

2025年臺灣國際科學展覽會

優勝作品專輯

作品編號

190002

參展科別

電腦科學與資訊工程

作品名稱

運用深度學習色彩校正模型之黃疸偵測

Jaundice Detection Using Deep Learning-
Based Color Correction Models

得獎獎項

四等獎

就讀學校

臺北市立第一女子高級中學

指導教師

周承復

陳怡芬

作者姓名

李奕薇

劉思帆

關鍵詞

黃疸、深度學習、色彩校正

作者簡介



大家好，我們是北一女中數資班的李奕薇、劉思帆。因為對資訊感興趣，在找尋研究題目時，發現了智慧醫療這個領域，由於好奇生物領域的醫療如何和資訊領域合作，於是決定進行相關研究。這一路上，感謝周承復教授、陳怡芬老師和吳孟勳學長，耐心的教導我們熟悉新事物，提供支持和想法，協助我們完成研究，我們會繼續努力前進！

2025年臺灣國際科學展覽會 研究報告

區別：

科別：電腦科學與資訊工程

作品名稱：運用深度學習色彩校正模型之黃疸偵測

Jaundice Detection Using Deep Learning-Based
Color Correction Models

關鍵詞：黃疸、深度學習、色彩校正

編號：

摘要

現今醫療中，黃疸的早期偵測對肝臟疾病的預防與治療至關重要，但多數人難以在症狀輕微時察覺。我們希望藉由智慧手機影像結合機器學習進行黃疸檢測，提升民眾自我監測的能力。Su 等人（2021）曾使用深度學習和機器學習進行黃疸預測，但其方法依賴專業色卡進行色彩校正，成本高且限制應用範圍。本研究提出以白平衡演算法中的白色補丁法與灰界演算法，搭配深度學習模型 DCCNM1和2 取代色卡，提升黃疸檢測的普及性與便利性。經黃疸偵測效果評估顯示，DCCNM2 在無色卡模型中表現最佳，雖然各指標略低於色卡校正，但其展現出優異的穩定性和準確性，證明其作為無色卡黃疸篩檢方案的可行性。本方法將能提供便捷的居家黃疸檢測途徑，尤其對偏鄉地區居民而言，不僅提升早期發現的機會，還能有效減輕醫護人員的負擔，推動大眾健康管理。

Abstract

Early detection of jaundice is crucial for the prevention and treatment of liver diseases; however, most people struggle to recognize symptoms at a mild stage. We aim to enhance self-monitoring capabilities by using smartphone imaging combined with machine learning for jaundice detection. Previous research by Su et al. (2021) applied deep and machine learning for jaundice prediction, yet relied on specialized color cards for color correction, resulting in higher costs and limited applicability. In response, our study proposes replacing color cards with white balance algorithms, including the white patch and gray world methods, combined with deep learning models DCCNM1 and DCCNM2, to improve accessibility and usability in jaundice detection. Evaluation results indicate that DCCNM2 achieved the best performance among models without color cards. Although its metrics slightly trail behind color card-corrected results, DCCNM2 demonstrates excellent stability and accuracy, proving its feasibility as a no-color-card alternative for jaundice screening. This method offers a convenient home-based jaundice detection solution, especially for residents in remote areas, enhancing early detection opportunities, reducing healthcare burden, and further promoting public health management.

壹、前言

一、研究動機

在現今的醫療過程中，醫護人員常透過視診直接根據病患的外部表徵判斷疾病。例如，黃疸患者的皮膚和鞏膜會呈現黃色，貧血患者則顯得蒼白，甲狀腺功能亢進的患者眼睛突出，而唐氏綜合症患者的耳朵低垂、眼距較寬。視診過程迅速且無需侵入式檢測或儀器拍攝體內影像。

黃疸是一種可透過觀察皮膚和鞏膜顏色來檢測的症狀，其主要原因是血液中總膽紅素（T-Bil）值過高。若肝臟無法正常運作，膽紅素便會回流至血液中，導致皮膚和鞏膜變黃。黃疸的出現可能暗示肝炎、肝癌或膽石症等疾病，若未能及時治療，可能導致肝硬化甚至死亡。因此，若能在症狀輕微時檢測到黃疸，將有助於早期診斷和治療相關疾病。

許多肝臟疾病或膽石症患者需定期前往醫院檢查，這不僅增加了醫療人力資源的負擔，也使偏鄉患者面臨時間與財力的壓力。他們常需長途跋涉至設備更完善的大型醫院或醫學中心進行檢查，這不僅耗時耗力，還可能因交通不便影響檢查頻率或治療效果。因此，提升醫療可及性，特別是在偏鄉地區，成為當前醫療體系中亟待解決的問題。

當T-Bil值稍微升高（如2-3mg/dL）時，患者往往難以自行察覺，通常只有在明顯的黃疸或身體不適出現時，才會前往醫院。隨著智慧醫療的逐漸普及，患者可在家中透過智慧型手機等設備進行自我檢測。已有研究利用智慧型手機拍攝病患影像，並運用機器學習技術根據眼白顏色來檢測黃疸，這將協助醫生進行診斷並為患者提供自我監測的可能。若能在家中以智慧手機進行簡單的黃疸偵測，將大大減少病患往返醫院的需求，提升偏鄉地區的醫療可及性，並減輕醫療系統的壓力。

Su等人（2021）使用深度學習進行照片前處理，並利用機器學習預測黃疸及膽紅素值。然而，由於訓練集的照片資料量較少，雖然準確度高但代表性不足。隨著深度學習及機器學習技術的進步，越來越多的技術可以用於檢測人類面部或肢體的特徵，例如面部標誌檢測和鞏膜分割等。這些深度學習模型能夠自動檢測眼睛間距、膚色、

鞏膜顏色等特徵，並以數字或敘述方式呈現。若能將非結構化照片轉換為結構化數據，將有效支持醫生的醫療判斷或直接檢測疾病特徵。

色彩校正在醫療科技中的重要性不僅限於黃疸的診斷，還適用於許多依賴顏色變化的病症，例如貧血患者的蒼白膚色及嘴唇，或心臟和肺部疾病患者的紫紺現象。皮膚病如銀屑病或異位性皮膚炎的診斷也需要精確觀察紅腫程度。透過正確的色彩校正，醫護人員能更準確評估病情，避免因環境、光線或設備差異導致的顏色失真，進而提高診斷的精度與可靠性。

Su等人（2021）所創建的黃疸偵測模型已 取得良好成效，但該研究要求患者使用專業色卡拍攝照片以進行準確的色彩校正。專業色卡不僅難以取得，且價格昂貴，並非所有患者皆能負擔。為提高黃疸偵測模型的普及性，我們嘗試以白平衡演算法和深度學習模型取代色卡進行色彩校正，並評估各種方法的有效性與實用性。如此一來，患者便可隨時隨地利用智慧手機進行黃疸自我檢測。

二、研究目的

1. 評估以白平衡取代色卡之色彩校正效能
2. 評估以深度學習方法取代色卡之色彩校正效能

貳、研究設備與器材

在本研究中，使用了多種設備和軟體。這些設備不僅提供了強大的運算能力，還支持我們進行高效的圖片處理和數據分析。以下將詳細介紹研究中使用的主要硬體和軟體工具，以及它們在研究過程中的重要性和作用。

一、硬體設備

本研究中模型訓練使用了本地端的個人筆電與遠端實驗室具GPU的電腦以進行研究。

（一）筆記型電腦2部

1. CPU: 13th Gen Intel(R) Core(TM) i5-13500H 2.60 GHz / RAM: 16.0 GB
2. CPU: 12th Gen Intel(R) Core(TM) i5-12500H 2.50 GHz / RAM: 16.0 GB

（二）實驗室電腦1部

CPU: i9-14900k / GPU: NVIDIA GeForce RTX 4090

二、資料處理與分析套件

我們主要使用 Python 作為程式書寫語言，並使用 vscode 創建環境和撰寫程式。以下為研究使用到的程式工具、辨識模組與套件。

（一）程式語言工具：本研究所使用的程式開發工具為Python，版本為3.9.19。

（二）MTCNN 人臉偵測辨識模組

MTCNN (Multi-task Cascaded Convolutional Networks) 是一種基於深度學習的高效人臉偵測和對齊技術。其結構由三個層級的卷積神經網路 (CNN) 組成，分別是 P-Net (Proposal Network)、R-Net (Refine Network) 和 O-Net (Output Network)。這種串級的CNN結構設計使得 MTCNN 能夠在多尺度的影像中進行人臉檢測，提高了準確性和偵測速度。

MTCNN的三個層級各自發揮著不同的功能，形成了一個完整的檢測流程：

1. P-Net (Proposal Network)：此層負責初步檢測影像中的人臉，通過生成多個 Bounding Box 來捕捉可能的人臉位置。使用NMS(Non-Maximum Suppression) 來過濾多餘的 Bounding Box。
2. R-Net (Refine Network)：在接收到來自 P-Net 的邊界框後，R-Net 檢查這些 Bounding Box 的準確性，並根據特徵進行分類，從而去除假陽性，進行進一步的人臉檢測與關鍵點定位，以提高準確度。
3. O-Net (Output Network)：O-Net提供最終的偵測結果。它不僅輸出精確的人臉邊界框，還能定位面部的關鍵點，如眼睛、鼻子和嘴巴的位置，從而實現更精細的面部對齊功能。




圖1：MTCNN 模型示意圖

(資料來源: Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint face detection and alignment using multi-task cascaded convolutional networks. *IEEE Signal Processing Letters*, 23(10), 1499-1503.)

MTCNN廣泛應用於各種場景，包括影像監控、面部識別等領域，其高效的檢測能力使其成為人臉分析的理想選擇。

在本實驗中，我們使用 MTCNN 對影像資料集進行人臉偵測與篩選，刪除未能偵測到人臉的影像，從而確保所有保留的影像中均包含可用於後續實驗的人臉畫面。

(三) Numpy

Numpy 是 Python 語言中的一個基礎套件，可進行大規模的多維陣列與矩陣運算，為陣列運算提供大量數學函式的函式庫。

(四) Keras

Keras 是建立在 Tensorflow 之上的深度學習 API，是一種用 Python 編寫的開源神經網路庫，方便使用者建立與訓練深度學習模型。

(五) scikit-learn

scikit-learn 是 Python 的一個機器學習函式庫，專為簡化數據分析與機器學習模型的構建和評估而設計。

(六) Pandas

Pandas 是一個 Python 資料分析函式庫，主要用於操作、分析表格數據和時間序列，讓使用者可輕鬆進行數據的讀取、清理、篩選和分析。

(七) CNN 卷積神經網絡

CNN (Convolutional Neural Network) 是一種基於深度學習的網絡架構，主要應用於影像處理和視覺數據分析。其特點是能自動學習並提取影像的特徵，使其在影像識別、物體檢測、影像分割等任務中表現優異。CNN 通常包含三大主要層級：卷積層 (Convolutional Layer)、池化層 (Pooling Layer)、和全連接層 (Fully Connected Layer)，每一層都有其特定功能，共同構成完整的影像處理流程。

CNN 的主要結構組成如下：

1. **卷積層 (Convolutional Layer)**：該層通過一組卷積濾波器 (Filters) 掃描影像數據，提取出局部特徵，如邊緣、紋理和顏色。每個濾波器聚焦於影像不同的細節，並產生特徵映射 (Feature Map)，這些映射形成特徵數據，進一步進行分析。
2. **池化層 (Pooling Layer)**：在卷積後，池化層用來降低特徵映射的維度，以減少計算量，同時保留重要信息。常見的池化方法有最大池化 (Max Pooling) 和平均池化 (Average Pooling)，它們通過濾除冗餘資訊，保留重要的特徵點，進一步穩固模型對影像的識別能力。
3. **激活函數**：激活函數引入非線性性質，有助於模型更好地擬合複雜的數據。常見的激活函數包括 ReLU (Rectified Linear Unit) 和 Sigmoid。

4. **全連接層 (Fully Connected Layer)**：此層將前面層的特徵進行線性展平，並通過激活函數（如 ReLU）轉換數據，使得模型可以進行分類。全連接層對於輸出最終結果至關重要，能夠將提取到的所有特徵組合，並生成預測結果或分類標籤。

在整體過程中，CNN 利用卷積層和池化層提取的影像特徵，進行特徵分類和標籤輸出。這使得 CNN 尤其適合應用於影像處理、語音識別和自然語言處理等任務，其高效的特徵提取能力在深度學習領域被廣泛使用，特別在影像識別領域具有極高的準確度與運算效率。




圖2：CNN 模型示意圖

（資料來源：卷積神經網路(Convolutional neural network, CNN)—CNN運算流程

(Tommy Huang, 2018))

在本研究中，我們利用 CNN 模型來識別影像中的特徵，進行人臉、物體和標誌的自動分類，達到高準確度的影像分類和分割效果。

(八) ResNet 殘差神經網絡

ResNet (Residual Network) 是一種基於深度學習的神經網絡架構，由微軟研究院的何愷明等人提出。ResNet 的核心創新在於引入了殘差學習 (Residual Learning)，有效解決了深層神經網絡中的退化問題，使得網絡可以構建得更深，以提取更豐富的特徵，並顯著提升影像識別的準確性。

ResNet 的主要結構特色如下：

1. **殘差塊 (Residual Block)**：傳統的深度網絡隨著層數的增加，會出現梯度消失和梯度爆炸的問題，導致模型性能下降。ResNet 通過殘差塊引入「捷徑連接 (Shortcut

Connection)」，即讓輸入數據繞過若干層，直接加到輸出上。這樣的設計可以有效減少信息丟失，使網絡即使在層數增加後，依然保持較好的訓練效果。

2. **捷徑連接**：捷徑連接允許數據不經過中間層直接到達下一層，即通過恒等映射（Identity Mapping）或線性變換保留輸入數據。這樣的結構讓網絡可以學習「殘差」（Residual）信息，減少計算難度，並確保網絡在層數增加時依然保持收斂。

3. **深度架構設計**：ResNet 的層數可以擴展到數十、數百甚至更深，典型的 ResNet 包括 ResNet-18、ResNet-34、ResNet-50、ResNet-101 等，其中數字表示層數。這種極深的結構得益於殘差設計，能夠有效提取影像的高層特徵，適用於各種複雜的影像處理任務。




Figure 3. Example network architectures for ImageNet. **Left:** the VGG-19 model [41] (19.6 billion FLOPs) as a reference. **Middle:** a plain network with 34 parameter layers (3.6 billion FLOPs). **Right:** a residual network with 34 parameter layers (3.6 billion FLOPs). The dotted shortcuts increase dimensions. Table 1 shows more details and other variants.

圖3：ResNet 模型示意圖

(資料來源: He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.)

ResNet 的成功使得殘差學習成為深度學習領域的重要技術，並被廣泛應用於影像分類、物體檢測等任務。在深層網絡結構中，殘差塊能保持數據特徵的完整性，使網絡具有更高的訓練穩定性和表現力。

在本研究中，我們採用 ResNet 進行影像分類和特徵提取，以利用其深層結構和高精確度的特徵學習能力，提升影像分析的精度和效率。

(九) U-Net 影像分割神經網絡

U-Net 是一種針對影像分割而設計的卷積神經網絡 (CNN) 架構，由奧拉夫·羅南伯格等人於 2015 年提出，並在醫學影像分析領域取得了廣泛應用。其特點在於特殊的 U 形結構，使得網絡在多層次上有效地保留空間資訊，並且能在影像中準確定位目標區域，達到精細的分割效果。

1. 主要結構組成：

(1) **編碼器 (Encoder)**：U-Net 的左半部分稱為編碼器，它由多層卷積層和池化層組成，逐層下採樣影像以提取深度特徵。在這個過程中，網絡會捕捉影像的局部模式和高階語義信息，使其能夠識別影像中的重要特徵和結構。

(2) **解碼器 (Decoder)**：右半部分為解碼器，通過反捲積層或上採樣層，將下採樣後的特徵映射回原影像的解析度。解碼器逐步還原影像的細節，並將最終的分割結果精確映射到原始影像的空間位置。

(3) **跳躍連接 (Skip Connections)**：U-Net 引入了跳躍連接，將編碼器中每一層的特徵映射直接傳遞到對應解碼器層。這樣的設計有助於保留影像中的空間信息，並減少下採樣過程中造成的細節損失。跳躍連接結合了低層次的細節和高層次的語義信息，使得分割結果更加精細。

2. 工作流程：

(1) **特徵提取**：編碼器通過下採樣逐步提取影像的深度特徵，捕捉目標區域的模式。

(2) **特徵還原**：解碼器通過上採樣重建影像細節，將特徵映射還原至原始尺寸。

(3) 分割結果輸出：最終的輸出層將影像分類到不同區域，生成精確的分割掩膜。




圖4：U-Net 模型示意圖

(資料來源:Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015* (pp. 234-241). Springer.)

U-Net 因其對影像細節的出色保留能力，被廣泛應用於醫學影像中的組織和器官分割，例如腦腫瘤、肺部結構和肝臟區域等。由於 U-Net 能夠對少量標註資料進行有效訓練，其高效性和靈活性使其在各種影像分割任務中表現出色。

在本研究中，我們採用 U-Net 對影像進行眼白的區域分割，特別適用於處理包含特定特徵區域的影像資料，從而提升我們影像分析的準確性和應用價值。

(十) SVM 支持向量機

支持向量機 (SVM, Support Vector Machine) 是一種監督式學習模型，主要用於分類和回歸分析。SVM 於 1990 年代由 Vladimir Vapnik 和 Alexey Chervonenkis 提出，並迅速成為機器學習領域的重要工具。其主要目的是尋找一條最佳的超平面 (hyperplane)，將不同類別的數據分開，並最大化邊界 (margin) 以提高模型的泛化能力。

SVM 的主要特點和結構如下：

1. **超平面**：在特徵空間中，SVM 通過一個超平面來劃分數據點。對於二分類問題，這個超平面將不同類別的數據點分隔開來。超平面的選擇基於數據點的分佈，使得兩類之間的距離 (邊界) 最大化。

2. **支持向量**：支持向量是位於邊界上或靠近邊界的數據點。這些數據點對於確定最佳超平面至關重要，因為它們的存在決定了邊界的最終位置。只有支持向量對模型的訓練和預測有直接影響，而其他點則不會影響超平面的形成。

3. **核函數 (Kernel Function)**：SVM 可以使用核函數將數據映射到更高維度的特徵空間，以便更好地分割線性不可分的數據。常見的核函數包括：

(1) 線性核：用於線性可分的數據。

(2) 多項式核：適合於多項式特徵的數據。

(3) 徑向基核 (RBF)：適用於非線性特徵，能夠有效捕捉複雜的數據分佈。

4. **正則化**：SVM 引入正則化參數 (C)，用於控制模型的複雜度。較大的 C 值會強調準確分類，而較小的 C 值則會更關注邊界的平滑性，防止過擬合。

SVM 在許多應用場景中表現出色，尤其是在文本分類、圖像識別和生物信息學等領域。由於其強大的數學基礎和優良的分類性能，SVM 特別適合於處理小樣本和高維數據的問題。




圖5：SVM 示意圖

(資料來源：[資料分析&機器學習] 第3.4講：支援向量機(Support Vector Machine)介紹 (Yeh James, 2017))

在本研究中，我們利用 SVM 進行效果評估，確保我們的黃疸偵測系統能夠在臨床應用中提供更準確的結果。

三、影像資料

為了順利進行實驗，我們需要大量受試者的圖片和資料，由於資料收集的倫理考量，我們遵循嚴格的倫理標準以維護受試者的隱私。

(一) 資料收集對象及範圍

本研究所使用的影像取自於台大醫院蘇東弘團隊，總共573名受試者，包括患有黃疸的照片157張和未患有黃疸對照組551張；使用 iPhone 所拍攝，共708張照片。

(二) 資料收集辦法和工具

資料收集主要通過使用智慧型手機攝影進行。為了確保影像的一致性，並使用RAW文件保存影像以避免自動顏色調整。

(三) 資料收集的過程

為了實驗的準確性，所有照片皆在嚴謹的程序下由受試者獲得。

1. 受試者簽署知情同意書並進行基本資料登記。
2. 在標準光照條件下拍攝面部影像。
3. 使用JaundiceChecker顏色卡拍攝。
4. 保存RAW影像文件至資料集。

(四) 資料收集倫理考量

我們遵循嚴格的倫理標準以保護受試者的隱私。所有參與者均簽署了知情同意書，確保他們充分了解本研究的目的和程序。此外，本研究已獲得臺大醫院倫理委員會的批准，遵循相關法規進行研究，以保障參與者的權益。

參、研究方法及過程

針對黃疸的判讀，醫療上通常透過色卡的使用進行色彩校正，以確保影像診斷的準確性。然而，色卡成本較高，且受限於拍攝環境的多樣性，造成使用上的不便。為了解決這些問題，本研究嘗試使用其他技術替代色卡，包括自動白平衡和深度學習的方法，進行色彩校正以提升診斷準確性。我們依次進行以下階段實驗：先以自動白平衡技術進行影像校正，隨後應用深度學習模型學習和校正影像中的色彩偏差，最終將這些方法整合進整體架構中，並與色卡校正效果進行對比，探討各方法的準確度與應用性。




圖6：運用三種不同色彩校正技術進行黃疸預測之研究流程

(本圖為作者繪製)

一、脸部偵測

透過智慧型手機所拍攝的受測者脸部影像，首先會先運用 OpenCV 中，脸部及眼部座標點偵測模型，辨識照片中是否含有脸部及雙眼的影像，並留下具有眼部和脸部照片的影像。

二、色彩校正

色彩校正是影像處理中的關鍵技術，特別是在醫療影像中，精確的顏色表現對於疾病的診斷至關重要。對於黃疸的診斷而言，眼白的顏色變化是判斷的重要指標，

因此準確的色彩校正能顯著提高診斷的可靠性。本研究針對色彩校正方法進行深入探討，主要包括利用色卡進行色彩校正、自動白平衡演算法的應用以及深度學習模型的訓練和實施。透過這些技術，旨在提高影像的色彩準確性，以支持黃疸的診斷和預測。

(一)以色卡進行色彩校正

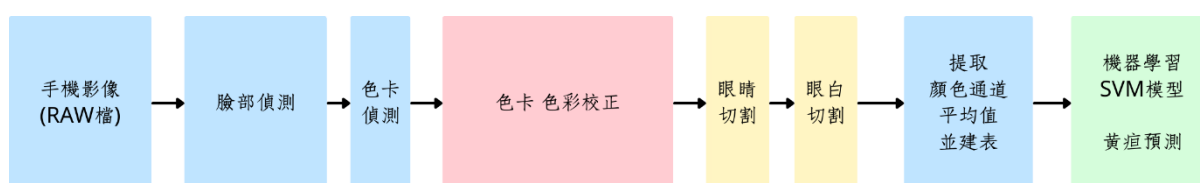


圖7：運用色卡色彩校正技術進行黃疸預測之研究流程
(本圖為作者繪製)

色卡在影像診斷中是一種常見的色彩校正工具，透過標準化的顏色參考，能有效減少不同光源和拍攝環境所引起的色彩偏差。在醫療應用中，色卡校正技術被廣泛用於確保影像的顏色準確性，以輔助疾病判讀，特別是像黃疸這類高度依賴色彩變化的病症。本研究首先使用色卡進行影像校正，旨在建立一個基準，以便後續自動白平衡和深度學習方法的比較分析。

透過色彩校正模型，偵測照片中受試者拿的色卡，將其擷取，並比較真實色卡影像和擷取出的色卡影像的色調及亮度，運用多項式回歸，將照片進行色彩校正。



圖8-1：未經過色卡色彩校正之照片示意圖



圖8-2：經過色卡色彩校正之照片示意圖

(資料來源：醫療團隊拍攝示意圖)

(二)以白平衡演算法進行色彩校正



圖9：運用白平衡演算法色彩校正技術進行黃疸預測之研究流程

(本圖為作者繪製)

物體在不同光照條件下能夠呈現相同的顏色，這種現象稱為「色彩恆常性」(Color Constancy)。人類眼睛具備色彩恆常性的能力，能透過調整對光譜的響應，適應各種光線變化。因此，自動白平衡 (Automatic White Balance, AWB) 會調整影像中的色彩，使其更接近肉眼在自然光照條件下所看到的顏色。

為了有效地進行色彩校正，我們採用了兩種不同的演算法：灰界演算法和白色補丁演算法。灰界演算法則基於自然界影像色彩成分的均勻分佈假設，利用 RGB 三個頻道的平均值進行色彩校正，實現自動白平衡。而白色補丁演算法假設影像中必定存在至少一個白色物體，並透過分析 RGB 通道的像素值，找出該白點以進行色彩調整。這個演算法透過將白點轉換為純白色，有效消除影像中的色偏，使顏色看起來更加自然。這些方法簡單且快速，適合在多種情況下進行顏色矯正。以下是兩種白平衡演算法的應用：

1. 灰界演算法

灰界演算法 (Gray World Algorithm, GW) 是一種簡單的自動白平衡方法。其核心假設是自然界中影像的 RGB 三個通道的平均值應該相等，接近中性灰。這種方法的優點在於計算快速且實現簡單，適合即時處理。當影像包含豐富的色彩且無單一顏色主導時，通常能提供較為準確的白平衡效果。

但該演算法也有其局限性。當影像中某一顏色佔據主導地位時，或場景色彩分佈不均勻時，可能會產生過度校正或顏色失真。此外，若場景中沒有灰色或中性顏色可作為參考時，效果會有所下降。灰界演算法適合用於光源條件一致且顏色多樣的場景，如自然風光或戶外拍攝。

本研究所使用的灰界演算法中，對影像進行白平衡處理的步驟如下：

- (1) 讀取指定資料夾中的影像。
- (2) 分離RGB通道。

(3) 使用紅色和綠色通道訓練線性回歸模型，預測藍色通道。調整公式如下：

$$R_{\max} = \max(R_{\text{old}})$$
$$G_{\max} = \max(G_{\text{old}})$$

$$R_{\text{new}} = \frac{R_{\text{old}}}{R_{\max}} \times 255$$

$$G_{\text{new}} = \frac{G_{\text{old}}}{G_{\max}} \times 255$$

$$B_{\text{new}} = \frac{B_{\text{old}}}{B_{\max}} \times 255$$

(4) 更新藍色通道以生成白平衡影像。

(5) 保存處理後的影像到新資料夾。

2. 白色補丁演算法

白色補丁演算法 (White-Patch Algorithm, WP) 又稱最大 RGB 值演算法，假設影像中存在至少一個白色物體，並從影像中尋找該白點，即RGB三個色彩頻道像素值總和最大的點。為了實現白平衡，演算法根據估測白點的RGB值與純白色之間的比例來調整整個影像的色彩。

$$I_{\text{new}} = [R_{\text{new}}, G_{\text{new}}, B_{\text{new}}]$$

當場景中真實存在白點時，這種方法通常能提供良好的白平衡效果。然而，若影像中不存在明顯的白色物體或被其他顏色佔據時，演算法可能會錯誤判斷，導致結果不如預期。此外，若場景中含有明亮的顏色，可能會影響白平衡的準確性，造成顏色失真。

本研究所使用的白色補丁演算法中，對影像進行白平衡處理的步驟如下：

- (1) 讀取指定資料夾中的所有影像。
- (2) 分離RGB通道。
- (3) 計算每個通道的最大像素值以估計白點。

(4) 根據白點調整每個通道的像素值，達到白平衡效果。調整公式如下：

$$R_{\text{new}} = \frac{R_{\text{old}}}{R_{\text{max}}} \times 255$$

$$G_{\text{new}} = \frac{G_{\text{old}}}{G_{\text{max}}} \times 255$$

$$B_{\text{new}} = \frac{B_{\text{old}}}{B_{\text{max}}} \times 255$$

(5) 合併調整後的RGB通道並保存結果。

(三)以深度學習模型進行色彩校正

深度學習是機器學習的一個子領域，專注於利用多層神經網路自動學習數據中的特徵，以進行預測和分類。相較於傳統的機器學習方法，深度學習可以自動從原始數據中提取特徵，避免繁瑣的手動特徵工程，特別適合處理影像、音訊和文本等複雜數據類型。我們利用卷積神經網路（CNN）對大量影像數據進行訓練，從而學習在不同光照和色彩條件下的準確顏色映射關係。透過這種方法，CNN 能夠自動學習最佳的色彩校正策略，並適應各種影像環境，顯著提高影像的色彩準確性。

運用深度學習模型進行色彩校正需分兩階段進行，第一階段為色彩校正模型建立，第二階段再運用儲存的模型進行色彩校正。




圖10：運用深度學習模型色彩校正技術進行黃疸預測之研究流程

(本圖為作者繪製)

第一階段：系統開發前期深度學習色彩校正模型建立

透過智慧型手機所拍攝的受測者臉部影像，首先會先運用 OpenCV 中，臉部及眼部座標點偵測模型，辨識照片中是否含有臉部及雙眼的影像，並留下具有眼部和臉部照片的影像。我們將已經過色卡校正照片，共708張成為訓練集，將眼睛的部分切割下來，對模型進行訓練。

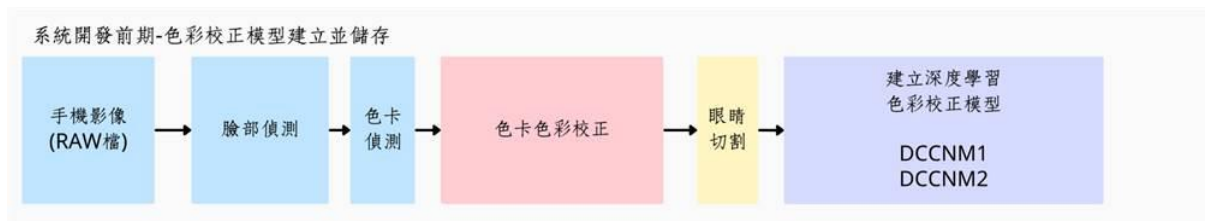


圖11：第一階段系統開發流程圖

（本圖為作者繪製）

（一）深度學習模型建立

我們利用兩種不同的深度學習模型，分別是 DCCNM1 和 DCCNM2，以應對多種光照和色彩環境下的色彩校正需求。這兩個模型通過訓練大量經過精確校正的影像數據來學習顏色映射關係，使其在面對不同環境變化時仍能準確還原原始顏色，提升了色彩校正的可靠性。DCCNM1 參考了 Lu 等人（2018）的模型結構，專注於顏色映射的深層網路設計，而 DCCNM2 則基於 ResNet 改進，參考 Kips 等人（2020）的研究，針對不同光照環境中的膚色估計進行了特別調整。這些模型的結合使我們能夠更全面地處理各種顏色偏差，從而提供更準確的影像校正結果。

1. Deep Color Correction Network Model 1 (DCCNM1) 深度學習色彩校正模型1

我們在研究中參考了 Lu, Li, Zhuo, Jing & Hui (2018) 提出的深度學習色彩校正模型架構 DCCN，並基於此設計了專門針對黃疸色彩校正的模型 Deep Color Correction Network Model 1 (DCCNM1)。該研究提出的 DCCN（深度色彩校正網路）旨在改善中醫舌像的色彩校正問題。由於中醫診斷依賴於舌像的精確色調，該研究構建了基於卷積神經網路（CNN）的架構，專門校正因光照變化和設備差異導致的色彩偏差。透過多層卷積層，DCCN 網路可以提取舌像中的顏色和紋理特徵，並使用色彩校正模塊將這些特徵映射至標準色彩空間，確保輸出影像的色調準確性，從而提高了舌像在診斷應用中的可靠性。

在我們的研究中，基於黃疸患者的需求，我們將 DCCN 應用於眼白的色彩校正。由於黃疸的診斷通常依賴於觀察眼白的黃化程度，我們調整了 DCCN 的架構，使其適應於不同光照和顏色環境下的眼白色彩校正。具體來說，我們對大量的黃疸眼白影像數據進行了訓練，讓 DCCNM1 模型學習各種條件下的顏色映射關係，從而能夠自動生成標準化的眼白影像，無論是光線變化還是顏色偏移。




圖12：DCCN 模型

(資料來源：Yunxi lu, Xiaoguang li, Li zhuo, Jing zhang, & Hui zhang. (2018, July). *Dccn: A Deep-Color Correction Network For Traditional Chinese Medicine Tongue Images.*)

本研究訓練 DCCNM1 的步驟如下：

- (1) **數據準備與處理**：讀取未校正和校正後的臉部影像資料，利用 MTCNN 模型進行臉部檢測，以精確定位左右眼的位置。對每張影像提取固定大小的眼部區域（128x200），確保校正前後的對應眼部影像大小一致。提取後的影像數據劃分為訓練集(50%)和測試集(50%)，並進行標準化處理，將像素值縮放至 $[0, 1]$ 範圍，以便進行模型訓練和效能評估。
- (2) **模型架構設計**：我們基於 DCCN 架構設計了專門用於眼白色彩校正的深度學習模型DCCNM1。具體設計如下：
 - (a) 卷積核（Kernel）大小：採用3x3的卷積核，以便於精細化的特徵提取，確保模型能有效捕捉到色彩校正所需的關鍵信息。
 - (b) 卷積層：使用四個卷積層，每層均設置64個3x3的卷積核，並使用 ReLU 激活函數，以捕捉眼部影像的細微特徵。
 - (c) 輸出層：最後一層設置為3x3的卷積層，激活函數為 sigmoid，將輸出限制在 $[0, 1]$ 範圍，以對應標準化後的像素值。

- (d) 損失函數：選擇均方誤差（MSE）作為損失函數，以最小化校正前後影像之間的差異。
- (3) **模型訓練**：使用標準化的影像數據，我們指定批次大小為16，進行模型訓練，設定的 epoch 為500。採用 Adam 優化器來加速收斂，並使用提前停止（Early Stopping）來避免過擬合的風險。
- (4) **效能監控**：在訓練過程中，我們監控訓練損失和驗證損失，以確保模型在驗證集上的表現持續改善。使用模型檢查點回調功能來保存最佳的模型權重，以便於後續的測試和應用。
- (5) **效能評估**：訓練完成後，使用測試集對模型進行評估，計算 RMSE、MAE 和 R^2 指標，以量化模型在實際應用中的色彩校正效果。根據這些指標，進一步調整模型參數以優化性能。

2. Deep Color Correction Network Model 2 (DCCNM2) 深度學習色彩校正模型2

我們參考了 KIPS, TRAN, MALHERBE 和 PERROT (2020) 提出的深度學習模型架構 LabNet，並基於此設計了專門應用於黃疸色彩校正的深度學習模型 Deep Color Correction Network Model 2 (DCCNM2)。該研究提出的 LabNet 旨在解決「真實環境下的皮膚顏色估算」問題，超越了傳統的色彩校正方法。LabNet 基於 ResNet 架構，利用其強大的特徵提取能力，在皮膚顏色估算中能有效地克服環境光線、光照角度、皮膚狀態等不穩定因素的干擾。透過 LabNet 的卷積層和殘差模塊，DCCNM2 模型可以精確學習不同光照條件下的顏色映射規則，從而提高皮膚顏色估算的準確性。

本研究基於 LabNet 的架構，針對黃疸患者的眼白色彩校正進行了相應的調整。由於黃疸診斷依賴於對眼白顏色的精確檢測，我們將 Labnet 的 ResNet 模塊調整成適合於眼白色彩校正的版本，並對大量經過標準化的黃疸眼白影像數據進行訓練。通過這些調整，使 DCCNM2 模型學習在不同光照或顏色環境下的顏色映射關係，從而能在各種光線條件下產生標準化的眼白顏色輸出。




圖13：LabNet 模型

(資料來源：Robin, K. I. P. S., Loïc, T. R. A. N., Malherbe, E., & Perrot, M. (2020). Beyond color correction: Skin color estimation in the wild through deep learning. *Electronic Imaging*, 32, 1-8.)

這種基於 LabNet 的架構改進讓我們的模型具備了應對多樣化環境的能力，實現了精確的色彩校正，有助於在不同光源條件下更穩定的黃疸診斷。本研究訓練DCCNM 2 的步驟如下：

- (1) **數據準備與處理**：讀取未校正和校正後的臉部影像資料，利用 MTCNN 模型進行臉部檢測，以精確定位左右眼的位置。對每張影像提取固定大小的眼部區域（128x200），確保校正前後的對應眼部影像大小一致。提取後的影像數據劃分為訓練集(50%)和測試集(50%)，並進行標準化處理，將像素值縮放至[0,1]範圍，以便進行模型訓練和效能評估。
- (2) **模型架構設計**：基於 LabNet 的架構，我們對 DCCNM2 進行了相應的調整，以適應眼白色彩校正的需求。具體調整如下：
 - (a) 卷積核大小：初始的卷積層使用較大的7x7卷積核來捕捉整體特徵，隨後的 ResNet 段落則採用了3x3的卷積核，以便於精細化的特徵提取。
 - (b) 卷積層：在 ResNet 模塊中，增加了卷積層的數量，每個區塊包含兩層卷積和批正規化，以提高特徵學習的效率。並使用 ReLU 作為激活函數，有效引入非線性特徵，幫助模型捕捉更複雜的顏色映射規則。
 - (c) 跳躍連接：保留 ResNet 的跳躍連接結構，以緩解梯度消失問題，促進信息在網路中的流動。
 - (d) 調整步幅和填充：根據需要調整步幅和填充，這有助於維持輸出尺寸的一致性，並有效捕捉影像中的重要特徵。

- (3) **模型訓練**：使用標準化的影像數據，我們指定批次大小為8，進行模型訓練，設定的 epoch 為500。採用 Adam 優化器來加速收斂，並使用提前停止（Early Stopping）來避免過擬合的風險。
- (4) **效能監控**：在訓練過程中，我們監控訓練損失和驗證損失，以確保模型在驗證集上的表現持續改善。使用模型檢查點回調功能來保存最佳的模型權重，以便於後續的測試和應用。
- (5) **效能評估**：訓練完成後，使用測試集對模型進行評估，計算 RMSE、MAE 和 R^2 指標，以量化模型在實際應用中的色彩校正效果。根據這些指標，進一步調整模型參數以優化性能。

(二)模型效能評估

本研究使用已色卡校正的照片訓練深度學習模型，並在測試集中進行預測，再將預測結果與真實值進行比較，計算出三項評估指標以評估模型的效能。以下是各指標的意義與功能：

1. **均方根誤差 (RMSE)**：衡量預測值與實際值之間的平均偏差幅度。其計算方式是取每個預測誤差的平方平均再開平方根，因此對大誤差更為敏感。RMSE 越小表示預測模型的準確性越高。
2. **平均絕對誤差 (MAE)**：計算預測值與實際值之間誤差的絕對值平均。MAE不會像 RMSE 對大誤差特別敏感，因此能直接反映預測誤差的平均水準，MAE越小表示模型誤差越小，預測更準確。
3. **決定係數 (R^2)**：描述模型解釋變異的程度。 R^2 的值介於 0 和 1 之間，越接近 1 表示模型對資料的擬合程度越高，解釋能力越強；值為 1 表示模型完全解釋了資料的變異，為 0 則表示模型無法解釋資料變異。

這兩個模型經過三項評估指標效能評估的結果如表1所示，皆有不錯的表現，因此可以做為色彩校正的深度學習模型。

表 1：模型效能評估

	RMSE	MAE	R^2
DCCNM1	16.48	10.61	0.88
DCCNM2	15.18	9.96	0.90

(三)儲存模型

在完成模型的訓練與評估後，我們將已訓練完成的 DCCNM1 與 DCCNM2 模型進行儲存，便於日後應用與更新。儲存過程中，採用了模型參數和網路架構的分別儲存方法，使模型在不同設備上重新加載時可直接執行。此外，儲存的模型便於未來新增數據進行微調和再訓練，以隨著醫療環境和色彩校正需求的變化進行調整和改進，確保其診斷準確度與穩定性。

第二階段：系統操作 - 運用深度學習模型進行色彩校正與黃疸預測

在模型儲存完成後，我們將需要校正的原始影像輸入到已訓練的 DCCNM1 和 DCCNM2 模型中。




圖14：第二階段系統開發流程圖

(本圖為作者繪製)

將原始影像進行基本的預處理，以適應模型的輸入要求，包括調整影像大小和色彩空間格式。透過 DCCNM1 模型與 DCCNM2 模型的顏色映射能力，原始影像在不同光照和色彩環境下的顏色偏差能得到自動校正，並生成顏色標準化後的影像輸出。此步驟確保了進行後續分析的影像色彩準確性，以提高診斷結果的可靠性。

三、眼白切割

在本研究中，我們首先請醫護人員協助對影像中病人的眼白區域進行標註，總計標註了2,378張眼睛的照片。其中，1664張用作訓練資料，714張用作測試集。完成標註後，我們利用這些資料訓練了一個U-Net模型，以擬合眼白的分割特徵。

U-Net是一種專為圖像分割任務設計的深度學習模型，其架構具有對稱的編碼器和解碼器結構。編碼器部分逐層提取特徵，逐步減少空間維度，同時增強特徵的表達能力；解碼器部分則通過上採樣操作逐步恢復原始圖像的尺寸，並結合來自編碼器的

高解析度特徵圖，以提高分割精度。這種特徵融合的策略使得U-Net在處理細節豐富的醫學影像或生物醫學圖像時，能夠有效捕捉目標物體的形狀和邊緣訊息，從而達到高效的分割效果。

為了評估模型的性能，我們採用了IoU（Intersection over Union, IoU）指標。IoU是用於衡量預測分割與真實標註之間重疊程度的指標，其值範圍從0到1，值越高表示預測效果越好。在本研究中，我們的U-Net模型達到了0.98的IoU，顯示出其在眼白分割任務中的優越表現。透過訓練後的U-Net模型，我們成功地建立了一個準確的眼白分割模型，能夠自動識別並分割出眼白區域。



圖15-1：眼睛原始影像



圖15-2：眼白切割影像

（資料來源：醫療團隊拍攝示意圖）

四、提取通道



圖16-1：RGB色彩眼睛影像



圖16-2：HSV色彩眼睛影像



圖16-3：LAB色彩眼睛影像

（資料來源：醫療團隊拍攝示意圖）

提取出的眼白影像中，計算左右眼的R、G、B(RGB色彩空間)，L、A、B(CIELAB色彩空間)，H、S、V(HSV色彩空間)，九個顏色通道的平均值，並建列表csv檔儲存。

	A	B	C	D	E	F	G	H	I	J
1	name	left_L	left_A	left_B	left_H	left_S	left_V	left_b	left_g	left_r
2	437_20220916XIMG_040	158.42550143267	134.25596943649	138.06876790831	11.319961795607	54.148997134671	168.35434574976	132.84957020057	145.98567335244	168.35434574976
3	274_20211109XIMG_268	129.55735294118	133.69852941177	138.59264705882	14.202941176471	64.163235294118	137.74117647059	103.42941176471	117.31911764706	137.73382352941
4	548_20230406XIMG_117	nan	nan	nan	nan	nan	nan	nan	nan	nan
5	248_20211015XIMG_252	125.6	137.08909090909	142.31818181818	11.638181818182	84.983636363636	140.56181818182	93.329090909091	110.97454545455	140.56181818182
6	138_20210629XIMG_162	79.035611717404	135.53589890867	138.37736932797	18.501435956347	92.902354968409	89.809879379667	57.169442848937	68.323377369328	89.744399770247
7	288_20211130XIMG_278	123.58490566038	136.98742138365	142.89937106918	11.345911949686	89.251572327044	138.53459119497	90.496855345912	109.08805031447	138.53459119497
8	081_20220303XIMG_344	104.211111111111	143.677777777778	143.277777777778	7.45555555555556	111.933333333333	128.377777777778	72.077777777778	86.155555555556	128.377777777778
9	482_20221208XIMG_072	171.46007475365	137.19775739042	136.36391437309	12.229018008835	50.757390417941	186.09140332994	149.10227658852	157.56472986748	186.09140332994
10	191_20210504XIMG_124	159.14988814318	131.47278150634	142.34899328859	16.419835943326	62.948545861298	166.75615212528	125.7524235645	147.96198686009	166.75466070097
11	182_20210413XAPC_018	151.06285949055	132.77362366475	135.96672144618	15.567378800329	47.198027937551	157.47986852917	129.38167625308	139.76129827445	156.95069843878
12	510_20230207XIMG_090	138.01886792453	133.85849056604	137.62382075472	11.454009433962	57.919811320755	146.09669811321	113.34787735849	125.63089622642	146.09669811321

圖17：csv檔示意圖

（本圖為作者所擷取）

如圖17，name代表對應的照片名稱；left_L代表左眼白的L(亮度)通道數值，left_A代表左眼白的A(紅綠色度)通道數值，left_B代表左眼白的B(黃藍色度)通道數值；left_H代表左眼白的H(色相)通道數值，left_S代表左眼白的S(飽和度)通道數值，left_V代表左眼白的V(明度)通道數值；left_b代表左眼白的B(藍色)通道數值，left_g代表左眼白的G(綠色)通道數值，left_r代表左眼白的R(紅色)通道數值，右眼(right)則依此類推。

五、黃疸預測

我們使用色卡進行色彩校正，以確保影像的色彩準確性，同時運用白平衡演算法來調整影像中的色偏，進一步提升影像的清晰度和可辨識性。此外，利用深度學習技術進行進一步的色彩校正。最終，我們將結合這些色彩校正方法，以機器學習進行效果評估，確保我們的黃疸偵測系統能夠在臨床應用中提供更準確的結果。具體步驟如下：

1. **資料載入與前處理：**載入色彩通道平均值的 CSV 檔，並載入臺大醫院蘇東弘團隊所提供的參與者身體徵象資料，此資料為 Excel 檔案，內容包含：照片名稱、拍攝日期、拍攝地點、T-Bil（總膽紅素）值等。將 T-Bil 值提取作為後續模型訓練和分析的依據。
2. **數據篩選與標籤生成：**將色彩通道平均值的 CSV 檔和身體徵象資料的 Excel 檔逐一比對，透過照片名稱確保兩份資料中均有出現，並提取其對應的 T-Bil 值，進行二元分類的標籤轉換：若 T-Bil 數值高於或等於2，則將該樣本標註為1（表示有可能黃疸），若低於2則標註為0（無黃疸）。此轉換後的標籤資料可用於後續模型的黃疸檢測訓練與測試。
3. **數據分割與平衡處理：**將色彩通道平均值的 CSV 檔中的數值正規化到 $[0, 1]$ 範圍，以確保所有特徵在相同尺度內，這樣可以提高模型的收斂速度與預測準確性。正規化後的資料被分割成訓練集（70%）和測試集（30%），以便進行模型訓練和性能評估。

針對訓練集，由於罹患黃疸的樣本數量相對較少，存在類別不平衡的問題，因此本實驗使用了 SMOTE（合成少數過採樣技術）來平衡資料中的類別分布。SMOTE 透過生成新的合成樣本來增強少數類別的樣本數，減少類別不平衡對模型訓練的影響，提升模型對於少數類別的辨識能力，從而提高黃疸檢測的準確性。

4. **模型構建與超參數調整**：選用支持向量機（SVM）模型，並使用 GridSearchCV 進行超參數調整，針對不同的 C 值及類別權重進行測試，尋找最佳模型參數，以提升預測性能。在完成模型訓練後，評估訓練集的各项性能指標，包括準確率、靈敏度、特異度及 AUC，以確保模型在黃疸檢測中的有效性。
5. **模型測試與評估**：使用最佳模型對測試集進行預測，並計算各项性能指標(準確率、靈敏度、特異度及 AUC)以評估模型的表現。

肆、研究結果與討論

本研究旨在推廣家用黃疸評估方法，針對傳統需依賴的色卡進行改良。色卡成本高且取得不易，限制了應用範圍，因此本研究探索使用白平衡演算法與深度學習模型進行色彩校正，以期降低成本並普及化。選用白色補丁演算法（WP）、灰界演算法（GW）、DCCNM1、DCCNM2方法，並針對其在黃疸偵測中的準確率、敏感度、特異度及AUC指標進行綜合評估。結果證實了色卡替代方案的可行性，並為未來黃疸自我檢測技術優化提供了基礎。

一、色彩校正結果

表2為原始圖片及經過色彩校正的眼睛影像：

表2：原圖和所有色彩校正方法之比較

原始	色卡	WP
		
GW	DCCNM1	DCCNM2
		

二、三種色彩校正技術下的黃疸預測結果

以機器學習進行黃疸偵測之色彩校正效果評估後，本研究使用四種指標來評估黃疸偵測的效果好壞。以下為指標之解釋與意義：

1. **準確率(Accuracy)**:反映模型的總體正確率，即所有預測正確的比例。高準確率代表模型在大多數情況下能正確分類，但不一定適合於偏重陽性或陰性樣本的場合。
2. **敏感度(Sensitivity)**:又稱為「召回率」或「真陽性率」，反映模型識別出實際陽性樣本的能力。在黃疸偵測中，較高的敏感性代表模型更能有效識別出有黃疸症狀的患者，有助於減少漏診。
3. **特異度(Specificity)**:表示模型識別出實際陰性樣本的能力，即排除非黃疸患者的準確性。特異性高，意味著模型較少誤判正常樣本為黃疸，適合需要降低誤判率的情況。
4. **AUC(ROC曲線下面積)**:衡量模型在不同閾值下的整體分類性能。AUC接近1，代表模型在各種閾值下的分類效果更佳，綜合反映了敏感性和特異性。

表3為用iPhone所拍攝之照片以三種色彩校正策略進行黃疸偵測之效果評估結果：

表3：使用iPhone拍攝之色彩校正效果評估

iPhone	Accuracy	Sensitivity	Specificity	AUC
原始	0.755	0.478	0.869	0.770
色卡	0.904	0.854	0.919	0.939
WP	0.821	0.571	0.892	0.779
GW	0.632	0.69	0.615	0.706
DCCNM1	0.824	0.538	0.899	0.810
DCCNM2	0.899	0.818	0.924	0.917

根據準確率、敏感性、特異性和AUC的數據分析，色卡方法在所有指標中表現最佳，其準確率達到 0.904，敏感性為 0.854，特異性高達 0.919，顯示出其在黃疸偵測中的可靠性。相較之下，DCCNM1 模型的準確率為0.824，但在敏感性上僅為0.538，顯示其在識別陽性樣本方面的不足。此外，GW 方法的特異性最低，僅0.615，表明其在識別非黃疸患者方面的弱點。DCCNM2 方法也展現良好的性能，其準確率為0.899，敏感性為 0.818，AUC 達 0.917，在多種模型中表現穩定。因此，整體來看，雖然色卡方法表現優異，但其他模型如 DCCNM2 也顯示出可行性，尤其在實際應用中對於降低成本的需求上，仍需進一步改善 DCCNM1 和 GW 的性能。

伍、結論

一、現有的居家黃疸偵測模型多採用色卡進行照片的色彩校正。然而，色卡成本高昂且不易取得，限制了應用的普及性。本研究旨在探討替代色卡的色彩校正方法，通過白平衡演算法及深度學習技術，以提升模型的普及性與便捷性。

二、在白平衡演算法中，灰界演算法的效果不佳，校正後的數據未優於原始照片；而白色補丁演算法則取得相對較好的數據，但整體效果仍未達到理想水準。

三、在深度學習方法方面，DCCNM1 模型取得了不錯的校正效果，顯示其對黃疸偵測的潛在應用價值。然而，在敏感性（即陽性樣本的檢測能力）上仍表現較弱，對高風險案例的識別能力尚有提升空間。因此，DCCNM1 模型雖在準確度和特異性上具備一定優勢，但若需進一步提升臨床實用性，則在識別黃疸陽性樣本的敏感性方面仍需改進。

四、在所有無色卡方法中，DCCNM2模型表現最佳，於準確度、特異性和AUC等數據上接近色卡校正的水準。雖然各項指標略低於色卡校正，但 DCCNM2 展現出優異的穩定性和準確性，證明其作為黃疸篩檢無色卡替代方案的可行性。DCCNM2 模型有潛力在大眾應用中提供便捷且可靠的居家黃疸偵測方法，為未來家庭健康監測提供有效支持。

陸、未來展望

- 一、在資料集方面，儘管本研究使用了較前人更多的資料，若能進一步擴充數據及照片收集，將有助於提升模型的準確性。
- 二、本研究目前僅使用 iPhone 拍攝的照片進行模型訓練、色彩校正和效果評估，未來將加入 Samsung 拍攝的照片，進行不同設備間效果差異的比較與優化，以提升模型的完整性和適用性，使可使用族群更廣。
- 三、未來計畫探討兩步驟白平衡演算法，結合白色補丁演算法(WP)與灰界演算法(GW)。透過先運用WP提高色彩校正的靈敏度，後續再應用GW調整整體灰度平衡，期望能進一步提升黃疸偵測的準確性。
- 四、本研究目前以機器學習中的SVM模型進行黃疸偵測，未來期望採用深度學習模型，以便更全面地觀察影像特徵，進而提高準確率。
- 五、希望最終整合本研究成果為簡易的應用程式，讓使用者僅需拍攝照片即可獲知黃疸評估結果，並實現免色卡操作。

柒、應用

- 一、將黃疸自我檢測應用於遠距醫療系統中，以便於偏鄉患者能在家中輕鬆檢測。透過智慧型手機拍攝影像，經過色彩校正後，運用機器學習算法即時分析，患者可獲得初步的健康評估與建議。若檢測結果顯示異常，系統可自動通知醫療機構，並安排後續的診斷與治療，減少患者到醫院的頻率，提升醫療資源的使用效率。
- 二、將本研究擴展至其他需色彩校正的病症偵測，如貧血、皮膚病等，讓大眾能於家中便捷地監測自身健康狀況。

捌、參考文獻資料

1. Amani, M., Falk, H., Jensen, O. D., Vartdal, G., Aune, A., & Lindseth, F. (2019, September). Color calibration on human skin images. In *International Conference on Computer Vision Systems* (pp. 211-223). Cham: Springer International Publishing.
2. Cardei, V. C., & Funt, B. (2000). Color correcting uncalibrated digital images. *Journal of Imaging Science and Technology*, 44(4), 288-294.
3. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
4. Huang, T. (2018, May 8). 卷積神經網路 (Convolutional neural network, CNN) — CNN運算流程. *Medium*. <https://chih-sheng-huang821.medium.com/%E5%8D%B7%E7%A9%8D%E7%A5%9E%E7%B6%93%E7%B6%B2%E8%B7%AF-convolutional-neural-network-cnn-cnn%E9%81%8B%E7%AE%97%E6%B5%81%E7%A8%8B-ecaec240a631>
5. Lu, Y., Li, X., Zhuo, L., Zhang, J., & Zhang, H. (2018, July). *DCCN: A deep-color correction network for traditional Chinese medicine tongue images*.
6. Robin, K. I. P. S., Loïc, T. R. A. N., Malherbe, E., & Perrot, M. (2020). Beyond color correction: Skin color estimation in the wild through deep learning. *Electronic Imaging*, 32, 1-8.
7. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015* (pp. 234-241). Springer.
8. Su, T. H., Li, J. W., Chen, S. C., Jiang, P. Y., Kao, J. H., & Chou, C. F. (2021, July). Jaundice detection by deep convolutional neural network using smartphone images. In *JOURNAL OF HEPATOLOGY* (Vol. 75, pp. S629-S629). RADARWEG 29, 1043 NX AMSTERDAM, NETHERLANDS: ELSEVIER.

9. Yeh, J. (2017, November 14). [資料分析&機器學習] 第3.4講：支援向量機 (Support Vector Machine) 介紹. *Medium*. <https://medium.com/jameslearningnote/%E8%B3%87%E6%96%99%E5%88%86%E6%9E%90-%E6%A9%9F%E5%99%A8%E5%AD%B8%E7%BF%92-%E7%AC%AC3-4%E8%AC%9B-%E6%94%AF%E6%8F%B4%E5%90%91%E9%87%8F%E6%A9%9F-support-vector-machine-%E4%BB%8B%E7%B4%B9-9c6c6925856b>
10. Zhang, K., Zhang, Z., Li, Z., & Qiao, Y. (2016). Joint face detection and alignment using multi-task cascaded convolutional networks. *IEEE Signal Processing Letters*, 23(10), 1499–1503.

【評語】190002

1. 由於環境光照條件不同本研究使用深度學習模型演算法 D C C NM2 來校正黃疸病人的經影像顏色，結果接近傳統色卡校正的結果。整體而言，實驗與步驟方法敘述非常完整，結果 A U C =0.917 也很好，只是所使用的方法模型都是既有模型(包括 S V M) 與觀念，方法論的創意稍弱。
2. 色彩核定比較色卡，但實際的色彩 ground truth 如何判定，可再詳細表述。
3. 深度學習模型訓練用色卡的結果，來訓練難以超越色卡校正的結果。唯一 specificity 比色卡法 0.919 還好，可作詳細討論。
4. 訓練資料較少建議可以採用 N-fold cross validation 進行實驗。