩校正任務中的效能表現，本研究採用兩項結構與像素層級的評估指標：峰值訊噪比（Peak Signal-to-Noise Ratio, PSNR）與結構相似度指數（Structural Similarity Index, SSIM）這兩項指標也常被用在電腦視覺的深度學習領域 [20-22]，PSNR 主要用以衡量重建影像與目標影像之間的整體像素誤差，其公式如下方式 3.7 所示：

$$PSNR(y, \hat{y}) = 10 \cdot \log_{10} \left( \frac{MAX^2}{MSE(y, \hat{y})} \right) \quad (3.7)$$

其中， $MAX$ 為像素的最大可能值（對於正規化影像為 1.0）， $MSE(y, \hat{y})$ 表示預測影像與目標影像之間的均方誤差。

SSIM 指標從亮度（Luminance）、對比度（Contrast）與結構（Structure）三方面綜合衡量重建影像與目標影像的感知一致性，並以滑動視窗的方式逐區塊比較。SSIM 的值域為 $[0,1]$ ，越接近 1 表示影像在視覺感知上與原圖越接近。對大小為  $K \times K$  的滑動視窗內，子影像  $x$ （參考影像）與  $y$ （待評估影像），定義如下方式 3.8 – 3.10：

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}, \quad (3.8)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}, \quad (3.9)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (3.10)$$

其中  $\mu_x, \mu_y$  為視窗內像素平均值， $\sigma_x, \sigma_y$  為視窗內像素方差， $\sigma_{xy}$  為視窗內兩影像像素協方差， $C_1 = (K_1L)^2, C_2 = (K_2L)^2, C_3 = (C_2L)^2$  為穩定常數，常用的取值為  $K_1 = 0.01, K_2 = 0.03, L = 255$ ，將以上公式合併即得到區域 SSIM，SSIM 公式如下方式 3.11：

$$SSIM(x, y) = [l(x, y)]^\alpha [c(x, y)]^\beta [s(x, y)]^\gamma, \quad (3.11)$$

常用的取值為  $\alpha = \beta = \gamma = 1$ ，化簡為下方式 3.12：

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(u_x^2 + u_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3.12)$$

### 3.2 空間約束半色調演算法

PCeP 每個像素點的排列方式如圖 3-2 所示，每個像素點只顯示一個顏色，而未被顏色覆蓋的區域就是留白 (Blank)，因為 PCeP 沒有背光源，是透過反射的方式顯示，所以適當的留白比例可以幫助提升顯示畫面的亮度。

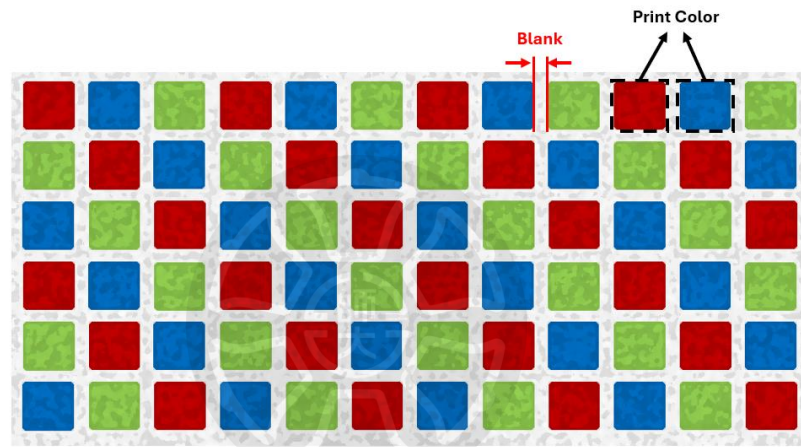


圖 3-2 PCeP 的印刷色彩及留白

本節提出的空間半色調演算法 (Spatially-Constrained Halftoning, SCH) 能適用於不同印刷塗佈率的 PCeP，本方法之最大優勢，在於僅需知道 PCeP 的印刷塗佈率，即可建立對應之色彩模型與半色調流程，無須額外的色彩量測或裝置校正，顯著降低系統部署的複雜度。本方法亦能有效提升 PCeP 最終輸出影像的色彩飽和度與主觀品質。具體流程如下，先透過塗佈率計算出色彩混和後的基本色彩，接著一張影像輸入進來後，需要先將色彩空間從 sRGB 轉換到 Linear sRGB 色彩空間，然後將輸入影像的亮度線性映射到 PCeP 的亮度範圍，接著為了避免誤差擴散會將誤差擴散到不同通道，所以在半色調演算法開始前需要根據 CFA 的排

列建立一個遮罩，最後透過基於 MCS 開發出的混合誤差抖色法，該方法之整體流程如圖 3-3 所示。

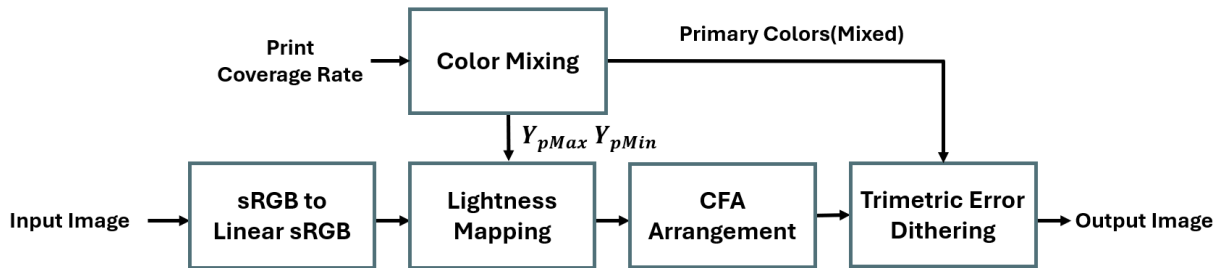


圖 3-3 空間約束半色調演算法流程圖

最後是多重色彩搜尋演算法，但並非採用 Lin 所提出的在  $CIE L^*a^*b^*$  空間進行誤差計算，而是轉換到提供了更好的感知均勻性的  $OKLab$ ， $OKLab$  解決了  $CIE L^*a^*b^*$  在色相預測上的問題，特別是藍色區域的色相預測不準確，並提升色彩細節還原能力，尤其對於中間調及高彩度區域表現顯著優於傳統方法。

### 3.2.1 色彩混合與印刷塗佈率

在 1.1 小節時提到，PCeP 實際上就是在具有 16 灰階的黑白色電子紙上印刷 RGB 的彩色濾光片 (Color Filter Array, CFA)，所以 Lin 提出了根據 PCeP 印刷塗佈率計算出色彩混和的概念[10]，該方法只需要知道使用的 PCeP 塗佈率，不需仰賴色彩量測。色彩混和的方式如圖 3-4 所示，其中  $B_{16}$  為第 16 階的藍色像素， $P$  為電子紙的塗佈率，以塗佈率 50% 為例， $K_{16}$  為第 16 灰階。




圖 3-4 Lin 提出的色彩混合計算示意圖

色彩混合的公式如式 3.13 所示，其中  $Col_{Mix,k}$  為第  $k$  階色彩混和後的色彩， $K_k$  為第  $k$  階灰階。

$$Col_{Mix,k} = Col_k \cdot P + K_k \cdot (1 - P) \quad (3.13)$$

### 3.2.2 亮度映射

由於輸入影像的亮度動態範圍通常與混色後所生成之基本色彩的亮度動態範圍存在差異，若不將輸入影像映射到 PCeP 的亮度範圍直接顯示，超出亮度範圍的部分將因無法正確對應而呈現過曝現象，導致畫面整體看起來偏白。相反地，若基本色彩的亮度範圍大於輸入影像，則將導致可用亮度資源未被充分利用，使最終顯示結果的對比度下降如圖 3-5 所示，鮮豔的色彩如紅色或是藍色會看起來偏灰。



圖 3-5 未進行亮度映射(左)、經過亮度映射後(右)顯示在 PCeP 的畫面

輸入影像彩色轉灰階的亮度計算公式，計算出 *CIE XYZ* 色彩空間中的  $Y$  值，計算公式如式 3.14 所示。

$$Y[m] = 0.212671 \cdot f_R[m] + 0.71516 \cdot f_G[m] + 0.072169 \cdot f_B[m] \quad (3.14)$$

其中  $Y[m]$  為在像素點  $m$  的亮度值，而  $f_R[m]$ ， $f_G[m]$  和  $f_B[m]$  則分別為去除 gamma 後的輸入影像  $f[m]$  的 *Linear sRGB* 三通道數值。透過亮度映射公式將輸入影像亮度線性映射到 PCeP 的亮度範圍，映射公式如下式 3.15 所示：

$$f'_{R,G,B}[m] = Y_{pMin} + (f_{R,G,B}[m] - Y_{iMin}) \times \frac{Y_{pMax} - Y_{pMin}}{Y_{iMax} - Y_{iMin}} \quad (3.15)$$

其中  $f'_{R,G,B}[m]$  為輸入影像在像素點  $m$  亮度映射後的 *Linear sRGB* 三通道數值， $Y_{pMax}$  為混色後的基本色彩亮度  $Y$  的最大值， $Y_{pMin}$  為混色後的基本色彩亮度  $Y$  的最小值， $Y_{iMax}$  為輸入影像亮度  $Y$  的最大值， $Y_{iMin}$  為輸入影像亮度  $Y$  的最小值。

### 3.2.3 印刷彩色濾光片排列

PCeP 每個像素只能顯示  $RGB$  其中一種顏色，所以在半色調演算法最後進行誤差擴散時，需要考慮到 CFA 排列的問題，避免將不同通道的誤差擴散到其他通道，PCeP 的 CFA 排列方式總共有兩種，如圖 3-6 所示：




圖 3-6 PCeP 的兩種 CFA 排列

### 3.2.4 混合誤差抖色法

MCS 演算法對影像的某個像素點進行操作時，考慮到這個像素點顏色的改變對三通道  $\Delta E_R$ 、 $\Delta E_G$ 、 $\Delta E_B$  成本函數的總和  $\Delta E_{sum}$  的變化量，但這樣的作法只是單純的考慮單一像素的最佳化，和過往研究提出的半色調演算法一樣，都沒有考慮到空間上色彩連續性的問題，導致畫面上產生雜訊和不自然的跳變，如圖 3-7 所示。為此，本研究提出了混合誤差抖色法 (Trimetric Error Dithering, TED)，具體的做法是將 MCS 演算法的  $\Delta E_{sum}$  從原本簡單的選擇最接近顏色，改成同時考慮了感知顏色誤差 (Perceptual Color Error)、誤差擴散 (Error Diffusion) 和空間連續性 (Spatial Coherency)。




圖 3-7 過往半色調演算法和本研究提出的方法顯示在 PCeP 的畫面

TED 演算法完整的流程圖如圖 3-8 上半部 (a) 所示，Toggle 計算流程如 (b) 所示，其中  $E_{OKLab}^{(k)}$  在色彩科學上更均勻的  $OKLab$  色彩空間來計算目標顏色與候選顏色之間的差異，確保選擇的顏色在視覺上最接近， $E_{diffusion}^{(k)}$  將選擇顏色後產生的誤差擴散到周圍的鄰近像素，避免產生大面積的色塊，讓整體色調過渡更平滑， $E_{spatial}^{(k)}$  懲罰那些與周圍同通道像素顏色差異過大的選擇，以保持影像的平滑度和紋理，避免產生不自然的噪點。

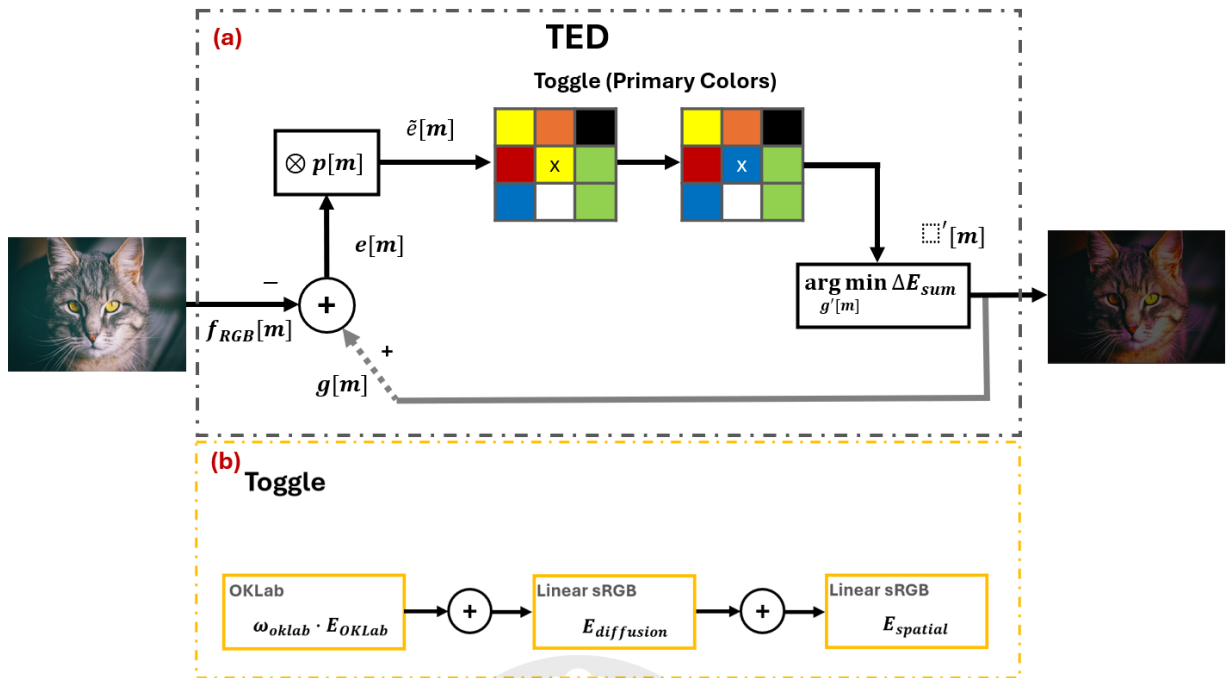


圖 3-8 TED 演算法流程圖(a)、Toggle 計算流程(b)

輸入影像  $f[m] \in [0,1]$  與對應半色調影像  $g[m] \in \{0,1\}$ ，其中  $m$  為影像中某一像素位置。在開始迭代前，先計算  $f[m]$  與  $g[m]$  之每個像素點的誤差  $e[m]$ ，如下方式 3.16 所示：

$$e[m] = g[m] - f[m] \quad (3.16)$$

為模擬人眼對影像的視覺感知，引入 PSF 計算公式如下方式 3.17 所示，用以模擬人眼的低通濾波特性。人眼感知誤差  $\tilde{e}[m]$  是誤差  $e_{ch}[m]$  與點擴散函數  $p[m]$  進行卷積後的結果，其中  $ch \in \{R, G, B\}$  為  $e_{ch}[m]$  中的 RGB 通道，計算公式如下方式 3.18 所示：

$$p[m] = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (3.17)$$

$$\tilde{e}[m] = e_{ch}[m] * p[m] \quad (3.18)$$

在 *OKLab* 色彩空間利用歐幾里德距離計算目標顏色與候選顏色之間的誤差  $E_{OKLab}$ ，計算公式如式 3.19–3.22 所示，其中候選色  $PC_{CFA,gl}$  為在哪個 *CFA* 通道的第  $gl$  個灰階值的顏色，*CFA* 代表該像素位置為哪個主要顏色的通道。 $\omega_L = 2$  為  $\Delta L$  的權重，給予  $\Delta L$  較高的權重是因為人類的視覺系統對亮度的變化遠比對色度的變化來得敏感[23]，對於 PCEP 這種色彩範圍和動態範圍都有限的顯示設備來說，優先保證正確的明暗結構，遠比追求微小的色彩精度更能討好人類的眼睛。

$$\Delta L = L_{PC_{CFA,gl}} - L_{target} \quad (3.19)$$

$$\Delta a = a_{PC_{CFA,gl}} - a_{target} \quad (3.20)$$

$$\Delta b = b_{PC_{CFA,gl}} - b_{target} \quad (3.21)$$

$$E_{OKLab} = \omega_L \Delta L^2 + \Delta a^2 + \Delta b^2 \quad (3.22)$$

計算擴散誤差  $E_{diffusion}$  的公式如下式 3.23 – 3.26 所示， $\Delta x, \Delta y, \Delta z$  為在 *Linear sRGB* 空間計算出來的差值，其中  $PC_{CFA,gl,c0}$  為在哪個 *CFA* 通道的第  $gl$  個灰階值的  $c0$  通道數值，假設現在處理的像素  $m$ ，其 *CFA* 值為 0，代表這個像素是一個紅色像素，因為主要顏色通道是紅色，所以  $c0$  為該像素點 R 通道的數值， $c1$  為該像素點 G 通道的數值， $c2$  為該像素點 B 通道的數值，如果 *CFA* 的值為 1，代表這個像素點為綠色，所以  $c0$  為該像素點 G 通道的數值， $c1$  為

該像素點 B 通道的數值， $c_2$  為該像素點 R 通道的數值， $g_{c_0}[m]$  為像素位置  $m$  目標顏色  $c_0$  通道的數值。最後  $E_{diffusion}$  的計算公式中， $p_{center}$  為 PSF 卷積核正中間的值， $e_{c_k}[m]$  為從先前像素累積到此的誤差，其中當  $k = x$ ， $c_k = c_0$ ，當  $k = y$ ， $c_k = c_1$ 。

$$\Delta x = PC_{CFA,gl,c_0} - g_{c_0}[m] \quad (3.23)$$

$$\Delta y = PC_{CFA,gl,c_1} - g_{c_1}[m] \quad (3.24)$$

$$\Delta z = PC_{CFA,gl,c_2} - g_{c_2}[m] \quad (3.25)$$

$$E_{diffusion} = \sum_{k \in \{x,y,z\}} [\Delta k^2 \cdot p_{center} + 2 \cdot \Delta k \cdot e_{c_k}[m]] \quad (3.26)$$

對於位置  $(i, j)$  的像素，計算同通道鄰近像素的平均值  $\bar{g}_{neighbor}$ ，其中  $\mathcal{N}$  是  $3 \times 3$  鄰域中同通道像素的集合， $N$  是鄰域中同通道像素的數量， $g_{n_i, n_j, c_0}$  為位置  $(n_i, n_j)$  處通道  $c_0$  的值，其公式如下式 3.27 所示：

$$\bar{g}_{neighbor} = \frac{1}{N} \sum_{(n_i, n_j) \in \mathcal{N}} g_{n_i, n_j, c_0} \quad (3.27)$$

飽和度  $S$ ，計算公式如下式 3.28 所示，其中  $\epsilon = 10^{-6}$  用於避免除零錯誤。

$$S = \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B) + \epsilon} \quad (3.28)$$

空間權重調整  $\omega_{neighbor}$ ，計算公式如下式 3.29 所示，其中當飽和度  $S$  值如果超過 0.7，代表該區域為高飽和度區域需要更極端的顏色選擇，就會對  $\omega_{neighbor}$  的值乘上 0.5，以降低空間約束允許算法選擇更極端的值來逼近目標顏色，而低飽和度區域保持較強的空間約束以維持平滑度。

$$\omega_{neighbor} = \begin{cases} 0.3 \cdot 0.5 = 0.15, & \text{if } S > 0.7 \\ 0.3, & \text{otherwise} \end{cases} \quad (3.29)$$

空間連續性暹罰  $E_{spatial}$ ，其計算公式如下式 3.30 所示：

$$E_{spatial} = \omega_{neighbor} \cdot (PC_{CFA,gl,c0} - \bar{g}_{neighbor})^2 \quad (3.30)$$

總誤差函數  $\Delta E$ ，計算公式如下式 3.31 所示：

$$\Delta E = 10 \cdot E_{OKLab} + E_{diffusion} + E_{spatial} \quad (3.31)$$

最後當  $\Delta E_{min} < 0$  時，誤差更新  $\tilde{e}_{n_i, n_j, c_k}$ ，其公式為下式 3.32 所示，對於  $(n_i, n_j) \in [i - hw, i + hw] \times [j - hw, j + hw]$ ， $k \in \{x, y, z\}$ ，其中  $hw$  為半個 PSF 卷積核的大小。

$$\tilde{e}_{n_i, n_j, c_k} = \tilde{e}_{n_i, n_j, c_k} + \Delta k_{optimal} \cdot p_{n_i - i + hw, n_j - j + hw} \quad (3.32)$$

### 3.3 訓練後量化

訓練後量化 (Post-training quantization, PTQ) 是一種用於減少深度神經網路記憶體佔用並提高推論速度的技術。在訓練後對網路進行 PTQ 轉換[20, 21]。這涉及將網路的權重和從高精度浮點 (如 FP32) 轉換為較低精度的整數表示(例如 INT8)，這個過程顯著降低了深度學習模型對於記憶體的需求和計算複雜度，使其更有效地部署在資源受限的設備上，如邊緣設備。值得注意的是 PTQ 可以實現更低的位元率以進行更快的優化。然而，在研究中發現大多數的邊緣裝置都支援 INT8 做 inference，像是自動駕駛的邊緣運算板也支援 INT8 推論[24]。因此，考慮到實際使用情況，本研究將模型量化為 INT8 以進行實際邊緣部署。

PTQ 後實際部署到 Jetson Orin 的流程圖如圖 3-9 所示，流程圖的最左邊開始，首先，在 PC 上載入.pth 權重，並將模型 export 成 ONNX 格式。接著準備 100 張左右訓練時用的 Input Images，轉成.npy 格式，尺寸與模型訓練時輸入的一致，這個 Calibration Dataset 會用來幫 TensorRT 計算 INT8 量化的 scaling factor。接下來在 Orin 上使用 TensorRT API 載入 ONNX 模型與 Calibration Dataset，生成真正的 INT8 engine。最後把訓練完的兩個模型的權重檔載入 Orin 後，就可以直接在 Orin 上做 Inference 了。

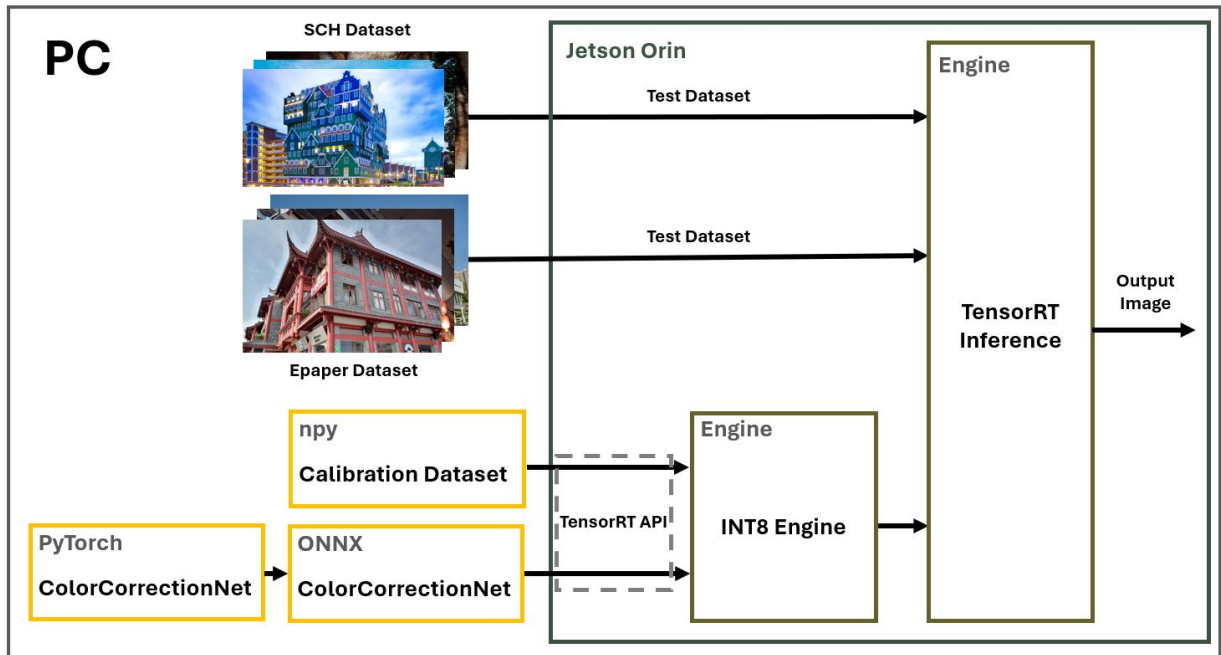


圖 3-9 PTQ 後實際部署到 Jetson Orin 流程圖

### 3.4 資料集

本研究總共使用了兩個不同的資料集，分別為電子紙製造商資料集（Epaper Dataset）和空間約束半色調資料集（SCH Dataset），電子紙製造商資料集 target image 的部分是由我們的電子紙製造商所提供，另一個空間約束半色調資料集 target image 的部分則是利用在 3.2 節提出的空間約束半色調演算法處理後的影像，使用兩個不同的資料集訓練出兩個模型是希望針對不同的應用場景，接下來會詳細的介紹這兩個資料集，而這兩個資料集的 input image 取自公開的資料集，但 target image 皆為本研究自行製作而成的，並沒有開源。

#### 3.4.1 電子紙製造商資料集

資料集的總共包含了 230 張的 input dataset 和 230 張的 target dataset，input dataset 的 230 張取自公開資料集 NTIRE 2024 low-light enhancement dataset [25] 的 230 張 target dataset，然後委託提供本研究使用電子紙的製造商，將每張影像針對

PCeP 的色彩表現調整到最佳化後，再提供給本研究用於所開發的色彩校正模型做訓練。訓練時資料集的拆分方式為 184: 23: 23，分別為 training、validation、test，採用固定的手動拆分，確保消融實驗結果的可靠度和訓練完後測試資料集的图片並不會被混進訓練或調整參數中，透過測試資料集證明模型在真實世界的實際效能。使用這個資料集的核心是為了要解決因半色調演算法後造成的文字彩邊問題。

半色調演算法最早被應用在印表機上技術最先出現在 19 世紀中後期的新聞報紙影像印刷中，用以在單色印刷中模擬照片的連續色調。在先前 2.1 小節提到的，半色調演算法非常適合拿來應用在色域相對狹窄的顯示器或列印限制下，盡可能保留原影像的視覺特性，在視覺上製造出連續色調的效果如圖 3-10 所示，但還是面臨了一大問題，就是顯示文字的問題，尤其是像電子紙這種特性就像是紙張一樣的電子顯示器，想要同時顧慮色彩表現跟閱讀文字舒適度上就面臨了極大的挑戰，先來介紹一下文字彩邊的問題如圖 3-11 所示。




圖 3-10 影像經過半色調演算法後顯示在彩色電子紙上




圖 3-11 Samsung QD-OLED 文字彩邊[1]

三星的 QD-OLED 面板是目前全世界最好的顯示面板，但也因為其獨特的鑽石型像素排列如圖 3-12 所示，所以才造成如圖 3-11 所示的文字毛邊現象 (Color fringing)，造成部分文書或是程式開發這類的使用者長時間使用會造成不適的原因，透過觀察可以發現越新的一代排列方式越來越接近方形，也代表著三星一直都在設法解決這個問題。

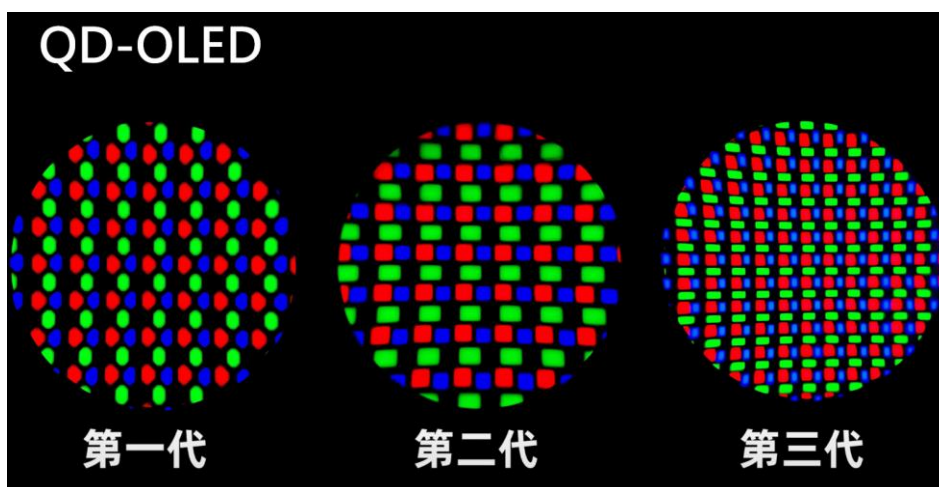


圖 3-12 Samsung QD-OLED 像素點排列

圖 3-13 中很明顯的可以看出來，經過半色調的影像顯示文字的效果並不理想，而這個資料集最大的特色是在 target images 的部分都是針對 PCeP 的色彩表現去對每張影像做調色，所以不需要經過半色調演算法或色彩校正演算法。實際的 target images 如圖 3-14 和圖 3-15 所示。



圖 3-13 原始影像(左)、半色調後的原始影像(右)



圖 3-14 原始 sRGB 影像(左)、電子紙製造商調色後顯示在 PCeP 的畫面(中)、半色調後的原始影像(右)



圖 3-15 原始 sRGB 影像(左)、電子紙製造商調色後顯示在 PCeP 的畫面(中)、半色調後的原始影像(右)

### 3.4.2 空間約束半色調資料集

資料集的 input dataset 來自於公開資料集 LIU4K-v2 [26]，LIU4K-v2 資料集包括 1600 個高解析度訓練資料集和 400 個高解析度驗證資料集，資料集中影像的解析度至少為 3K，其中大多數為 4K - 6K。本研究使用的 PCeP 顯示器解析度為 1872\*1404，所以這個資料集非常適合本研究使用，因為原始影像的解析度如果低於 PCeP 顯示器的解析度的話，雖然可以利用線性插值的方式將原始影像放大到 PCeP 的解析度，但這樣的做法就會造成影像模糊化，而在本研究中開發的是全解析度的色彩校正模型，所以任何細節的損失都希望可以避免。在本研究中為了增加模型的泛化性，LIU4K-v2 資料集中有提供不同類型的影像，在本研究中使用了動物、建築和街道共 1104 張影像，訓練時資料集的拆分方式如下表 3-1 所示，一樣為固定的手動拆分，確保消融實驗結果的可靠度和訓練完後測試資料集的图片並不會被混進訓練或調整參數中。

表 3-1 資料集詳細配置

Type \ Dataset	Training	Validation	Test
Animal	249	30	30
Building	320	40	40
Street	315	40	40
Total	884	110	110



## 第四章 實驗結果

接下來會依序介紹本篇論文所做的實驗結果，首先是本研究的實驗環境和所有用到的相關設備。再來是本研究提出的 AI 調色模型在兩個不同資料集完整的消融實驗，然後是將本研究提出的半色調演算法顯示在電子紙上的結果跟過往研究的差異，並且也會展示兩個資料集分別在 PC 和 Jetson Orin 推理後的影像實際顯示在 PCeP 的畫面，並使用本篇論文所提出的量化指標 CIEDE2000 來進行誤差比較，最後是色彩校正模型經過 PQT 後在 Jetson Orin NX 推理跟 PC 上使用全精度推理，兩者在 PSNR、SSIM 和 FPS 上面的完整結果比較。

### 4.1 實驗環境與設備

本研究開發的深度學習模型的訓練平台 CPU: R9 7950X、GPU: 4090 如圖 4-1 所示。測試模型經過訓練後量化的邊緣運算設備為 Nvidia Jetson Orin NX 16G。本研究所使用的印刷彩色電子紙為 E Ink *Kaleido*<sup>TM</sup>3，解析度為 1872×1404 像素，每個 pixel 表面印刷了 RGB 濾光片，具有 16 階的色階，如圖 4-2 所示。本論文所使用 X-Rite i1 Pro 3 分光光度計進行量測，在跟先前研究所開發出來的演算法進行比較需要有辦法將 32 色 Color Checker 的顏色量化出來才能使用量化指標來量化結果，X-Rite i1 Pro 3 的功用是用來量測將 32 色 Color Checker 的影像經過半色調演算法後的結果顯示在 PCeP 上的 CIE Lab 數值。電子紙的顯示畫面透過 Canon MG4270 掃描獲取，設備如圖 4-3 所示。



圖 4-1 Nvidia RTX 4090 (左)、AMD R9 7950X (右)



圖 4-2 E Ink Kaleido 彩色電子紙(左)、Nvidia Jetson Orin NX 16G(右)

## 4.2 消融實驗

在本研究中針對兩個不同的資料集都做了消融實驗(Ablation Study)，因為兩個資料集的 target images 的影像顏色校正方式截然不同，在研究中也發現同樣的參數選擇在另一個資料集上的表現並不好，所以確實有必要針對兩個資料集都做消融實驗。模型的 baseline 為 3.1 節提出的 ColorCorectionNet 的網路架構圖，其中損失函數(Loss Function)為 MSE Loss，優化器(Optimizer)為 AdamW，正則化為 L2 Norm，使用 torch2 的混合精度訓練。本論文判斷影像品質的好壞以 SSIM 為



圖 4-3 Canon MG4270 掃描機(左)、X-Rite i1 pro 分光光度計

主 PSNR 為輔來調整模型參數，接下來會依序的介紹消融實驗的結果。

### 4.2.1 電子紙製造商資料集的消融實驗

在電子紙製造商資料集所使用的模型架構跟 baseline 的一樣，因為在 SCH Dataset 的訓練結果損失函數使用組合損失的效能比 MSE 來的好，所以在這個資料集使用了測試資料集做測試。CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0 的組合損失函數為 L1 Loss + SSIM Loss，其中 L1 Loss 的權重為 0.1，SSIM Loss 的權重為 1.0，訓練了 300 個 Epoch 後，實際在 Epaper Dataset 測試資料集的結果如表 4-1 所示，CCN\_MSE 的 SSIM 為 0.91853，雖然 CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0 的 PSNR 和

Loss 的結果都比 CCN\_MSE 還好，但本研究的主要指標為 SSIM，所以在 Epaper Dataset 訓練的損失函數還是使用 MSE。

表 4-1 電子紙製造商測試資料集的結果

	SSIM	PSNR	Loss
CCN_MSE	<b>0.91853</b>	23.9796	0.0056
CCN_L1_SSIM_L1_0.1_L2_1.0	0.91795	<b>24.0473</b>	<b>0.0055</b>

消融實驗的結果如下圖 4-4 所示，在消融實驗中使用了 4 項指標做為評估模型好壞的依據，分別為 SSIM、PSNR、FLOPS 和 Parameters，以 SSIM 作為主要評估的指標，副評估指標為 PSNR。在每一個 Epoch 訓練結束後，就會 Inference 23 張 validation images，並跟 validation images 計算出每張的 SSIM 跟 PSNR，最後取平均值。SSIM 的值為[0,1]越接近 1 代表兩張影像的亮度、對比度和結構相似度都很相近，而 PSNR 的值最低為 0db 數值越高越好，FLOPS 跟 Parameters 的數值都是越小越好。從圖 4-4 的 SSIM 部分可以看出 MSE 的 SSIM 最高，所以最後的架構使用的是 MSE。

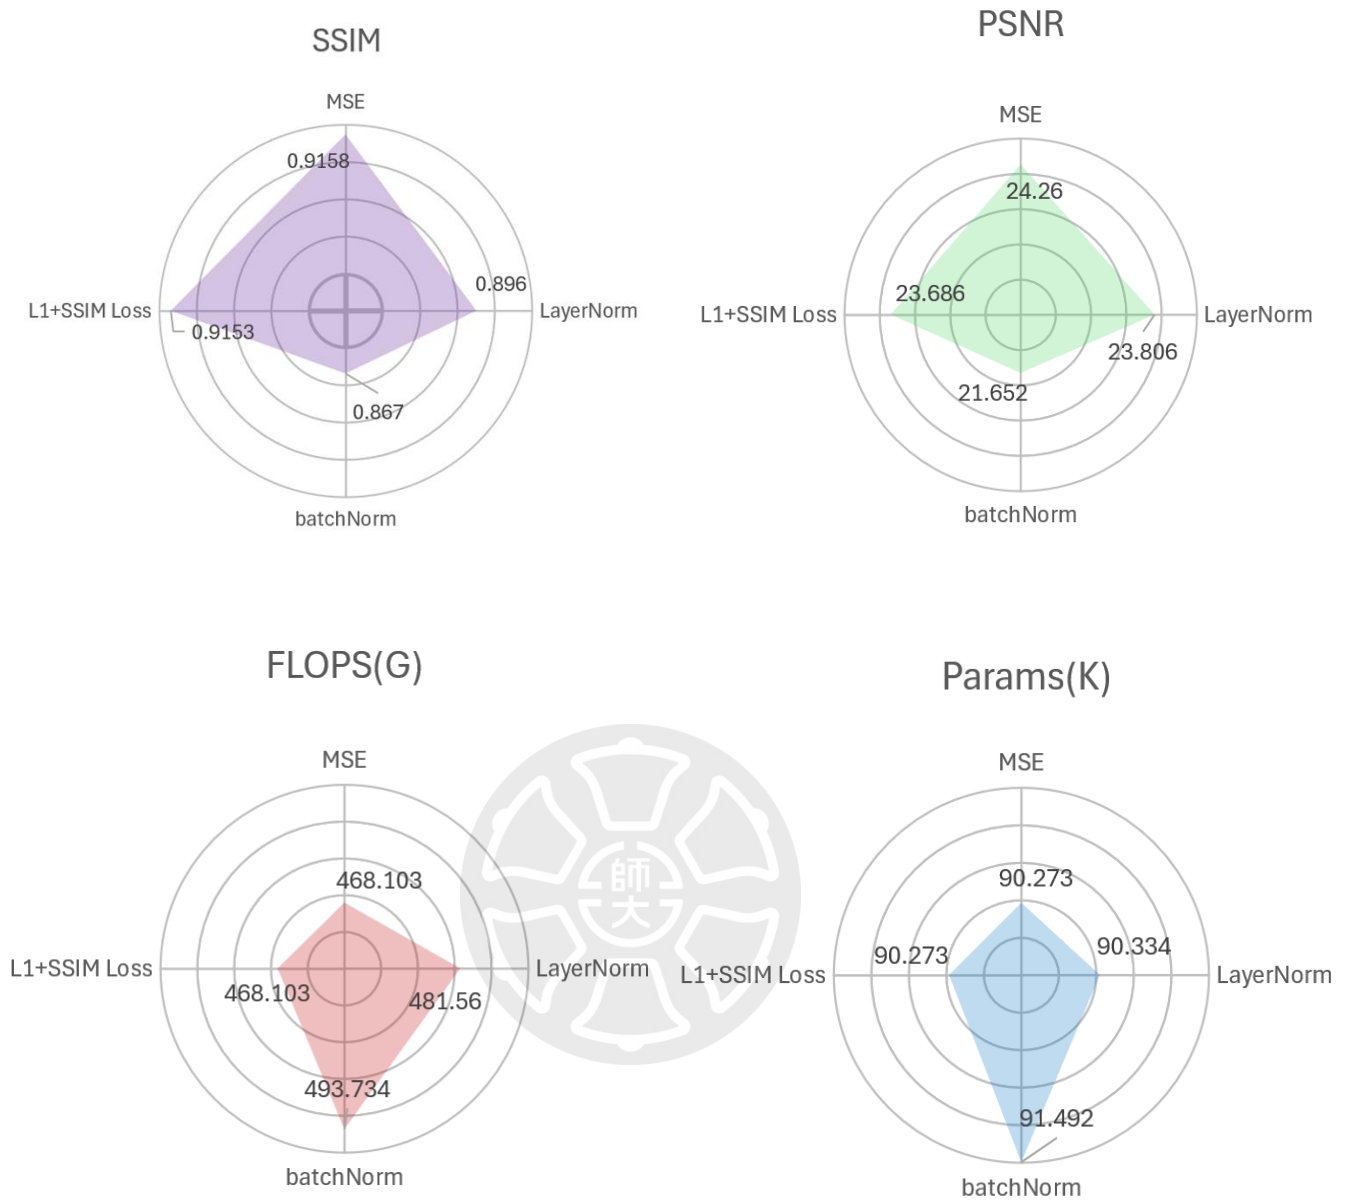


圖 4-4 電子紙製造商資料的消融實驗

圖 4-5 和圖 4-6 為 Epaper Dataset 訓練集和驗證集的訓練狀況，從兩張圖中可以發現，使用組合損失函數的 CCN\_L1\_SSIM\_L1\_1.0\_L2\_0.5 在 SCH Dataset 中有很好的效能，但在電子紙製造商資料集訓練中的第 7 個 Epoch 開始 SSIM 會直接掉到 0.075 到 60 個 Epoch 都不曾變好，代表訓練已經陷入了一個局部最小值 (Local Minimum)。發現這個問題後，將 L1 Loss 權重調整為 0.1，SSIM Loss 權重調整為 1.0 以 SSIM Loss 為主後，在訓練的過程中就沒有遇到陷入局部最小值的狀況了

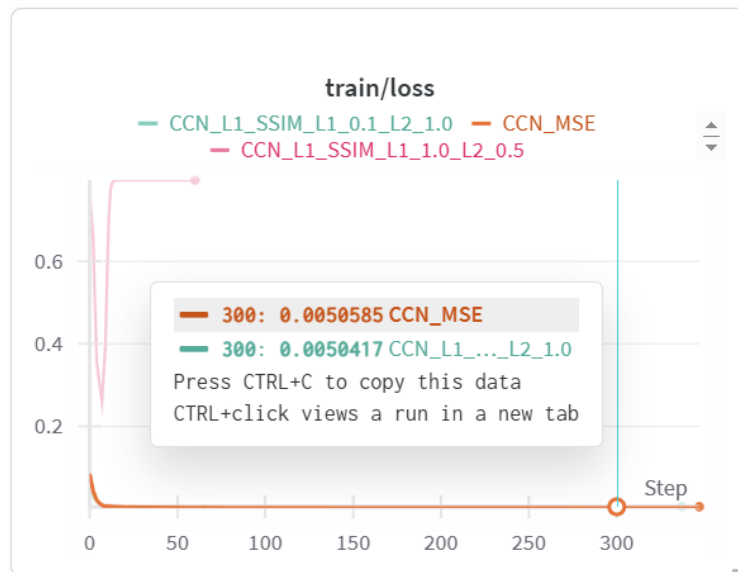
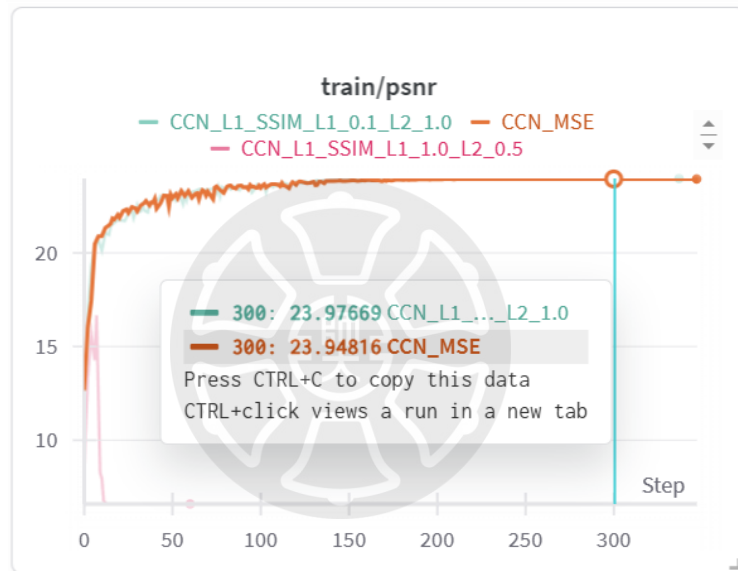



圖 4-5 電子紙製造商資料集的訓練狀況

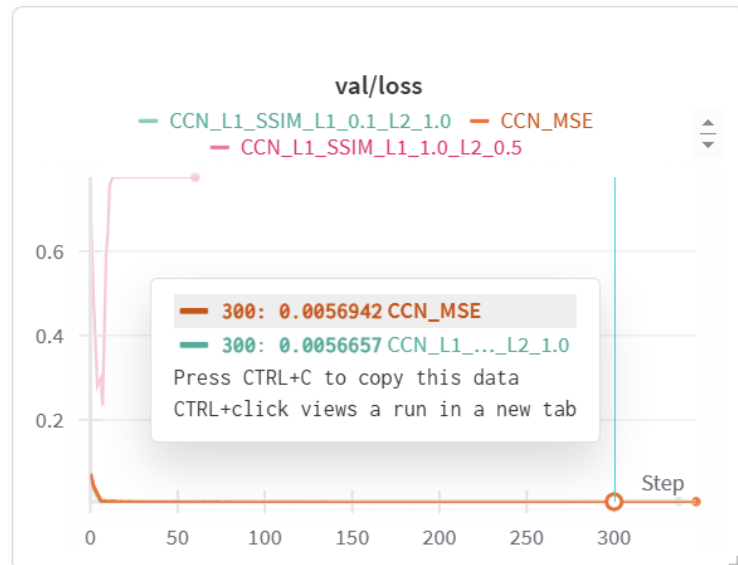

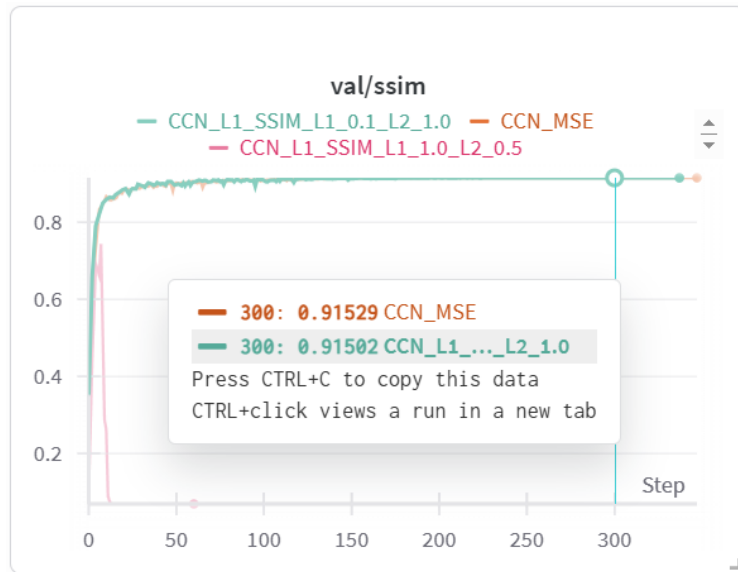


圖 4-6 電子紙製造商資料集的驗證狀況

## 4.2.2 空間約束半色調資料集的消融實驗

從下圖 4-7 可以看出，在空間約束半色調資料集的消融測試中效果最好的是把 Loss Function 從 MSE 替換成 L1 Loss + SSIM Loss 的組合損失函數，這邊的 L1 Loss 權重為 0.1，SSIM Loss 權重為 1.0。

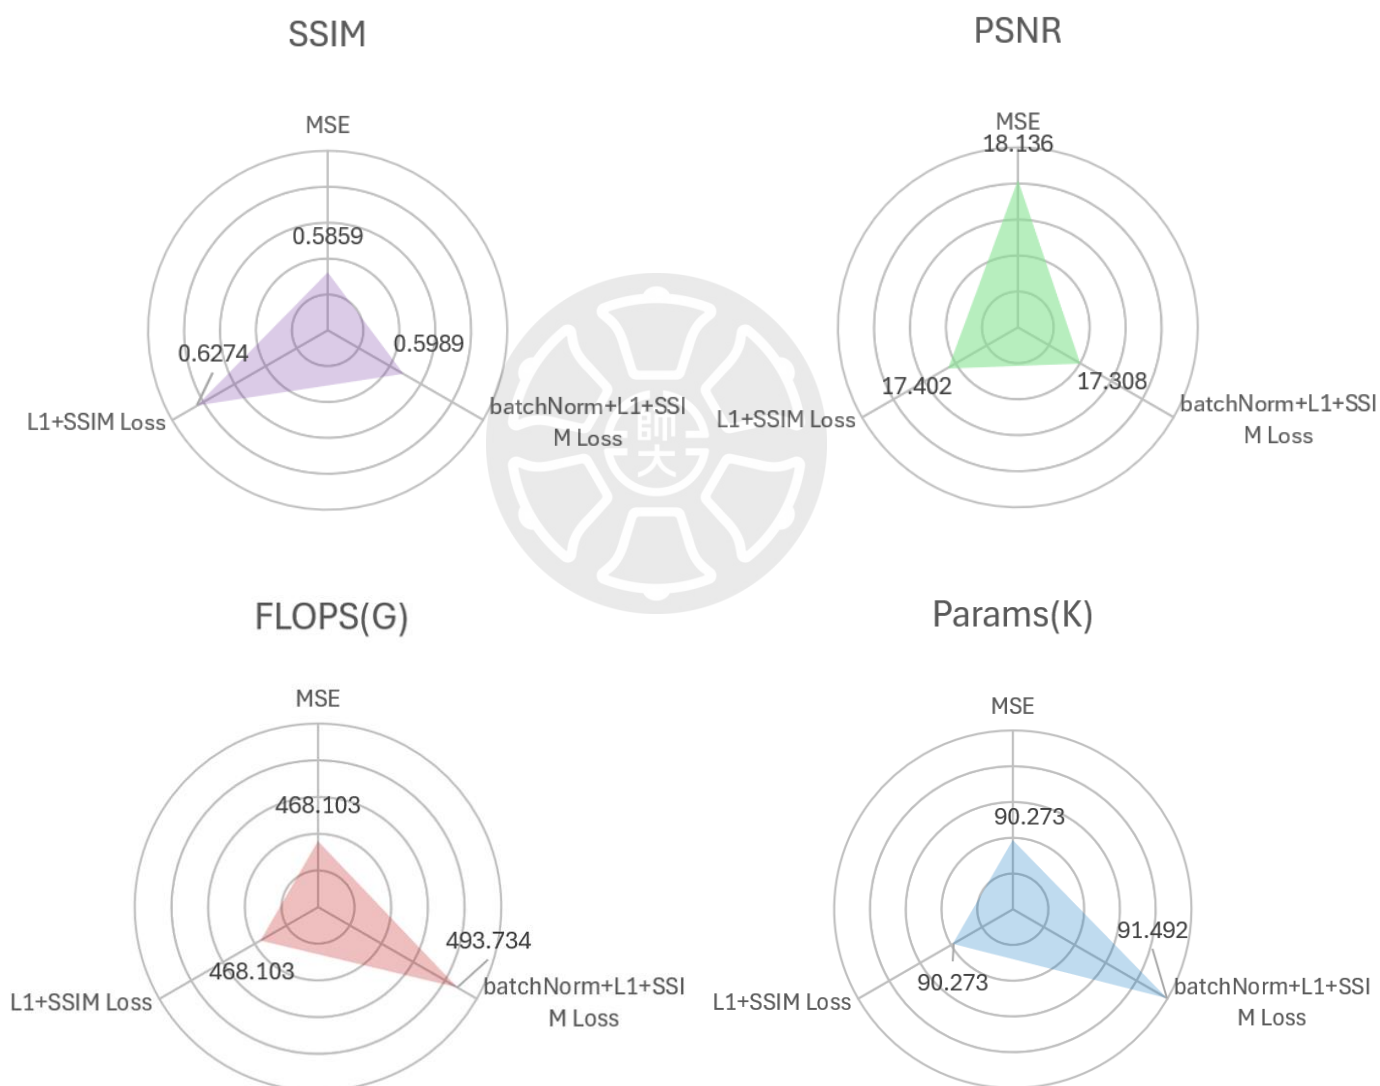


圖 4-7 空間約束半色調資料集的消融實驗

下圖 4-8 和圖 4-9 為空間約束半色調資料集訓練集和驗證集的訓練狀況，其中 CCN\_L1\_SSIM 的 L1 Loss 權重為 1.0，SSIM Loss 權重為 0.5，CCN\_L1\_SSIM\_BatchNorm 的權重設定跟 CCN\_L1\_SSIM 一樣，但在每一層的 Conv Block 輸出都加上 Batch Normalization 加入模型訓練收斂的速度，從圖 4-8 和圖 4-9 可以看出 CCN\_L1\_SSIM 在 SSIM 指標的效能最好。



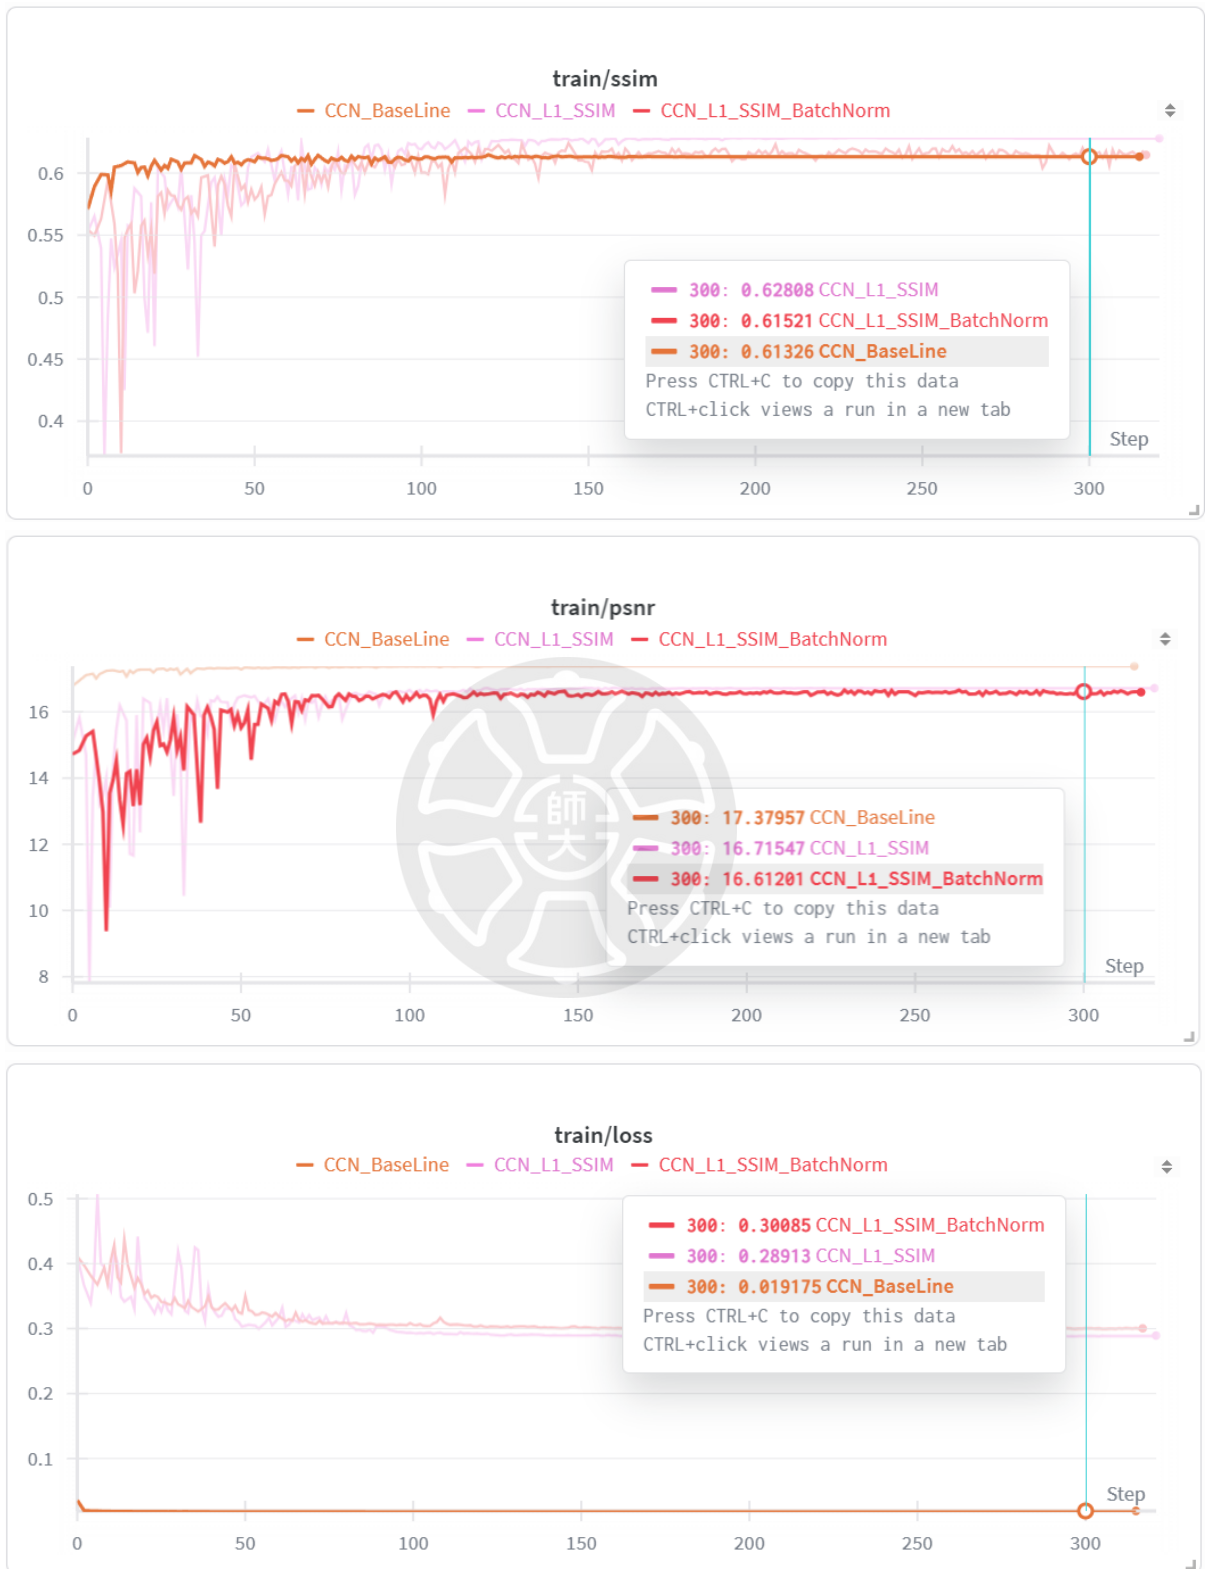


圖 4-8 空間約束半色調資料集的訓練狀況 1

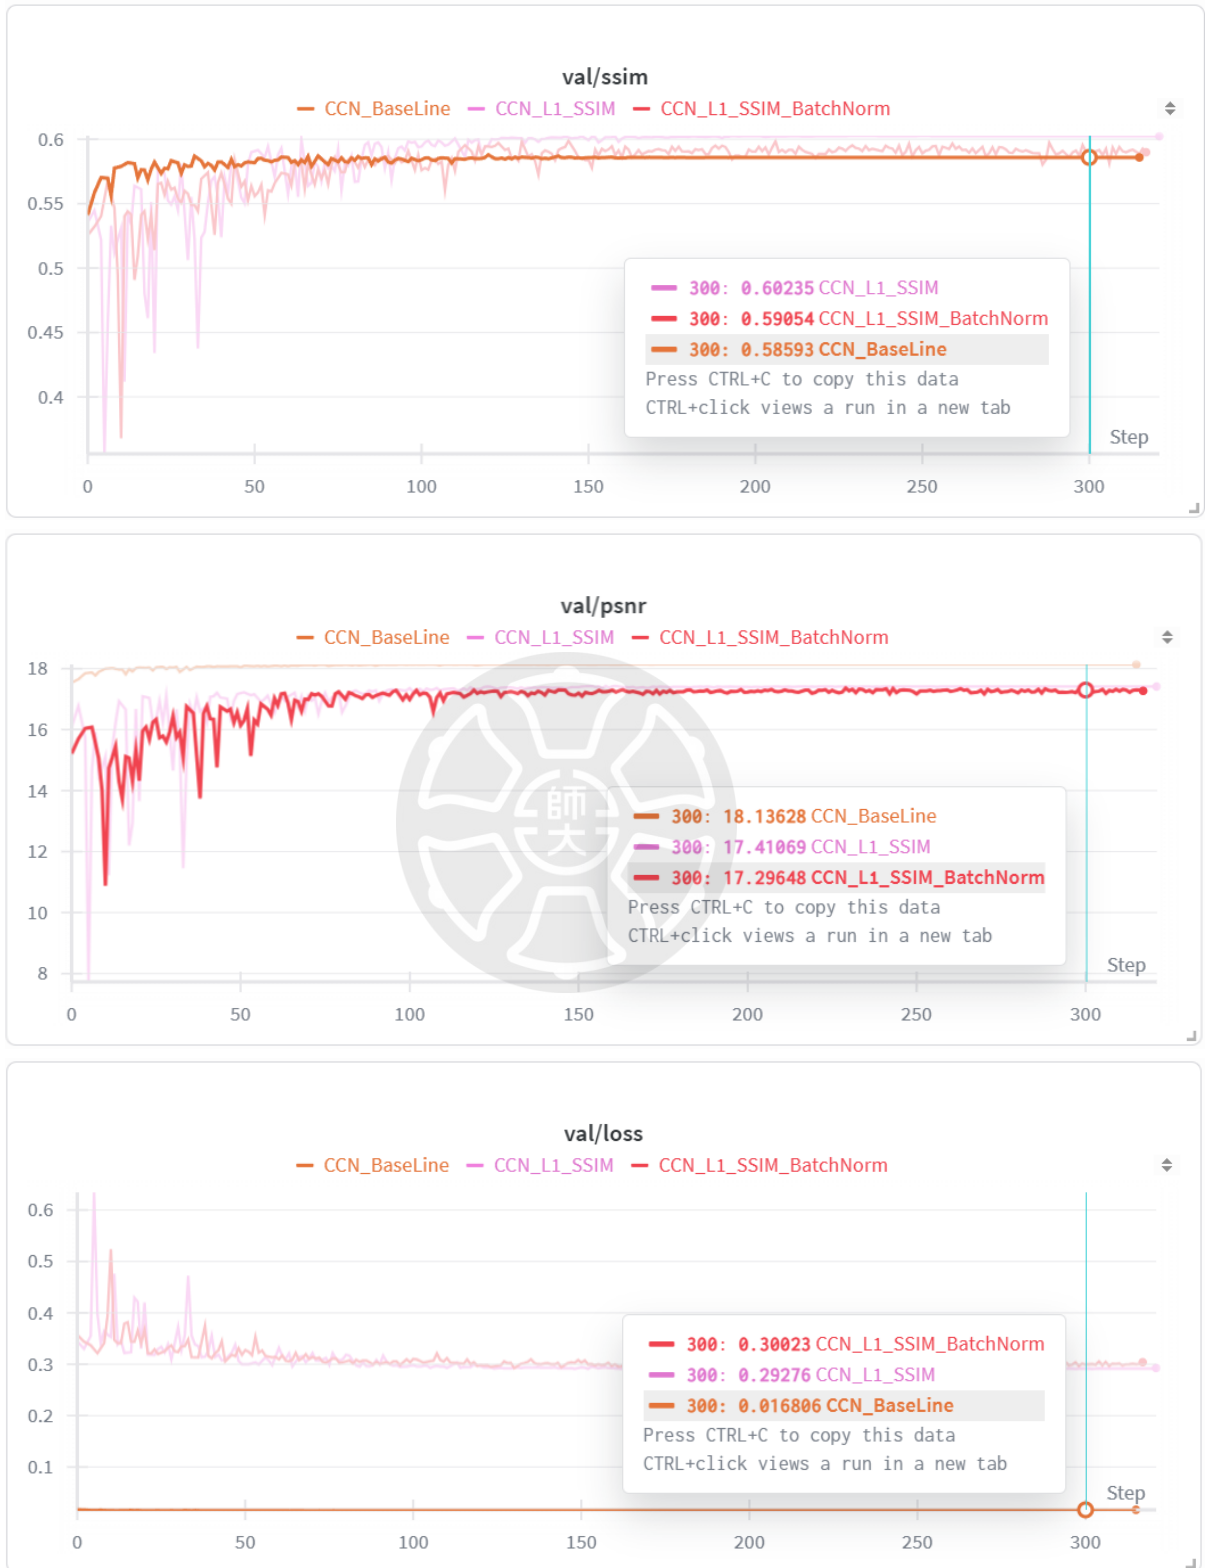


圖 4-9 空間約束半色調資料集的驗證狀況 1

先前提到的 CCN\_L1\_SSIM，最開始的 L1 Loss 權重為 1.0，SSIM Loss 權重為 0.5 時，在電子紙製造商資料集根本訓練不起來，但在空間約束半色調資料集的效能卻是最好的，所以將原本的 CCN\_L1\_SSIM 的 L1 Loss 權重設定成 0.1，SSIM Loss 權重設定成 1.0 後，重新在電子紙製造商資料集訓練，發現是可以訓練的，所以為了驗證 CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0 在這個資料集的效能比 CCN\_L1\_SSIM 更好，為此，單獨做了一次這兩個模型架構的消融實驗，訓練集和驗證集的訓練狀況如圖 4-10 和圖 4-11 所示，CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0 在 SSIM 指標的效能比 CCN\_L1\_SSIM 更好，所以最後的架構使用的是 CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0。






圖 4-10 空間約束半色調資料集的訓練狀況 2






圖 4-11 空間約束半色調資料集的驗證狀況 2

同樣的訓練了 300 個 Epoch 後，實際在空間約束半色調測試資料集的結果如表 4-2 所示，CCN\_L1\_SSIM\_L1\_0.1\_L2\_1.0 的 SSIM 為 0.61171。

表 4-2 空間約束半色調測試資料集的結果

	SSIM	PSNR	Loss
CCN_L1_SSIM_L1_0.1_L2_1.0	<b>0.61171</b>	16.85894	0.40281
CCN_L1_SSIM_L1_1.0_L2_0.5	0.59806	<b>17.05393</b>	<b>0.30705</b>

### 4.3 印刷彩色電子紙顯示結果

本節將展示本研究所使用的演算法和過往研究提出的演算法實際顯示到電子紙顯示器上的畫面。

#### 4.3.1 色彩校正演算法的顯示結果

本小節會展示過往研究提出的半色調演算法和本研究提出的空間約束半色調演算法實際顯示在 PCeP 上的畫面。會依序展示原始影像、未經任何色彩校正 (No Calibration) 的原始影像顯示到 PCeP 的畫面，接著是 6 種方法顯示在 PCeP 上的畫面，包含色彩校正矩陣 (Color Correction Matrix)、色域映射 (Gamut Mapping)、直接二元搜索 (Direct Binary Search)、留白半色調 (Blank)、真實色彩 (True Color)，最後是本研究提出的空間約束半色調演算法 (Spatially-Constrained Halftoning)，展示畫面如圖 4-12 - 圖 4-16 所示。

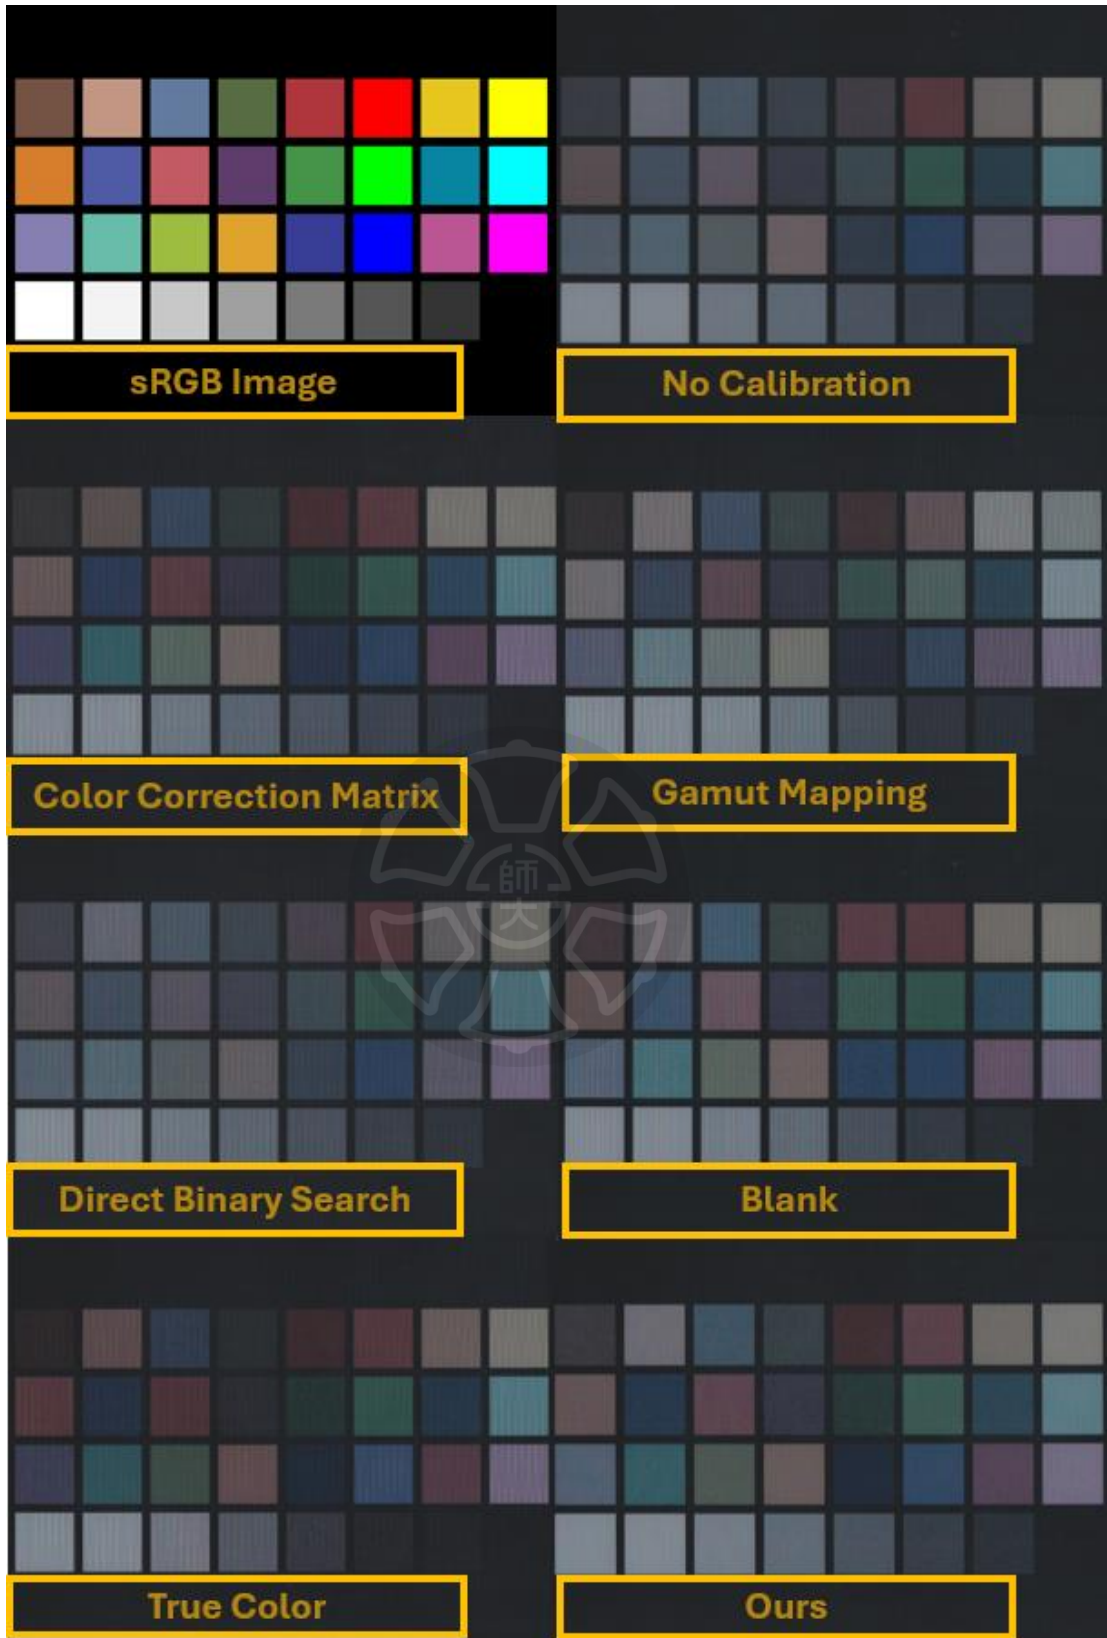


圖 4-12 原始影像與六種方法顯示在 PCeP 上之 1



圖 4-13 原始影像與六種方法顯示在 PCEP 上之 2




圖 4-14 原始影像與六種方法顯示在 PCeP 上之 3




圖 4-15 原始影像與六種方法顯示在 PCEP 上之 4

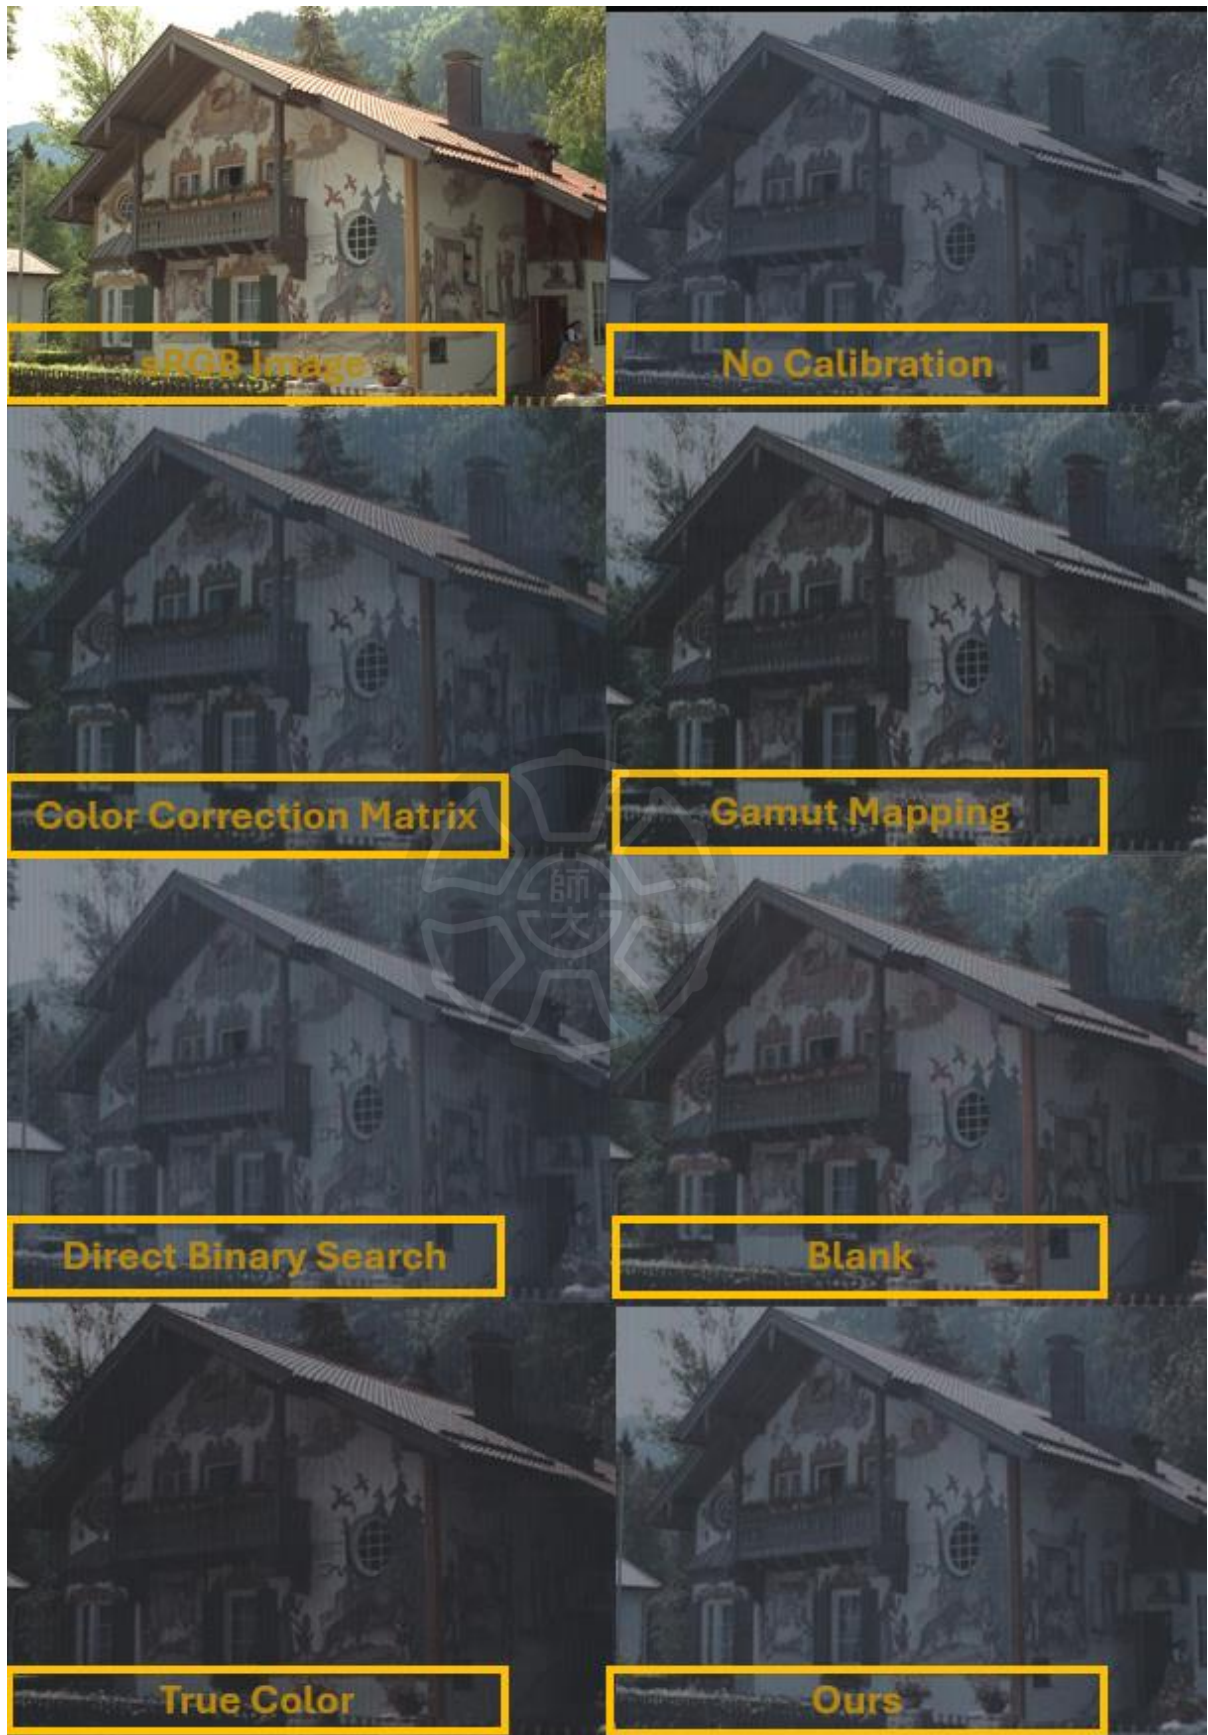


圖 4-16 原始影像與六種方法顯示在 PCeP 上之 5

### 4.3.2 ColorCorrectionNet 推理的顯示結果

本小節會展示電子紙製造商資料集和空間約束半色調資料集分別使用 GPU 和在 Jetson Orin 上進行推理後顯示在 PCEP 上的畫面，內容分別為兩個資料集的 target image、GPU inference 和 Jetson Orin inference 後的顯示在 PCEP 上的結果。這邊將電子紙製造商資料集的 target image 稱為 Epaper Target，將空間約束半色調演算法資料集的 target image 稱為 SCH Target，畫面展示如圖 4-17 - 圖 4-22 所示。



圖 4-17 Epaper Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCEP 上之 1

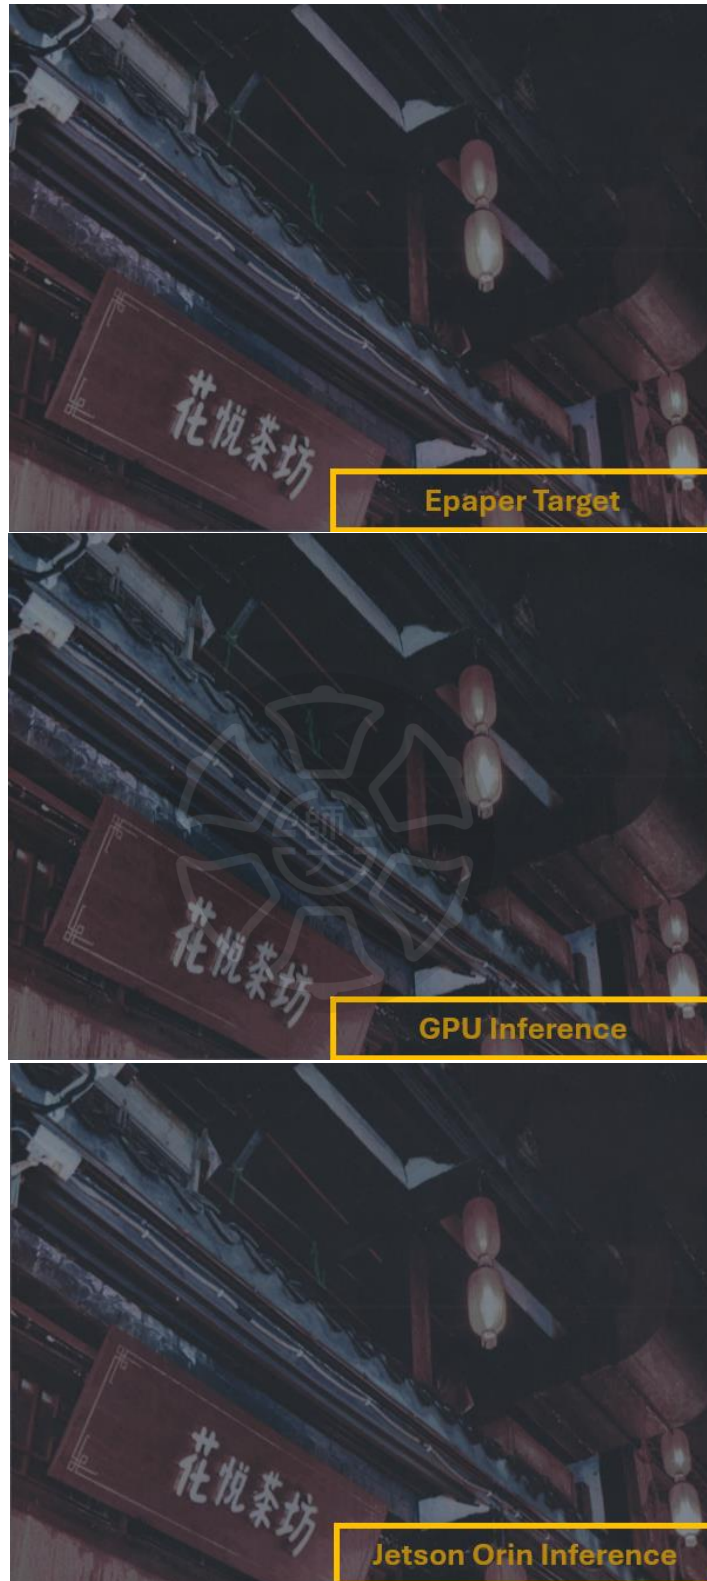


圖 4-18 Epaper Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCEP 上之 2



圖 4-19 Epaper Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCCP 上之 3



圖 4-20 SCH Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCEP 上之 1




圖 4-21 SCH Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCEP 上之 2




圖 4-22 SCH Target (上)、GPU Inference (中)、Jetson Orin Inference (下)分別顯示在 PCEP 上之 3

### 4.3.3 色彩誤差比較

本研究使用 X-Rite 的 Color Checker 作為色彩校正樣本，該色卡本身只有 24 種色彩，本研究額外加入了 R、G、B、C、M、Y、W、K，總共 32 色，32 色的 Color Checker 如下圖 4-23 所示，表 4-3 為 32 色色卡在 D65 光源下的 sRGB 值。



圖 4-23 輸入 PCeP 上的 32 色色卡

表 4-3 D65 光源下的 32 色色卡 sRGB 值

D65 sRGB				D65 sRGB			
No.	R	G	B	No.	R	G	B
1	115	82	68	17	187	86	149
2	194	150	130	18	8	133	161
3	98	122	157	19	243	243	242
4	87	108	67	20	200	200	200
5	133	128	177	21	160	160	160
6	103	189	170	22	122	122	121
7	241	126	44	23	85	85	85
8	80	91	166	24	52	52	52
9	193	90	99	R	255	0	0
10	94	60	108	G	0	255	0
11	157	188	64	B	0	0	255
12	224	163	46	C	0	255	255
13	56	61	150	M	255	0	255
14	70	148	73	Y	255	255	0
15	175	54	60	K	0	0	0
16	231	199	31	W	255	255	255

*CIE Lab* 色彩空間的歐幾里德距離  $\Delta E_{ab}$  被廣泛應用於色彩差異的量化評估。 $\Delta E_{ab}$  已經被證明在評估人眼感知的色彩差異時存在系統性偏差，特別是在不同色相、明度和彩度區域的感知均勻性表現不一致。在過往的研究中雖然都會跟過往的方法進行  $\Delta E_{ab}$  的比較，但卻沒有一個比較的基準，每種色彩校正的方法都會先將 32 色色卡的影像做亮度或是色域的壓縮到自己定義的範圍後，再計算  $\Delta E_{ab}$ 。因此在本研究提出採用 CIEDE2000 作為評估指標，首先 CIEDE2000 引入了參數化的權重函數 SL、SC、SH，分別對明度、彩度和色相差異進行非線性調整，使得計算結果更符合人眼在不同色彩區域的感知特性。其次，該公式特別改善了中性灰色附近的色彩差異評估，透過彩度相關的旋轉項 (RT) 修正了藍色區域的色相非線性問題，這對於評估 Color Checker 中包含的多個中性灰階色塊尤為重要。再來是因為開發色彩校正演算法的目的是為了讓 PCEP 這種窄色域的

顯示器畫面顯示的色彩越接近 LCD 越好，因此本研究提出直接跟完整的 sRGB 色域計算  $\Delta E_{ab}$ 。

計算  $\Delta E_{ab}$  的方法為，先將經過色彩校正演算法後的 Color Checker 影像顯示到 PCeP 電子紙上，接著使用 X-Rite i1 Pro 3 分光光度計進行量測 PCeP 上 32 個顏色的 Lab 數值後，計算 32 色 CIEDE2000  $\Delta E_{ab}$  取平均，而平均的  $\Delta E_{ab}$  越小代表色彩越貼近真實色彩。PCeP 顯示 32 色色卡的色彩誤差如圖 4-24 所示，圖上的縱軸為  $\Delta E_{ab}$  的數值，橫軸為五個色彩校正方法和本研究提出的 SCH，本研究提出的空間約束半色調演算法與過往的色彩校正方法相比取得了很好的成績，主要解決了其他的半色調演算法因為沒有考慮到空間上色彩連續性的問題，導致畫面上產生雜訊和不自然的跳變。




圖 4-24 PCeP 顯示 32 色色卡的色彩誤差

## 4.4 訓練後量化結果

首先是在電子紙製造商資料集分別用 GPU 和 Jetson Orin 進行推理的結果如下表 4-4 所示，使用的是 Epaper Dataset 的測試資料集，總數為 23 張，輸入的影像大小為 1872\*1404\*3，GPU 採用全精度和 PTQ 成 INT8 後在 Jetson Orin NX 上的實驗結果顯示，量化後模型在推論時的 SSIM 和 PSNR 跟在 RTX4090 上效能是差不多的，在 FPS 的部分 Orin 只跟 GPU 差了 0.31，運算一張高解析影像只需要 0.82 秒，已經非常符合應用在 PCeP 顯示影像的需求，證明了 AI 調色模型在邊緣裝置上運算的可能性和效能。

表 4-4 Orin 與 GPU 在 Epaper Dataset 推理結果的比較

Device	RTX4090	Jetson Orin
Dimension	1872*1404*3	1872*1404*3
Precision	Full	INT8
PSNR	23.98 dB	24.19 dB
SSIM	0.9185	0.9204
Time(s)	15.04	18.98
FPS	1.529	1.219

在空間約束半色調資料集分別用 GPU 和 Jetson Orin 進行推理的結果如下表 4-5 所示，使用的是 SCH Dataset 的測試資料集，總數為 110 張，這個資料集比起 Epaper Dataset 資料集，額外的對 target images 做了誤差擴散，因此提高了模型學習調色的難度，從推理結果可以看出模型 PTQ 後在 Jetson Orin 上推論比起 GPU 在 SSIM 指標中有略顯的下降，但在 4.3.2 小節實際顯示在 PCeP 的畫面，雖然有部分的色偏，但綜觀運算時間和實際的視覺感受，證明了 AI 調色模型學習色彩校正半色調演算法，並使用 GPU 取代開發 FPGA 應用在邊緣運算設備的可行性。

表 4-5 Orin 與 GPU 在 SCH Dataset 推理結果的比較

Device	RTX4090	Jetson Orin
Dimension	1872*1404*3	1872*1404*3
Precision	Full	INT8
PSNR	16.86 dB	16.06 dB
SSIM	0.6117	0.4353
Time(s)	70.95	90.74
FPS	1.55	1.219

上述內容為輸入實際影像在 PC 和 Jetson Orin 上分別評估模型在兩個資料集推理效能的結果，為了獲得可靠且可比較的結果，接下來會分別在 GPU 和 Jetson Orin 上進行壓力測試。在 GPU 的部分維持原本的全精度計算，而 Jetson Orin 的部分則將本研究提出的模型量化成 FP32 和 INT8，使用隨機的 tensor 取代實際輸入影像測試純推理的 FPS，能反映模型與推理引擎在無 I/O 和 CPU 資料傳輸延遲下的極限效能。測試過程會先將 1872\*1404\*3 的隨機 tensor 預載入 GPU 中，並進行 100 推理後取平均 FPS，實際的測試結果如下表 4-6 所示，從實驗結果可以看出，將模型從 FP32 轉換為 INT8 精度，在 SSIM 和 PSNR 中跟全精度相比只降低了少量指標，但 INT8 的 FPS 比 FP32 高出了接近 5 倍的效能，大幅的降低了記憶體與運算資源需求。

表 4-6 Orin 與 GPU 壓力測試的比較

Device	RTX4090	Jetson Orin	
Dimension	1872*1404*3	1872*1404*3	
Precision	Full	FP32	INT8
Time(s)	8.057	49.66	10.6218
FPS	12.41	2.01	9.41

## 第五章 結論與未來展望

### 5.1 結論

在本篇論文提出了一個針對 PCEP 這種電子紙開發的深度學習架構叫做 ColorCorrectionNet，在本篇論文中還提出了兩個模型用來應對不同的場景，並實際部屬到 Nvidia Jetson Orin NX 上，本論文使用了一種訓練後量化的方法，將模型從全精度轉換為 INT8 精度。在 Nvidia Jetson Orin NX 上的實驗結果顯示，量化後模型輸出的影像品質僅輕微下降，但在推論速度提升將近 5 倍，大幅的降低了記憶體與運算資源需求。本研究所提出的空間約束半色調演算法也改善了過往方法會造成畫面上產生雜訊和不自然的跳變問題，也讓影像的畫面看起來更平滑，最後是提出使用 CIEDE2000 作為新的量化指標，並提出也希望未來的研究可以直接跟完整的 sRGB 色域計算  $\Delta E_{ab}$ 。

### 5.2 未來展望

本論文提出了一個全新的概念利用 AI 調色的方式來解決過往一直很難解決的非線性色彩問題，並且成功的部屬到了 Jetson Orin NX 這種邊緣運算裝置，證明方法的可行性。利用演算法的方法需要具備相當程度的色彩學相關知識，且也不易於做加速運算。而本論文提出的深度學習網路架構部分未來還可以針對低光源影像的部份去開發，因為目前的實用場景在自動駕駛或是影像辨識時往往都會遇到光線不足導致影像辨識結果不佳的問題。

## Reference

- [1] "為何常有人說 OLED 顯示器不適合文書使用?淺淡常見 OLED 面板像素結構特性及限制." <https://www.hkepc.com/21802/%E7%82%BA%E4%BD%95%E5%B8%B8%E6%9C%89%E4%BA%BA%E8%AA%AA%BA%E5%99%A8%E4%B8%8D%E9%81%A9%E5%90%88%E6%96%87%E6%9B%B8%E4%BD%BF%E7%94%A8%E6%B7%BA%E6%B7%A1%E5%B8%B8%E8%A6%8B%OLED%E9%9D%A2%E6%9D%BF%E5%83%8F%E7%B4%A0%E7%B5%90%E6%A7%8B%E7%89%B9%E6%80%A7%E5%8F%8A%E9%99%90%E5%88%B6> (accessed.
- [2] Z. Fan, "Error diffusion for CMYK color images," in *PICS*, 1999, pp. 324-326.
- [3] R. Hersch and V. Ostromoukhov, "Recent Progress in Digital Halftoning for Color Reproduction State of the Art Report."
- [4] N. Damera-Venkata and B. L. Evans, "Design and analysis of vector color error diffusion halftoning systems," *IEEE transactions on image processing*, vol. 10, no. 10, pp. 1552-1565, 2001.
- [5] Z. Fan, "Analysis of color error diffusion with vector error filters," in *Color Imaging XI: Processing, Hardcopy, and Applications*, 2006, vol. 6058: SPIE, pp. 287-293.
- [6] H. Haneishi, T. Suzuki, N. Shimoyama, and Y. Miyake, "Color digital halftoning taking colorimetric color reproduction into account," *Journal of Electronic Imaging*, vol. 5, no. 1, pp. 97-106, 1996.
- [7] M. Analoui and J. P. Allebach, "Model-based halftoning using direct binary search," in *Human vision, visual processing, and digital display III*, 1992, vol. 1666: SPIE, pp. 96-108.
- [8] J.-R. Liao, "Theoretical bounds of direct binary search halftoning," *IEEE Transactions on Image Processing*, vol. 24, no. 11, pp. 3478-3487, 2015.
- [9] W.-C. Kao and C.-M. Lin, "Video Halftoning for Multi-Particle Color Electronic Paper," in *2025 IEEE International Conference on Consumer Electronics (ICCE)*, 2025: IEEE, pp. 1-2.
- [10] 林忠謀, "彩色電子紙半色調演算法與晶片設計," 碩士, 電機工程學系, 國立臺灣師範大學, 台北市, 2025. [Online]. Available: <https://hdl.handle.net/11296/22z92q>
- [11] H.-C. Lee, *Introduction to color imaging science*. Cambridge University Press,

- 2005.
- [12] H.-Y. Chen, Y.-P. Hsu, W.-T. Chang, J.-L. Ho, Y.-F. Lee, and W.-C. Kao, "Adaptive Color Calibration for Digital Cameras," in *2021 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)*, 2021: IEEE, pp. 1-2.
  - [13] W.-C. Kao, K.-D. Hong, and C.-Y. Hsu, "Color reproduction of multi-pigment color electronic papers," in *2023 IEEE International Conference on Consumer Electronics (ICCE)*, 2023: IEEE, pp. 1-2.
  - [14] S. Agnihotri, J. Grabinski, and M. Keuper, "Improving feature stability during upsampling—spectral artifacts and the importance of spatial context," in *European Conference on Computer Vision*, 2024: Springer, pp. 357-376.
  - [15] W. Quan, W. Zhao, W. Wang, H. Xie, F. L. Wang, and M. Wei, "Lost in UNet: Improving infrared small target detection by underappreciated local features," *IEEE Transactions on Geoscience and Remote Sensing*, 2024.
  - [16] T. Vu, C. Van Nguyen, T. X. Pham, T. M. Luu, and C. D. Yoo, "Fast and efficient image quality enhancement via desubpixel convolutional neural networks," in *Proceedings of the European Conference on Computer Vision (ECCV) Workshops*, 2018, pp. 0-0.
  - [17] R. Yang *et al.*, "NTIRE 2024 challenge on blind enhancement of compressed image: Methods and results," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2024, pp. 6524-6535.
  - [18] D. Şener and S. Güney, "Enhancing Steganography in  $256 \times 256$  Colored Images with U-Net: A Study on PSNR and SSIM Metrics with Variable-Sized Hidden Images," *Review of Computer Engineering Studies*, vol. 11, no. 2, 2024.
  - [19] A. Kumar, R. Shen, S. Bubeck, and S. Gunasekar, "How to fine-tune vision models with sgd," *arXiv preprint arXiv:2211.09359*, 2022.
  - [20] J. M. Montero and J.-L. Lisani, "Enhancing Underwater Images Using Deep Learning with Subjective Image Quality Integration," *arXiv preprint arXiv:2507.05393*, 2025.
  - [21] H. F. Ates, S. Yildirim, and B. K. Gunturk, "Deep learning-based blind image super-resolution with iterative kernel reconstruction and noise estimation," *Computer Vision and Image Understanding*, vol. 233, p. 103718, 2023.
  - [22] S. K. Jha, V. Gupta, P. J. Sharma, A. Mishra, and S. Joshi, "Deep learning super-resolution for temperature data downscaling: a comprehensive study using residual networks," *Frontiers in Climate*, vol. 7, p. 1572428, 2025.
  - [23] B. B. Lee, "Sensitivity to chromatic and luminance contrast and its neuronal substrates," *Current Opinion in Behavioral Sciences*, vol. 30, pp. 156-162, 2019/12/01/ 2019, doi: <https://doi.org/10.1016/j.cobeha.2019.08.006>.
  - [24] Q. Zhou *et al.*, "Octo:{INT8} training with loss-aware compensation and

- backward quantization for tiny on-device learning," in *2021 USENIX Annual Technical Conference (USENIX ATC 21)*, 2021, pp. 177-191.
- [25] "NTIRE 2024." <https://cvlai.net/ntire/2024/> (accessed 2025-07-16).
- [26] J. Liu, D. Liu, W. Yang, S. Xia, X. Zhang, and Y. Dai, "A comprehensive benchmark for single image compression artifact reduction," *IEEE Transactions on image processing*, vol. 29, pp. 7845-7860, 2020.



## 自 傳

我是童培軒，大學畢業於資訊工程學系，期間積極參與專題研究與競賽，曾代表學校參加全國大專院校專題競賽人工智慧組並獲得佳作，這段經驗讓我首次體會到將理論落實為可行產品的成就感。

就讀碩士班的研究重點為深度學習模型的設計與應用，並在碩士期間執行過企業合作計畫。這些計畫不僅要求我開發高效的 AI 解決方案，也讓我有機會與企業工程師密切溝通，定期參與會議，並在結案時親自向合作公司的董事長與副總報告研究成果。這些經歷訓練了我的專案管理、溝通與簡報能力，也讓我理解如何將研究與產業需求緊密結合。

在研究領域中，我提出了將 AI 調色技術應用於電子紙的創新方法，開發了針對印刷彩色電子紙的深度學習架構 ColorCorrectionNet。本研究針對不同應用場景設計了兩種模型，並成功部署於 NVIDIA Jetson Orin NX。透過訓練後量化 (Post-Training Quantization, PTQ) 技術，使模型在 Jetson Orin NX 上的推論僅犧牲掉很少的精度，但速度提升約 5 倍。在壓力測試中可達到接近 RTX4090 推論時的 FPS 效能，證明了模型在嵌入式裝置上的即時運算能力。

我所開發的 AI 調色模型並應用於電子紙的創新方法。整體研究成果已發表於 IEEE，也已經前往過美國參加國際研討會進行發表與交流，非常寶貴的經驗也幫助我拓展了國際舞台上的視野。

我熱衷於關注最新的科技發展，並常常思考將 AI 技術落地於實際產品中的可能性，尤其關注深度學習模型的嵌入式優化與加速和智慧物聯網，並擅長從演算法設計、效能優化到系統部署的完整開發流程。我相信憑藉這些專業背景與實務經驗，能為人工智慧與高效能運算領域貢獻價值。



## 學術成就

### 1. 論文發表

[1] P. -H. Tung, C. -K. Lu, Y. -H. Chien and W. -Y. Wang, "Enhancing E-Paper Color Fidelity: A Deep Learning Approach to Color Correction," *2025 IEEE International Conference on Consumer Electronics (ICCE)*, Las Vegas, NV, USA, 2025, pp. 1-2, doi: 10.1109/ICCE63647.2025.10929770.

### 2. 參與研究計畫

- (2023/08/01-2024/07/31)。使用自適應演算法優化彩色電子紙顏色表現優化之研究。元太科技。
- (2023/08/01-2024/07/31)。使用自適應演算法優化彩色電子紙顏色表現優化之研究。國發基金。
- (2024/08/01-2025/06/31)。使用自適應演算法優化彩色電子紙顏色表現優化之研究(II)。國發基金。